

DEPARTAMENTO DE GEOGRAFÍA Y ORDENACIÓN DEL TERRITORIO

FACULTAD DE FILOSOFÍA Y LETRAS

UNIVERSIDAD DE ZARAGOZA



**ESTIMACIÓN DE BIOMASA RESIDUAL MEDIANTE
IMÁGENES DE SATÉLITE Y TRABAJO DE CAMPO.
MODELIZACIÓN DEL POTENCIAL ENERGÉTICO DE
LOS BOSQUES TUROLENSES**

ALBERTO GARCÍA MARTÍN

TESIS DOCTORAL

2009

ESTIMACIÓN DE BIOMASA RESIDUAL MEDIANTE IMÁGENES DE SATÉLITE Y TRABAJO DE CAMPO. MODELIZACIÓN DEL POTENCIAL ENERGÉTICO DE LOS BOSQUES TUROLENSES



Tesis doctoral realizada por
Alberto García Martín

Dirigida por el profesor titular
de Análisis Geográfico Regional
Dr. Juan de la Riva Fernández
y el profesor titular
de Máquinas y Motores Térmicos
Dr. Francisco Javier Royo Herrero

Departamento de Geografía y Ordenación del Territorio
Facultad de Filosofía y Letras
Universidad de Zaragoza

Diciembre, 2009

*A quién me ha guiado, por ayudarme a no perderme en el camino.
A los que a pesar de mis ausencias, siguen estando ahí.
A mis padres y a mi familia, por haberme enseñado a ser.
A Marta, por ayudarme a no perderme en el camino, por seguir estando ahí
y por haberme enseñado a ser.*

AGRADECIMIENTOS

Rara vez se consigue llegar a los objetivos marcados en soledad, tanto en el ámbito profesional, como en el social. La realización de una tesis doctoral es una larga tarea que se desarrolla de forma ineludible en estos dos ámbitos, por lo que cuando se finaliza, el que la firma está obligado a agradecer la ayuda que ha recibido a lo largo de todo el camino recorrido.

En primer lugar, este trabajo no hubiera sido posible sin la confianza depositada por el Dr. Juan de la Riva Fernández y el Dr. Francisco Javier Royo Herrero, directores de esta tesis, para que participara en el proyecto LIGNOSTRUM, el cual ha proporcionado el contexto y los materiales necesarios para el desarrollo de la presente investigación. Esta confianza inicial se fue transformando a lo largo del tiempo, en especial en el caso de Juan, en sabios consejos, en apoyo incondicional y en amistad, ingredientes sin los cuales la tarea iniciada no se hubiera podido terminar.

Asimismo, debo agradecer al por entonces Ministerio de Educación y Ciencia la concesión de una beca de Formación de Profesorado Universitario que me permitió centrarme durante la mayor parte de la realización de la tesis exclusivamente en esta tarea, a la vez que me proporcionó la oportunidad de iniciarme como docente en la Universidad. En este contexto, es también justo acordarse de otras instituciones que me permitieron iniciar la investigación que concluye en esta tesis doctoral, como son el Gobierno de Aragón, el Centro de Investigación de Recursos y Consumos Energéticos y el Grupo de Investigación Geoforest del Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza. En especial, remarcar mi agradecimiento al Departamento de Geografía y Ordenación del Territorio, ya que durante estos últimos años me ha dado cobijo y las personas que lo integran se han convertido en parte de mi familia. De igual forma, deseo agradecer la oportunidad que la Dra. Thuy Le Toan me brindó para realizar dos estancias de investigación en el Centre d'Etudes Spatiales de la Biosphère de Toulouse.

Diferentes personas de las instituciones nombradas merecen ser destacadas en estos agradecimientos. Así, del Centro de Investigación de Recursos y Consumos Energéticos me gustaría agradecer la colaboración recibida por parte de Jesús Pascual y de Daniel García, ya que sin ellos parte de los contenidos de esta tesis no hubieran sido posibles. En este mismo sentido, del Departamento de Geografía y Ordenación del

Territorio me gustaría agradecer toda la atención y la paciencia prestada por el Dr. Fernando Pérez Cabello, que ha ayudado a resolver muchos de los momentos más escabrosos de la investigación. Agradecer también la ayuda prestada y, sobretodo, la amistad de todos los compañeros que han ido pasando este tiempo por la sala de becarios. Es difícil nombrar a todos, por lo que dejo este agradecimiento en genérico. Sin embargo, me gustaría destacar la compañía y la ayuda que Raquel Montorio me ha dado durante todo este tiempo, escuchando mis problemas y participando en su resolución.

Finalmente queda el agradecimiento a todos mis amigos y a mis hermanas, por ayudarme a desconectar y, en especial, por perdonar mis eternas ausencias, a mis padres, por enseñarme a ser como soy y estar incondicionalmente y, por último, a Marta, porque todos sabemos que los malos momentos siempre los soporta la persona que está siempre a tu lado, y esa persona Marta, eres tú.

ÍNDICES

ÍNDICE GENERAL

CAPÍTULO 1. ANTECEDENTES, OBJETIVOS, METODOLOGÍA Y ÁREA DE ESTUDIO	1
1.1. La biomasa residual forestal como recurso energético	3
1.1.1. Las energías renovables.....	3
1.1.2. La energía de la biomasa	5
1.1.3. La biomasa residual forestal.....	8
1.2. Objetivos e hipótesis.....	17
1.3. La estimación de biomasa en el contexto de las aplicaciones forestales de la teledetección para la evaluación de parámetros forestales continuos e información biofísica	22
1.3.1. Fundamentos de teledetección.....	23
1.3.2. Aplicaciones forestales de la teledetección	25
1.3.3. Aplicaciones de inventario forestal y de extracción de información biofísica ..	27
1.3.3.1. Aplicaciones de inventario forestal	27
1.3.3.2. Estimación de biomasa en ámbitos forestales.....	31
1.3.3.2.1. Importancia del conocimiento de la biomasa forestal y su estudio mediante teledetección	32
1.3.3.2.2. Utilización de los sensores pasivos para la estimación de biomasa..	35
- Utilización de sensores de baja resolución espacial.....	35
- Utilización de sensores de resolución espacial media.....	36
- Utilización de sensores de alta resolución espacial.....	43
1.3.3.2.3. Utilización de los sensores activos para la estimación de biomasa...	44
1.3.3.2.4. Utilización de otras técnicas de teledetección para la estimación de biomasa.....	48
1.3.3.2.5. Factores restrictivos en la estimación de biomasa forestal.....	50
1.4. Fases de la investigación y metodología estadística para el modelado de la biomasa residual forestal	52
1.4.1. Marco tecnológico e institucional de la investigación	53
1.4.2. Fases del trabajo de investigación.....	55
Fase 1. Obtención de la variable dependiente (biomasa residual forestal) y de las variables independientes (información radiométrica, topográfica y forestal) ...	55
Fase 2. Formulación del modelo de estimación de biomasa residual forestal y validación	62
Fase 3. Aplicación de la metodología para la estimación de la biomasa residual forestal actual en la provincia de Teruel	66
1.4.3. Técnicas estadísticas para el ajuste de los modelos de estimación de la biomasa residual forestal.....	68
1.4.3.1. Análisis de correlaciones	69

1.4.3.2. Ajuste de los modelos de regresión	69
1.4.3.2.1. Regresión lineal.....	70
- Valoración de la exactitud de la predicción	71
- Supuestos del análisis de regresión lineal y soluciones en caso de incumplimiento	73
- Métodos de selección de variables	77
1.4.3.2.2. Regresión curvilínea	79
- Valoración de la exactitud de la predicción	80
- Método de ajuste del modelo	81
1.4.3.2.3. Regresión logística	81
- Valoración de la exactitud de la predicción	82
- Método de selección de variables	84
1.4.3.3. Validación de los modelos	84
1.5. El área de estudio: delimitación y presentación general	85
1.5.1. Caracterización física de la provincia de Teruel.....	86
1.5.1.1. Aspectos fisiográficos y lito-geológicos	86
1.5.1.2. Aspectos climáticos	90
1.5.1.3. Aspectos edáficos	91
1.5.1.4. Aspectos biogeográficos	93
1.5.1.4.1. La cubierta forestal de Teruel	94
1.5.1.4.2. Otras formaciones vegetales.....	96
1.5.2. Caracterización socio-económica de la provincia de Teruel	97
1.5.2.1. Modelo territorial y aspectos demográficos	97
1.5.2.2. Actividades económicas	99
1.5.2.3. Infraestructuras, transporte e infoestructuras.....	102
CAPÍTULO 2. OBTENCIÓN DE LAS VARIABLES A EMPLEAR EN EL MODELO DE ESTIMACIÓN DE LA BIOMASA RESIDUAL FORESTAL POTENCIAL DE LA PROVINCIA DE TERUEL	105
2.1. Los datos de biomasa residual forestal	107
2.1.1. Trabajo de campo y obtención de las regresiones de biomasa residual forestal por árbol.....	109
2.1.1.1. Diseño, métodos de muestreo y composición de la muestra	110
2.1.1.2. Análisis estadístico y ajuste de las regresiones de estimación de biomasa residual forestal por árbol.....	113
2.1.1.2.1. Análisis estadístico	113
2.1.1.2.2. Ajuste de las regresiones de estimación de biomasa residual forestal por árbol.....	115
2.1.2. Aplicación de las regresiones de biomasa residual forestal por árbol a las parcelas del IFN-2	118

2.1.2.1. El IFN-2 de la provincia de Teruel	118
- Localización y delimitación de la parcela en el campo	120
- Apeo de la parcela.....	122
2.1.2.2. Metodología para el cálculo de la biomasa residual forestal en las parcelas seleccionadas del IFN-2	123
2.1.3. Espacialización de las parcelas del IFN-2 con información de biomasa residual forestal.....	124
2.2. El modelo digital de elevaciones de la provincia de Teruel	129
2.3. Las variables radiométricas derivadas de las imágenes ópticas	135
2.3.1. Características de las imágenes ópticas utilizadas	135
2.3.1.1. Características generales	136
2.3.1.1.1. El programa Landsat.....	136
2.3.1.1.2. Características orbitales de Landsat 5.....	137
2.3.1.1.3. Toma de datos en Landsat 5: el sensor TM	137
2.3.1.1.4. Información de utilidad forestal proporcionada por las bandas de TM	138
2.3.1.2. Características particulares de las imágenes utilizadas	139
2.3.2. Aplicación de pretratamientos: corrección geométrica y radiométrica.....	141
2.3.2.1. Corrección geométrica.....	142
2.3.2.1.1. Establecimiento de los puntos de control	143
2.3.2.1.2. Cálculo de las funciones de transferencia	145
2.3.2.1.3. Transferencia de los ND originales a la posición corregida.....	146
2.3.2.2. Corrección radiométrica.....	148
2.3.2.2.1. Corrección del efecto de la dispersión atmosférica	150
2.3.2.2.2. Transformación de los ND originales a valores de reflectividad espectral.....	151
- Cálculo de la radiancia espectral	152
- Cálculo de la reflectividad sin normalización topográfica	153
- Cálculo de la reflectividad con normalización topográfica	154
2.3.3. Aplicación de transformaciones y elaboración de neocanales	160
2.3.3.1. Análisis de componentes principales.....	161
2.3.3.2. Transformación Tasseled-Cap.....	162
2.3.3.3. Índices de vegetación	164
2.4. Obtención de la información radiométrica de las imágenes radar.....	167
2.4.1. Características de las imágenes radar empleadas.....	167
2.4.1.1. Características generales	167
2.4.1.1.1. El satélite Envisat.....	167
2.4.1.1.2. Características orbitales de Envisat.....	168
2.4.1.1.3. Toma de datos con el sensor ASAR.....	169

2.4.1.1.4. Información de utilidad forestal proporcionada por el sensor ASAR	176
2.4.1.2. Características particulares de las imágenes utilizadas	177
2.4.2. Aplicación de pretratamientos: calibración radiométrica absoluta y georreferenciación	180
2.4.2.1. Calibración radiométrica absoluta	180
2.4.2.2. Georreferenciación de las imágenes radar	181
2.5. Las variables topográficas derivadas del MDE	184
- Mapa de pendientes	185
- Mapa de orientaciones	185
- Mapas de insolación potencial	186
- Mapa de curvatura	187
2.6. Las variables forestales derivadas del Mapa Forestal de Aragón	190
- Mapa del Tipo Climático Estructural	191
- Mapa del Nivel de Madurez	193
CAPÍTULO 3. ESTABLECIMIENTO DE LOS MODELOS DE ESTIMACIÓN DE LA BIOMASA RESIDUAL FORESTAL DE LA PROVINCIA DE TERUEL	195
3.1. Modelos de estimación con variables radiométricas derivadas de imágenes Landsat y variables auxiliares topográficas y forestales	197
3.1.1. Estimación de la biomasa residual forestal a partir de la información de las variables independientes obtenida mediante ventanas fijas	198
3.1.1.1. Metodología para la extracción de la información y para evaluación de la heterogeneidad espacial interna de las parcelas del IFN-2	198
3.1.1.2. Estudio de las correlaciones entre la biomasa residual forestal y las variables espectrales y topográficas continuas en los grupos de parcelas delimitados	204
3.1.1.3. Ajuste de modelos de regresión	210
3.1.1.3.1. Modelos de regresión logística	211
- Modelo de regresión logística del primer clúster	211
- Modelo de regresión logística del segundo clúster	216
- Modelo de regresión logística del tercer clúster	218
- Modelo de regresión logística del cuarto clúster	218
3.1.1.3.2. Modelos de regresión simple	220
- Modelos de regresión simple del primer clúster	221
- Modelos de regresión simple del segundo clúster	224
- Modelos de regresión simple del tercer clúster	227
- Modelos de regresión simple del cuarto clúster	235
3.1.1.3.3. Modelos de regresión lineal múltiple	239
- Modelos de regresión múltiple del primer clúster	242
- Modelos de regresión múltiple del segundo clúster	246

- Modelos de regresión múltiple del tercer clúster	248
- Modelos de regresión múltiple del cuarto clúster.....	253
3.1.1.4. Conclusiones	258
3.1.2. Estimación de la biomasa residual forestal a partir de la información de las variables independientes obtenida mediante la utilización de áreas homogéneas	266
3.1.2.1. Estimación mediante la utilización de áreas forestales homogéneas delimitadas a partir de fotografía aérea de alta resolución	268
3.1.2.1.1. Procedimiento de delimitación de las aéreas forestales homogéneas y extracción de la información de las variables independientes continuas	268
3.1.2.1.2 Estudio de las correlaciones entre biomasa residual forestal y las variables espectrales y topográficas continuas considerando el grado de aptitud de las áreas homogéneas	272
3.1.2.1.3. Ajuste de modelos de regresión	275
- Modelos de regresión simple	276
- Modelos de regresión lineal múltiple.....	279
3.1.2.1.4. Conclusiones	286
3.1.2.2. Estimación mediante la utilización de áreas forestales homogéneas delimitadas a partir de técnicas de segmentación y ventanas fijas.....	292
3.1.2.2.1. Procedimiento de segmentación de la imagen Landsat y de extracción de la información radiométrica en las nuevas unidades espectrales.....	292
3.1.2.2.2. Estudio de las correlaciones entre biomasa residual forestal y las variables espectrales considerando los distintos tipos de segmentación.....	302
3.1.2.2.3. Ajuste de modelos de regresión	308
- Modelos de regresión simple	308
- Modelos de regresión lineal múltiple.....	311
3.1.2.2.4. Conclusiones	316
3.1.3. Validación de las cartografías de estimación de biomasa residual forestal...	320
3.2. Modelos de estimación a partir del coeficiente de retrodispersión de las imágenes ASAR.....	330
3.2.1. Minimización del efecto de la topografía en las imágenes ASAR para el estudio de la relación entre el coeficiente de retrodispersión y la biomasa residual forestal.....	330
3.2.2. Estudio de las relaciones entre la biomasa residual forestal y el coeficiente de retrodispersión de las imágenes ASAR de orbita ascendente.....	335
3.2.3. Ajuste de modelos de regresión	336
3.2.4. Conclusiones	340

CAPÍTULO 4. EVALUACIÓN DEL EFECTO DE LA TEMPORALIDAD EN LA ESTIMACIÓN DE LA BIOMASA RESIDUAL FORESTAL MEDIANTE IMÁGENES LANDSAT TM.....	343
4.1. Validación temporal de la metodología óptima de estimación de biomasa residual forestal ajustada mediante el uso de la imagen Landsat de junio de 1994.....	346
4.1.1. Determinación del número de parcelas, extracción de la información y obtención de los 10 grupos de parcelas a partir de los CV en las imágenes de julio de 1993 y agosto de 1994.....	349
4.1.2. Estudio de las correlaciones entre la biomasa residual forestal y las variables espectrales en los grupos de parcelas delimitados en las imágenes de julio de 1993 y junio de 1994.....	351
4.1.3. Ajuste de modelos de regresión con las imágenes de julio de 1993 y agosto de 1994.....	360
4.1.3.1. Modelos de regresión simple.....	360
4.1.3.2. Modelos de regresión lineal múltiple.....	366
4.1.4. Validación de las cartografías de estimación obtenidas con las imágenes de julio de 1993 y agosto de 1994.....	375
4.2. Análisis de la variación del contenido de humedad en los meses de junio, julio y agosto para las cuatro especies de pino consideradas.....	377
4.2.1. Los datos de contenido de humedad.....	378
4.2.2. Análisis de la variación del contenido de humedad.....	380
4.3. Conclusiones.....	382
CAPÍTULO 5. LA BIOMASA RESIDUAL FORESTAL ACTUAL DE LA PROVINCIA DE TERUEL. INVENTARIO DEL RECURSO Y LOCALIZACIÓN DE ZONAS ÓPTIMAS PARA SU APROVECHAMIENTO.....	387
5.1. Estimación de la biomasa residual forestal actual de Teruel.....	390
5.2. Inventario del recurso energético.....	393
5.2.1. Inventario a escala provincial.....	396
5.2.2. Inventario a escala comarcal.....	397
5.2.3. Inventario a escala municipal.....	399
5.3. Determinación de las zonas de aprovechamiento óptimas mediante la utilización de un índice espacial.....	412
5.3.1. Obtención y modelización de los índices parciales.....	413
5.3.1.1. Índice parcial en función de la cantidad de biomasa residual forestal (I_{BRF}).....	413
5.3.1.2. Índice parcial en función de la superficie de la masa forestal (I_{sup}).....	416
5.3.1.3. Índice parcial en función de la pendiente (I_{pend}).....	418
5.3.1.4. Índice parcial en función de la distancia a desembosque (I_{dist}).....	420
5.3.2. Combinación de los índices de aptitud parcial.....	422
5.3.3. Resultados de los índices parciales y de los índices de aptitud global.....	422

5.3.3.1. Resultados de los índices parciales.....	422
- Resultados del índice I_{BRF}	422
- Resultados del índice I_{sup}	423
- Resultados del índice I_{pend}	424
- Resultados del índice I_{dist}	425
5.3.3.2. Resultados del índice de aptitud multiplicativo (I_{aptM}).....	426
5.3.3.3. Resultados del índice de aptitud ponderado (I_{aptP}).....	427
5.3.4. Conclusiones.....	432
CAPÍTULO 6. CONCLUSIONES GENERALES Y LÍNEAS DE FUTURO.....	437
6.1. Conclusiones generales.....	439
6.2. Líneas futuras de trabajo.....	460
CAPÍTULO 7. BIBLIOGRAFÍA.....	463

ÍNDICE DE FIGURAS

Figura 1.1.	Distribución del consumo de energía primaria en España en 2007	3
Figura 1.2.	Distribución del consumo de energía primaria de origen renovable en España en 2007	6
Figura 1.3.	Cadena de generación de la biomasa como recurso energético	7
Figura 1.4.	Biomasa residual forestal y fuste maderable procedente de una corta fitosanitaria	9
Figura 1.5.	Aspecto de una masa forestal tras la aplicación de actividades selvícolas y detalle de la biomasa residual generada por uno de los pies	11
Figura 1.6.	Acumulación de fustes al pie de la carretera para su recolección y amontonamiento de la biomasa residual para su abandono en el bosque.....	11
Figura 1.7.	Esquemas de distintas instalaciones para el aprovechamiento energético de la biomasa residual forestal	13
Figura 1.8.	Ciclo del CO ₂ en relación con el aprovechamiento energético de la biomasa forestal	14
Figura 1.9.	Diagrama de flujos de la fase metodológica 1.....	61
Figura 1.10.	Diagrama de flujos de la fase metodológica 2.....	65
Figura 1.11.	Diagrama de flujos de la fase metodológica 3.....	67
Figura 1.12.	Localización del área de estudio: la provincia de Teruel	86
Figura 1.13.	Mapa fisiográfico de la provincia de Teruel	88
Figura 1.14.	División comarcal de la provincia de Teruel	98
Figura 2.1.	Diagrama de flujos del proceso metodológico seguido para obtención de los datos de biomasa residual forestal	108
Figura 2.2.	Localización de las zonas donde se realizó el muestreo de campo.....	111
Figura 2.3.	A) Materiales utilizados en el trabajo de campo; B) pie arbóreo apeado desramado y despuntado; C) medición de la altura posterior al apeo; D) pesada de la biomasa en húmedo.....	112
Figura 2.4.	Zonas de la cuadrícula UTM en que se divide la provincia de Teruel.....	125
Figura 2.5.	Representación del fichero shape que contiene las 617 parcelas del IFN-2 con información de biomasa residual forestal y su tabla alfanumérica	125
Figura 2.6.	Localización de las 482 parcelas del IFN-2 utilizadas sobre una composición RGB 7-4-3 de la imagen Landsat TM de 29 de junio de 1994.....	126
Figura 2.7.	Ejemplo de hoja de la BCN25: los puntos representan cotas de altitud, las polilíneas azules son curvas de nivel con equidistancia de 10 m.....	130
Figura 2.8.	La estructura TIN para la obtención de un MDE: (A) nodos y ejes de la estructura TIN; (B) nodos, ejes y facetas triangulares de la estructura TIN. Fuente: Adaptado de ESRI ArcMap 9.1.....	132
Figura 2.9.	Diagrama de flujos del proceso seguido para la elaboración del MDE ...	133

Figura 2.10.	Generación del modelo TIN: (A) fichero .shp con las curvas de nivel utilizadas; (B) fichero .shp con las cotas topográficas; (C) fichero .shp con la red hidrográfica; (D) detalle del modelo TIN.....	134
Figura 2.11.	MDE raster de la provincia de Teruel con proyección cartográfica y resolución de 25 m.....	135
Figura 2.12.	Las imágenes Landsat 5 TM adquiridas una vez eliminada la proyección cartográfica asignada en el nivel de procesamiento 1G: (A) imagen de 28 de julio de 1993; (B) imagen de 29 de junio de 1994; (C) imagen de 16 de agosto de 1994	141
Figura 2.13.	Detalle de las ortofotografías de 1 m de resolución espacial utilizadas para la localización de puntos de control.....	144
Figura 2.14.	Puntos de control utilizados en el proceso de georreferenciación de la imagen de 28 de julio de 1993.....	145
Figura 2.15.	Composición RGB 4-3-2 de la imagen Landsat del 29 de junio de 1994 corregida geoméricamente y adaptada a los límites del área de estudio.	147
Figura 2.16.	Componentes principales seleccionados de la imagen de junio de 1994: A) CP1; B) CP2; C) CP3	162
Figura 2.17.	Ejes TTC de brillo (A), verdor (B) y humedad (C) y composición RGB TTC de la imagen de junio de 1994 (D).....	163
Figura 2.18.	Distintos índices de vegetación obtenidos de la imagen de junio de 1994: (A) NDVI; (B) SAVI; (C) MSI; y (D) MID57	166
Figura 2.19.	Resolución en el acimut en la misma línea de observación	170
Figura 2.20.	Resolución en profundidad	171
Figura 2.21.	Efectos del relieve que deforman la imagen radar: (A) efecto de recorte; (B) efecto de repliegue; (C) efecto de sombra	172
Figura 2.22.	Variación del coeficiente de retrodispersión de un área homogénea debido a la topografía	173
Figura 2.23.	Localización de las imágenes ASAR utilizadas (en rojo las de órbita ascendente y en negro las de órbita descendente) respecto al área de estudio (en rosa)	178
Figura 2.24.	Proceso de georreferenciación de una imagen SAR con el método de tablas lookup del software GAMMA.....	181
Figura 2.25.	(A) imagen ASAR registrada el 19 de junio de 2003 (órbita descendente); (B) imagen ASAR registrada el 11 de octubre de 2003 (órbita ascendente).....	183
Figura 2.26.	Mapa de pendientes de la provincia de Teruel	188
Figura 2.27.	Mapa de orientaciones de la provincia de Teruel	188
Figura 2.28.	Mapa de insolación potencial anual en horas de la provincia de Teruel..	189
Figura 2.29.	Mapa de insolación potencial anual en iluminación recibida de la provincia de Teruel	189
Figura 2.30.	Mapa de Tipos Climático Estructurales (TCE) de la provincia de Teruel.....	192
Figura 2.31.	Mapa de Niveles de Madurez de la provincia de Teruel.....	193

Figura 3.1.	Utilización del CV para la determinación de la heterogeneidad de las parcelas: (A) parcela con un alto CV (alta heterogeneidad espacial); (B) parcela con un bajo CV (baja heterogeneidad espacial).....	202
Figura 3.2.	Clústeres de agrupación de grupos identificados sobre el gráfico de correlaciones entre MSI y la biomasa residual forestal para cada grupo de parcelas delimitado usando el CV en la imagen de junio de 1994.....	209
Figura 3.3.	Auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual en el grupo del percentil 10 de la imagen de junio de 1994.....	212
Figura 3.4.	Cartografía de probabilidad de existencia de biomasa residual forestal con respecto a los umbrales de corte definidos usando las parcelas del primer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	215
Figura 3.5.	Cartografía de probabilidad de existencia de biomasa residual forestal con respecto a los umbrales de corte definidos usando las parcelas del segundo clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	217
Figura 3.6.	Cartografía de probabilidad de existencia de biomasa residual forestal con respecto a los umbrales de corte definidos usando las parcelas del tercer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	219
Figura 3.7.	Gráficos de dispersión que relacionan la biomasa residual forestal con algunas de las variables independientes mejor correlacionadas usando las parcelas del clúster 1	222
Figura 3.8.	Gráficos de dispersión que relacionan la biomasa residual forestal con algunas de las variables independientes mejor correlacionadas usando las parcelas del clúster 2	225
Figura 3.9.	Gráficos de dispersión que relacionan la biomasa residual forestal con algunas de las variables independientes mejor correlacionadas usando las parcelas del clúster 3	229
Figura 3.10.	Parcelas del IFN-2 identificadas como erróneas: (A) parcela 286; (B) parcela 340; y (C) parcela 426	231
Figura 3.11.	Signatura espectral de las parcelas identificadas como erróneas.....	231
Figura 3.12.	Gráficos de dispersión de los cuatro modelos con mayor capacidad predictiva de la Tabla 3.11.....	234
Figura 3.13.	Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del tercer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	235
Figura 3.14.	Gráficos de dispersión de los seis modelos con mayor capacidad predictiva de la Tabla 3.12.....	238
Figura 3.15.	Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del cuarto clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	239
Figura 3.16.	Histogramas y gráficos de distribución normal de las variables transformadas de la biomasa residual forestal (rz_biomasa) (A y B) y de la insolación potencial (cd_INS_POT) (C y D).....	242

Figura 3.17.	Gráfico de dispersión del modelo N1 de la Tabla 3.22	252
Figura 3.18.	Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del tercer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	253
Figura 3.19.	Gráficos de dispersión de los cinco modelos de la Tabla 3.24.....	256
Figura 3.20.	Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del cuarto clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV.....	257
Figura 3.21.	Áreas forestales homogéneas a partir de la fotointerpretación de las ortoimágenes de resolución de 1 m del SIG Oleícola Español: (A) área homogénea de aptitud 1; (B) área homogénea de aptitud 3.....	271
Figura 3.22.	AOI's de las áreas forestales homogéneas delimitadas mediante análisis visual utilizadas para la extracción del valor medio de las variables radiométricas y forestales sin considerar los píxeles situados en la frontera.....	272
Figura 3.23.	Gráficos de dispersión de los modelos de la Tabla 3.27	277
Figura 3.24.	Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas incluidas en el grupo de calidad 3 derivadas de la utilización del método de extracción de áreas homogéneas creadas con fotografía aérea	278
Figura 3.25.	Gráficos de dispersión de la variable transformada de la biomasa residual forestal (rz_biomasa residual) con las variables dependientes TC3, la transformada de INS_POT (cd_INS_POT), INV_POT y CURVA..	282
Figura 3.26.	Gráficos de dispersión de los modelos de regresión lineal univariantes de las Tablas 3.30 y 3.31.....	285
Figura 3.27.	Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas incluidas en el grupo de calidad 3 derivadas de la utilización del método de extracción de áreas homogéneas creadas con fotografía aérea	286
Figura 3.28.	Procedimiento de extracción de la información radiométrica combinando el uso de técnicas de segmentación y ventanas fijas con restricciones ..	294
Figura 3.29.	Procedimiento de segmentación RGB clustering en ERDAS Imagine: (A) selección de las 3 bandas; (B) disposición de los píxeles en el espacio tridimensional de las 3 bandas y seccionado por las particiones establecidas; (C) cluster resultante del seccionado tridimensional.....	298
Figura 3.30.	Gráficos de dispersión de los mejores modelos para cada una de las variables consideradas en las Tablas 3.34 y 3.35	310
Figura 3.31.	Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas incluidas en el grupo del percentil 6 derivadas de la utilización del método de extracción de segmentación (S4) y ventanas con restricciones.....	311
Figura 3.32.	Gráficos de dispersión de modelos de regresión lineal univariantes de las Tablas 3.37 y 3.38.....	315
Figura 3.33.	Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas incluidas en el grupo del percentil 6 derivadas	

	de la utilización del método de extracción de segmentación (S4) y ventanas con restricciones	316
Figura 3.34.	$RMSE_r$ de cada una de las cartografías de estimación obtenidas en los apartados 3.1.1 y 3.1.2 con el máximo de parcelas disponibles en cada una de ellas para la validación	323
Figura 3.35.	$RMSE_r$ de cada una de las cartografías de estimación obtenidas en los apartados 3.1.1 y 3.1.2 con todas parcelas disponibles en cada una de ellas para la validación, las incluidas en el grupo del percentil 9, las incluidas en el percentil 8 y las que quedan en este grupo tras eliminar 3 parcelas con comportamiento atípico	326
Figura 3.36.	Localización de tres subsectores en el área de estudio (delimitada en rosa) que maximizan el número de imágenes ASAR de orbita ascendente (en rojo) y descendente (en negro). En verde los subsectores que tienen en cuenta las imágenes ascendentes; en azul el que considera las descendentes	332
Figura 3.37.	Detalle de los tres subsectores (delimitados en amarillo) sobre la imagen Landsat TM de junio de 1994 y localización de las parcelas del IFN-2 (puntos rojos).....	332
Figura 3.38.	Ejemplos de modificación de los límites de las áreas forestales homogéneas con objeto de que sean también homogéneas desde el punto de vista topográfico	334
Figura 3.39.	Gráficos de dispersión obtenidos con las 5 imágenes ASAR consideradas	337
Figura 3.40.	Relación según el modelo de Hsu et al., (1994) entre el coeficiente de retrodispersión de la banda C con polarización VV y con un ángulo de incidencia de 26° y la biomasa en un bosque de pinos contenida en la copa (crown), la debida al sustrato (ground) y a la suma de estos dos estratos del bosque (total)	338
Figura 3.41.	Relación entre el coeficiente de retrodispersión de la banda C - polarización VV y ángulo de incidencia de 26°- y AGB. El punto 1 simula la respuesta de un suelo húmedo y relativamente rugoso; el punto 2 un suelo con humedad media y liso; el punto 3 un suelo poco rugoso y seco; el punto 4 un suelo liso y seco. El área en gris representa los bosques de baja densidad y poca biomasa, medios en los que las características del suelo determinan la relación.....	339
Figura 4.1.	Auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual en el grupo del percentil 10 de la imagen de julio de 1993	357
Figura 4.2.	Auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual en el grupo del percentil 10 de la imagen de agosto de 1994.....	358
Figura 4.3.	Gráficos de dispersión de los cuatro modelos con mayor capacidad predictiva de la Tabla 4.5 (imagen de julio de 1993).....	363
Figura 4.4.	Gráficos de dispersión de los cuatro modelos con mayor capacidad predictiva de la Tabla 4.6 (imagen de agosto de 1994).....	364
Figura 4.5.	Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del percentil 4 derivadas de la utilización	

	del método de extracción de ventanas 3x3 y el CV en la imagen de julio de 1993	365
Figura 4.6.	Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CV en la imagen de agosto de 1994	365
Figura 4.7.	Gráficos de dispersión de los modelos de regresión lineal univariantes de las Tablas 4.10 y 4.11	371
Figura 4.8.	Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CV en la imagen de julio de 1993	372
Figura 4.9.	Gráficos de dispersión de los tres modelos de regresión lineal univariantes de la Tabla 4.13	374
Figura 4.10.	Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CV en la imagen de agosto de 1994	375
Figura 4.11.	$RMSE_r$ obtenido en cada una de las cartografías de estimación derivadas de las tres imágenes disponibles con el método de extracción de las ventanas de 3x3 píxeles y CV considerando las parcelas incluidas en sus respectivos grupos del percentil 4	377
Figura 4.12.	Gráfico de barras de error que compara el contenido de humedad de las muestras de las cuatro especies consideradas en los meses de junio (6), julio (7) y agosto (8)	381
Figura 5.1.	Cartografía de la biomasa residual forestal en la provincia de Teruel obtenida a partir de la aplicación de la Ecuación 36 sobre la imagen de julio de 2008	394
Figura 5.2.	Cartografía de biomasa residual forestal en la provincia de Teruel en julio de 2008 expresada tons/píxel	395
Figura 5.3.	Detalle de la superficie provincial –sector septentrional de las comarcas de Bajo Martín, Bajo Aragón y Matarraña- no inventariada	396
Figura 5.4.	Distribución porcentual por comarcas de la biomasa residual forestal	398
Figura 5.5.	Biomasa residual forestal en la comarca de Andorra-Sierra de los Arcos (tons/ha, julio 2008)	402
Figura 5.6.	Biomasa residual forestal en la comarca del Bajo Aragón (tons/ha, julio 2008)	403
Figura 5.7.	Biomasa residual forestal en la comarca del Bajo Martín (tons/ha, julio 2008)	404
Figura 5.8.	Biomasa residual forestal en la comarca de la Comunidad de Teruel (tons/ha, julio 2008)	405
Figura 5.9.	Biomasa residual forestal en la comarca de Cuencas Mineras (tons/ha, julio 2008)	406
Figura 5.10.	Biomasa residual forestal en la comarca de Gúdar-Javalambre (tons/ha, julio 2008)	407

Figura 5.11. Biomasa residual forestal en la comarca del Jiloca (tons/ha, julio 2008) ...	408
Figura 5.12. Biomasa residual forestal en la comarca del Maestrazgo (tons/ha, julio 2008)	409
Figura 5.13. Biomasa residual forestal en la comarca del Matarraña (tons/ha, julio 2008)	410
Figura 5.14. Biomasa residual forestal en la comarca de la Sierra de Albarracín (tons/ha, julio 2008)	411
Figura 5.15. Cartografía obtenida tras reclasificar la cantidad de biomasa residual estimada en 2008 con los valores del índice I_{BRF}	416
Figura 5.16. Cartografía obtenida tras reclasificar la superficie de cada tesela forestal con los valores del índice I_{sup}	418
Figura 5.17. Cartografía obtenida tras reclasificar la pendiente de las zonas forestales con los valores del índice I_{pend}	419
Figura 5.18. Cartografía obtenida tras reclasificar la distancia a pistas, caminos y carreteras con los valores del índice I_{dist}	421
Figura 5.19. Distribución de la superficie forestal de pináceas respecto al índice I_{BRF}	423
Figura 5.20. Distribución de la superficie forestal de pináceas respecto al índice I_{pend}	424
Figura 5.21. Distribución de la superficie forestal de pináceas respecto al índice I_{dist}	425
Figura 5.22. Cartografía obtenida tras aplicar el índice I_{aptM}	426
Figura 5.23. Distribución de la superficie forestal de pináceas respecto al índice I_{aptM}	427
Figura 5.24. Cartografía obtenida tras aplicar el índice I_{aptP} con los pesos de la prueba A	428
Figura 5.25. Cartografía obtenida tras aplicar el índice I_{aptP} con los pesos de la prueba B	429
Figura 5.26. Cartografía obtenida tras aplicar el índice I_{aptP} con los pesos de la prueba C	429
Figura 5.27. Distribución de la superficie forestal de pináceas respecto a la prueba A del índice I_{aptP}	430
Figura 5.28. Distribución de la superficie forestal de pináceas respecto a la prueba B del índice I_{aptP}	431
Figura 5.29. Distribución de la superficie forestal de pináceas respecto a la prueba C del índice I_{aptP}	432

ÍNDICE DE TABLAS

Tabla 1.1.	Modelos de regresión incluidos en la función “Estimación curvilínea” de SPSS	80
Tabla 2.1	Superficie forestal arbolada por especie dominante en la provincia de Teruel.....	109
Tabla 2.2.	Composición de la muestra por especies: nº de pies y % sobre el total muestreado, nº y % de pies procedentes de repoblaciones, rango de los diámetros muestreados, desviación estándar y error estándar de la media de la biomasa residual forestal (peso en seco).....	113
Tabla 2.3.	Modelos de regresión ajustados para la estimación de biomasa residual, R ² ajustado, desviación típica, nº de casos eliminados, expresión de los pesos utilizados y p-valor de los estadísticos de Kolmogorov-Smirnov y Levene	117
Tabla 2.4.	Comparación de los modelos de regresión por especie propuestos con sus respectivas formas alométricas.....	118
Tabla 2.5.	Radio de las parcelas del IFN-2 según diámetros de los pies encontrados	122
Tabla 2.6.	Composición de la muestra de parcelas monoespecíficas del IFN-2 por especies para las que se tiene información de biomasa residual forestal: número de parcelas, valor medio, desviación estándar, valor mínimo y valor máximo.....	127
Tabla 2.7.	La familia de satélites Landsat.....	136
Tabla 2.8.	Bandas de registro del sensor TM: amplitud espectral y localización en el espectro electromagnético	138
Tabla 2.9.	Número de puntos de control utilizados y <i>RMSE</i> obtenido en píxeles y en metros	146
Tabla 2.10.	ND mínimos de cada una de las bandas de las imágenes Landsat utilizadas	151
Tabla 2.11.	Coefficientes de calibración (<i>offset</i> y <i>gain</i>) de las imágenes Landsat 5 TM utilizadas.....	152
Tabla 2.12.	NDVI promedio de las distintas cubiertas en las imágenes Landsat TM utilizadas	157
Tabla 2.13.	Umbral de NDVI usados en cada imagen para separar las categorías (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa en forma de bosque.....	158
Tabla 2.14.	Valores calculados para la constante de Minnaert en función de las bandas de cada imagen y las categorías (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa en forma de bosque	158
Tabla 2.15.	Valores de la pendiente y del coeficiente de determinación obtenidos al aplicar la regresión entre la reflectividad y el coseno del ángulo de incidencia (IL) antes de realizar la normalización (sin N.T.) y después (con N.T.) utilizando píxeles de cualquier tipo de cubierta	159

Tabla 2.16.	Valores de la pendiente y del coeficiente de determinación obtenidos al aplicar la regresión entre la reflectividad y el coseno del ángulo de incidencia (IL) antes de realizar la normalización (sin N.T.) y después (con N.T.) utilizando píxeles con NDVI entre 0,40 y 0,45.....	159
Tabla 2.17.	Autovalores (porcentaje de información original que contiene cada CP) de las imágenes utilizadas.....	161
Tabla 2.18.	Coefficientes utilizados para la aplicación de la TTC	164
Tabla 2.19.	Índices de vegetación calculados.....	167
Tabla 2.20.	Bandas de frecuencia normalmente utilizadas en la región de las microondas.....	174
Tabla 2.21.	Características de las imágenes ASAR utilizadas.....	178
Tabla 3.1.	Variables independientes consideradas para la estimación de la biomasa residual forestal.....	201
Tabla 3.2.	Umbral de CV de cada una de las bandas reflectivas de la imagen de junio de 1994 utilizados para la delimitación de los 10 grupos de parcelas con distinto grado de heterogeneidad espacial-radiométrica....	203
Tabla 3.3.	Coefficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes radiométricas continuas en cada uno de los grupos delimitados usando el CV.....	205
Tabla 3.4.	Coefficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes topográficas continuas en cada uno de los grupos delimitados usando el CV.....	207
Tabla 3.5.	Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 1, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$	214
Tabla 3.6.	Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 2, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$	217
Tabla 3.7.	Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 3, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$	218
Tabla 3.8.	Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 4, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$	220
Tabla 3.9.	Modelos de regresión simple calculados para el clúster 1: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	223
Tabla 3.10.	Modelos de regresión simple calculados para el clúster 2: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	226
Tabla 3.11.	Modelos de regresión simple calculados para el clúster 3: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	232

Tabla 3.12.	Modelos de regresión simple calculados para el clúster 4: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión	236
Tabla 3.13.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes radiométricas correlacionadas con ella en el clúster 1	240
Tabla 3.14.	Pruebas de normalidad aplicadas a las variables independientes topográficas	241
Tabla 3.15.	Modelos de regresión múltiple calculados para el clúster 1: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión	244
Tabla 3.16.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en el clúster 2	245
Tabla 3.17.	Modelos de regresión múltiple calculados para el clúster 2: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables.....	246
Tabla 3.18.	Modelos de regresión calculados para las muestras N_3 y N_5 del clúster 2 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión	247
Tabla 3.19.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en el clúster 3	249
Tabla 3.20.	Modelos de regresión múltiple calculados para el clúster 3: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables.....	251
Tabla 3.21.	Modelos de regresión calculados para las muestras N_1 , N_4 y N_5 del clúster 3 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión	251
Tabla 3.22.	$RMSE$ y $RMSE_r$ de los modelos de regresión lineal múltiple calculados para el clúster 3	252
Tabla 3.23.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en el clúster 4	254
Tabla 3.24.	Modelos de regresión múltiple calculados para el clúster 4: muestra de parcelas sobre la que se ha calculado, variable seleccionada,	

	coeficiente de determinación ajustado, error estándar y coeficientes de regresión.....	255
Tabla 3.25.	Coeficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes radiométricas en cada uno de los 3 grupos delimitados en función de la aptitud de las áreas homogéneas creadas con fotografía aérea	273
Tabla 3.26.	Coeficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes topográficas continuas en cada uno de los 3 grupos delimitados en función de la aptitud de las áreas homogéneas creadas con fotografía aérea	274
Tabla 3.27.	Modelos de regresión simple calculados con las áreas homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	276
Tabla 3.28.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes radiométricas correlacionadas con ella utilizando las áreas forestales homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3	280
Tabla 3.29.	Pruebas de normalidad aplicadas a las variables independientes topográficas correlacionadas con la biomasa residual forestal utilizando las áreas forestales homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3	281
Tabla 3.30.	Modelos de regresión múltiple calculados con las áreas homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables	283
Tabla 3.31.	Modelos de regresión calculados para las muestras N_1 , N_2 y N_5 de las áreas homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión.....	284
Tabla 3.32.	Parámetros de entrada de las cuatro segmentaciones aplicadas a la composición RGB TM7-TM4-TM3 tras aplicar la máscara del MFA	301
Tabla 3.33.	Coeficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes radiométricas continuas en los grupos del percentil 7 y 6 según el tipo de segmentación y usando ventanas fijas sin restricciones.....	304
Tabla 3.34.	Modelos de regresión simple calculados con la información de las 130 parcelas del grupo del percentil 6 obtenida mediante la utilización de la segmentación S4 y ventanas con restricciones: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	308

Tabla 3.35.	Modelos de regresión simple calculados con la información de las 130 parcelas del grupo del percentil 6 obtenida mediante la utilización de ventanas fijas sin restricciones: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión 308
Tabla 3.36.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes radiométricas correlacionadas con ella utilizando los datos obtenidos mediante la segmentación S4 y ventanas con restricciones 312
Tabla 3.37.	Modelos de regresión múltiple calculados con los datos obtenidos mediante la segmentación S4 y ventanas con restricciones: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables 313
Tabla 3.38.	Modelo de regresión calculado para la muestra N ₂ con los datos obtenidos mediante la segmentación S4 y ventanas con restricciones al eliminar las variables introducidas en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión 314
Tabla 3.39.	Cartografías de estimación de biomasa residual forestal obtenidas en los apartados 3.1.1 y 3.1.2. según el método de extracción de la información, el tipo de modelo utilizado, apartado donde aparecen y número de figura 323
Tabla 3.40.	Número de parcelas utilizado para la validación de las 8 cartografías obtenidas en los apartados 3.1.1 y 3.1.2 y error de estimación obtenido 327
Tabla 3.41	Comparación de los coeficientes de regresión de las ecuaciones que han servido para obtener las cartografías de estimación 1, 3, 7 y 8 329
Tabla 3.42.	Características de las imágenes y las parcelas contenidas en los tres subsectores 331
Tabla 3.43.	Características de las áreas forestales homogéneas con los nuevos límites 334
Tabla 3.44.	Coefficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las 5 imágenes ASAR consideradas 335
Tabla 3.45.	Modelos de regresión simple calculados con las 5 imágenes ASAR consideradas: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión 336
Tabla 4.1.	Umbral de CV de cada una de las bandas reflectivas de la imagen de julio de 1993 utilizados para la delimitación de los 10 grupos de parcelas con distinto grado de heterogeneidad espacial-radiométrica 350
Tabla 4.2.	Umbral de CV de cada una de las bandas reflectivas de la imagen de agosto de 1994 utilizados para la delimitación de los 10 grupos de parcelas con distinto grado de heterogeneidad espacial-radiométrica 350

Tabla 4.3.	Coeficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal con las variables radiométricas continuas obtenidas de la imagen de julio de 1993 en cada uno de los grupos delimitados usando el CV.....	352
Tabla 4.4.	Coeficientes de correlación de <i>Pearson</i> obtenidos al relacionar la biomasa residual forestal con las variables radiométricas continuas obtenidas de la imagen de agosto de 1994 en cada uno de los grupos delimitados usando el CV.....	353
Tabla 4.5.	Modelos de regresión simple calculados para el grupo de parcelas del percentil 4 con las variables derivadas de la imagen de julio de 1993: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	361
Tabla 4.6.	Modelos de regresión simple calculados para el grupo de parcelas del percentil 4 con las variables derivadas de la imagen de agosto de 1994: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión.....	362
Tabla 4.7.	Comparación de los R^2 obtenidos en los modelos de regresión simple ajustados con las variables TM5, TM7, TC3 y MID57 para las parcelas incluidas en el grupo del percentil 4 de las imágenes de junio de 1994, julio de 1993 y agosto de 1994.....	363
Tabla 4.8.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en percentil 4 de la imagen de julio de 1993.....	367
Tabla 4.9.	Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en en percentil 4 de la imagen de agosto de 1994	368
Tabla 4.10.	Modelos de regresión múltiple calculados con el grupo de parcelas del percentil 4 de la imagen de julio de 1993: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables	369
Tabla 4.11.	Modelo de regresión calculado para las muestra N_2 de la imagen de julio de 1993 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión.....	370
Tabla 4.12.	Modelos de regresión múltiple calculados con el grupo de parcelas del percentil 4 de la imagen de agosto de 1994: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables	373
Tabla 4.13.	Modelos de regresión calculados para las muestras N_1 , N_2 y N_5 de la imagen de agosto de 1994 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión.....	373

Tabla 4.14.	<i>RMSE</i> de los modelos de regresión lineal múltiple de la Tabla 4.12.....	375
Tabla 4.15.	Denominación utilizada para designar las cartografías obtenidas en el Capítulo 4 dependiendo de la imagen empleada y del método de regresión utilizado.....	376
Tabla 4.16.	Número de parcelas empleado para la validación de las cartografías de estimación de biomasa residual creadas en el Capítulo 4 y errores de estimación obtenidos	376
Tabla 4.17.	Muestreo de campo realizado por el Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza en el marco del proyecto FIRERISK (Cordillera Ibérica y Prepirineo).....	379
Tabla 4.18.	Resultado del análisis ANOVA ajustado para explorar las diferencias en el contenido de humedad de las muestras de las cuatro especies consideradas en los meses de junio (6), julio (7) y agosto (8).....	381
Tabla 4.19.	Comparación del rango de MID57 en los modelos que se han utilizado para obtener cartografía con el de los modelos desechados ajustados con otras variables relacionadas con la humedad para la misma muestra de parcelas	384
Tabla 5.1.	ND mínimo y coeficientes de calibración de cada banda de la imagen de julio de 2008 utilizados para la corrección de la dispersión atmosférica y el cálculo de la radiancia espectral	391
Tabla 5.2.	Valores calculados para la constante de Minnaert para la imagen de julio de 2008 en función de las bandas y las categorías (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa en forma de bosque	391
Tabla 5.3.	Biomasa residual forestal en cada una de las comarcas turolenses	397
Tabla 5.4.	Densidad media de biomasa residual forestal por comarca	398
Tabla 5.5.	Biomasa residual forestal por municipios de la comarca de Andorra–Sierra de los Arcos.....	399
Tabla 5.6.	Biomasa residual forestal por municipios de la comarca del Bajo Aragón.....	399
Tabla 5.7.	Biomasa residual forestal por municipios de la comarca del Bajo Martín... ..	400
Tabla 5.8.	Biomasa residual forestal por municipios de la comarca de la Comunidad de Teruel	400
Tabla 5.9.	Biomasa residual forestal por municipios de la comarca de Cuencas Mineras	400
Tabla 5.10.	Biomasa residual forestal por municipios de la comarca de Gúdar-Javalambre	401
Tabla 5.11.	Biomasa residual forestal por municipios de la comarca del Jiloca.....	401
Tabla 5.12.	Biomasa residual forestal por municipios de la comarca de Maestrazgo	401
Tabla 5.13.	Biomasa residual forestal por municipios de la comarca del Matarraña..	412
Tabla 5.14.	Biomasa residual forestal por municipios de la comarca de la Sierra de Albarracín.....	412

Tabla 5.15.	Valores de I_{BRF} en función de la cantidad de biomasa residual forestal calculada en tons/ha.....	415
Tabla 5.16.	Valores de I_{BRF} en función de la cantidad de biomasa residual forestal calculada en tons/píxel	415
Tabla 5.17.	Valores de I_{sup} en función de la superficie (ha) de la masa forestal	417
Tabla 5.18.	Valores de I_{pend} en función de la pendiente (%) del terreno	419
Tabla 5.19.	Valores de I_{dist} en función de la superficie (ha) de la masa forestal	420
Tabla 5.20.	Pesos asignados a cada uno de los índices parciales considerados en las tres pruebas con el índice I_{aptP}	428

***CAPÍTULO 1:
ANTECEDENTES, OBJETIVOS,
METODOLOGÍA Y ÁREA DE ESTUDIO***

1.1. La biomasa residual forestal como recurso energético

1.1.1. Las energías renovables

La consideración por parte de la sociedad occidental de la trascendencia que el abastecimiento energético tiene en el mantenimiento de sus modos de vida comenzó en los años 70 a causa de la crisis petrolífera. El aumento generalizado de los precios del petróleo llevó a la búsqueda de energías alternativas, entre las cuales se encontraban las renovables: solar, eólica, biomasa, hidráulica... (Domínguez, 2002). Sin embargo, el incumplimiento de las expectativas de crecimiento de los precios del petróleo y los elevados precios de las energías renovables a corto plazo (inversión en investigación y desarrollo tecnológico) propició un descenso en el interés del impulso de éstas durante la década de los 80 (Gobierno de Aragón-IDAE, 1997; Esteban *et al.*, 2004).

Desde los años 90 hasta la actualidad, el papel que las energías renovables juegan en el suministro energético se ha ido matizando, adquiriendo cada vez una mayor importancia. Entre las causas de este aumento se encuentran, junto a las razones de tipo estrictamente económico, otras con un marcado carácter medioambiental, social y territorial (Gobierno de Aragón-IDAE, 1997; Domínguez, 2002). Así, desde el punto de vista económico, existe una gran preocupación a nivel europeo por la excesiva dependencia energética del petróleo, que se sitúa en torno al 50% (Comisión de las Comunidades Europeas, 2006). Esta situación se da también a escala nacional, ya que, a pesar del crecimiento relativo de las fuentes de energía renovables en los últimos años, casi la mitad de la energía primaria consumida en España en 2007 procedió de este recurso fósil (Figura 1.1) (Ministerio de Industria, Turismo y Comercio, 2008).

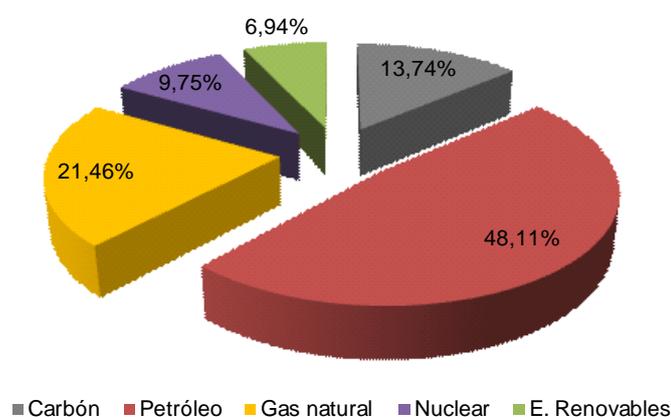


Figura 1.1. Distribución del consumo de energía primaria en España en 2007. Fuente: Ministerio de Industria, Turismo y Comercio (2008)

El aumento en el precio del barril de crudo en los dos últimos años (llegando a alcanzar recientemente valores muy por encima de los 100 \$ en el caso del barril de crudo *Brent*, el de referencia en Europa) hace que esta dependencia se refleje en los datos macroeconómicos españoles, poniendo en peligro la buena marcha de la economía nacional al provocar una desaceleración del crecimiento (Pérez, 2007). Además, las energías renovables contribuyen a garantizar el suministro energético, prioridad básica de cualquier política energética, mitigando los efectos perniciosos producidos por situaciones puntuales de inestabilidad internacional que ponen en peligro el suministro de combustibles fósiles (Gobierno de Aragón-IDAIE, 1997; Mourelatou y Smith, 2004).

En cuanto al aspecto medioambiental, las energías renovables juegan un papel esencial en la reducción de las emisiones de CO₂ a la atmósfera generadas por los procesos de producción de energía, ya que la emisión de este gas, principal responsable del efecto invernadero y del calentamiento global, es prácticamente nula (Mourelatou y Smith, 2004). Es precisamente esta preocupación por el medio ambiente y la toma de conciencia de que las reservas de combustibles fósiles no son ilimitadas lo que ha llevado en los últimos años a que la sociedad demande cada vez más, y de una forma más clara, el uso de fuentes de energía renovables.

La incorporación paulatina de las energías renovables al sistema de producción de energía supone el paso de un modelo de producción de carácter concentrado (apoyado en la localización en determinados puntos de centros de extracción, producción y distribución de combustibles fósiles) a un modelo mucho más abierto desde el punto de vista territorial, debido a que las distintas energías renovables están mucho más diseminadas por el territorio, lo que provoca la descentralización de la producción energética, la diversificación de la misma y complementariedad en un sistema energético regional. De esta manera, la impronta geográfica de las energías renovables es muy importante, ya que se trata de utilizar un recurso natural endógeno, lo que repercute positivamente tanto en el medio ambiente del área afectada como en su desarrollo económico y social, extendiéndose estos efectos locales a una escala regional (Gobierno de Aragón-IDAIE, 1997; Esteban *et al.*, 2004). Este hecho enlaza directamente con el concepto de “desarrollo sostenible” ya que el uso de energías renovables implica utilizar de forma sostenible los recursos energéticos disponibles manteniendo el nivel de desarrollo actual, pero teniendo en cuenta las necesidades de las generaciones venideras.

Los distintos escenarios de consumo energético planteados para el siglo XXI coinciden en señalar el aumento generalizado de la demanda energética (Esteban *et al.*, 2004; Mourelatou y Smith, 2004; Comisión de las Comunidades Europeas, 2006). Una vez reconocido el peligro que entraña la excesiva dependencia actual de combustibles fósiles importados y la incidencia que la utilización de estos recursos tiene en el cambio climático (o calentamiento global), tanto la Unión Europea (UE) como España han ido desarrollando planes específicos para la promoción y el desarrollo de las energías renovables.

Teniendo en cuenta los tres objetivos esenciales de la política energética de la UE –seguridad en el suministro, competitividad y protección medioambiental (Consejo de la Unión Europea, 1995; Mourelatou y Smith, 2004) –, se desarrolló el Comunicado de la Comisión Europea *Energía para el Futuro: Fuentes de Energía Renovables. Libro Blanco para una Estrategia y un Plan de Acción Comunitarios* (Comisión de las Comunidades Europeas, 1997). En este documento, que constituye la base para la promoción y desarrollo de las energías renovables en la UE, se fijó como objetivo que la producción de energía en 2010 procediera en un 12% de fuentes renovables. Un paso más en la potenciación de la consideración de estas energías como pilar básico dentro de la política energética de la UE se dio en 1998, al enunciarse los objetivos medioambientales específicos de su política energética, en los que se destaca la necesidad de reducir el impacto medioambiental de la producción y consumo de energía y el aumento de la cuota de producción y consumo de energías limpias (Comisión de las Comunidades Europeas, 1998).

En el contexto nacional, en 1999 se aprobó el *Plan de Fomento de las Energías Renovables en España* (PFER) (IDAE, 1999) como respuesta a la necesidad de promocionar una política energética que, por un lado, disminuyera la excesiva dependencia exterior y, por otro, preservara el medio ambiente y asegurara un desarrollo sostenible. En este *Plan de Fomento* se marcó el mismo objetivo que el fijado en el Comunicado de la Comisión de 1997 (12% de producción en 2010).

1.1.2. La energía de la biomasa

Para conseguir este porcentaje de participación de las energías renovables en la producción energética final, tanto en la UE como en España se confiaba en el aumento del uso de la biomasa (Comisión de las Comunidades Europeas, 1997; IDAE, 1999). Así, en el caso español, el PFER fijaba que la contribución de la biomasa a la producción de

energía en 2010 debía ser casi tres veces superior a la de 1998: 9.629 ktep – kilotoneladas equivalentes de petróleo- en 2010 frente a los 3.629 ktep en 1998. En el año 2007, casi la mitad de la energía primaria consumida en España procedente de energías renovables tuvo su origen en la biomasa (Figura 1.2) (Ministerio de Industria, Turismo y Comercio, 2008).

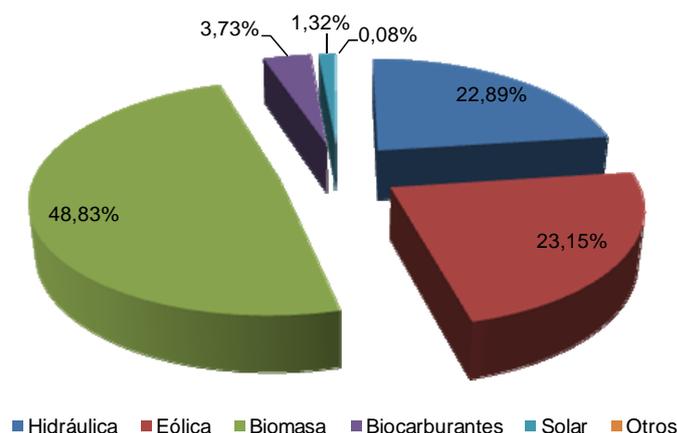


Figura 1.2. Distribución del consumo de energía primaria de origen renovable en España en 2007.
Fuente: Ministerio de Industria, Turismo y Comercio (2008)

El término *biomasa* refiere a toda la materia orgánica producida por un proceso biológico y, desde el punto de vista energético, aglutina al conjunto de sustancias orgánicas renovables de origen vegetal, animal o derivadas de cualquier proceso de transformación natural o artificial de las mismas, que pueden producir energía al ser sometidas a determinados procesos físicos, químicos o biológicos. En esta definición no se incluye a los combustibles fósiles y sus derivados debido a que, aunque también tuvieron un origen biológico hace millones de años, no pueden considerarse como renovables (Gobierno de Aragón-CIRCE, 1997; Sebastián, 1999; Jarabo, 1999).

En origen, la energía de la biomasa proviene directamente de la luz solar. Por el proceso de la fotosíntesis, los vegetales transforman la energía solar recibida en moléculas orgánicas de alto contenido energético a partir de sustancias simples y del CO₂ presente en el aire, almacenándolas después. Con posterioridad, el reino animal incorpora, transforma y modifica dicha energía. Durante este proceso de transformación de la materia orgánica se generan subproductos que no poseen valor para la cadena nutritiva o que no son útiles para la fabricación de bienes de mercado, pero que pueden

emplearse como combustible en diferentes aprovechamientos energéticos (Gobierno de Aragón-CIRCE, 1997; Sebastián, 1999; Jarabo, 1999).

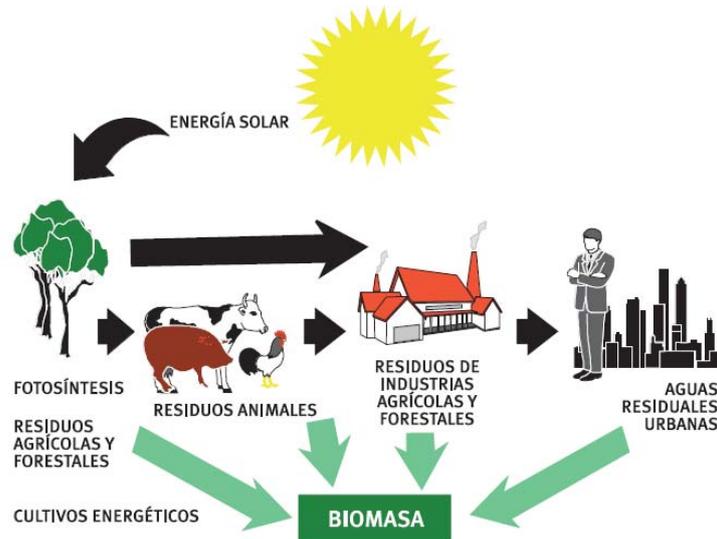


Figura 1.3. Cadena de generación de la biomasa como recurso energético. Adaptado de IDAE (2007)

Una diferencia particular de la biomasa respecto a otras energías renovables como la eólica o la solar es su capacidad natural de almacenamiento, lo que la convierte en un “stock” energético que se renueva con suficiente rapidez para el uso humano (Puig, 1985; Jarabo, 1999). Sin embargo, es importante señalar que, para que la biomasa sea considerada como un recurso renovable, su utilización debe ser más lenta o igual que la velocidad a la cual se regenera este recurso (Domínguez, 2002). Otras características significativas de la biomasa como recurso energético son su gran diversidad y su escasa concentración espacial, lo que implica un gran número de procesos de transformación para su aprovechamiento final (Gobierno de Aragón-CIRCE, 1997).

Así pues, existen distintos tipos o fuentes de biomasa que pueden ser utilizados para producir energía. En el presente trabajo se adopta la clasificación utilizada en el “Atlas de biomasa para usos energéticos de Aragón” (Gobierno de Aragón-CIRCE, 1997):

- **Biomasa natural:** es la biomasa que se produce en la naturaleza sin ningún tipo de intervención humana. Un ejemplo de explotación de este tipo de biomasa sería la recogida de leña en los bosques.
- **Biomasa residual:** dentro de este grupo están incluidos los subproductos que no tienen utilidad en las actividades forestales y agrícolas, en los procesos de

transformación de la madera y en los procesos de las industrias agroalimentarias. También se consideran dentro de este grupo los vertidos biodegradables como las aguas residuales industriales y urbanas y los residuos de origen ganadero (denominados “biomasa residual húmeda”). Destaca el hecho de que el uso con fines energéticos de este tipo de residuos puede mitigar algunos de los problemas medioambientales ocasionados por su acumulación y/o eliminación.

- **Cultivos energéticos:** son cultivos producidos con la única finalidad de obtener biomasa transformable en combustible, ya sea para automoción o para generar energía eléctrica o calor. Estos cultivos se seleccionan debido a su capacidad de producir materia vegetal con un número reducido de cuidados, no importando que la producción sea apta para el consumo alimentario. Algunos ejemplos de cultivos energéticos en el grupo de los herbáceos son el sorgo (*Shorgum sp.*) y el cardo (*Cynara cardunculus*) y, entre los leñosos, el chopo (*Populus sp.*) y el eucalipto (*Eucaliptus sp.*).

Dentro de estos recursos considerados como proveedores de biomasa, el PFER señalaba a los **residuos forestales** como uno de los más importantes para cumplir con sus objetivos. Así, en dicho plan se recoge que en 2010 la contribución energética de los residuos forestales debía ser de 450.000 tep-año.

1.1.3. La biomasa residual forestal

La **biomasa residual forestal** refiere a las hojas-acículas, ramas, rabeones e incluso a árboles de pequeñas dimensiones (diámetros inferiores a 7,5 cm) generados tanto en tratamientos selvícolas como en aprovechamientos madereros parciales o finales que no son extraídos habitualmente por no ser convertibles en subproductos, pero que pueden ser utilizados como combustible orgánico (Gobierno de Aragón-CIRCE, 1997; Gobierno de Aragón-IDAIE, 1997; IDAE, 1999; Esteban *et al.*, 2004; Velázquez, 2006).

Siguiendo el concepto de “árbol completo” introducido por Young *et al.* (1964), la biomasa residual forestal de un árbol estaría compuesta por la suma de su *follaje*, su *ramaje* y de la *parte superior de su tallo no útil para propósitos comerciales* (raberón). Dentro del concepto de *follaje* quedan incluidos las hojas y/o acículas, los nuevos brotes y los órganos reproductivos; por su parte, el término *ramaje* incluye la madera y la corteza

de las ramas vivas o muertas. Por último, la *parte superior del tallo no útil para propósitos comerciales* (raberón) refiere a la sección superior del tallo que no es utilizada en operaciones madereras debido a su pequeño diámetro y a su alto grado de ramaje, oscilando el diámetro inferior de esta parte superior del tallo entre los 5-10 cm (Hakkila y Parikka, 2002). De aquí en adelante, éstos serán los componentes del árbol a los cuales nos referiremos como biomasa residual forestal.

Tomando el diagrama de Young *et al.* (1964) para un árbol medio, el 100% del volumen del árbol se reparte como sigue (Gobierno de Aragón-CIRCE, 1997): 60% en el fuste maderable, 20% en el tocón o raíces, 15% en las ramas (y follaje) y 5% en el raberón. De esta manera, dejando a un lado el tocón y las raíces (ya que estas partes son muy costosas de extraer), la biomasa residual forestal compuesta por las ramas, el follaje y el raberón suponen aproximadamente un 20% del volumen total del árbol.



Figura 1.4. Biomasa residual forestal y fuste maderable procedente de una corta fitosanitaria

A continuación, se realiza una descripción más detallada de estos residuos según la actividad forestal que los genera.

- **Residuos procedentes de tratamientos selvícolas:** estos residuos proceden de la necesidad de llevar a cabo tratamientos para la mejora y el mantenimiento de los montes y masas forestales (Gobierno de Aragón-CIRCE, 1997). Las actividades selvícolas generadoras de estos residuos son diversas y se pueden clasificar según sean sobre el vuelo arbóreo (parte superficial del

árbol) o sobre el no arbóreo (parte subterránea), si bien estos últimos se llevan a cabo en contadas ocasiones ya que son muy costosos (Esteban *et al.*, 2004), por lo que sólo se comentarán los del primer grupo. Así pues, centrándonos en los tratamientos sobre el vuelo arbóreo, se distinguen los siguientes tipos (Esteban *et al.*, 2004):

- Los que no suponen la corta de árboles: dentro de este grupo estarían las podas, olivaciones (aclareo de la copa) y trasmochos (corta de las ramas del árbol, dejando sólo el fuste).
- Intermedios: tienen por objeto mejorar la masa forestal. Se trata de los clareos (realizados sobre árboles de pequeñas dimensiones sobre los que no se obtiene rendimiento económico alguno) y las claras (sobre ejemplares de mayores dimensiones sobre los que sí que se obtiene un rendimiento económico).
- Finales: suponen la corta de la masa forestal, obteniéndose de ella un aprovechamiento económico importante. Dentro de este grupo se incluyen las cortas de hecho (cuando se elimina toda o casi toda la masa arbórea de una zona), el aclareo sucesivo (se dejan algunas masas de árboles para permitir la diseminación de las semillas en la zona tratada) y la entresaca (cortas de pies distribuidos por toda la zona forestal).

Entre los objetivos perseguidos por estos tratamientos selvícolas se encuentran la realización de tareas fitosanitarias que reduzcan el riesgo de plagas y enfermedades, la disminución del riesgo de incendios forestales y de su severidad en el caso de producirse mediante la limpieza de los montes o mediante la apertura de cortafuegos, la apertura de pistas forestales o de caminos para líneas eléctricas, facilitar la regeneración natural y transformar masas monoespecíficas en agrupaciones pluriespecíficas (Gobierno de Aragón-CIRCE, 1997; Esteban *et al.*, 2004).

- **Residuos de corta de pies maderables:** refieren a los residuos generados durante las tareas de corta final y saca de una masa forestal para su aprovechamiento maderero, tanto en montes de carácter público como privado.



Figura 1.5. Aspecto de una masa forestal tras la aplicación de actividades selvícolas y detalle de la biomasa residual generada por uno de los pies

Los tratamientos más comunes aplicados a esta biomasa residual forestal en España son la quema controlada o el amontonamiento del material en el monte, siendo pocas veces triturada o astillada y abandonada en el monte para favorecer su rápida incorporación al suelo (Velázquez, 2006). En ocasiones, las ramas y copas son asignadas a los habitantes del municipio para su aprovechamiento como leñas, aunque la disminución de la población en zonas boscosas y la generalización del uso de combustibles fósiles en el medio rural hacen que esto suceda en pocas ocasiones. Como se ha indicado anteriormente, una salida de estos residuos es su uso como fuente de energía renovable, si bien es necesario señalar que este aprovechamiento debe de producirse de tal forma que quede garantizado el aporte orgánico al suelo del bosque ya que de estos materiales reciben los árboles la mayor parte de los nutrientes (Gobierno de Aragón-CIRCE, 1997; Sebastián, 1999; Pascual *et al.*, 2006).



Figura 1.6. Acumulación de fustes al pie de la carretera para su recolección y amontonamiento de la biomasa residual para su abandono en el bosque

El aprovechamiento energético de la biomasa residual forestal se produce por tres vías: mediante su utilización en aplicaciones eléctricas, en aplicaciones térmicas y en aplicaciones de cogeneración (producción conjunta de energía eléctrica y térmica) (Sebastián y Royo, 2005; IDAE, 2005b). La tecnología empleada en estas aplicaciones es la combustión de los residuos que, previamente, han sido objeto de diversas tareas de pretratamiento necesarias para su utilización: de reducción granulométrica (astillado, triturado, molienda...), de reducción de la humedad (secado natural o forzado) y de densificación (pelletizado o briquetado) (Gobierno de Aragón-CIRCE, 1997; Gobierno de Aragón-IDAE, 1997).

Las aplicaciones térmicas han sido desde el principio de la humanidad el sistema más extendido para aprovechar energéticamente los residuos forestales (utilización de leñas). En la actualidad se han desarrollado un gran número de mejoras en el desarrollo de sistemas de combustión que permiten su utilización tanto a aplicaciones en el sector doméstico (de carácter individual, colectivo y centralizado) como en el sector industrial (aplicaciones en hornos, en secaderos y en calderas industriales (Gobierno de Aragón-IDAE, 1997).

La producción de electricidad mediante el uso de los residuos forestales y de biomasa en general se ha desarrollado durante los últimos años, siendo muy notables los esfuerzos en innovación tecnológica llevados a cabo. Los residuos forestales suplen la materia prima de dos tipos de plantas de producción de electricidad: centrales de biomasa y centrales de co-combustión (quema de los residuos conjuntamente con combustibles fósiles, lo que supone una disminución del uso de éstos), siendo estas últimas las que alcanzan una mayor potencia de generación eléctrica (Gobierno de Aragón-IDAE, 1997; Asikainen *et al.*, 2002).

La cogeneración -producción conjunta de energía térmica y eléctrica- se plantea cuando una empresa presenta consumos térmicos y eléctricos importantes, aunque no es una tecnología exclusiva de este sector, ya que aparece cada vez con mayor frecuencia en el sector residencial, comercial y de servicios. Esta tecnología presenta como gran ventaja la consecución de rendimientos globales superiores a los sistemas de producción de energía térmica o eléctrica por separado. Requiere de inversiones importantes y suele instalarse en empresas generadoras de residuos biomásicos en grandes proporciones (industrias de transformación de la madera, papeleras...) por lo que la contribución de los

residuos forestales en esta aplicación es escasa (Gobierno de Aragón-IDAIE, 1997; Serra y Royo, 2005).

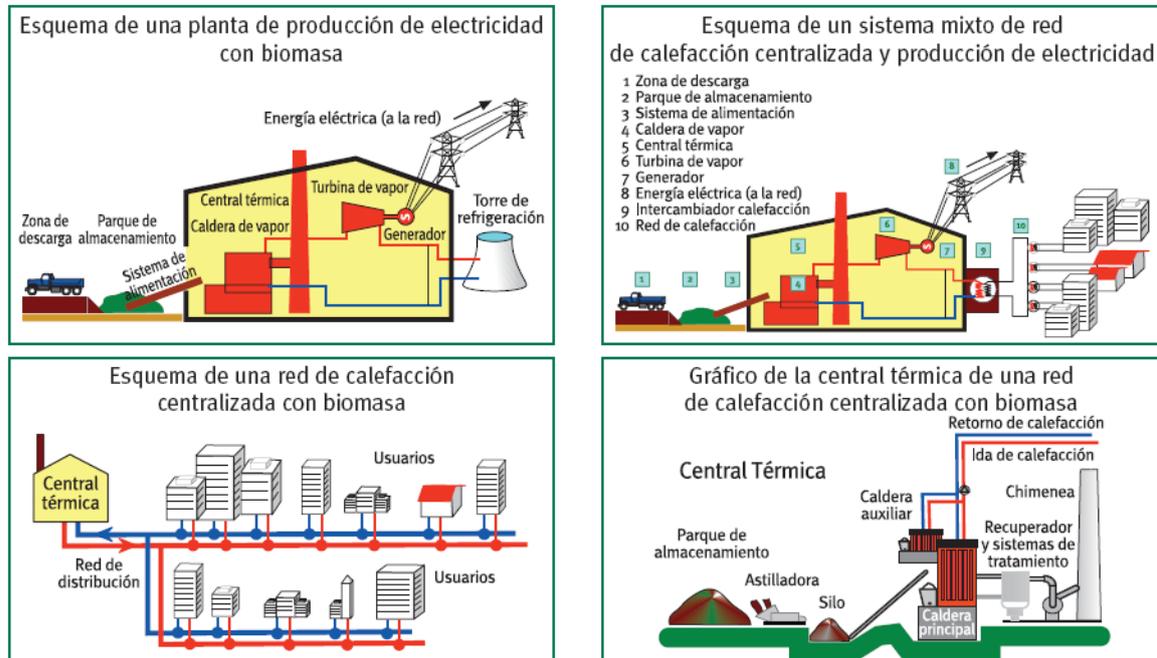


Figura 1.7. Esquemas de distintas instalaciones para el aprovechamiento energético de la biomasa residual forestal. Adaptado de IDAE (2007)

Los beneficios del aprovechamiento energético de los residuos forestales dentro de un esquema sostenible son múltiples, pudiendo clasificarse en dos grupos: medioambientales y socio-económicos.

- **Beneficios medioambientales:** los que, de forma directa, se producen tanto en la fase de producción-recolección del recurso como en su transformación energética.
 - o Fase producción-recolección: los aspectos más positivos son los de disminución del riesgo de incendios y de la severidad de éstos en caso de producirse, así como la mengua en la aparición de parásitos y plagas forestales, todo ello al recogerse un material que generalmente queda disperso por el monte, entrando en un proceso de lenta descomposición y secado, ocasionando además un impacto paisajístico visual negativo y problemas de movilidad para la fauna (IDAIE, 2005a; Velázquez, 2006). Además, la realización de los trabajos selvícolas conducentes a la obtención de residuos para su utilización

energética permite mejorar el estado de las masas forestales naturales y artificiales, permitiendo su regeneración, conservación y aumentando su productividad (Eriksson *et al.*, 2002; Raison, 2002).

- **Fase de aplicación:** el hecho más destacable es que la producción de CO₂, derivada de la combustión de biomasa, presenta un balance cuanto menos neutro, al emitirse a la atmósfera una cantidad de carbono equivalente o inferior a la fijada durante la formación del residuo forestal. Así pues, en un sistema forestal sostenible, el CO₂ emitido por la combustión de los residuos forestales es reciclado en forma de nueva biomasa conforme se produce el crecimiento de los árboles (Figura 1.8). Además, dada la composición de estos residuos, las emisiones de azufre y cloro son inapreciables (Domínguez, 2002; Eriksson *et al.*, 2002; Hakkila y Parikka, 2002; Richardson *et al.*, 2002; IDAE, 2005a; Sebastián y Royo, 2005). Por lo tanto, el uso de los residuos forestales para producir energía tiene un balance positivo en la lucha contra el calentamiento global y el cambio climático (Richardson *et al.*, 2002; Eriksson *et al.*, 2002).

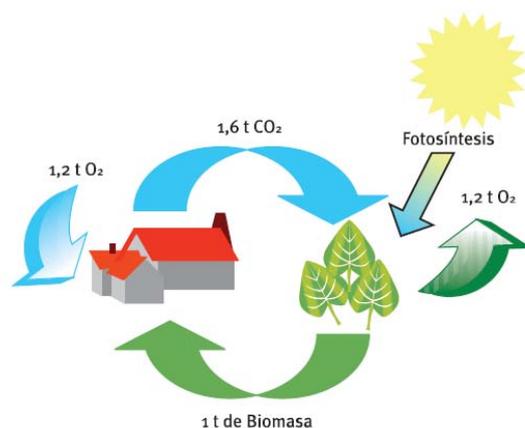


Figura 1.8. Ciclo del CO₂ en relación con el aprovechamiento energético de la biomasa forestal.
Adaptado de IDAE (2007)

- **Beneficios socio-económicos:** patentes tanto a escala local como regional.
 - **A escala local:** el aprovechamiento de los residuos forestales supone la valorización y el empleo de un subproducto que, en la mayoría de las ocasiones, no presenta valor de mercado alguno. Este uso de los residuos puede contribuir a un aumento de la renta agraria. La

aparición de empresas dedicadas a la generación, recolección, transporte y aprovechamiento de los residuos no sólo tiene incidencia en la generación de empleo, sino que puede suponer también un importante impulso a la mejora de infraestructuras y a una diversificación de la actividad económica del espacio rural, ayudando a fijar una población necesaria para el mantenimiento del medio natural (Gobierno de Aragón-CIRCE, 1997; Domínguez, 2002; Richardson *et al.*, 2002; Borsboom *et al.*, 2002; IDAE, 2005a).

- A escala nacional: Como ya se ha comentado, el aprovechamiento energético de los residuos forestales contribuye a reducir la dependencia energética del petróleo, lo que ayuda a equilibrar la balanza de pagos nacional. Además, es importante destacar que el ahorro de emisiones de CO₂ a la atmósfera debido al uso de la biomasa residual ayuda a cumplir los acuerdos internacionales suscritos por España en materia de emisiones contaminantes y lucha contra el cambio climático (Cumbre de Río de Janeiro, Protocolo de Kyoto, Cumbre de Montreal, etc.) (Domínguez, 2002; Eriksson *et al.*, 2002; IDAE, 2005a).

Así pues, tal y como concluyen Eriksson *et al.* (2002, pp. 15), “cuando los beneficios medioambientales y sociales de la utilización energética de los bosques son tenidos en cuenta, la utilización de la biomasa (residual) forestal para la producción de energía se hace medioambientalmente, económicamente y socialmente justificable”.

Sin embargo, a pesar de tales beneficios medioambientales y socio-económicos, el despegue de la actividad industrial en el campo de la biomasa en general y de la residual forestal en particular, no ha ido cumpliendo las expectativas y su progresión es más lenta que la de otras fuentes de energía renovables como la eólica (Domínguez *et al.*, 2003). Este hecho se puso también de manifiesto en el *Balance del Plan de Fomento de las Energías Renovables en España durante el periodo 1999-2004*, elaborado por el Instituto para la Diversificación y Ahorro de la Energía (IDAE), que apuntaba que el desarrollo del área de la biomasa, junto a otras como la minihidráulica y la solar, estaba muy por debajo del ritmo necesario para lograr los objetivos. Así, en el caso concreto de la biomasa residual forestal, el incremento de su uso hasta el año 2004 había sido solamente de 9.671 tep, un 2,15% respecto al objetivo de incremento marcado en el

PFER (IDAE, 2005a; Pascual *et al.*, 2006). Ante la necesidad de introducir cambios urgentes y sustanciales, al objeto de llegar a los objetivos fijados para 2010, se realizó el *Plan de Energía Renovables 2005-2010* (PER) que es una revisión del anterior PFER (IDAE, 2005a).

En el PER 2005-2010 se definen nuevos objetivos para el área de la biomasa, incrementándose el aporte de los residuos forestales hasta las 462.000 tep-año en 2010. A su vez, se identifican los problemas y barreras detectados durante la vigencia del primer plan que han impedido el crecimiento de esta energía renovable, distinguiéndose entre barreras en la *fase de producción* y en la *fase de transformación energética del recurso*. Dentro de las primeras, se destaca como uno de los principales inconvenientes el desconocimiento de la capacidad real de producción de biomasa residual de una masa forestal (IDAE, 2005a).

Este desconocimiento es un punto fundamental, ya que impide conocer la oferta constante de biomasa que asegure la producción en las centrales termoeléctricas que la pudieran utilizar (Domínguez *et al.*, 2003, IDAE, 2005b). Para superar esta importante barrera, además de la adopción de medidas generales como la creación de la *Comisión Interministerial para el aprovechamiento energético de la biomasa* creada en la Orden PRE/472/2004, de 24 de febrero, el PER 2005-2010 propone como medida concreta el desarrollo de la Disposición Adicional Cuarta de la Ley 43/2003, de 21 de noviembre, de Montes. Esta Disposición, titulada *Uso energético de la biomasa residual forestal*, dice textualmente: “El Gobierno elaborará, en colaboración con las comunidades autónomas, una estrategia para el desarrollo del uso energético de la biomasa residual forestal, de acuerdo con los objetivos indicados en el Plan de Fomento de las Energías Renovables en España”. Esta tarea, aunque sin asignación presupuestaria, queda encargada durante el periodo 2005-2010 a la Dirección General de la Biodiversidad del Ministerio de Medio Ambiente (IDAE, 2005a).

De esta manera, dicha Disposición otorga un papel importante a las comunidades autónomas, no especificando ninguna metodología para cuantificar con precisión la cantidad de biomasa residual forestal existente en un determinado territorio. En el caso de Aragón, la sexta comunidad autónoma en cuanto a los objetivos energéticos en biomasa residual forestal según el PER 2005-2010 (32.985 tep), la proposición no de Ley núm. 87/06 para la elaboración de un plan de aprovechamiento de la biomasa residual forestal, presentada en las Cortes de Aragón el 25 de abril de 2006, fue rechazada

(BOCA n.º 247-2006), por lo que, en estos momentos, no está estandarizada ninguna metodología que permita determinar la cantidad de este recurso energético.

Así pues, la determinación de una metodología que permita superar esta barrera es una cuestión esencial, ya que el primer paso para el crecimiento de esta fuente de energía debe ser el conocimiento de la cantidad de recursos potencialmente disponibles para ser usados (Esteban *et al.*, 2004; Pascual *et al.*, 2006; Velázquez, 2006). Esta metodología debe ser sencilla y extrapolable, tanto en el espacio como en el tiempo, para obtener así una fuente de información fácilmente actualizable.

A este respecto, diversos trabajos han demostrado la utilidad de las imágenes de satélite para estimar variables forestales (p.e. Jakubauskas, 1996; Gerylo *et al.*, 2002; Haapanen *et al.*, 2004). Las imágenes proporcionadas por la teledetección registran información de carácter completo y continuo de un territorio, siendo obtenidas en intervalos frecuentes. Estas características permiten superar algunas de las limitaciones que presentan los muestreos puntuales de los inventarios (Salvador y Pons, 1998a; Hyypä y Hyypä, 2001), si bien es ineludible el trabajo de campo (Howard, 1991; Roller y Bergen, 2000).

1.2. Objetivos e hipótesis

El **objetivo general** de la presente tesis doctoral es *desarrollar una metodología eficaz para estimar y localizar la biomasa residual forestal de los bosques de *Pinus sylvestris*, *P. halepensis*, *P. nigra* y *P. pinaster* de la provincia de Teruel mediante ajustes de regresión entre los valores obtenidos a partir de trabajo de campo e información forestal preexistente, por una parte, y los registros de las imágenes de satélite y de información auxiliar de carácter topográfico y forestal, por otra*. Este procedimiento permitirá inventariar los montes respecto de una variable hasta ahora no utilizada: los residuos energéticamente aprovechables que se obtendrían de la realización de los tratamientos selvícolas adecuados y de futuras explotaciones madereras en los pinares turolenses.

Se pretende, por tanto, desarrollar un modelo sencillo y aplicable a escala provincial y regional que proporcione una cartografía fiable y actualizable sobre los recursos de biomasa residual forestal existentes, eliminando de esta manera una de las principales barreras en la utilización energética de este recurso: su conocimiento preciso

en cantidad y localización. A su vez, *con el empleo de una metodología sencilla se pretende que el método desarrollado pueda ser adoptado por las distintas Administraciones como herramienta útil, tanto para la gestión forestal como para la planificación del territorio*, ya que la planificación energética tiene una alta incidencia en la ordenación territorial, circunstancia ésta que alcanza su máximo exponente cuando se trata de energías renovables, dada la estrecha relación que existe entre éstas y el territorio.

Este objetivo general se fundamenta en la **hipótesis** de que *es posible estimar de forma precisa la biomasa residual forestal mediante el uso de imágenes de teledetección y de trabajo de campo*. Esta hipótesis descansa en el hecho de que la estimación de variables forestales continuas, en general, y de biomasa, en particular, constituye una de las líneas de trabajo más prolíficas y fructíferas de la teledetección. *Aunque la biomasa no puede ser medida directamente mediante imágenes de satélite, la información de reflectividad proporcionada por éstas sí puede ser relacionada con la biomasa estimada a partir de trabajo de campo* (Dong *et al.*, 2003; Muukkonen y Heiskanen, 2005). Este mismo principio se puede aplicar a la biomasa residual forestal, ya que no deja de ser una fracción de la total considerada en muchos de los trabajos de estimación abortados en el ámbito de la teledetección. Además, *a priori*, esta fracción de la biomasa total -compuesta por follaje, ramaje y riberón- será más fácilmente relacionable con imágenes ópticas de satélite, ya que éstas registran fundamentalmente la parte superior del dosel vegetal. En cuanto a la utilización de imágenes radar, esta fracción de biomasa se presta a su estudio mediante imágenes de satélite de banda C, dado que hojas y ramas son los principales mecanismos retrodispersores en esta longitud de onda.

Subsidiario de aquel objetivo general, implícito en él, subyace el interés por *conseguir una metodología adaptada y operativa en medios mediterráneos*. El repaso a la literatura científica referente a la estimación de parámetros forestales continuos y de biomasa (véase apartado 1.3) muestra cómo la mayoría de experiencias se han llevado a cabo en bosques de ambientes boreales (p.e. Fazakas *et al.*, 1999; Kurvonen *et al.*, 1999; Mäkelä y Pekkarinen, 2001; Reese *et al.*, 2002; Kurvonen *et al.*, 2002; Muukkonen y Heiskanen, 2005; Rauste, 2005). Los bosques de estos ambientes están caracterizados por ser monoespecíficos, presentar una alta densidad y homogeneidad y por estar situados sobre topografías poco complejas, generalmente sobre llanuras o suaves relieves alomados. En estos ambientes, diferentes técnicas se han mostrado como óptimas en relación a los objetivos expresados. En cambio, un menor número de trabajos

se ha orientado a la estimación de estas mismas variables en medios más complejos como los tropicales y mediterráneos.

Centrándonos en los medios mediterráneos, las investigaciones desarrolladas han mostrado cómo las características de estos bosques -pluriespecíficos, de alta heterogeneidad espacial y escasa densidad forestal, localizados en zonas de topografía compleja, generalmente en áreas de montaña con acusadas pendientes- dificultan en gran manera la generación de modelos robustos que permitan estimar los parámetros forestales (p.e. Salvador y Pons, 1998a,b; Shoshany, 2000; Mallinis *et al.*, 2004; Vázquez de la Cueva, 2005; Maselli y Chiesi, 2006). En este contexto, el presente trabajo de investigación trata de implementar una serie de técnicas y métodos en el tratamiento de las variables que eviten algunas de las fuentes de error detectadas en esos trabajos como responsables del escaso poder funcional de los modelos desarrollados hasta ahora, sin olvidar que el resultado final debe ser una metodología aplicable a escala provincial o regional, sencilla y asumible por parte de los agentes de planificación forestal y ordenación del territorio.

*Desde el punto de vista temático, del objeto de estudio, cabe destacar la escasez de trabajos previos orientados a la estimación de la fracción de biomasa del árbol que en esta tesis se define como biomasa residual forestal. Así, sólo se han encontrado algunos ejemplos de utilización de imágenes radar como los trabajos de Beaudoin *et al.* (1994) y Austin *et al.* (2003), que analizan las relaciones de los coeficientes de retrodispersión de las bandas P y L, respectivamente, con los diferentes componentes del árbol; existiendo también ejemplos de utilización de imágenes LIDAR (p.e., Popescu, 2007) y de combinación de datos radar y ópticos, como el trabajo de Moghaddam *et al.* (2002), en el que se estima la biomasa del follaje en un bosque de coníferas. En cambio, no se ha encontrado investigación alguna relativa a la estimación de nuestra variable-objetivo mediante el uso exclusivo de imágenes ópticas. Por todo ello, resulta de gran interés - casi necesario- indagar las posibilidades de estimación de biomasa residual forestal mediante el uso de este último tipo de imágenes, no sólo por el interés que tiene el conocimiento de la distribución espacial de esta variable desde el punto de vista energético, sino también desde el punto de vista metodológico, dada la escasez de experiencias previas en medios mediterráneos.*

En cuanto al aspecto técnico-metodológico, el análisis estadístico de regresión, utilizado para relacionar los datos de biomasa residual forestal con la información

multiespectral de satélite y las variables auxiliares topográficas y forestales, responde en su elección, por un lado, a la pretensión de desarrollar un modelo sencillo y fácilmente asumible por las Administraciones responsables de la gestión y la planificación territorial y, por otro, a que ha sido ampliamente utilizado en los trabajos que tienen por objeto la estimación de parámetros forestales continuos mediante teledetección (p.e. Roy y Ravan, 1996; Salvador y Pons, 1998a,b; Steininger, 2000; Foody *et al.*, 2003; Mallinis *et al.*, 2004; Lu, 2005; Lu *et al.*, 2005). El método *k-NN*, que tan buenos resultados genera en medios boreales, es descartado en este trabajo debido a que no se ajusta a las condiciones de heterogeneidad y fragmentación de los bosques mediterráneos, características éstas que hacen que no se cumpla una de las premisas básicas para aplicarlo, la de uniformidad en el área incluida en la imagen de satélite (Mallinis *et al.*, 2004).

Para lograr el objetivo general planteado y *desarrollar una metodología eficaz para estimar y localizar la biomasa residual forestal de los bosques de Pinus sylvestris, P. halepensis, P. nigra y P. pinaster de la provincia de Teruel mediante ajustes de regresión entre los valores obtenidos a partir de trabajo de campo e información forestal preexistente, por una parte, y los registros de las imágenes de satélite y de información auxiliar de carácter topográfico y forestal, por otra*, es necesaria la consecución de una serie de **objetivos parciales-operativos**:

- I. *Conocimiento de la cantidad de biomasa residual forestal presente en determinados puntos en los bosques de pináceas de la provincia de Teruel.* Objetivo que refiere a la variable dependiente del modelo a desarrollar. Para ello, resulta imprescindible el trabajo de campo, con objeto de desarrollar ecuaciones alométricas específicas para cada especie de pino presente en el territorio, debiendo ser estas ecuaciones aplicables a las tablas de inventario existentes.
- II. *Obtención de variables radiométricas derivadas de imágenes de satélite que sean útiles para ser relacionadas con la información de biomasa residual forestal y que permitan el establecimiento de un modelo operativo sencillo y fácilmente actualizable a escala provincial o regional.* Este segundo objetivo parcial refiere a la necesidad de seleccionar las imágenes adecuadas para desarrollar el modelo planteado en las condiciones expresadas. Imágenes que deben ser objeto de una serie de pretratamientos y tratamientos para poder

ser utilizadas en el modelo. Se trata de conocer la dimensión espectral de la información sobre el área de estudio.

- III. *Obtención de variables auxiliares -topográficas y forestales- susceptibles de ser utilizadas en el modelo de estimación.* Al igual que el objetivo anterior, éste refiere a la preparación de una serie de variables útiles para ajustar el modelo de estimación de la biomasa residual forestal. En este caso, se trata de modelar la información topográfica de la zona de estudio (elevaciones, pendientes, etc.) y la de carácter forestal (nivel de madurez...), ya que estas variables presentan una dimensión informacional independiente de la espectral y, posiblemente, correlacionada con la biomasa, que puede matizar y mejorar el modelo de regresión.
- IV. *Determinación de un método idóneo para relacionar la información de biomasa residual con la espectral y de las variables auxiliares.* Como se ha señalado, la heterogeneidad espacial de los bosques mediterráneos es, *a priori*, una de las principales barreras que impiden el establecimiento de modelos estimativos de variables forestales mediante teledetección. Por ello, se pretende ensayar distintos procedimientos de extracción de la información radiométrica -que será relacionada con la de biomasa- identificando cuál de ellos logra reducir en mayor medida la heterogeneidad de la muestra y, por tanto, sirve para establecer ajustes más sólidos y robustos, tanto desde el punto de vista biofísico como estadístico.
- V. *Formulación del mejor modelo de regresión entre información de biomasa residual forestal e información espectral y auxiliar.* Núcleo central de la presente tesis doctoral, este objetivo parcial implica el estudio de la correlaciones de las variables de los objetivos I, II y III, considerando los distintos métodos de relación-extracción del objetivo IV, así como el cálculo de distintos tipos de modelos de regresión en función de esas relaciones (logística, lineal, curvilínea, etc.), considerando siempre las premisas que dirigen este trabajo.
- VI. *Verificación de la consistencia temporal de la metodología y de las relaciones biofísicas entre la biomasa residual forestal y las variables espectrales más útiles para su estimación.* Se trata, en definitiva, de replicar la metodología encontrada como más eficiente usando para ello otras imágenes de satélite de

características análogas. Este objetivo parcial permitirá concluir si la metodología empleada y las relaciones biofísicas existentes entre variables radiométricas y la cantidad de biomasa residual son independientes de la fecha de la imagen utilizada y si, por tanto, las estimaciones de biomasa son fácilmente actualizables.

VII. *Estimación de la biomasa residual forestal de la provincia de Teruel en la actualidad.* Mediante este último objetivo parcial se pretende ofrecer un inventario de este recurso energético utilizando para ello una imagen de satélite reciente; este inventario se realiza a tres escalas: provincial, comarcal y municipal. Asimismo, mediante análisis SIG, se pretende determinar qué zonas resultan más adecuadas para la extracción de biomasa residual forestal en función de la cantidad existente y de otros factores de índole espacial que condicionan o impiden su explotación desde el punto de vista técnico y económico.

La escala de trabajo elegida es 1:50.000, ya que es la adecuada para el análisis con las imágenes de satélite que se van a emplear (Landsat y Envisat-ASAR) y a la cual viene referida la información forestal que se utiliza en esta investigación para delimitar la superficie forestal de la provincia de Teruel y para obtener las variables forestales auxiliares que se van a utilizar.

1.3. La estimación de biomasa en el contexto de las aplicaciones forestales de la teledetección para la evaluación de parámetros forestales continuos e información biofísica

Tarea implícita en la concepción general y en los objetivos de la presente investigación es la revisión de la literatura científica en relación con la aplicación de la teledetección a la estimación de la biomasa, que se enmarca en el contexto de los parámetros forestales continuos y la información biofísica. El logro exitoso de los objetivos formulados exige dedicar a esta labor de revisión un importante esfuerzo, que se recoge en el presente apartado. Tras unas –breves- referencias básicas a la teledetección, se abordan sus aplicaciones forestales, profundizando posteriormente en

el ámbito de los inventarios forestales y, finalmente, en las principales experiencias existentes en relación con la estimación de biomasa.

1.3.1. Fundamentos de teledetección

La *teledetección* es la disciplina científica que obtiene información sobre un objeto, un área o un fenómeno a través del análisis de los datos adquiridos por un dispositivo que no está en contacto con ese objeto, área o fenómeno (Lillesand y Kiefer, 2000). En sentido estricto, el término *teledetección espacial* se reserva para el conjunto de técnicas que permiten adquirir e interpretar imágenes de la superficie terrestre obtenidas desde sensores transportados en satélites, empleando para ello la energía electromagnética como medio de detectar y medir las características y propiedades de los objetos. Aunque la fotografía aérea y los sensores aerotransportados quedan fuera de este término de teledetección espacial, éstos recursos son técnicas complementarias que en muchas ocasiones actúan como herramientas auxiliares de los sensores espaciales (Chuvieco, 2002).

Un sistema de teledetección espacial se compone de una fuente de energía, que es el origen de la radiación electromagnética que capta el sensor; la cubierta terrestre, que recibe la radiación electromagnética y la refleja o emite conforme sus características físicas; un sistema sensor, que capta esa energía procedente de los objetos y que se encuentra instalado en un satélite; un sistema de recepción-comercialización, que almacena los datos adquiridos por el sensor y, finalmente, un intérprete o usuario, que convierte esos datos en información (Chuvieco, 1996).

La teledetección (de aquí en adelante se emplea el término en su sentido más amplio, incluyendo tanto sensores satelitales como aerotransportados) es considerada como un instrumento de análisis geográfico, ya que considera el planeta Tierra como un sistema integrado del cual se obtienen imágenes que proporcionan una perspectiva sintética de la interacción de los fenómenos y variables que lo forman, considerando diferentes escalas de detalle. La utilización para ello de la energía electromagnética permite la indagación en el territorio desde una perspectiva no posible con la mera observación del ojo humano, aportando nuevas dimensiones de análisis (de la Riva, 1997). A este respecto, aunque el espectro electromagnético es un sistema continuo, la teledetección lo separa, a efectos prácticos, en una serie de regiones en la cuales la radiación electromagnética presenta un comportamiento similar. Su denominación y rango espectral más aceptados son los siguientes (Chuvieco, 1996): espectro visible (de

0,4 a 0,7 μm), infrarrojo próximo (de 0,7 a 1,3 μm), infrarrojo medio (de 1,3 a 8 μm), infrarrojo térmico (de 8 a 14 μm) y micro-ondas (a partir de 0,1 cm).

El criterio más empleado para la clasificación de los distintos sensores hace referencia al origen de la energía que captan. Así pues, existen dos tipos de sensores: activos y pasivos. Los sensores activos están caracterizados por emitir energía en la región de las micro-ondas, energía que es reflejada por la superficie terrestre y es posteriormente captada por el sensor. Los denominados sensores SAR (*Synthetic Aperture Radar*) y LIDAR (*Light Detection and Ranging*) son los que operan de esta forma. Los sensores pasivos son aquellos que solamente recogen la energía electromagnética procedente de la superficie terrestre, ya sea ésta reflejada del Sol o emitida en función de su temperatura.

Otro criterio complementario para clasificar los sensores es la resolución espacial de las imágenes que proporcionan: baja, media y alta. La resolución espacial hace referencia al tamaño de píxel de la imagen de satélite, que es la unidad mínima de información en la imagen (Chuvieco, 1996). Existen diversos umbrales para incluir un sensor en uno de los tres grupos de resolución espacial aludidos; en este trabajo emplearemos los umbrales utilizados por Lu (2006), por lo que serán considerados sensores de baja resolución aquellos cuyas imágenes están formadas por píxeles de más de 100 m, de media resolución aquellos entre 10-100 m y de alta resolución los que proporcionan imágenes con píxeles inferiores a 10 m. La superficie de observación real de los distintos sensores (área de terreno registrada) está en relación directa con el tamaño del píxel; así, los sensores de alta resolución espacial que proporcionan píxeles de menos de 10 m recogen información simultánea de áreas pequeñas, mientras que los sensores de baja resolución cubren en una sola imagen grandes extensiones de terreno¹.

Por otro lado, los sensores también se caracterizan por su resolución espectral, radiométrica y temporal. La resolución espectral hace referencia al número y anchura de las bandas de información espectral que recoge el sensor; cuantas más sean y más estrechas, más sencilla resultará la caracterización espectral de las cubiertas registradas.

¹ Así, por ejemplo, las imágenes proporcionadas por el satélite Ikonos, encuadrado dentro del grupo de los satélites con sensores de alta resolución espacial, tienen 1 m en la banda del pancromático y 4 m en las bandas multiespectrales, siendo la superficie de observación muy reducida (imágenes de 11 x 11 km). En cambio, Tiros-NOAA, que pertenece a la familia de satélites equipados con sensores de baja resolución espacial (1,1 km en el NADIR) registra información radiométrica de forma simultánea en grandes áreas (aproximadamente unos 3000 x 3000 km).

Por su parte, la resolución radiométrica alude a la sensibilidad del sensor para codificar la información espectral recibida en niveles digitales (ND); una vez más, a mayor resolución radiométrica, más fácil será la identificación de cubiertas y la caracterización de las variables a estudiar en la imagen. Finalmente, la resolución temporal refiere a la frecuencia con la cual el sensor proporciona imágenes de una misma zona; cuanto menor sea el periodo de revisita, más fácil será la observación de determinados fenómenos caracterizados por su rápida evolución temporal (Chuvieco, 2002).

Estos cuatro tipos de resolución que caracterizan a los sensores a bordo de las plataformas satelitales están íntimamente relacionados entre sí. El aumento de cualquiera de ellos implica un incremento notable del volumen de datos a almacenar, por lo que las imágenes obtenidas (archivos de estructura matricial en los que cada píxel aparece codificado con un ND en función de las características del sensor) son de un tamaño mayor, haciéndose más difícil su almacenamiento y su procesamiento.

Teniendo en cuenta las interrelaciones de los distintos tipos de resolución, el diseño de los sensores se hace teniendo en cuenta los fines para los cuales se va a emplear. Así, los satélites destinados a la observación meteorológica precisan de una alta resolución temporal, relegando a un papel menos importante la resolución espacial o espectral. Por el contrario, satélites destinados a la obtención de cartografía de alta precisión están diseñados de forma que las resoluciones espacial y espectral sean las más importantes, siendo menor la resolución temporal. Así pues, tal y como señala Chuvieco (1996, pp. 97), un solo sensor “no puede cubrir todas las expectativas”.

En este sentido, tiene que ser el usuario el que seleccione el tipo de sensor e imágenes a utilizar en función de sus objetivos y de las hipótesis del trabajo a realizar, partiendo de la premisa de que la teledetección es una herramienta adecuada para resolver el problema concreto que se plantea investigar (Lillesand y Kiefer, 2000).

1.3.2. Aplicaciones forestales de la teledetección

Las aplicaciones forestales de la teledetección son muy numerosas y contrastadas. Tras una revisión bibliográfica sobre el tema (Chuvieco, 1996; de la Riva, 1997; Roller y Bergen, 2000; Bergen *et al.*, 2000; Doblón, 2000; Lillesand y Kiefer, 2000; Franklin, 2001; Chuvieco, 2002), una clasificación genérica nos lleva a distinguir tres tipos: (i) aplicaciones para la generación de cartografía forestal (especies y unidades de manejo); (ii) aplicaciones para la observación y el seguimiento de las alteraciones-

afecciones del bosque; y (iii) aplicaciones de inventario forestal y de extracción de información biofísica.

La generación de cartografía de ocupación del suelo a partir del tratamiento digital de imágenes de satélite es una de las aplicaciones de la teledetección más prolífica, siendo en muchas ocasiones la fase culminante del tratamiento digital de las imágenes (Chuvienco, 2002). En este contexto se sitúa la obtención de cartografía forestal a partir de clasificación de los patrones de respuesta espectral de especies forestales y bosques. Mediante estas técnicas se obtiene información sobre las especies arbóreas presentes en un territorio y sobre su distribución-disposición en el mismo. La finalidad para la cual se crea esta cartografía forestal y la habilidad del usuario son los factores que controlan la exactitud y la utilidad del producto final (Franklin, 2001). Así, imágenes procedentes de distintos sensores han sido utilizadas con propósitos más o menos simples, como la obtención de una máscara forestal-no forestal (Haapanen *et al.*, 2004), o proyectos de gran complejidad, como la realización de una cartografía forestal a gran escala de Siberia (Wagner *et al.*, 2003).

En cuanto al segundo grupo de aplicaciones, la teledetección se ha mostrado como una herramienta útil para estudiar las variaciones del bosque, tanto las inducidas directamente por el hombre, como las catalogadas como naturales (aunque el factor humano puede estar también en el origen de estas alteraciones). Dentro del primer grupo estarían clasificadas actividades tales como la detección de zonas de deforestación y el seguimiento de explotaciones forestales (Turner *et al.*, 2001; Van Laake y Sánchez-Azofeifa, 2004; Cayuela *et al.*, 2006; Frohn y Hao, 2006; Phua *et al.*, 2007), así como el seguimiento y evaluación de zonas de reforestación y regeneración forestal (Yanasse *et al.*, 1997; Saatchi *et al.*, 1997; Lucas *et al.*, 2002; Zhang *et al.*, 2004). Algunas de las afecciones naturales de los bosques que se han estudiado mediante el uso de imágenes de teledetección son el estrés hídrico (Pierce *et al.*, 1990; Riggs y Running, 1991; Xiao, *et al.*, 2005), la defoliación (Radeloff *et al.*, 1999; Falkenström y Ekstrand, 2002; Heikkilä *et al.*, 2002) y los incendios forestales (Chuvienco, 1999). Dentro de estas aplicaciones, es quizás en el ámbito de los incendios forestales donde se ha desarrollado un mayor número de trabajos mediante el uso de técnicas teledetección. A este respecto, las imágenes de satélite se han mostrado útiles para la gestión y planeamiento de los espacios antes del fuego (Chuvienco *et al.*, 2002; Fiorucci *et al.*, 2005; Lasaponara *et al.*, 2006; Verbesselt *et al.*, 2006), para la detección de los incendios y su seguimiento (Pozo *et al.*, 1997; Roy *et al.*, 2002; Calle *et al.*, 2005), para la evaluación y gestión de los

espacios afectados por incendios forestales (Key y Benson, 2006; Pérez-Cabello *et al.*, 2006; De Santis y Chuvieco, 2007) y, finalmente, para la cuantificación de las emisiones atmosféricas causadas en estos incendios (Wooster *et al.*, 2003; Palacios-Orueta *et al.*, 2005; Palumbo *et al.*, 2006). En este sentido, los encuentros científicos organizados periódicamente por el Grupo de interés en incendios forestales de la EARSeL (*European Association of Remote Sensing Laboratories*), fundado en 1995, resultan de gran interés para el seguimiento de los avances surgidos en el seno de la teledetección para el estudio de los incendios forestales.

Por último, las aplicaciones de inventario forestal y de extracción de información biofísica son también una de las líneas más fructíferas de la teledetección en los últimos años (Roller y Bergen, 2000; Dobson, 2000; Franklin, 2001; Goetz, 2002; McRoberts y Tomppo, 2007; Tomppo *et al.*, 2008). Dado que la presente investigación se inserta dentro de este tercer tipo de aplicaciones, dedicamos el resto de este apartado 1.3 a la profundización en los diferentes trabajos que se han desarrollado en la literatura científica; un primer subapartado se dedica a las aplicaciones de inventario forestal en general, otro segundo, más específico, se centra en la estimación de la variable biofísica biomasa forestal.

1.3.3. Aplicaciones de inventario forestal y de extracción de información biofísica

1.3.3.1. Aplicaciones de inventario forestal

Los inventarios forestales, además de tratar de conocer los tipos de especies y bosques presentes en un territorio y la distribución de los mismos (cuestión ya abordada en la generación de cartografía forestal mediante teledetección), también centran su interés en el conocimiento de algunos parámetros forestales de tipo continuo. Franklin (2001) destaca 7 de estos parámetros forestales como de gran interés para caracterizar los atributos estructurales de un bosque, ya sean referidos a una masa forestal individualizada o discreta (con límites definidos) o a un territorio forestal o de arbolado continuo: (i) densidad de copas del bosque; (ii) diámetro del tallo a la altura del pecho (*dbh*); (iii) volumen; (iv) altura; (v) densidad del tallo; (vi) edad y (vii) estado de desarrollo.

Aunque las técnicas de clasificación digital de imágenes de satélite se han empleado para generar cartografías de algunas de estas variables, las aplicaciones de la teledetección para la estimación de estos parámetros se han centrado mayoritariamente en el desarrollo de modelos empíricos o semi-empíricos basados en las relaciones

estudiadas en los modelos físicos de transferencia radiativa en bosques. En este sentido, se han desarrollado gran cantidad de estudios que tienen por objeto estimar los parámetros forestales enumerados como variables dependientes que pueden ser estimadas o predichas mediante el uso de imágenes de satélite calibradas, aplicándose normalmente la siguiente metodología: (i) establecimiento de una serie de parcelas de muestreo en un área forestal y medición del parámetro forestal que se quiere estudiar; (ii) adquisición de las imágenes de satélite adecuadas para la estimación del parámetro que contienen esas parcelas; (iii) localización de las parcelas en la imagen; (iv) extracción de los datos radiométricos de las parcelas; (v) desarrollo de un modelo que relacione los datos de campo con la información radiométrica; (vi) utilización del modelo para estimar el parámetro forestal estudiado en el resto de píxeles forestales de la imagen a partir de su valor radiométrico (Franklin, 2001).

Así pues, el parámetro forestal estudiado y muestreado en la parcelas (por ejemplo, el *dbh* o la altura) constituye la variable dependiente y los datos espectrales obtenidos de la imagen en esas localizaciones se convierten en las variables independientes. Una vez ajustado el modelo de relación mediante la distintos procedimientos estadísticos, el modelo es invertido para conocer el valor de la variable dependiente en el resto de áreas forestales contenidas en la imagen, por cuanto se asume que los datos espectrales dependen y se relacionan de igual manera que en el modelo obtenido (Franklin, 2001).

Como se ha señalado con anterioridad, las imágenes proporcionadas por los sensores transportados a bordo de plataformas satelitales o de aviones registran información de carácter continuo y completo a lo largo de un territorio, siendo estas imágenes obtenidas en intervalos más o menos frecuentes. Estas características ayudan a superar algunos de los problemas asociados a las limitaciones de los inventarios puntuales tradicionales, como son el uso de extrapolaciones hechas a partir de parcelas que sólo representan una muestra discreta en una dimensión espacial continua que, a menudo, resultan poco consistentes, o la necesidad de emplear largos periodos de tiempo para la realización de estos inventarios en extensas áreas de terreno (Salvador y Pons, 1998a). Además, la teledetección puede reducir el gasto en la realización de inventarios forestales, ya que puede eliminar gran parte del trabajo de campo necesario, el cual consume la mayor parte del presupuesto asignado a dichos inventarios (Hyypä e Hyypä, 2001).

Las mejoras introducidas por la teledetección en la realización de inventarios forestales quedan perfectamente reflejadas en las palabras de McRoberts y Tomppo (2007, p. 413), quienes afirman que “los datos de teledetección no solamente han contribuido a incrementar la velocidad, la eficiencia de coste y la precisión de los inventarios, sino que también han facilitado la construcción de mapas de atributos forestales con resoluciones espaciales y exactitudes que no eran posibles unos años atrás”. Reflejo de esto es la utilización en Finlandia, desde 1990, de imágenes de satélite para generar cartografía forestal a escala nacional de forma operativa mediante la combinación de parcelas de campo y registros de estas imágenes (Tomppo *et al.*, 2008).

Existe una ingente producción científica sobre la estimación de parámetros forestales continuos mediante el uso de la teledetección. Una revisión bibliográfica sobre el tema nos muestra la gran variedad de sensores (aerotransportados y satelitales) utilizados para ello.

Dentro de los sensores pasivos, encontramos ejemplos en cada uno de los tres tipos definidos anteriormente en función de resolución espacial de las imágenes que proporcionan. Así, los trabajos de Zhang *et al.* (2004), Tottrup *et al.* (2007) y Muukkonen y Heiskanen (2007) ofrecen una visión de la utilización de imágenes de baja resolución espacial para estimar, respectivamente, la edad, el estado de desarrollo y el volumen de madera de bosques en grandes extensiones. Sin duda, la utilización de imágenes de resolución media como Landsat y Spot para derivar parámetros forestales a escala regional es la aplicación más abundante en la bibliografía, existiendo, sobre todo, numerosos trabajos centrados en la estimación de volumen de madera (Ardö, 1992; Gemmel, 1995; Trotter *et al.*, 1997; Fazakas *et al.*, 1999; Reese *et al.*, 2002; Mäkelä y Pekkarinen, 2001; Mäkelä y Pekkarinen, 2004; Magnusson y Fransson, 2005; Hall *et al.*, 2006). En cuanto a la utilización de imágenes de alta resolución espacial, existe un menor número de referencias; sirvan como ejemplo los trabajos realizados en el seno del Instituto de Investigación Forestal de Finlandia (Pekkarinen, 2002; Tuominen y Pekkarinen, 2005). Por último, dentro de este grupo de sensores pasivos cabe señalar también el uso de sensores hiperespectrales para estas aplicaciones, como en el trabajo de Jia *et al.* (2006), que emplean imágenes AVIRIS para estimar atributos forestales relacionados con incendios y, los trabajos llevados a cabo en el seno del CREAM, que experimentaron la utilidad del sensor aerotransportado CASI para tareas de inventario y cartografía forestal (Baulies y Pons, 1995; Salvador *et al.*, 1997).

El hecho de que los sensores activos radar sean sensibles al tamaño y a la estructura de la vegetación (Dobson, 2000; Lillesand y Kiefer, 2000) ha hecho que en los últimos años se haya multiplicado el uso de imágenes radar en la estimación de parámetros forestales continuos. A grandes rasgos, estos trabajos se basan en la relación existente entre el tamaño del pulso radar emitido por el sensor (longitud de onda) y el tamaño de los componentes de la planta, así como en la relación existente entre la densidad de cubierta vegetal y el coeficiente de retrodispersión obtenido. De esta forma, la banda C (con una longitud de onda entre de 3,75 y 7,5 cm), debido a su escasa capacidad de penetración en el dosel vegetal, ha sido principalmente utilizada para estimar cuestiones relativas a la estructura general de los bosques como, por ejemplo, la existencia de zonas de corta y de zonas quemadas (Kuntz y Siegert, 1999; Quegan *et al.*, 2000; Huang y Siegert, 2004). Por el contrario, las bandas L y P (longitud de onda entre 15-30 cm y entre 30-100 cm, respectivamente), dada su gran capacidad de penetración en el dosel vegetal, son sensibles a las principales estructuras leñosas de los árboles (ramas primarias de la corona arbórea y al tronco), por lo que se han empleado principalmente en trabajos enfocados a estimar volúmenes de madera (Fransson, 1999; Santoro *et al.*, 2003; Kellndorfer *et al.*, 2003; Tansey *et al.*, 2004; Santoro *et al.*, 2006). A este respecto, es conveniente destacar que las experiencias llevadas a cabo con la banda P han sido todas ellas desarrolladas mediante sensores aerotransportados, ya que no existen sensores con esta longitud de onda a bordo de plataformas satelitales. En iguales condiciones de adquisición, la banda P ha mostrado mayor sensibilidad para la estimación de volúmenes de madera que la banda L, siendo su grado de saturación algo más elevado (Israelsson *et al.*, 1994; Kellndorfer *et al.*, 2003), lo que indica el potencial de esta banda cuando sea incorporada a bordo de una plataforma satelital. Otros parámetros también estimados con imágenes procedentes de bandas L y P son la altura del árbol, edad, área basal y *dbh* (Dobson, 2000; Lu, 2006), aunque, como se verá más adelante, la estimación de la biomasa es sin duda el parámetro forestal más estudiado mediante el uso de imágenes radar.

Dentro del uso de los sensores radar a la estimación de variables forestales destacadas por Franklin (2001), son interesantes las aplicaciones que hacen uso de técnicas polarimétricas e interferométricas, denominadas en inglés *POLinSAR* (*Polarimetric and Interferometric SAR*). Un buen ejemplo de la aplicación de estas técnicas para estimación de parámetros forestales físicos a partir del uso de sensores aerotransportados es la tesis doctoral de Garestier (2006), en cuyo último capítulo se analizan las posibles limitaciones de los métodos utilizados en condiciones espaciales.

Las aplicaciones de inventario forestal mediante la utilización de LIDAR se han centrado sobre todo en obtener, por un lado, estimaciones de la altura y de la anchura de la corona de árboles individuales y, por otro, de altura media y densidad de los bosques, pudiendo ser posteriormente utilizadas estas medidas para estimar, mediante ecuaciones alométricas, el volumen y la biomasa de cada individuo y de los bosques en general (McRoberts y Tomppo, 2007). Algunos ejemplos de la utilización de LIDAR para la estimación de la altura de los árboles son los trabajos de Nilsson (1996), Næsset (1997), Koukoulas y Blackburn (2005) y Balzter *et al.* (2007a), mientras que para la estimación y análisis del diámetro de la corona pueden citarse los trabajos de Persson *et al.* (2002), Popescu *et al.* (2003) y Brandtberg *et al.* (2003). A partir de estas propiedades se han llevado a cabo trabajos más complejos tendentes a determinar la estructura de áreas boscosas (Hyde *et al.*, 2005; Hill y Thomson, 2005; Goodwin *et al.*, 2006) e incluso algún tipo de clasificación (Dubayah y Drake, 2000; Donoghuea *et al.*, 2007; Mutlu *et al.*, 2008).

El alto volumen de trabajos citados da idea de la complejidad que existe en la estimación de estos parámetros forestales mediante técnicas de teledetección, ya que para estimar una misma variable (por ejemplo, volumen de madera) se han citado distintos trabajos que lo abordan con diferentes sensores y técnicas, resultando una estimación con más o menos éxito, pero quedando siempre una parte de la varianza de la variable sin explicar. Estos problemas se comentarán más adelante junto a los relativos a la estimación de la variable biomasa que, junto el LAI^2 (*Leaf Area Index*), es una de las más importantes variables biofísicas estimadas mediante teledetección.

1.3.3.2. Estimación de biomasa en ámbitos forestales

Las variables biofísicas biomasa y *LAI* son dos parámetros forestales de primer orden de importancia. Su separación del resto de parámetros hasta ahora analizados se debe a dos motivos: en primer lugar, que estas variables -aunque trascendentes- no suelen estar contempladas en la realización de inventarios forestales, por lo que no se muestrean directamente en la fase de trabajo de campo; en segundo lugar, que, al contrario que otros parámetros como *dbh* o volumen de madera, no son dos variables exclusivas de los bosques, sino que son también variables críticas en el estudio de zonas

² El índice de área foliar (*LAI*), definido como la ratio entre la superficie foliar verde –por una sola cara– total de la planta y la superficie del suelo que ocupa, caracteriza el crecimiento fenológico, la estructura de la planta y la respuesta al estrés hídrico, proporcionando además información crítica para entender los balances globales del carbono, el agua y energía (Allen *et al.*, 1998; Gower *et al.*, 1999; Running *et al.*, 1999; Kergoat *et al.*, 2002; Chen *et al.*, 2006).

de matorral, pastizales y praderas. Dado que la metodología de trabajo seguida en teledetección para la estimación de estas dos variables biofísicas es análoga en muchos casos a la empleada en la estimación de los parámetros forestales de inventario comentados y que el presente trabajo se orienta hacia la estimación de biomasa residual forestal, nos centraremos a partir de ahora en sintetizar las distintas aproximaciones que se han hecho para estimación de biomasa en ámbitos forestales, comentando las distintas técnicas utilizadas y problemas detectados.

1.3.3.2.1. Importancia del conocimiento de la biomasa forestal y su estudio mediante teledetección

El interés suscitado en los últimos años por el estudio de la biomasa viene dado por su importancia para entender y modelizar el cambio climático, el cual ha sido identificado como el mayor problema medioambiental del presente siglo. Una de las mayores incógnitas que existen para entender el futuro devenir del clima y de sus consecuencias es la cuantificación de los *inputs* (emisiones de CO₂) y los *outputs* (sumideros de CO₂) del ciclo de carbono (C), cuestión señalada como uno de los elementos principales en el Protocolo de Kyoto (Le Toan, 2002).

En este sentido, aunque gran parte de las emisiones de CO₂ provienen del uso de combustibles fósiles, también son muy importantes las cantidades de este gas liberadas a la atmósfera durante los incendios forestales (Palacios-Orueta *et al.*, 2005; Lu, 2006). Para estimar las emisiones de gases de efecto invernadero debidas a los incendios forestales se han desarrollado varios métodos, algunos de ellos a partir de la utilización de datos proporcionados por teledetección (Palacios-Orueta *et al.*, 2005). Estos métodos requieren de estimaciones sobre la biomasa que se ha quemado y de factores de emisión para cuantificar la cantidad de gases liberados durante el incendio (Palumbo *et al.*, 2006). Una de las mayores incertidumbres para mejorar estos modelos de emisiones es la falta de información sobre la biomasa quemada (carga de combustible) debido a su alta variabilidad espacio temporal (Palumbo *et al.*, 2006; Chuvieco *et al.*, 2006).

Como resulta obvio, si los incendios forestales son uno de los más importantes emisores de carbono a la atmósfera es por el importante papel que los bosques tienen como sumideros de carbono terrestre (Díaz y Romero, 2004; ASEMFO, 2004; Montero *et al.*, 2005; Muukkonen y Heiskanen, 2005; Muukkonen y Heiskanen, 2007). Tal y como se ha explicado anteriormente, la biomasa es el resultado de la acción fotosintética de la vegetación en la cual el CO₂ presente en el aire es transformado en moléculas orgánicas.

Este secuestro de CO₂ es máximo en la biomasa forestal, aunque también se produce en otras partes del sistema bosque. Así pues, la biomasa forestal representa la cantidad potencial de C que puede ser liberada a la atmósfera debida a la deforestación o la conservada en la superficie terrestre cuando los bosques son correctamente gestionados (Brown *et al.*, 1999; Lu y Batistiella, 2005).

Este papel relevante de los bosques en el ciclo de C fue destacado en las conclusiones del Protocolo de Kyoto (Brown *et al.*, 1999). Por ello resulta fundamental conocer la cantidad y la distribución de la biomasa forestal, cuestión que ha sido identificada como una de las mayores incertidumbres en lo concerniente a los presupuestos globales de C (Hall *et al.*, 2006).

Por otra parte, el conocimiento de la biomasa forestal es también importante por su utilidad como indicador estructural y funcional de los atributos de los ecosistemas forestales, para la definición de diferentes hábitats terrestres, para el estudio de la productividad del ecosistema, para la localización de nutrientes, para el conocimiento de las zonas de acumulación de combustible y para el planeamiento y la gestión de operaciones forestales con propósitos comerciales, todo ello a lo largo de un amplio rango de condiciones medioambientales (Labrecque *et al.*, 2003; Zheng *et al.*, 2004; Lu, 2005; Hall *et al.*, 2006).

Las imágenes de teledetección constituyen una fuente primaria de información para la estimación de biomasa (Lu, 2006). De acuerdo con la *Guía de Buenas Prácticas del Panel Intergubernamental para el Cambio Climático* (cuyas siglas en inglés son IPCC-GPG), las técnicas de teledetección son especialmente útiles para verificar las cartografías y estadísticas de usos del suelo, las de cambios de usos del suelo y las estimaciones de reserva de C en los bosques, haciendo especialmente referencia este último apartado a las estimaciones de biomasa total aérea (Muukkonen y Heiskanen, 2005; 2007), que en la bibliografía anglosajona aparece referida como *aboveground biomass* (AGB).

Como en el caso de la estimación de parámetros forestales continuos, existe en la literatura científica un gran número de aproximaciones que han intentado estimar la biomasa total aérea³ (a partir de ahora denominada simplemente *biomasa*) mediante la

³ Como se ha indicado en el primer apartado 1.1, el tocón y las raíces de un árbol son muy costosos de extraer. Esta razón, junto con la escasez de ecuaciones alométricas que permitan

utilización de técnicas de teledetección, utilizando para ello tanto imágenes ópticas como radar. A este respecto, es importante resaltar que la biomasa no puede ser medida directamente mediante imágenes de satélite, pero la información de reflectividad⁴ proporcionada por éstas sí que puede ser relacionada con la biomasa estimada a partir de trabajo de campo (Dong *et al.*, 2003; Muukkonen y Heiskanen, 2005).

Además de la utilización de imágenes de satélite, otros dos métodos han sido también empleados para estimar y cartografiar biomasa (Lu, 2006): (i) la utilización de mediciones en el campo y (ii) la utilización de Sistemas de Información Geográfica (SIG). El primero de estos dos métodos es el más preciso, siendo requisito imprescindible contar con un gran número de parcelas muestreadas en el campo que sirvan tanto para desarrollar el modelo de estimación como para validarlo. Los problemas de esta técnica aparecen a la hora de obtener información sobre la distribución de la biomasa en grandes áreas, ya que es muy costoso en tiempo y dinero y es difícil de llevar a cabo en zonas con problemas de accesibilidad. Como resultado se obtienen cartografías muy costosas de actualizar y que presentan un grado de incertidumbre elevado en determinados espacios. Por su parte, los métodos que se basan en la utilización de los SIG necesitan, además del trabajo de campo para obtener los datos de biomasa, un alto volumen de capas de información auxiliar como, por ejemplo, cartografía forestal con información sobre especies, estado de desarrollo o nivel de madurez, estructura, cartografía de suelos, elevaciones, pendientes, etc., siendo la calidad y adecuación de estas capas requisito fundamental para la exactitud de los resultados de la estimación de biomasa. Es de destacar que las relaciones entre la variable biomasa y estas capas de información auxiliar no es directa (son capas de información sobre diferentes variables relacionadas con la superficie forestal, no con la cantidad de biomasa), siendo difícil completar con esta información auxiliar todas las variables y escenarios que condicionan la mayor o menor cantidad de biomasa.

estimar la biomasa subterránea o la biomasa total de forma precisa (Keith *et al.*, 2000), hace que la inmensa mayoría de trabajos en teledetección consideren solamente la biomasa total aérea (AGB), que es más fácilmente estimable en las parcelas de muestreo, ya sea mediante el uso de ecuaciones alométricas específicas (mucho más extendidas en la bibliografía que las de biomasa subterránea) o mediante trabajo de campo de carácter destructivo. Una alternativa que suple la escasez de ecuaciones alométricas para estimar la biomasa subterránea es el establecer relaciones entre ésta y la biomasa total aérea (Brown *et al.*, 1999; Keith *et al.*, 2000).

⁴ Entendida como la relación entre el flujo incidente y el reflejado por una superficie (Chuvieco, 1996). La reflectividad varía entre 0 (superficie perfectamente absorbente) y 1 (superficie totalmente reflectora). La reflectividad de un determinado tipo de cubierta depende de sus características físicas y químicas y de las condiciones de observación, siendo distinta en las distintas bandas del espectro electromagnético (reflectividad espectral).

Frente a estos dos métodos, las propiedades ya comentadas de las imágenes de satélite proporcionan una serie de ventajas que convierten a la teledetección en una herramienta óptima para la estimación de biomasa, sobre todo si se consideran grandes áreas de estudio y zonas de difícil acceso. Así, la información de carácter continuo y completo a lo largo de un territorio, la periodicidad de esta información, el carácter digital de la misma y las correlaciones existentes entre las bandas espectrales con los parámetros de la vegetación convierten a las imágenes de teledetección en una fuente primaria de información para la estimación de la biomasa en grandes áreas, superando las restricciones planteadas utilizando solamente trabajo de campo o SIG (Lu, 2006).

Sin embargo, ninguna de las aproximaciones desarrolladas en el seno de la teledetección ha logrado presentar una técnica consistente y enteramente reproducible y aplicable a escala regional o continental (Muukkonen y Heiskanen, 2005). Los principales problemas en la estimación de biomasa mediante teledetección aparecen a la hora de estudiar bosques caracterizados por la presencia de múltiples especies y diferentes rangos de edad (Brown *et al.*, 1999), así como bosques de estructura compleja, como son los bosques tropicales y los mediterráneos (Foody *et al.*, 2001; Mallinis *et al.*, 2004). En consecuencia, abundan en la bibliografía trabajos desarrollados a varias escalas de trabajo y en diferentes ecosistemas que intentan ofrecer una metodología adecuada para estimar la biomasa en su correspondiente área de estudio, solventando los distintos problemas encontrados mediante el concurso de diferentes sensores y técnicas estadísticas.

1.3.3.2. Utilización de los sensores pasivos para la estimación de biomasa - Utilización de sensores de baja resolución espacial

Los sensores pasivos de baja resolución se han empleado para la estimación de biomasa a escala nacional, continental y global, siendo AVHRR, SPOT VEGETATION y MODIS los más utilizados. Los problemas detectados en la estimación de biomasa mediante el uso de estos sensores son debidos precisamente al gran tamaño de los píxeles de las imágenes que proporcionan (1,1 km en el caso de AVHRR, entre 250 m y 1km en MODIS y 1 km en SPOT VEGETACION), ya que, generalmente, existe una enorme diferencia entre el tamaño de las parcelas muestreadas en el campo y el de los píxeles, con lo que resulta difícil la integración de los datos de campo con los de las variables espectrales derivadas de la imagen; además, un gran número de estos píxeles representan situaciones de mezcla de distintos tipos de cubiertas. Una solución a este problema es la utilización de sensores de resolución media como un paso intermedio

entre los datos de campo y los datos radiométricos de los sensores de baja resolución (Lu, 2006).

Ejemplos de esta forma de proceder son los trabajos de Häme *et al.* (1997), Tomppo *et al.* (2002) y Zheng *et al.*, (2007), en los que las relaciones empíricas establecidas previamente entre las parcelas de campo e imágenes Landsat son utilizadas con posterioridad sobre imágenes AVHRR, IRS-1C WiFS y MODIS, respectivamente, para estimar la biomasa presente en amplias regiones de norte de Europa, en el caso de los dos primeros, y en Estados Unidos, en el último. Por su parte, Muukkonen y Heiskanen (2007) relacionan datos del IFN de Finlandia con datos de MODIS, utilizando el sensor ASTER, de mayor resolución espacial que Landsat, para garantizar la consistencia de las relaciones entre biomasa y reflectividad. Una aproximación diferente es el trabajo de Anaya *et al.*, (2008, 2009), donde las relaciones entre las parcelas con estimaciones de biomasa y los compuestos de MODIS se establecen directamente, usándose imágenes de resolución media (Landsat) para constatar que la vegetación de la parcela correspondía a un píxel puro de MODIS, dada la diferencia de tamaño entre ambas fuentes (entre 0,01 y 0,1 ha las parcelas de campo y 25 ha los píxeles de MODIS).

- Utilización de sensores de resolución espacial media

En la bibliografía referida a la estimación de biomasa a escalas regional y local, al igual que en las aplicaciones de la teledetección en tareas de inventario forestal, la utilización de imágenes ópticas con resolución media aparece ampliamente representada, siendo Landsat el satélite más utilizado (Roy y Ravan, 1996; Todd *et al.*, 1998; Fazakas *et al.*, 1999; Steininger, 2000; Foody *et al.*, 2001; Mickler *et al.*, 2002; Reese *et al.*, 2002; Foody *et al.*, 2003; Labrecque *et al.*, 2003; Phua y Saito, 2003; Calvao y Palmeirin, 2004; Mallinis *et al.*, 2004; Lu *et al.*, 2004; Zheng *et al.*, 2004; Lu, 2005; Lu y Batistiella, 2005; Hall *et al.*, 2006; Labrecque *et al.*, 2006). La frecuente utilización de este sensor para la estimación de biomasa a estas escalas responde a la utilidad de sus imágenes para cartografiar y hacer un seguimiento controlado de las condiciones biofísicas forestales de una manera consistente y replicable (Jakubauskas, 1996). Su resolución espacial (30 m en las bandas reflectivas), su resolución espectral (3 bandas en la región del visible, una en el infrarrojo cercano y 2 en el infrarrojo medio), el carácter global y periódico de su cobertura a lo largo de las últimas décadas y su buena comercialización son los factores que explican su frecuente uso por parte de científicos procedentes de diversas áreas de conocimiento (Chuvienco, 2002). Los métodos estadísticos empleados para estimar biomasa usando imágenes TM o ETM+ son principalmente modelos de regresión lineales

y no lineales, modelos de redes neuronales y modelos de interpolación del vecino más próximo, alcanzándose diferentes grados de éxito en el cumplimiento de los objetivos enunciados. A este respecto, los principales problemas para lograr una buena estimación aparecen cuando los bosques estudiados presentan una estructura compleja (Lu, 2006).

Dado que esta tesis está referida a una escala regional, parece conveniente ahondar un poco más en los trabajos llevados a cabo a esta escala, tanto los relativos a la estimación de biomasa, como los referentes a la estimación de parámetros forestales de inventario y de la variable biofísica *LAI*. Como hemos indicado, la mayoría de estos trabajos se basan en la utilización de imágenes Landsat. Se pretende con ello un conocimiento exhaustivo de los diferentes condicionantes y de las técnicas aplicadas para ser tenidos en cuenta, más tarde, a la hora de plantear la metodología de trabajo de la presente investigación.

Un análisis detallado sobre la bibliografía existente nos muestra cómo cuando los ámbitos de aplicación corresponden a bosques boreales densos, homogéneos y de topografía poco compleja, los resultados son más directos y precisos que cuando se trabaja en entornos tropicales y mediterráneos, si bien es cierto que, tal y como indican Hyyppä y Hyyppä (2001, p. 2613), "...la comparación de resultados de estudios previos es extremadamente difícil debido a las diferencias existentes entre las áreas de estudio y las características estudiadas del área forestal, los procedimientos de validación, los parámetros usados como criterio de evaluación (R^2 , error estándar), la selección de las parcelas incluidas en el estudio y el número de predictores usados en el modelo".

Un hecho que refleja la utilidad de las imágenes Landsat para la estimación de los parámetros forestales en **medios boreales** es la incorporación de este tipo de imágenes en la elaboración del Inventario Forestal Nacional (IFN) de Finlandia desde la década de los 90 (Fazakas *et al.*, 1999; Mäkelä y Pekkarinen, 2001; Pekkarinen, 2002; Haapanen *et al.*, 2004; McRoberts y Tomppo, 2007; Tomppo *et al.*, 2008). Este inventario forestal combina datos de campo obtenidos en parcelas de muestreo, información radiométrica procedente de imágenes Landsat e información auxiliar por medio de métodos estadísticos no paramétricos, siguiendo un esquema metodológico empírico: la información forestal de las parcelas de muestreo localizadas en la imagen de satélite es generalizada a todo el área comprendida, utilizando para ello las propiedades espectrales de esas parcelas proporcionadas por la imagen y el resto de píxeles que la componen (Mäkelä y Pekkarinen, 2001). El método estadístico no paramétrico utilizado es el *k-NN*

(*k-Nearest neighbour*). En este método, el valor del parámetro forestal estimado para cada píxel de la imagen es calculado como un valor medio de los parámetros observados en las parcelas de referencia en las que sí que existen datos de campo, utilizando para ello un criterio de similitud. Esta similitud es definida en términos de distancia espectral (por ejemplo, distancia euclidiana) pudiéndose variar el número de parcelas tomadas como referencia (Fazakas *et al.*, 1999; Reese *et al.*, 2002; Haapanen *et al.*, 2004).

Este tipo de inventario basado en la utilización de imágenes de satélite se ha mostrado útil para la estimación de atributos forestales de áreas de medio y de gran tamaño (escala municipal, regional o nacional), pero la precisión alcanzada a nivel de parcela y de cuartel forestal no es la adecuada para la gestión forestal (Mäkelä y Pekkarinen, 2001; Pekkarinen, 2002; Tuominen y Pekkarinen, 2005). Un buen ejemplo de cómo aumenta la precisión de este método a medida que el área de inventario considerada es mayor es el trabajo de Fazakas *et al.* (1999). En este trabajo se utiliza el error cuadrático medio (RMSE) para evaluar las diferencias en 6 áreas forestales de diferente tamaño (7,39, 11,9, 16,4, 34,6, 73,1 y 510 ha) entre los valores reales de volumen de madera y de biomasa proporcionados por el inventario y los estimados a partir de la utilización de una imagen Landsat y del método *k-NN*. El resultado es que, mientras que en el primer nivel de agregación el RMSE es superior a 70% para ambas variables, en el nivel de agregación de 510 ha es solamente de 8,7% para la biomasa y de 4,6% para el volumen de madera. En la conclusión, el autor considera como aceptable el RMSE que se obtiene a partir del nivel de agregación de 100 ha de terreno real (inferior al 10%). Aunque para algunas cuestiones medioambientales y de gestión forestal el conocimiento de las variables forestales a este nivel de precisión es más que suficiente (Reese *et al.*, 2002), diferentes métodos han sido evaluados en estos ambientes para mejorar la precisión a nivel de parcela y cuartel forestal, entre los que destacan el uso de técnicas de segmentación sobre imágenes Landsat (Mäkelä y Pekkarinen, 2001; Hall *et al.*, 2006), la utilización de datos de campo referidos a unidades de muestreo más grandes que las parcelas de inventario tradicionales (Mäkelä y Pekkarinen, 2004) o el empleo de imágenes de mayor resolución espacial (Pekkarinen, 2002; Muukkonen y Heiskanen, 2005; Tuominen y Pekkarinen, 2005), obteniéndose distintos grados de éxito.

En **medios forestales tropicales** el principal problema que se presenta a la hora de estimar parámetros continuos mediante teledetección es su elevada heterogeneidad, fruto de la estructura compleja y de la gran riqueza de especies que caracteriza estos bosques húmedos (Lu, 2005; Lu y Batistiella, 2005; Lu *et al.*, 2005). Debido a esta

compleja estructura forestal aparecen determinados problemas que inciden notablemente en la bondad de la estimación de biomasa hecha mediante imágenes de satélite, como son, por ejemplo, (i) el impacto de las sombras de la propia cubierta en la signatura espectral; (ii) la aparición de cuarteles con idénticas cantidades de biomasa pero con estructura muy diferente (un cuartel compuesto por varios ejemplares de una especie de gran altura puede tener la misma cantidad de biomasa que otro compuesto por un ejemplar de gran altura de esa especie y varios de otra especie con un porte mucho menor); y (iii) la existencia de una gran cantidad de vegetación, lo que puede llevar a situaciones de saturación en la respuesta espectral del sensor (Foody *et al.*, 2001; Lu *et al.*, 2004; Lu, 2006). Estas características propias de entornos tropicales convierten en inapropiados algunos de los métodos usados en otros ambientes (Foody *et al.*, 2001). Además, estas peculiaridades aumentan la ya de por sí difícil tarea de elaborar modelos de estimación de biomasa fácilmente transferibles entre regiones (Foody *et al.*, 2003).

Un excelente trabajo que muestra la dificultad de estimar biomasa debido a la complejidad estructural de estos bosques es el trabajo desarrollado en la cuenca del río Amazonas por Lu *et al.* (2004). En esta investigación, las relaciones entre parámetros forestales e información espectral obtenida con Landsat son analizadas en tres áreas de estudio relativamente próximas entre sí, demostrándose que, en ocasiones, los cambios en la reflectividad de la vegetación están directamente relacionados con la estructura forestal en vez de con cambios en la cantidad de biomasa. Una solución para mejorar la capacidad de predicción de la variable biomasa en estos ambientes es la utilización conjunta de información espectral y de textura proporcionada por imágenes Landsat, siendo obtenida esta última variable a partir de la aplicación de diferentes filtros de textura (media, varianza, homogeneidad, contraste, entropía, kurtosis, etc.) sobre cada una de las bandas que componen la imagen, utilizando para ello ventanas móviles (*kernels*) de diferentes tamaños (Lu, 2005; Lu y Batistiella, 2005). Los principales problemas de este método son el tener que identificar qué informaciones de textura están más correlacionadas con la biomasa y poco correlacionadas entre sí, qué tamaño de *kernel* utilizar para calcularlas y sobre qué bandas aplicar estos *kernel*; tareas todas ellas que consumen un gran tiempo, ya que no existe un criterio específico a seguir y es dependiente de las características intrínsecas del área de estudio (Lu, 2006). Por último, indicar que la regresión es el método estadístico más utilizado para estimar biomasa en bosques tropicales mediante imágenes Landsat (Roy y Ravan, 1996; Steininger, 2000; Foody *et al.*, 2003; Lu, 2005; Lu *et al.*, 2005), aunque también se ha probado el uso de redes neuronales (Foody *et al.*, 2001; Foody *et al.*, 2003).

Las experiencias llevadas a cabo para la estimación de parámetros forestales mediante imágenes Landsat en **medios mediterráneos** (en los cuales se incluye el área de estudio de esta tesis) son más bien escasas. Las regiones mediterráneas están caracterizadas por presentar unos patrones vegetales que presentan una alta heterogeneidad espacio-temporal. Esta heterogeneidad es debida a la existencia de grandes zonas de transición vegetal que están compuestas por la mezcla de especies en los diferentes estratos y que son resultado de la respuesta vegetal, más o menos evolucionada, ante los numerosos y continuados impactos y alteraciones sufridos con anterioridad, tanto de origen antrópico como natural, siendo difícil alcanzar la vegetación “clímax” y dando lugar a paisajes altamente fragmentados. Esta característica definitoria de las áreas mediterráneas tiene su reflejo en las diferentes aproximaciones hechas en el seno de la teledetección para el estudio de los bosques mediterráneos, identificándose una serie de limitaciones en su uso para la evaluación de los principales variables forestales continuas, incluida la biomasa (Shoshany, 2000). Además de esta diversidad de las áreas forestales mediterráneas en cuanto a composición de especies y estados de desarrollo, también hay que tener en cuenta otros factores como son la complejidad del relieve que generalmente presentan (Mallinis *et al.*, 2004).

Restringiéndonos a ámbitos mediterráneos europeos, los trabajos de Salvador y Pons (1998a,b), aunque no estudian directamente la variable biomasa forestal, constituyen una de las primeras referencias en la utilización de imágenes Landsat para la estimación de parámetros de inventario forestal. En concreto, los dos trabajos señalados intentan desarrollar modelos predictivos para las variables cobertura del dosel vegetal, área basimétrica, volumen del tallo y *LAI*, todas ellas obtenidas a partir de datos proporcionados por el Inventario Ecológico Forestal de Cataluña (IEFC) en zonas de bosque dominadas por *Pinus sylvestris*, *P. nigra* y *Quercus ilex* situadas en áreas montañosas. El método estadístico que se utilizó para relacionar los datos de campo de estas variables con los de reflectividad proporcionados por Landsat fue la regresión, tanto simple como múltiple. Los resultados obtenidos indican que, aunque las relaciones encontradas entre los parámetros y los valores radiométricos son significativas, no se puede llegar a establecer un modelo de estimación robusto y operacional, señalándose la alta heterogeneidad espacial de los bosques estudiados como una de las principales causas. En el trabajo de Mallinis *et al.* (2004) sí que se consideró la variable biomasa como uno de los parámetros forestales a estimar mediante el uso de una imagen Landsat en una zona de paisaje mediterráneo. En concreto, el área de estudio de este trabajo se localizó al norte de Grecia, estando las áreas forestales de esta zona compuestas por

Pinus sylvestris con un rico sotobosque compuesto por varias especies de arbustos. Para elaborar este trabajo se utilizaron 34 parcelas de campo que representaban toda la posible variabilidad de las condiciones forestales del área de estudio. La biomasa de estas parcelas fue calculada mediante ecuaciones de regresión obtenidas a partir del muestreo efectuado sobre 30 ejemplares de cada especie presente. Para incrementar la información espectral proporcionada por Landsat, fueron aplicadas varias transformaciones (análisis de componentes principales, *Tasseled-Cap* y varios índices de vegetación) sobre la imagen una vez corregida geométrica y radiométricamente. El método estadístico utilizado fue el análisis de regresión, desestimando el uso de *k-NN* tan común, como hemos visto, en medios boreales ya que, como indican los autores, “una de las asunciones de este método (*k-NN*) es la existencia de bosques de similares características a lo largo del área de referencia cubierta por la imagen de satélite” (Mallinis *et al.*, 2004, p. 454), condición ésta que no se da en entornos mediterráneos. Los resultados recogidos en este trabajo muestran la dificultad de encontrar un modelo predictivo para la variable biomasa, siendo ésta más difícil de modelar que otras de las variables forestales consideradas, como la densidad y el área basal, identificándose como uno de los factores responsables la compleja estructura de los bosques mediterráneos.

Aparte del trabajo de Mallinis *et al.* (2004), no se han encontrado en la bibliografía más experiencias llevadas a cabo en medios forestales mediterráneos para la estimación de biomasa forestal a escala regional mediante imágenes Landsat. Por el contrario, sí se han localizado otros dos interesantes trabajos que centran su atención en la estimación de otros parámetros forestales continuos. El primero de ellos, Vázquez de la Cueva (2005), analiza las relaciones existentes entre los registros de una imagen y los datos proporcionados por el Tercer Inventario Forestal Nacional (IFN-3) en la porción occidental del Sistema Central, siendo el objetivo explorar los patrones de relación entre estos datos considerando distintas especies presentes (*Pinus pinaster*, *Quercus ilex* y *Q. pyrenaica*). Para ello utiliza un total de 764 parcelas (196 de *P. pinaster*, 198 de *Q. ilex* y 330 de *Q. pyrenaica*), para las que se dispone de datos sobre área basimétrica, densidad de pies, altura de la masa, fracción de cabida cubierta total de la vegetación y fracción de cabida cubierta total arbórea. La metodología empleada es el análisis de correlación, empleando 3 grupos distintos de parcelas para cada especie, de tal manera que el primero de ellos contiene todas las disponibles, mientras que en el segundo se eliminan aquellas que presentan *outliers* y valores extremos y en el tercero se prescinde de las parcelas que, según una clasificación no supervisada, se encuentran en áreas con respuesta espectral

heterogénea. Los resultados muestran correlaciones significativas para casi todas las variables cuando todas las parcelas son tomadas en consideración, alcanzando los mayores coeficientes las variables fracción de cabida cubierta total de la arbórea y densidad de pies. Sin embargo, estas correlaciones dejan de ser significativas en algunas variables cuando se utilizan los grupos más restringidos, siendo achacada esta situación por el autor a la ausencia de relaciones biofísicas sólidas debido a la heterogeneidad de los medios mediterráneos, dado que en condiciones de homogeneidad se han obtenido buenos resultados en la estimación de parámetros utilizando metodologías similares.

El segundo trabajo, realizado por Maselli y Chiesi (2006), se centra en la estimación de volumen de madera en la Toscana (Italia). Este trabajo es especialmente interesante porque compara tres métodos distintos de estimación: dos de ellos basados en la utilización de una imagen Landsat (*k-NN* y análisis de regresión localmente calibrado) y uno basado en un método de interpolación espacial a partir de principios geoestadísticos (*kriging*). Utilizan para ello un total de 2000 parcelas obtenidas del Inventario forestal regional de la Toscana, en la cuales aparecen representadas las distintas especies de coníferas y frondosas que conforman los bosques de la región. Un análisis exploratorio de las relaciones entre el volumen de madera y las bandas de TM mostró que las correlaciones eran negativas y bastante bajas (inferiores a 0,3), siendo identificada esta situación como consecuencia de la alta heterogeneidad de los bosques y de la combinación de otros factores que influyen las firmas espectrales (topografía y visibilidad-influencia del suelo y de la vegetación arbustiva de monte bajo). Las comparaciones entre los tres métodos propuestos en este trabajo muestran que, considerando la densidad de muestreo original, todos ellos presentan niveles de exactitud similares y bajos a nivel de píxel, siendo ligeramente mejor la regresión que el *k-NN* en el caso de los métodos que utilizan imágenes de satélite. Cuando la densidad de parcelas es progresivamente reducida, la exactitud obtenida por medio de interpolación espacial va disminuyendo, mientras que la derivada de los dos métodos que utilizan datos radiométricos no se ve afectada, aunque se detectan errores a escala de píxel análogos a las propiedades del método de *kriging*. Para mejorar las estimaciones, en este trabajo se propone el análisis de las varianzas de los errores para integrar las estimaciones obtenidas por los métodos que utilizan información espectral y la obtenida mediante interpolación espacial. Este método de integración mejora las estimaciones obtenidas utilizando cada uno de los tres métodos por separado.

- *Utilización de sensores de alta resolución espacial*

En cuanto a la utilización de imágenes de alta resolución espacial para la estimación de biomasa, Lu (2006) destaca la utilidad de las obtenidas tanto a partir de sensores aerotransportados (incluyendo la fotografía aérea) como satelitales, destacando en este grupo Ikonos y QuickBird. Tal y como destaca este autor, la interpretación de imágenes aéreas tiene una contrastada aplicación en tareas forestales de inventario tales como la estratificación del bosque y la estimación de volúmenes de madera, pudiendo ser algunas de las técnicas empleadas para la estimación de parámetros biofísicos mediante fotografía aérea extrapoladas al uso de imágenes de satélite de alta resolución. De esta manera, la alta precisión espacial que tienen estas imágenes las convierten en una fuente potencialmente muy valiosa para la estimación de biomasa. Algunos ejemplos de la aplicación de imágenes Ikonos a tal efecto son los trabajos de Thenkabail *et al.* (2004), que estiman la biomasa de palmeras en una zona de sabana de África, y el de Proisy *et al.* (2007), que estiman biomasa forestal en una zona tropical de la Guayana francesa. Por su parte, Leboeuf *et al.* (2007) han mostrado recientemente la utilidad de contar con imágenes QuickBird para estimar biomasa forestal con gran precisión en medios boreales ($R^2 = 0,84$).

En contraste con su elevado potencial, conviene destacar algunas desventajas derivadas de las características propias de estas imágenes que impiden su uso generalizado para estimar biomasa, sobre todo a escala regional; tales son: (i) la necesidad de contar con una infraestructura capaz de almacenar todas las imágenes necesarias para cubrir una región entera; (ii) el elevado tiempo que conlleva procesarlas; (iii) el alto precio de las imágenes; y (iv) la gran influencia que las sombras de la cobertura forestal y la topografía tienen en ellas. A pesar de estos inconvenientes, las imágenes de alta resolución espacial son idóneas para la validación o para la evaluación de la precisión obtenida en la estimación de biomasa regional mediante el uso de imágenes de resolución media como Landsat.

Por último, dentro de la estimación de biomasa forestal mediante sensores pasivos resta tratar el uso de los satélites hiperespectrales. En este sentido, al iniciar la revisión bibliográfica se esperaba encontrar un gran número de referencias, ya que el gran número de bandas que contienen estas imágenes y los reducidos rangos espectrales que las definen son dos características que pueden ayudar a encontrar buenos modelos de estimación de parámetros biofísicos forestales, al quedar identificadas de forma precisa las regiones del espectro electromagnético mejor

correlacionadas con estas variables (Treitz y Howarth, 1999). A este respecto, destacar el trabajo de Pu *et al.* (2005), en el que se demuestra cómo los datos proporcionados por el sensor espacial Hyperion son más útiles para la estimación de LAI que los proporcionados por Landsat. Sin embargo, se han encontrado pocos trabajos que utilicen este tipo de imágenes (aerotransportadas o satelitales) para estimar específicamente biomasa forestal. Entre los que utilizan imágenes de sensores aerotransportados destacan las experiencias llevadas a cabo por Baulies y Pons (1995), que obtuvieron altos coeficientes de correlación en medios mediterráneos mediante la utilización del sensor CASI, y la de San Miguel-Ayanz (1996), que utilizó conjuntamente -y con éxito- datos AVIRIS y del sensor radar AIRSAR. En el caso de las imágenes de satélite, destacan las experiencias llevadas a cabo por Muukkonen y Heiskanen (2007) y Zheng *et al.* (2007) con MODIS, si bien el uso en estos trabajos de imágenes de mayor resolución espacial pero menor espectral como paso intermedio para relacionar los datos de campo con los datos MODIS, resta la potencialidad que este sensor tiene para identificar regiones del espectro electromagnético más precisas para estimar la biomasa que las consideradas en los sensores multiespectrales.

1.3.3.2.3. Utilización de los sensores activos para la estimación de biomasa

Como hemos visto con anterioridad, las imágenes radar (SAR) están íntimamente relacionadas con el tamaño y la estructura de la vegetación. Este hecho, unido a su capacidad para obtener datos en regiones cubiertas permanentemente por nubes y en ausencia de luz solar, han convertido las imágenes radar en unas de las más profusamente utilizadas para la estimación de biomasa forestal (Dobson, 2000; Lu, 2006). Un repaso a la bibliografía nos muestra cómo se han alcanzado diferentes niveles de éxito en función de la longitud de onda (principalmente bandas C, L y P), la polarización utilizada (HH, VV, HV y VH) y las características estructurales de la vegetación estudiada, así como de las condiciones ambientales.

Así, recordando que la banda C es la que menos penetra en el dosel vegetal, Le Toan *et al.* (1992) encontraron bajas correlaciones entre el coeficiente de retrodispersión de esta banda y la biomasa forestal total en un área experimental de *Pinus Pinaster*, debido a la saturación de la señal radar en las parcelas homogéneas que contenían los ejemplares de mayor edad, que eran los que más biomasa contenían. Esto se debe a que la copa del árbol y las partes que la componen (follaje, ramaje y tronco) son los principales mecanismos de retrodispersión a esta longitud de onda; de esta manera, al no poder traspasar la señal radar las copas de los árboles más desarrollados, se producía

una saturación en la señal. Dada esta temprana saturación de la banda C a la hora de estimar biomasa total, el uso de imágenes de satélite de esta banda no ha recibido mucha atención en la literatura científica (Quegan *et al.*, 2000).

Aun así, podemos encontrar algunos trabajos que han empleado datos de la banda C procedentes de sensores situados a bordo de los satélites ERS-1 y -2, Radarsat, SIR-C y Envisat (Foody, 1997; Kasischke *et al.*, 1997; Kurvonen *et al.*, 1999; Paloscia *et al.*, 1999; Pulliainen *et al.*, 1999; Kurvonen *et al.*, 2002). Aunque en algunas ocasiones se confirma que las relaciones entre biomasa y el coeficiente de retrodispersión son bajas o nulas debido, principalmente, a la ya comentada saturación (Kasischke *et al.*, 1997; Foody, 1997), se han experimentado diferentes metodologías para mejorar esta situación como, por ejemplo, la estratificación de los datos de biomasa por especies, la utilización de ratios que incluyan otras bandas además de la C o el uso de modelos de inversión (Foody, 1997; Kasischke *et al.*, 1997; Kurvonen *et al.*, 1999; Kurvonen *et al.*, 2002). En este sentido, los trabajos de Kurvonen *et al.* (1999), Pulliainen *et al.* (1999) y Kurvonen *et al.* (2002) han mostrado que, si se consideran grandes superficies, es posible obtener estimaciones de biomasa mediante la banda C bastante similares a las obtenidas con banda L, que tiene mucha mayor capacidad de penetración en el dosel vegetal.

En medios mediterráneos, la utilidad de la banda C con polarización VV proporcionada por ERS-1 fue analizada por Paloscia *et al.* (1999), obteniéndose como resultado estimaciones de biomasa forestal solamente algo inferiores a las obtenidas con la banda L y polarización HH proporcionada por JERS-1 ($R^2=0,65$ para ERS-1 y $R^2=0,77$ para JERS-1). Sin embargo, estos resultados contrastan con los obtenidos también en medios mediterráneos por Svoray *et al.* (2001), que encontraron bajas correlaciones entre el coeficiente de retrodispersión de ERS-2 y la biomasa total y el *LAI* de cuatro formaciones típicas mediterráneas (bosque, matorral, matorral ralo y vegetación herbácea). En cambio, cuando el coeficiente de retrodispersión es relacionado con un índice generado en este trabajo para sintetizar la información sobre la densidad volumétrica de la biomasa de las hojas verdes, encontraron una correlación alta y significativa (0,92), lo que confirma la sensibilidad de la banda C al follaje de la parte superior del dosel vegetal.

En consonancia con lo expresado en los párrafos anteriores, son mucho más frecuentes en la bibliografía los trabajos que han empleado el coeficiente de retrodispersión de la banda L para estimar biomasa forestal con imágenes de satélite.

Así, aunque mediante el uso de sensores aerotransportados se ha mostrado que el nivel de saturación del coeficiente de retrodispersión de la banda P es mayor que el de la banda L y que en esta última la polarización cruzada (HV o VH) funciona mejor que la paralela (HH y VV) (Le Toan, 1992; Beaudoin *et al.*, 1994; Kasischke *et al.*, 1997), la ausencia de satélites equipados con esta banda P y con banda L multipolarimétrica ha hecho que la mayoría de los trabajos desarrollados a escala regional con imágenes de satélite utilicen la banda L en polarización HH proporcionada por JERS-1 (Kurvonen *et al.*, 1999; Luckman *et al.*, 1998; Pulliainen *et al.*, 1999; Kurvonen *et al.*, 2002; Castel *et al.*, 2002; Santos *et al.*, 2002; Austin *et al.*, 2003; Rauste, 2005), siendo menor el número de experiencias llevadas a cabo con la banda L multipolarimétrica de SIR-C (Foody, 1997; Ranson y Sun, 2000). Lo que se deduce de la lectura de estos trabajos es que la presencia de formaciones forestales caracterizadas por estar compuestas por varias especies y por su compleja disposición estructural condiciona la utilización de imágenes de satélite de banda L con fines operativos de estimación de biomasa, debido a la temprana saturación de la señal (aunque con un umbral superior a la banda C). En cambio, sí son viables modelos operativos en ambientes monoespecíficos de estructura simple, aunque es necesario seguir investigando. Otro aspecto interesante a destacar es la posibilidad de extraer información de biomasa referida específicamente a los distintos componentes del árbol (follaje, ramaje y tronco) mediante el uso de imágenes de satélite de banda L, tal y como queda demostrado en el trabajo de Austin *et al.* (2003). Este último aspecto también ha sido comprobado para la banda P en los trabajos realizados mediante el sensor aerotransportado AISAR por Beaudoin *et al.* (1994) y Saatchi y Moghaddam (2000), ofreciendo mejores resultados que la banda L en la estimación de biomasa total, aunque muy parecidos cuando sólo se estima biomasa de la copa. Finalmente, señalar dentro de esta revisión de la utilización del coeficiente de retrodispersión en imágenes de satélite para la estimación de biomasa, las expectativas abiertas hace poco mediante el lanzamiento del satélite japonés ALOS-Palsar, provisto de un sensor en banda L multipolarimétrica. Se espera que este satélite confirme a escala regional los buenos resultados obtenidos con sensores aerotransportados como AIRSAR en la utilización de la banda L con polarización HV para estimar biomasa (Dobson, 2000; Le Toan *et al.*, 2004; Shimada *et al.*, 2005).

En cuanto a la aplicación de técnicas polarimétricas e interferométricas SAR (*PolInSAR*) para la estimación de biomasa forestal, señalar que la mayoría de los trabajos que utilizan estas técnicas se basan en el hecho de que a partir del conocimiento de la altura de un bosque se puede obtener información sobre la cantidad de la biomasa

mediante el uso de ecuaciones alométricas (Mette *et al.*, 2003; Balzter *et al.*, 2007b). En efecto, la aplicación de técnicas de interferometría sobre pares de imágenes SAR proporcionadas por sensores aerotransportados o satelitales tomadas desde posiciones casi idénticas se ha mostrado como una herramienta óptima para la modelización de la variable física altura del bosque (Askne *et al.*, 1997; Balzter, 2001; Balzter *et al.*, 2007b). De esta manera, existen en la literatura ejemplos de la utilización de estas técnicas para la modelización de la variable altura en bosques, que finalmente se han orientado a la obtención de la variable biomasa total, preferentemente mediante imágenes proporcionadas por sensores aerotransportados como E-SAR o RAMSES (Mette *et al.*, 2004a; Garestier, 2006). Esta metodología presenta dos puntos débiles para su generalización a escala regional: en primer lugar, es necesario que los bosques del área de estudio se organicen en cuarteles forestales homogéneos en altura; en segundo lugar, es fundamental contar con ecuaciones alométricas que relacionen de una forma precisa altura y biomasa de las especies estudiadas (Mette *et al.*, 2004b).

Otro tipo de análisis interferométrico para obtener información de biomasa a partir de dos imágenes obtenidas casi desde la misma posición y con un escaso intervalo temporal es el análisis de coherencia entre ellas; es decir, el análisis de las diferencias entre estas dos imágenes. Esta técnica se ha probado con éxito mediante la utilización de imágenes ERS-1 y ERS-2, tomadas en las condiciones anteriormente expresadas. En este escenario, la decorrelación entre los coeficientes de retrodispersión de ambas imágenes es principalmente causada por el movimiento de hojas y ramas, que son los principales elementos causantes de la retrodispersión en la banda C de ERS. De esta manera, se puede establecer cómo a medida que la biomasa incrementa existe una mayor cantidad de la señal registrada que proviene de elementos inestables, generadores de retrodispersión, por lo que la coherencia entre imágenes tiende a ser menor. Así pues, se trata de una relación inversa: a menor coherencia entre el par de imágenes SAR, mayor cantidad de biomasa (Le Toan *et al.*, 2002; 2004). Ejemplos de este segundo tipo de aplicación, con algunas variantes, son los trabajos de Castel *et al.* (2000) y Gaveau (2002).

El método indirecto de obtener información sobre la cantidad de biomasa también es aplicado a partir de sistemas LIDAR. Como hemos visto con anterioridad, es posible obtener la cantidad de biomasa de un ejemplar o de un bosque a partir de la aplicación de ecuaciones alométricas sobre estimaciones de la altura y de la anchura de la corona de árboles individuales, así como de altura media y densidad de bosques, variables todas

ellas proporcionadas por LIDAR (McRoberts y Tomppo, 2007). Ésta es la forma de proceder de Lefsky *et al.* (1999), Drake *et al.* (2002), Bortolot y Wynne (2005) y Popescu (2007), obteniéndose buenos resultados. Entre los trabajos citados es de destacar el último, ya que en éste no sólo se obtiene la biomasa total del árbol, sino que se logra estimar la biomasa de cada uno de sus componentes a partir de datos derivados de LIDAR. Las limitaciones de esta técnica para la estimación de biomasa a escala regional son análogas a las citadas para el uso de técnicas interferométricas que relacionaban altura con biomasa. Recientemente, Nelson *et al.* (2009) han utilizado el sistema LIDAR GLAS situado a bordo del satélite ICESat para estimar volúmenes de madera en Siberia, utilizando como paso intermedio una cartografía de usos del suelo obtenida con MODIS, siendo los resultados en la zona comparables a los obtenidos en trabajos independientes basados en estimaciones basadas en trabajo de campo.

1.3.3.2.4. Utilización de otras técnicas de teledetección para la estimación de biomasa

Este subapartado, dedicado a la estimación de biomasa forestal mediante otras herramientas de teledetección, engloba dos técnicas: en primer lugar, el uso de técnicas de combinación de imágenes ópticas y radar y, en segundo lugar, el uso de modelos de simulación de reflectividad.

Como hemos visto en los dos anteriores subapartados, cada sensor tiene sus propias características a la hora de sintetizar la información que recoge de la superficie observada. De esta manera, la utilización de dos o más sensores proporciona una gran oportunidad para conocer la cubierta observada desde diferentes puntos de vista, obteniéndose una base de datos mucho más rica y completa. Dado que los sensores ópticos proporcionan información sobre la reflectividad del dosel vegetal y los sensores radar son capaces de proporcionar conocimiento acerca de la estructura interna de la formación estudiada, la combinación o fusión de ambos tipos de datos puede mejorar la estimación de la variable biomasa forestal. Así, la combinación de ambos tipos de datos puede resolver las situaciones de saturación y de presencia de píxeles mixtos, tan frecuentes cuando se utilizan estas metodologías por separado, obteniéndose variables independientes poco correlacionadas entre sí, que pueden mejorar el ajuste del modelo predictivo de biomasa (Lu, 2006). Ejemplos de esta integración de datos son los trabajos de Moghaddam *et al.* (2002) y Treuhft *et al.* (2003). En el primero de ellos se utilizaron conjuntamente datos radar procedentes del sensor aerotransportado AIRSAR y datos ópticos de Landsat 5 TM para estimar la biomasa del follaje en un bosque de coníferas de topografía compleja de Oregón (EE.UU.). En concreto, dentro de los datos

proporcionados por AIRSAR, se utilizó tanto información referida al coeficiente de retrodispersión de las bandas C y L, como información de coherencia interferométrica en banda C, mientras que de Landsat TM solamente se tuvieron en cuenta las seis bandas reflectivas, no calculándose ningún índice o ratio con ellas. Los resultados obtenidos demuestran que la combinación de datos radar y ópticos mejora las estimaciones de la biomasa del follaje obtenidas utilizando solamente datos Landsat. El segundo trabajo - Treuhaft *et al.* (2003)- estima biomasa forestal a partir de perfiles de densidad de área foliar obtenidos mediante el uso de datos interferométricos en banda C y datos hiperespectrales proporcionados por un sensor aerotransportado; así, los datos radar son empleados para producir los perfiles de densidad relativos, mientras que los datos hiperespectrales sirven para crear el índice de área foliar, obteniéndose resultados satisfactorios en la estimación de biomasa.

Por último, señalar el potencial de los modelos de simulación de reflectividad para estimar biomasa forestal. Como hemos visto, la biomasa forestal es un parámetro global o de conjunto que está relacionado con muchos otros, parciales, como la composición de especies, la densidad de árboles o la estructura de la cubierta. Parámetros estos últimos que no son fácilmente analizables por los satélites ópticos, ya que –recordemos- éstos solamente recogen información de la parte superior del dosel vegetal. Es por ello por lo que muchas veces los cambios en las cantidades de biomasa no son reflejados directamente en los datos de reflectividad proporcionados por los sensores satelitales. Esta situación puede ser solucionada mediante la utilización de modelos de simulación de reflectividad, que son capaces de considerar diferentes variables que mejoran la estimación de parámetros estructurales forestales. A este respecto, Franklin y Hieraux (1991) mostraron el potencial de estos modelos para estimar biomasa leñosa y del follaje. Diferentes modelos de reflectividad útiles para la estimación de parámetros forestales están presentes en la bibliografía científica, pudiéndose clasificar todos ellos en 4 categorías: modelos geométricos, modelos de medio turbido, modelos híbridos y modelos de simulación computerizados. Cada uno de estos tipos utiliza diferentes variables estructurales como, por ejemplo, el tamaño de la hoja, la forma geométrica y orientación de las hojas y ramas, la disposición de la vegetación en distintas capas, etc. Sin embargo, a pesar de los esfuerzos realizados en este campo para modelar la reflectividad de distintas cubiertas vegetales con el objeto de predecir características como altura, densidad o *LAI* mediante datos de satélite, la complejidad de las características de la cubierta vegetal, las condiciones atmosféricas, el ángulo solar y la geometría de observación, así como la incidencia de la pendiente y la orientación del terreno son

aspectos que introducen una enorme dificultad en la precisión alcanzada mediante el uso de estos modelos (Lu, 2006).

1.3.3.2.5. Factores restrictivos en la estimación de biomasa forestal

Como hemos visto, la teledetección presenta un enorme potencial para la estimación de parámetros forestales continuos, en general, y de biomasa forestal, en particular. En las últimas páginas se ha presentado una revisión de las diferentes formas mediante las cuales se ha abordado la estimación de la biomasa forestal desde el seno de esta disciplina, considerando distintos tipos de sensores (activos y pasivos), resoluciones espaciales, características intrínsecas del área estudiada, métodos estadísticos, etc.

Dada la extensa colección de datos y técnicas de teledetección útiles a la hora de abordar un proyecto que tiene como finalidad estimar la biomasa forestal de un territorio, parece fundamental seleccionar entre todas ellas la que más se adecue a los objetivos marcados y a las posibles restricciones o limitaciones de diversa índole que afecten a un proyecto tal. A nuestro juicio, son tres los principales factores que determinan el tipo de imágenes y de técnicas a utilizar: el económico, el tecnológico y el temporal, encontrándose muchas veces estos tres factores interrelacionados entre sí.

En efecto, el presupuesto disponible para abordar un proyecto de estimación de biomasa mediante teledetección condiciona de gran manera el diseño del mismo. Por ejemplo, la partida económica es el principal factor que condiciona la cantidad y calidad de los datos de campo de biomasa que posteriormente serán relacionados con la información de satélite. Si se cuenta con suficiente dinero, lo ideal es la realización de trabajo de campo en un número suficiente de parcelas para que el modelo de estimación resultante sea estadísticamente robusto, reservando algunas de ellas para la validación final. Si, por el contrario, se dispone de pocos recursos económicos, los datos de biomasa tendrán que ser obtenidos de manera indirecta, por ejemplo, mediante la aplicación de ecuaciones alométricas previamente publicadas a datos de inventario forestal o de otras fuentes, con lo que, en principio, los errores de partida serán mayores que en la situación anterior. La disponibilidad de dinero también controla la selección de imágenes de satélite a utilizar. Así, se ha visto cómo las imágenes de alta resolución espacial tienden a ofrecer buenos resultados, dado que evitan el uso de píxeles heterogéneos; sin embargo, este tipo de imágenes suele cubrir extensiones de terreno no muy extensas, por lo que es necesario contar con un gran número de ellas si se quiere

abordar un estudio a escala regional, por lo que será necesario contar con una gran cantidad de dinero. Esta misma situación se da si queremos utilizar imágenes de resolución media como Landsat, Spot o ERS para realizar un trabajo a escala nacional.

El factor tecnológico refiere a la disponibilidad de recursos tanto humanos como físicos. En efecto, contar con un personal con formación suficiente en el tratamiento e interpretación de imágenes de satélite es un paso previo fundamental a la hora de iniciar un proyecto de estimación de biomasa mediante teledetección. Así pues, el tipo de imágenes y de técnicas a utilizar debe estar en función de la formación de las personas que van a abordar estas tareas, careciendo de sentido el uso de, por ejemplo, imágenes LIDAR si el equipo técnico carece de conocimientos para interpretarlas y trabajarlas. Aunque la formación continua es deseable en cualquier ámbito de trabajo, esta formación lleva implícito el consumo de dinero y de tiempo, recursos no siempre fácilmente disponibles. Además de este conocimiento relativo al tratamiento de datos de teledetección, también es deseable la posesión de conocimientos medioambientales y geográficos (ya que la variable a estudiar se sitúa en estas ramas de conocimiento), así como la posesión de cierta destreza en el uso de la estadística, dado que muchas veces el resultado final es un modelo matemático de relación entre datos espectrales y de biomasa. En cuanto a los recursos físicos, éstos refieren tanto a los equipos informáticos necesarios para almacenar y procesar los datos como al *software* específico para realizar ciertos tratamientos sobre las imágenes y sobre la información alfanumérica en general. Las imágenes de satélite son generalmente archivos de gran volumen, que ocupan mucho espacio en el disco duro y necesitan de ordenadores potentes para ser procesadas. Así mismo, es necesario contar con *software* específico que permita realizar las tareas necesarias -como la georreferenciación, la normalización radiométrica o topográfica o la generación de nuevas bandas de información- y que, normalmente, es caro; por lo que, una vez más, el factor económico debe ser tenido en cuenta.

Por último, es necesario considerar el tiempo con el que se cuenta para abordar el proyecto. Efectivamente, el tiempo es un recurso limitado que obliga a adoptar determinadas decisiones al inicio del trabajo de investigación, que resultan fundamentales a la hora de obtener los resultados. Como hemos visto, la utilización de unas imágenes o técnicas u otras está en función de los conocimientos previos del personal encargado de la realización del trabajo, siendo necesario un periodo más o menos prolongado de formación si se desea utilizar recursos para los que no se dispone de conocimientos previos. Además, como ocurre en cualquier trabajo de investigación,

los primeros resultados obtenidos no son siempre los previstos, por lo que es necesario dedicar más tiempo de lo inicialmente planteado para tareas que, en principio, se preveían terminadas para una determinada fecha. De igual forma, destacar que, durante el desarrollo del trabajo, los resultados parciales pueden sugerir el empleo de nuevas metodologías que, previsiblemente, puedan mejorar lo obtenido hasta ese momento; sin embargo, la necesidad de cumplir con los plazos fijados impone la necesidad de concluir en un determinado punto, apuntando en las conclusiones posibles líneas de investigación futuras.

En conclusión, la conjugación de estos factores debe ser tenida en cuenta a la hora de establecer la metodología de trabajo que dé lugar a la consecución del objetivo de estimar la biomasa forestal en un área determinada, teniendo que estar a su vez este objetivo supeditado a la disponibilidad de estos tres factores. Al igual que en cualquier otro tipo de proyecto o de investigación, la temprana planificación de las tareas a realizar -siendo consciente del objetivo y de los recursos disponibles- determinará el éxito o el fracaso del labor abordada.

1.4. Fases de la investigación y metodología estadística para el modelado de la biomasa residual forestal

La metodología científica empleada se enmarca en una argumentación de tipo hipotético-deductivo. De esta manera, a partir de la hipótesis de que es posible estimar la biomasa residual forestal mediante el uso de imágenes de teledetección, información auxiliar y trabajo de campo, se formulan una serie de modelos que se verifican experimentalmente a partir de la utilización de datos de campo reservados a tal efecto.

Así pues, al igual que la mayoría de las aplicaciones desarrolladas en el seno de la teledetección para la estimación de parámetros forestales continuos (Franklin, 2001), esta investigación se centra en el desarrollo de un modelo empírico en el cual la biomasa residual forestal se convierte en la variable dependiente que intenta ser estimada o predicha mediante el uso de imágenes de satélite debidamente calibradas y la ayuda de otras informaciones auxiliares. Se trata, por tanto, de la elaboración de un modelo a escala provincial aprovechando las propiedades de las imágenes de satélite para registrar información de carácter continuo y completo a lo largo de un territorio en intervalos más o menos frecuentes, superando las limitaciones puntuales de los inventarios.

1.4.1. Marco tecnológico e institucional de la investigación

La metodología que se aplica en esta investigación se sitúa en el contexto de las tecnologías de la información geográfica (teledetección y SIG) como fuentes de información y herramientas para el análisis geográfico y la gestión forestal. En el apartado 1.3 se ha mostrado la utilidad de la teledetección en distintos campos relacionados con la gestión forestal como, por ejemplo, la obtención de cartografía de especies; el análisis del riesgo, detección y seguimiento post-fuego de incendios forestales; las tareas de inventario, etc. (Chuvieco *et al.*, 2002; Wagner *et al.*, 2003; Calle *et al.*, 2005; Pérez-Cabello *et al.*, 2006; McRoberts y Tomppo, 2007; Tomppo *et al.*, 2008). En cuanto a los SIG, entendidos estos como un “sistema compuesto por hardware, software y procedimientos para capturar, manejar, manipular, analizar, modelizar y representar datos georreferenciados, con el objeto de resolver problemas de gestión y planificación” (NCGIA, 1997), diferentes trabajos han dado cuenta de su operatividad en cuestiones relativas al ámbito forestal, como el proyecto FIREMAP (<http://www.geogra.uah.es/firemap/>), que los utiliza para la estimación del riesgo de incendios, o el proyecto SIBosC (Sistema de Información de los Bosques de Cataluña) (http://www.creaf.uab.es/esp/proyectos/10_230.htm), que es un SIG de información forestal que integra un gran número de cartografías de distinto origen; en cualquier caso, la utilización de estas tecnologías de la información en el ámbito de la Geografía es abundante y fructífera (Chuvieco *et al.*, 2005). En el marco de la presente investigación, los SIG -como tecnología de integración de la información que funciona como una base de datos sofisticada en la que se relaciona información espacial y temática mediante una extensa colección de funciones analíticas, de visualización, de edición, etc.- permiten el modelado de todos los materiales necesarios para la obtención de las variables que más tarde se utilizarán en la formulación del modelo de estimación, así como el análisis de estas variables y su representación final. Se trata, pues, de una herramienta importante e imprescindible para la ejecución y el éxito de la presente tesis.

Para su correcto desarrollo, el presente trabajo se integró dentro del proyecto LIGNOSTRUM (AGL2002-03917-AGR-FOR), cuyo objetivo era conseguir un incremento considerable de la utilización de los residuos agrícolas y forestales como recurso energético, proponiéndose como área de estudio y experimentación la provincia de Teruel. En este proyecto, financiado por la Comisión Interministerial de Ciencia y Tecnología (CICYT), se considera la creación de una metodología fiable, veraz y extrapolable que permita cuantificar los residuos forestales y agrícolas en un territorio a

escala provincial, la caracterización energética de estos residuos, la búsqueda de la tecnología más adecuada para su aprovechamiento y la localización de emplazamientos adecuados para la instalación de plantas de producción energética. Los integrantes del equipo investigador encargados de llevarlo a cabo pertenecen a dos organismos distintos:

- **Fundación CIRCE** (Centro de Investigación de Recursos y Consumos Energéticos) (<http://circe.cps.unizar.es/>, Universidad de Zaragoza). Dirigidos por el Dr. Francisco Javier Royo Herrero, los investigadores del proyecto que pertenecen a este centro poseían de forma previa a la concesión del proyecto LIGNOSTRUM una dilatada experiencia tanto en la evaluación de recursos de biomasa residual forestal y agrícola, como en el estudio de las tecnologías para su aprovechamiento energético (producción de electricidad y calor).
- **Grupo GEOFOREST** del Departamento de Geografía y Ordenación del Territorio (<http://geoforest.unizar.es/>, Universidad de Zaragoza). Este grupo ha estado trabajando con profusión en los últimos años en el empleo de la teledetección y los SIG como herramientas de apoyo para el análisis de la dinámica ambiental del territorio en relación con la actividad humana y los caracteres físicos del medio, así como en el desarrollo de trabajos experimentales de campo. El investigador responsable del grupo en el proyecto es el Dr. Juan de la Riva Fernández.

El autor de esta tesis se inscribe en este último grupo de investigación desde junio de 2004, aunque con anterioridad han sido varios los trabajos tutorizados por sus integrantes, relacionados principalmente con el uso de teledetección y los SIG como herramientas para el análisis del territorio.

De las diferentes actividades en las que el proyecto LIGNOSTRUM fue dividido, la de cuantificación de los recursos de biomasa residual agrícola y forestal, la de localización de emplazamientos adecuados para la instalación de plantas de producción energética y la de difusión de resultados fueron desarrolladas por los dos organismos, quedando las de caracterización energética y búsqueda de la tecnología más adecuada para su aprovechamiento en manos de CIRCE. En concreto, la tarea de desarrollar la metodología para evaluar los recursos de biomasa residual forestal fue asignada, dentro de GEOFOREST, a quien firma este trabajo de investigación, constituyendo la base sobre la que se asentaron sus objetivos.

Los recursos físicos y logísticos utilizados son los disponibles en el Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza (equipamiento informático, *software* específico, bibliografía...), corriendo la financiación de los materiales necesarios (imágenes de satélite, datos de inventario forestal, cartografía digital, modelos digitales de elevaciones...) y del trabajo de campo a cargo del proyecto LIGNOSTRUM. En concreto, los programas informáticos disponibles en este Departamento y que han sido utilizados son: ERDAS Imagine 8.7 para el tratamiento y análisis digital de las imágenes de satélite, ArcGIS-ArcINFO y ArcVIEW como SIGs para el tratamiento de la información auxiliar y la edición de la cartografía y, finalmente, SPSS y EXCEL para el tratamiento estadístico de todos los datos. Además, en el *Centre d'Etudes Spatiales de la Biosphère* (CESBIO) se hizo uso del programa GAMMA REMOTE SENSING para el calibrado y procesado de las imágenes radar utilizadas en este trabajo.

1.4.2. Fases del trabajo de investigación

La metodología seguida en este trabajo se articula en tres fases: la primera de ellas se dirige a la obtención de la variable dependiente (biomasa residual forestal) y de las variables independientes (información radiométrica, topográfica y forestal), quedando la segunda reservada a la formulación del modelo de estimación que utiliza ambas y a su validación. Finalmente, en la tercera fase se aplica el modelo más adecuado a una imagen de similares características a las que se han empleado en su creación, pero de fecha más reciente, obteniéndose así un inventario actual de este recurso energético en la provincia de Teruel. En las siguientes páginas se desarrollan las distintas actividades en que se articulan estas tres fases, que se relacionan con los objetivos parciales-operativos anteriormente enunciados. Por último, antes de presentar y caracterizar el área de estudio, se muestra el método estadístico y sus distintas variantes utilizadas para la obtención de los diferentes modelos de estimación: el análisis de regresión.

Fase 1. Obtención de la variable dependiente (biomasa residual forestal) y de las variables independientes (información radiométrica, topográfica y forestal)

Esta fase está dividida en 4 actividades, que se presentan a continuación.

I. Obtención de los datos de biomasa residual forestal

Esta actividad está en relación con el objetivo operativo I y se estructura en tres partes diferenciadas. La primera de ellas refiere expresamente a la obtención de cuatro ecuaciones alométricas (una para cada especie de *Pinus* considerada) que permitan

conocer la cantidad de biomasa residual de cada pie arbóreo a partir del conocimiento de su *dbh* y su altura. Para ello se realiza un muestreo estratificado por especies; dado su carácter destructivo, el trabajo de campo tiene que ser coincidente con tareas selvícolas dirigidas por la Administración Forestal. Posteriormente a la realización de este muestreo se procede al tratamiento estadístico de los datos obtenidos para la formulación de las ecuaciones alométricas. La segunda parte de esta actividad refiere a la aplicación de estas ecuaciones a los datos disponibles en el Segundo Inventario Forestal Nacional de la provincia de Teruel (IFN-2), cuyas labores de muestreo se realizaron entre otoño de 1993 y primavera-verano de 1994. Las ecuaciones alométricas se aplican a cada uno de los pies recogidos en las parcelas del IFN-2 ya que, en las tablas adjuntas, aparece información sobre el *dbh* y la altura de cada ejemplar que las compone. Finalmente, la tercera y última parte consiste en la espacialización de los datos obtenidos de biomasa residual forestal por parcelas, obteniéndose una cartografía de puntos que será el documento base a partir del cual se extraerá la información radiométrica y de las variables auxiliares. Varios procesos de filtrado se aplican para eliminar determinadas parcelas en función de criterios de homogeneidad y calidad de los datos.

Esta actividad se desarrolla en el Capítulo 2, concretamente en el apartado 2.1.

II. Obtención de las variables radiométricas

En esta segunda actividad se aborda el tratamiento de las imágenes de satélite seleccionadas para ser relacionadas con los datos de biomasa residual forestal obtenidos en la actividad I. Es ésta una tarea larga, compleja y crítica para la bondad de los resultados finales de la investigación.

Dado que se emplean dos tipos de imágenes de satélite distintas -ópticas y radar-, los pretratamientos a aplicar en ambos casos son diferentes; por ello, se dedican apartados diferentes dentro del mismo Capítulo 2.

En el apartado 2.3 se llevan a cabo las tareas de tratamiento digital sobre tres imágenes Landsat 5 TM. La elección de este tipo de imágenes responde al hecho, anteriormente comentado (véase 1.3.3), de que, en la bibliografía existente sobre aplicaciones de teledetección a tareas de inventario forestal y de estimación de biomasa a escalas regional y local, éste es el tipo de imágenes ópticas más utilizadas (p.e. Roy y Ravan, 1996; Todd *et al.*, 1998; Salvador y Pons, 1998a,b; Fazakas *et al.*, 1999; Steininger, 2000; Foody *et al.*, 2001; Mickler *et al.*, 2002; Reese *et al.*, 2002; Foody *et al.*,

2003; Labrecque *et al.*, 2003; Phua y Saito, 2003; Calvao y Palmeirin, 2004; Mallinis *et al.*, 2004; Lu *et al.*, 2004; Zheng *et al.*, 2004; Lu, 2005; Lu y Batistiella, 2005; Hall *et al.*, 2006; Labrecque *et al.*, 2006). Además, como también se ha comentado, la frecuente utilización de este sensor para la estimación de biomasa a estas escalas responde a la utilidad de sus imágenes para cartografiar y hacer un seguimiento controlado de las condiciones biofísicas forestales de una manera consistente y replicable (Jakubauskas, 1996). Otros factores que inclinaron también la balanza hacia el empleo de estas imágenes fueron el carácter periódico de su cobertura sobre el área de estudio, la obtención mediante una sola escena de la mayor y más interesante parte del territorio que compone el área de estudio y las previsiones de liberalización de estos productos o, en todo caso, su sencilla adquisición a partir de distribuidores autorizados a precio razonable. Estos últimos factores están en consonancia con el objetivo expresado de crear una metodología sencilla y aplicable que pueda ser aprovechada por los agentes y Administraciones responsables de la planificación territorial.

Las tres imágenes seleccionadas son sincrónicas a los trabajos de campo del IFN-2, estando todas ellas libres de nubes en su mayor parte. Tres son los tratamientos que se aplican al objeto de obtener variables radiométricas consistentes y susceptibles de ser relacionadas con los datos de biomasa residual forestal:

- **Corrección geométrica.** Consiste en la eliminación de las alteraciones que afectan a la localización correcta de los píxeles. La importancia de una precisa corrección geométrica es evidente en este trabajo ya que las imágenes van a ser relacionadas con localizaciones precisas para las que se conoce la cantidad de biomasa residual forestal y porque van a ser integradas en un SIG con otras informaciones (cartografía forestal, elevaciones, pendientes...). Para llevar a cabo la corrección geométrica se utiliza un modelo empírico.
- **Corrección radiométrica.** Este pretratamiento se aplica para corregir las distorsiones que introducen la atmósfera y la topografía en la señal registrada. Considerando la irregular topografía del área de estudio, la influencia del relieve en los ND es, *a priori*, muy alta, por lo que es imprescindible contar con un modelo digital de elevaciones (MDE) de calidad para eliminar esta influencia. Se utiliza para ello un MDE de la provincia de Teruel creado a tal efecto en el apartado 2.2 a partir de la Base Cartográfica Numérica 1:25000 (BCN25).

- **Aplicación de transformaciones a las imágenes y elaboración de neocanales.** Las experiencias realizadas en estimación de biomasa con Landsat se apoyan en funciones que utilizan tanto los valores de las bandas originales como transformaciones de éstas: componentes principales, índices de vegetación, etc. En concreto, en este subapartado se aplica a cada imagen un análisis de componentes principales, la transformación *Tasseled-Cap* y el cálculo de distintos índices, entre los que destacan NDVI, SAVI, MSAVI...

En el apartado 2.4 se abordan una serie de técnicas de tratamiento necesarias para explorar la utilidad de imágenes radar Envisat-ASAR para estimar biomasa residual forestal. Aunque en la memoria del proyecto LIGNOSTRUM no se había contemplado el uso de imágenes radar, la obligada lectura de la bibliografía existente antes de comenzar a desarrollar esta tesis llevó a considerar la posibilidad de explorar el uso de este tipo de imágenes. Para ello, se establecieron contactos con personal del *Joint Research Centre* (JRC) de Ispra (Italia) y, posteriormente, con la Dra. Tuy Le Toan, investigadora del *Centre d'Etudes Spatiales de la Biosphère* (CESBIO) en Toulouse (Francia). La Dra. Le Toan tenía una sólida experiencia investigadora en el uso de imágenes radar para la estimación de biomasa, con un elevado número de publicaciones científicas en esta línea (Le Toan *et al.*, 1992; Dobson *et al.*, 1992; Beaudoin *et al.*, 1994; Le Toan y Floury., 1998; Quegan *et al.*, 2000; Castel *et al.*, 2001; Le Toan *et al.*, 2002; Moreau y Le Toan, 2003; Wagner *et al.*, 2003; Le Toan *et al.*, 2004), siendo además actualmente la coordinadora de la misión *BIOMASS (Biomass monitoring mission for carbon assessment)* de la Agencia Espacial Europea, ESA, (<http://www.cesbio.ups-tlse.fr/fr/mission2.htm>) cuyo objetivo es la creación de un satélite SAR en banda P para observar la distribución espacial de la biomasa forestal a escala global, prestando especial atención sobre las regiones consideradas como críticas en la generación y el secuestro de carbono.

A la vista del objetivo general de esta tesis y de las características del área de estudio, la Dra. Le Toan determinó que las imágenes radar que, *a priori*, mejor se adaptaban a nuestro trabajo eran las proporcionadas por el sensor ASAR situado a bordo de la plataforma espacial Envisat. En efecto, la información en banda C suministrada por este sensor se han mostrado útil en la estimación de algunas fracciones de la biomasa de la copa de los árboles que están contenidas en la fracción de biomasa delimitada como residual en este trabajo (Moghaddam *et al.*, 2002). Esto se debe a que, como se ha señalado en la revisión bibliográfica, los elementos de los árboles que fundamentalmente controlan la retrodispersión en esta longitud de onda son el follaje y las ramas (Le Toan *et*

al., 1992; Dobson, 2000). Por otra parte, bajo determinadas condiciones y mediante la aplicación de determinadas técnicas, es posible también estimar biomasa total utilizando información en banda C procedente de imágenes de satélite (Kurvonen *et al.*, 1999, Pulliainen *et al.*, 1999; Kurvonen *et al.*, 2002), existiendo experiencias positivas en medios mediterráneos (Paloscia *et al.*, 1999), aunque también negativas (Svoray *et al.*, 2001). Otras características de las imágenes Envisat-ASAR, que las convierten en especialmente útiles para nuestro objetivo, son su resolución espacial y su tamaño de escena (30 m de píxel y 100 km, respectivamente, en el sistema de captura *Image Mode*), apropiadas para la escala regional. Por último, destacar la disposición y las facilidades mostradas por CESBIO para la adquisición de este tipo de imágenes de forma gratuita –en el marco de un acuerdo de colaboración con la ESA- y para su procesamiento.

En total se seleccionaron 9 imágenes Envisat-ASAR que contenían diferentes sectores de la provincia de Teruel y que fueron capturadas a lo largo del año 2003, tanto en órbita ascendente (5) como en descendente (4) al objeto de minimizar algunos de los efectos que la topografía compleja del área de estudio podía tener en la señal registrada. Dos son los tratamientos que se aplican con el objetivo de obtener variables radiométricas susceptibles de ser relacionadas con los datos de biomasa residual forestal:

- **Calibración radiométrica absoluta.** Consistente en normalizar el coeficiente de retrodispersión de las imágenes por unidad de superficie sobre el terreno en la horizontal. Como resultado, las imágenes quedan expresadas en unidades de σ^0 , que es la medida utilizada en la mayoría de trabajos que se sirven de imágenes radar para estimar parámetros biofísicos.
- **Corrección geométrica.** Aplicada con objeto de transformar las coordenadas fila/columna de las imágenes SAR en coordenadas ortogonales, por ejemplo del sistema UTM. Como en las imágenes Landsat, la importancia de este pre-tratamiento es máxima debido a que estas imágenes van a ser relacionadas con los datos de biomasa residual y van a ser integradas en un SIG.

III. Obtención de las variables auxiliares topográficas

Esta tercera actividad se vincula con el objetivo operativo III y consiste en la aplicación de una serie de algoritmos al MDE creado en el apartado 2.2 para derivar

información topográfica útil a la hora de estimar la biomasa residual forestal. Así, mediante la utilización de herramientas SIG se derivan las siguientes coberturas topográficas: elevación, pendiente, orientación, insolación potencial anual, insolación potencial en los equinoccios de primavera y otoño, insolación potencial en los solsticios de invierno y verano y curvatura de la superficie.

Todas estas variables independientes, a excepción de la orientación, se incorporan al modelo como variables continuas. La orientación se reclasifica en dos categorías: norte y sur. Por su parte, todas las variables relacionadas con la insolación potencial se calculan considerando dos unidades distintas: el número de horas de insolación y la cantidad de iluminación recibida, por lo que de cada tipo de insolación potencial se incorporan dos variables.

Esta actividad se desarrolla en el Capítulo 2, en el apartado 2.5.

IV. Obtención de las variables auxiliares forestales

Al igual que la actividad anterior, ésta se relaciona también con el objetivo operativo III. En concreto, se considera que es útil el conocimiento y modelado de variables forestales que informen acerca de la estructura y fisonomía de los bosques estudiados ya que, como se ha subrayado, la estructura heterogénea de los bosques mediterráneos condiciona la obtención de modelos de estimación de parámetros forestales mediante teledetección.

En este sentido, para conocer la influencia de la estructura y de la fisonomía-fisiología de las masas forestales en la estimación de biomasa residual, se consideraron las variables Tipo Climático Estructural (TCE) y Nivel de Madurez, ambas procedentes del *Mapa Forestal de Aragón 1:50.000* (MFA), que sigue la metodología utilizada en el *Mapa Forestal de España: Escala 1:200.000* (Escudero y Franchès, 2004).

Por cuanto se dispone del *Mapa Forestal de Aragón 1:50.000* en formato digital, se utilizan herramientas SIG para extraer de él la información sobre TCE y Nivel de Madurez de los bosques de la provincia de Teruel, generándose, mediante funciones de reclasificación, una cartografía distinta para cada variable. Posteriormente, para facilitar la interpretación en el modelo de ambas, las categorías presentes en cada una de ellas son reclasificadas en dos grupos, distinguiéndose entre las clases que, por definición, presentan mayores cantidades de biomasa y las que menos tienen. De esta manera, estas dos variables se incorporan al modelo como variables categóricas.

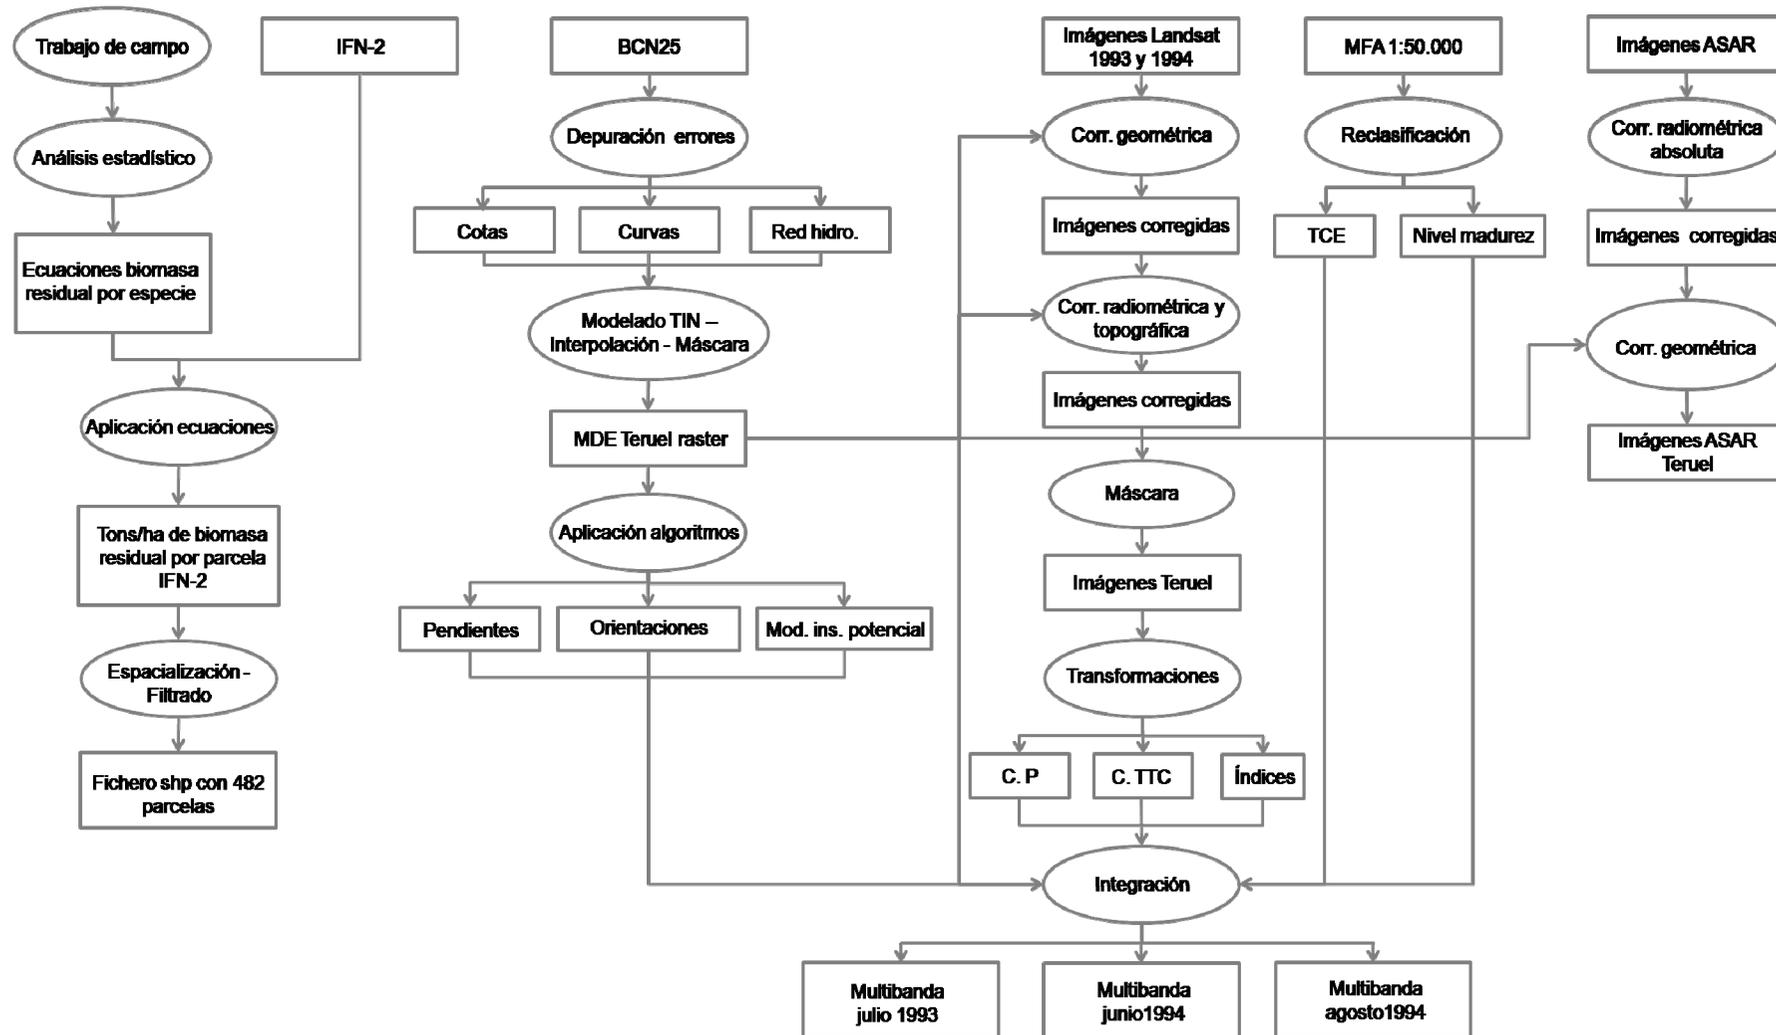


Figura 1.9. Diagrama de flujos de la fase metodológica 1

Esta actividad y los procedimientos que la integran se describen en el apartado 2.6 del Capítulo 2.

La Figura 1.9 ofrece una visión esquemática de estas cuatro actividades que componen esta primera fase de la investigación, mostrando los distintos procesos y resultados parciales que engloba y las interrelaciones entre ellos.

Fase 2. Formulación del modelo de estimación de biomasa residual forestal y validación

Esta fase se divide en 3 actividades, que se muestran en las siguientes páginas.

V. Extracción de la información de las variables radiométricas, topográficas y forestales para su relación con los datos de biomasa residual forestal mediante distintas metodologías

En relación con el objetivo operativo IV, esta actividad consiste en ensayar, con las imágenes Landsat, distintos procedimientos de extracción de la información radiométrica y auxiliar, identificando cuál de ellos es el más adecuado para establecer el mejor modelo de estimación, tanto en términos estadísticos como operativos. En cambio, en las imágenes Envisat-ASAR, en función de sus particularidades, solamente se utiliza un método de extracción.

Dada esta peculiaridad con respecto a las imágenes Landsat, esta actividad V no se desarrolla en un apartado específico de la presente tesis, sino que se reparte a lo largo de distintos apartados, integrados todos ellos en el Capítulo 3, en que se aborda el establecimiento de distintos modelos de regresión.

Respecto de las imágenes Landsat, aunque se contó desde un inicio con un total de tres escenas coetáneas con los datos del IFN-2 (julio de 1993, junio de 1994 y agosto de 1994), los ensayos de extracción de la información radiométrica sólo se llevan a cabo con la imagen de junio de 1994. Esto se justifica por la alta auto-correlación existentes entre ellas, ya que recogen información del mismo espacio en un breve periodo de tiempo (13 meses) y siempre en el periodo estival. De esta manera, las imágenes de julio de 1993 y de agosto de 1994 se reservan para la validación, tanto del método de extracción que arroje mejores resultados con la imagen de junio de 1994, como de las relaciones biofísicas encontradas entre la biomasa residual y las variables radiométricas.

De esta manera, teniendo en cuenta que solamente se utiliza en esta actividad la imagen Landsat de junio de 1994, la forma de proceder es la siguiente: utilizando la cartografía puntual de biomasa residual forestal creada en el apartado 2.1, se ensayan procedimientos simples de extracción de la información radiométrica, topográfica y forestal; una vez extraída la información se estudian las correlaciones entre la variable dependiente (biomasa) y las independientes (radiométricas, topográficas o forestales) y se establece un modelo de regresión; si los resultados son susceptibles de ser mejorados, se ensaya otro método más complejo que elimine alguno de los problemas identificados; este procedimiento se repite hasta que se considera que no es posible mejorar el modelo a través de la utilización de otro método de extracción.

VI. Formulación de distintos métodos de estimación de la biomasa residual forestal en la provincia de Teruel

Esta actividad, segunda de la fase 2, se dirige al cumplimiento del objetivo operativo V, por lo que constituye la parte central de esta investigación.

En el caso de las imágenes Landsat, al igual que la actividad V (con la que está íntimamente relacionada), se desarrolla a lo largo del Capítulo 3 de una manera secuencial, utilizándose siempre la imagen de junio de 1994. En primer lugar, se estudian las correlaciones entre la variable dependiente y las independientes obtenidas a partir de la aplicación del mecanismo más simple de extracción de la información. También, debido a la importancia de evitar la formulación de modelos no robustos, son examinadas las auto-correlaciones entre variables independientes. Este segundo análisis se efectúa con el fin de cumplir uno de los requisitos básicos del análisis de regresión: la ausencia de variables independientes altamente correlacionadas (Hair *et al.*, 1999). En función de los resultados obtenidos en el análisis de correlación se formula el modelo de regresión más factible, vigilando el estricto cumplimiento de las reglas básicas que afecten al tipo de regresión seleccionada. La formulación del modelo de regresión lleva implícita la división de la muestra en dos subgrupos, de tal manera que un porcentaje de la muestra se emplea para ajustar el modelo, mientras la segunda se utiliza para validarlo.

El análisis de los resultados finales obtenidos en el primero de los modelos lleva a una fase de reflexión sobre el método de extracción seleccionado, las técnicas estadísticas utilizadas y el grado de satisfacción logrado en relación con el objetivo marco de la presente investigación. Esta fase de reflexión desemboca en la formulación de una nueva aproximación para encontrar un nuevo modelo de regresión modificando algunos

de los criterios y técnicas aplicadas con anterioridad, ya que se conoce mejor todas las variables implicadas en el modelo. Sobre los nuevos resultados obtenidos se abre otro proceso de análisis y reflexión que llevará al enunciado de otro nuevo modelo de estimación.

Se trata pues de un proceso dinámico e interactivo en el que las estrategias a aplicar en el nuevo modelo quedan definidas en función de los resultados anteriores y de las soluciones aportadas por otros autores que han encontrado problemas similares en trabajos análogos sobre estimación de parámetros forestales de inventario, LAI o biomasa.

En el caso de las imágenes Envisat-ASAR este proceso es mucho más sencillo, ya que las peculiaridades de este tipo de imágenes hacen que solamente se cuente con unas pocas parcelas tipo sobre las que poder estudiar cuál es la relación entre la biomasa residual forestal y la información proporcionada por este tipo de imágenes. Se trata, pues, de un análisis meramente exploratorio de tales relaciones, no pudiendo ser utilizados los modelos estimativos que se obtienen, dada la escasa población de la muestra utilizada. Junto a este motivo se añade el de la no coetaneidad de los datos de campo de la biomasa residual (1994) con estos datos radiométricos (2003).

VII. Validación de la metodología y de las relaciones biofísicas encontradas en los modelos de estimación en la dimensión temporal

Esta actividad se relaciona con el objetivo operativo VI y consiste en la utilización de las imágenes Landsat de julio de 1993 y junio de 1994 para validar, en primer lugar, la consistencia de la mejor metodología encontrada para extraer la información radiométrica en este tipo de imágenes y, en segundo, para conocer la estabilidad de las relaciones encontradas entre la biomasa residual forestal y las variables radiométricas obtenidas de la imagen de junio de 1994.

Para ello, se replica el mejor método encontrado en el Capítulo 3, teniendo en cuenta determinadas particularidades de las dos escenas empleadas, que explican que las parcelas del IFN-2 a considerar varíen ligeramente con respecto a la de junio de 1994. Una vez obtenidos los datos, se replica todo el proceso de cálculo de los modelos de regresión (análisis de correlaciones, ajuste de los modelos, validación de los mismos) y se validan las nuevas cartografías de estimación obtenidas utilizando también la misma metodología que en las obtenidas en el Capítulo 3.

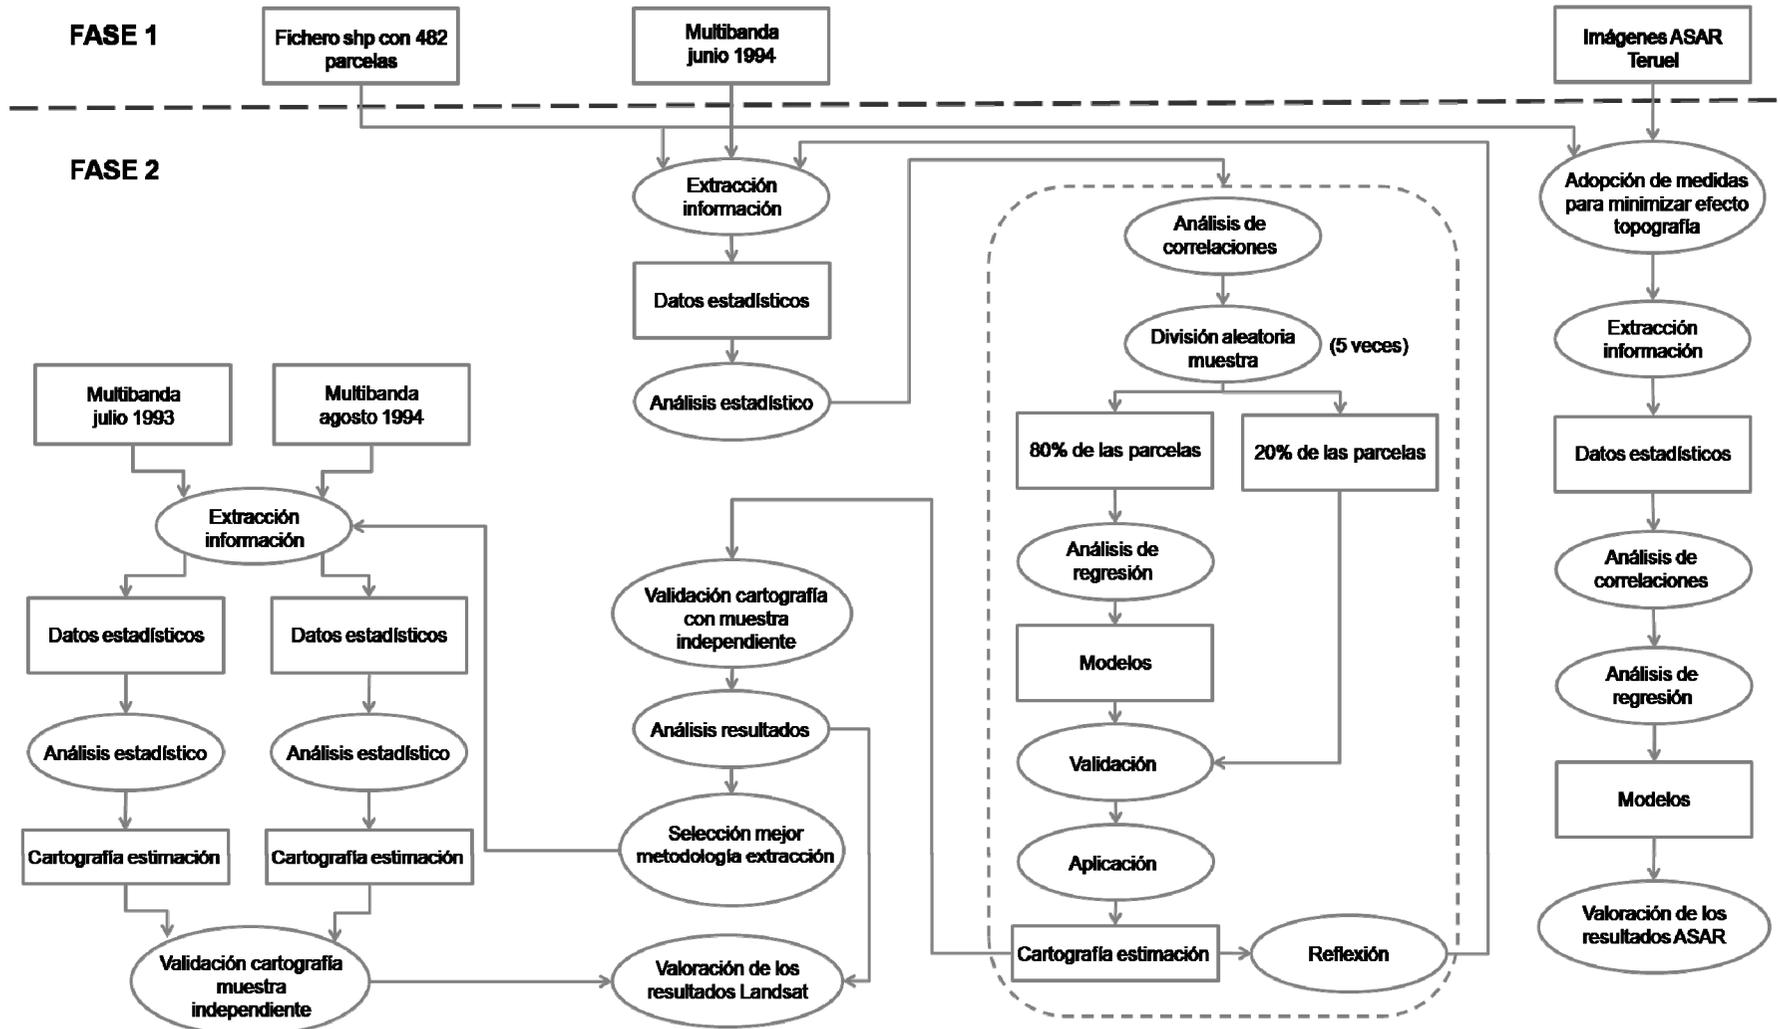


Figura 1.10. Diagrama de flujos de la fase metodológica 2

El éxito en esta actividad determina la posibilidad de extrapolar la metodología ajustada en el tiempo, haciendo posible la estimación de la biomasa residual en el área de estudio en la actualidad mediante el uso de una imagen Landsat más reciente que las utilizadas para calibrar y validar los modelos de estimación. Esta actividad se desarrolla a lo largo del Capítulo 4.

La figura 1.10 recoge el diagrama de flujos de las distintas actividades contempladas en esta fase metodológica 2.

Fase 3. Aplicación de la metodología para la estimación de la biomasa residual forestal actual en la provincia de Teruel

Esta última fase comprende tres actividades, relacionadas directamente con el objetivo operativo VII y desarrolladas a lo largo del Capítulo 5.

VIII. Selección de la imagen, aplicación de pretratamientos y estimación de la biomasa residual forestal

Para obtener la información de la biomasa residual forestal actual en el área de estudio es necesario, en primer lugar, adquirir una imagen Landsat análoga en cuanto a sus características espaciales y temporales a las utilizadas en los capítulos 3 y 4; debe, por tanto, contener todo el territorio estudiado, estar libre de nubes y haber sido adquirida por el sensor en verano.

Una vez adquirida la imagen, debe ser sometida a los pretratamientos de corrección geométrica y radiométrica, teniendo que ser estos procesos tan rigurosos como en las imágenes que han servido para ajustar el modelo de estimación. Se trata, en definitiva, de garantizar la correcta estimación de la biomasa en cada punto del territorio a partir del valor radiométrico de cada píxel, sin que éste valor esté influenciado por las distorsiones que introducen la atmósfera y la topografía en la señal registrada por el sensor. Seguidamente, caso de ser necesario para la aplicación de la ecuación de estimación, se aplican las transformaciones necesarias para la obtención de neocanales.

El último paso consiste en la aplicación del modelo de estimación de biomasa residual más adecuado de los obtenidos en los capítulos 3 y 4 en función de la fecha de adquisición de la imagen.

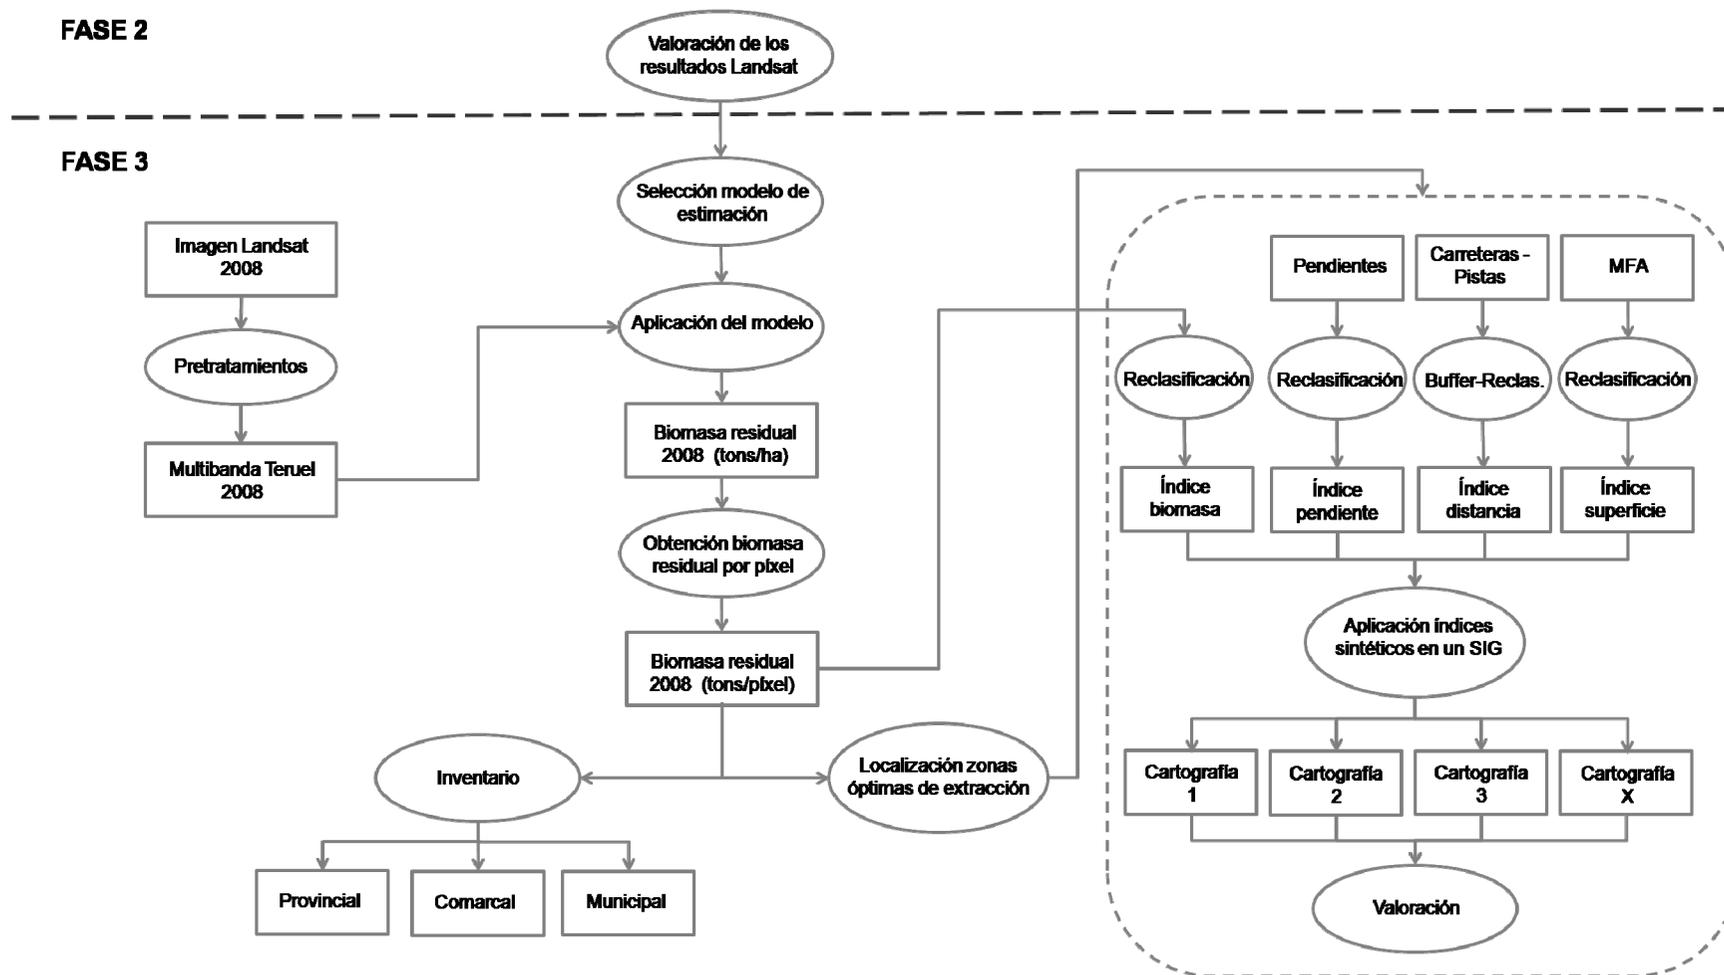


Figura 1.11. Diagrama de flujos de la fase metodológica 3

IX. Inventario de los recursos energéticos de biomasa residual forestal del área de estudio a escala provincial, comarcal y municipal

Esta actividad consiste en derivar información cartográfica y estadística sobre el recurso utilizando para ello las tres divisiones administrativas existentes en el área de estudio, si bien sólo se crearán mapas para las dos primeras⁵. De esta manera se proporcionan datos precisos del territorio a los agentes implicados en la promoción y el desarrollo de las energías renovables en general y de la biomasa en particular.

X. Desarrollo de una metodología para localizar las zonas óptimas de explotación de biomasa residual forestal

Una vez conocida la cantidad de recurso existente en cada punto de la provincia de Teruel, se combina esta variable con otras tres de fuerte impronta espacial que, junto a la primera, determinan la viabilidad de extracción de la biomasa residual para su uso energético: la pendiente, la extensión del área forestal y la distancia a pistas, caminos y carreteras. Con esta finalidad se utilizan herramientas SIG para, en primer lugar, asignar distintos grados de aptitud en función del valor de cada variable en cada punto del territorio, siendo utilizado para ello bibliografía específica relativa a la incidencia de estos factores en la eficiencia-rentabilidad de la explotación. En segundo lugar, las capas resultantes de esta reclasificación son combinadas en el SIG mediante la utilización de uno o varios índices que ofrecen como resultado final una cartografía de las zonas óptimas para el aprovechamiento de la biomasa residual, estableciendo una escala cuantitativa dentro de ellas.

La figura 1.11 recoge el diagrama de flujos de los procesos y resultados parciales y finales de esta última fase de la metodología.

1.4.3. Técnicas estadísticas para el ajuste de los modelos de estimación de la biomasa residual forestal

En los siguientes subapartados se presentan las técnicas estadísticas usadas en el análisis de las correlaciones y en el ajuste de los modelos de regresión entre los datos de biomasa residual forestal obtenidos del trabajo de campo (variable dependiente) y las

⁵ La provincia de Teruel incluye 236 municipios, por lo que generar cartografía específica para cada uno de ellos incrementaría en exceso el volumen de esta tesis. No obstante, esta cartografía puede ser obtenida en cualquier momento en caso de ser requerida por las distintas Administraciones, dado el carácter digital de la información base y su integración en un SIG.

variables radiométricas, topográficas y forestales obtenidas a partir de las imágenes de satélite, del MDE y del MFA, respectivamente (variables independientes).

1.4.3.1. Análisis de correlaciones

El análisis de correlación es una técnica estadística que describe la relación entre dos variables medidas en una muestra común de individuos (Ebdon, 1982). Para determinar la existencia o no de esta relación, su fuerza, su dirección y su significación estadística, se utiliza el coeficiente de correlación de *Pearson*. Este coeficiente -o *producto-momento*- es una medida paramétrica de la fuerza y la dirección de la relación lineal entre dos variables. Éstas deben estar medidas en una escala métrica y se presupone que proceden de poblaciones normalmente distribuidas (Ebdon, 1982). La correlación de *Pearson* se calcula mediante la aplicación de la siguiente ecuación:

$$R = \frac{(\sum xy / n) - (\bar{x}\bar{y})}{s_x s_y} \quad \text{Ecuación 1}$$

donde R es el coeficiente de correlación de *Pearson*, x e y refieren a los valores de las variables, n es el número de observaciones, \bar{x} e \bar{y} son las medias de las variables y s_x y s_y son las desviaciones estándar de muestra de las variables (adaptado de Ebdon, 1982).

El resultado varía entre -1 y 1, indicando el valor 0 la ausencia de correlación y siendo ésta mayor cuanto más alto sea el valor obtenido. El signo indica si la correlación es directa (positiva) o indirecta (negativa) (Ebdon, 1982, Hair *et al.*, 1999; Pardo y Ruiz, 2005). El nivel crítico de significación (p) para considerar las correlaciones como significativas ha sido 0,05, siguiéndose las directrices convencionales. Así, se rechazará la hipótesis nula de independencia y se concluirá que existe relación entre las dos variables cuando $p < 0,05$. La prueba de significación se realiza mediante el estadístico t (Ebdon, 1982; Hair *et al.*, 1999; Pardo y Ruiz, 2005), que adopta la siguiente forma:

$$t = \frac{R\sqrt{n-2}}{\sqrt{1-R^2}} \quad \text{Ecuación 2}$$

donde R es el coeficiente de correlación de *Pearson* y n es el número de casos (adaptado de Pardo y Ruiz, 2005).

1.4.3.2. Ajuste de los modelos de regresión

El análisis de regresión es una técnica estadística de dependencia utilizada para

predecir una única variable criterio (dependiente) a partir del conocimiento de una o más predictoras (independientes). Cada variable independiente es analizada y ponderada; estas ponderaciones indican su utilidad y su contribución relativa a la predicción. Al calcular las ponderaciones, el procedimiento del análisis de regresión asegura la máxima predicción a partir del conjunto de variables independientes consideradas (Hair *et al.*, 1999). En este trabajo se consideran tres tipos de regresión: lineal, curvilínea y logística.

1.4.3.2.1. Regresión lineal

La regresión lineal se basa en el cálculo de una ecuación de una línea de mínimos cuadrados para predecir la variable dependiente a partir de los valores de una o de varias independientes (regresión lineal simple o múltiple, respectivamente). Tanto la variable dependiente como las independientes deben estar medidas en escala métrica, aunque bajo determinadas circunstancias es posible incluir datos no métricos para las independientes. El resultado es una ecuación de regresión -simple o múltiple- que estima la variable dependiente dando información acerca de la(s) independiente(s) más útil(es) (Ecuación 3) (Ebdon, 1982; Hair *et al.*, 1999; Etxeverría, 1999).

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad \text{Ecuación 3}$$

donde Y es la variable dependiente que se quiere predecir, β_0 es el valor de la constante, β_n es el coeficiente de regresión de la variable independiente X_n (adaptado de Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

Las diferencias entre los valores reales de la variable dependiente (Y_i) y los predichos (Y_i') mediante la ecuación lineal ajustada por mínimos cuadrados reciben el nombre de residuos (r_i), de tal manera que se cumple la siguiente igualdad (Ecuación 4):

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i' - \bar{Y})^2 + \sum_{i=1}^n (Y_i - Y_i')^2$$

STC	=	SCR	+	SCE
Suma total de cuadrados		Suma de los cuadrados de la regresión		Suma de cuadrados de los residuos

Ecuación 4

donde Y_i es el valor real para la observación i , \bar{Y} es la media de los valores reales, Y_i' es el valor pronosticado para la observación i (adaptado de Etxeverría, 1999; Hair *et al.*, 1999).

- Valoración de la exactitud de la predicción

Para cuantificar la proporción de la varianza de la variable dependiente que es explicada por las independientes se utiliza el coeficiente de determinación (R^2), que es el cociente entre la suma de los cuadrados de la regresión y la suma total de cuadrados.

$$R^2 = \frac{\sum_{i=1}^n (Y'_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad \text{Ecuación 5}$$

donde R^2 es el coeficiente de determinación, Y_i es el valor real para la observación i , \bar{Y} es la media de los valores reales, Y'_i es el valor pronosticado para la observación i (adaptado de Etxeverría, 1999; Hair *et al.*, 1999).

El valor resultante es siempre positivo y varía entre 0 y 1, siendo mayor el poder explicativo del modelo de regresión cuanto más alto sea (Ebdon, 1982; Etxeverría, 1999; Hair *et al.*, 1999; Pardo y Ruiz, 2005).

Una variante del R^2 es el *coeficiente de determinación corregido o ajustado* (R^2_a), que tiene en cuenta el número de variables independientes incluidas en la ecuación de regresión (Ecuación 6), corrigiendo el efecto de aumento de R^2 por la adición de variables independientes al modelo de regresión si éstas tienen escaso poder explicativo y/o si los grados de libertad se vuelven demasiado pequeños. De esta manera, el R^2_a se hace más pequeño a medida que se tienen menos observaciones por variable independiente, resultando muy adecuado para comparar ecuaciones con un número diferente de variables independientes, tamaños muestrales diferentes o ambos (Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

$$R^2_a = R^2 - \left(\frac{p(1 - R^2)}{n - p - 1} \right) \quad \text{Ecuación 6}$$

donde R^2 es el coeficiente de determinación, p es el número de variables independientes y n es el número de casos (adaptado de Pardo y Ruiz, 2005).

Los residuos también pueden ser utilizados para valorar globalmente la exactitud de la predicción. De los distintos estadísticos que los utilizan se han seleccionado tres: el error estándar de la estimación (S_e), el error cuadrático medio ($RMSE$) y el $RMSE$ relativo

($RMSE_r$) (Ecuaciones 7, 8 y 9, respectivamente). El primero, proporcionado por defecto por el programa estadístico utilizado (SPSS), permite una rápida comparación de los distintos modelos creados; el segundo, se ha seleccionado por ser muy utilizado en trabajos de estimación de parámetros forestales (p.e. Fazakas *et al.*, 1999; Hagner, 2002; Pekkarinen, 2002; Mäkelä y Pekkarinen, 2004; Muukkonen y Heiskanen, 2005; Tuominen y Pekkarinen, 2005; Hall *et al.*, 2006; Labrecque *et al.*, 2006); el tercero se ha considerado muy útil porque ofrece una medida del error independiente del rango de valores reales observados en la submuestra de validación, lo que permite la comparación directa entre los modelos ajustados en este trabajo y los obtenidos en otros (p.e. Mäkelä y Pekkarinen, 2001; Hagner, 2002; Pekkarinen, 2002; Mäkelä y Pekkarinen, 2004; Muukkonen y Heiskanen, 2005; Tuominen y Pekkarinen, 2005). Los tres índices se interpretan de igual forma: cuanto menor es el valor obtenido, mejor es el modelo de regresión.

$$S_e = \sqrt{\frac{\sum_{i=1}^n (Y_i - Y_i')^2}{n-2}} \quad \text{Ecuación 7}$$

donde S_e es el error estándar de la estimación, Y_i es el valor real para la observación i , Y_i' es el valor pronosticado para la observación i y n es el número de casos (adaptado de Pardo y Ruiz, 2005).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - Y_i')^2}{n}} \quad \text{Ecuación 8}$$

donde $RMSE$ es el error cuadrático medio, teniendo los restantes términos idéntico significado que en la Ecuación 7 (adaptado de Pekkarinen, 2002).

$$RMSE_r = \frac{RMSE}{\bar{Y}} * 100 \quad \text{Ecuación 9}$$

donde $RMSE_r$ es el error cuadrático medio relativo, $RMSE$ es el error cuadrático medio e \bar{Y} es la media de los valores reales (adaptado de Muukkonen y Heiskanen, 2005).

El examen de la significación estadística se hace a dos niveles: a nivel de modelo y a nivel de los coeficientes de regresión de las variables independientes seleccionadas

(incluida también la constante). Para contrastar la hipótesis de que la cantidad de variación explicada por el modelo es mayor que la variación explicada por su media (es decir, que $R^2 > 0$) se utiliza el estadístico F (Ecuación 10), sobre el que se aplica la prueba de significación (normalmente $p < 0,05$) (Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

$$F = \frac{\sum_{i=1}^n (Y'_i - \bar{Y})^2 / p}{\sum_{i=1}^n (Y_i - Y'_i)^2 / (n - p - 1)} \quad \text{Ecuación 10}$$

donde F es el estadístico F , Y'_i es el valor pronosticado para la observación i , \bar{Y} es la media de los valores reales, Y_i es el valor real para la observación i , p es el número de variables independientes y n es el número de casos (adaptado de Etxeverría, 1999; Hair *et al.*, 1999).

Por su parte, el estadístico t (Ecuaciones 11 y 12) y su prueba de significación permiten validar la hipótesis de que los coeficientes de regresión β_n y la constante β_0 calculados en el modelo son distintos de 0 y, por lo tanto, son representativos para toda la población (Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

$$t_{\beta_0} = \frac{\beta_0}{S_{\beta_0}} \quad \text{Ecuación 11}$$

donde t_{β_0} es el estadístico t de la constante, β_0 es la constante y S_{β_0} es el error estándar de la constante (adaptado de Pardo y Ruiz, 2005).

$$t_{\beta_n} = \frac{\beta_n}{S_{\beta_n}} \quad \text{Ecuación 12}$$

donde t_{β_n} es el estadístico t del coeficiente de regresión $-\beta_n-$ de la variable independiente n y S_{β_n} es el error estándar de β_n (adaptado de Pardo y Ruiz, 2005).

- Supuestos del análisis de regresión lineal y soluciones en caso de incumplimiento

El análisis de regresión debe respetar una serie de supuestos subyacentes que deben ser contrastados dos veces: en primer lugar para las variables individuales que lo pueden integrar (dependiente e independientes) y en segundo lugar para el valor teórico

del modelo una vez calculado, ya que éste actúa colectivamente sobre las variables utilizadas y, por tanto, debe cumplir los mismos supuestos que las variables individuales. Así pues, es necesario un examen previo de las variables para saber si se puede o no aplicar un modelo de regresión lineal, mientras que el examen posterior permite afirmar que éste es válido (Ebdon, 1982; Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005). A continuación se detalla cada uno de estos supuestos, indicando los métodos estadísticos utilizados para la evaluación de su cumplimiento y las soluciones que pueden ser aplicadas a las variables individuales en caso de incumplimiento.

- **Supuesto de normalidad.** Aspecto fundamental del análisis de regresión, refiere a la necesidad de que tanto la variable dependiente como las independientes se ajusten a una distribución normal. Si las variables consideradas se alejan en exceso de la normalidad, los test estadísticos de significación de la regresión $-t$ y F - carecen de valor, por lo que no se puede inferir la validez del modelo (Hair *et al.*, 1999; Pardo y Ruiz, 2005).

La normalidad univariante de las variables del modelo de regresión lineal es fácil de contrastar mediante métodos gráficos y test estadísticos. Dentro de los primeros se encuentran el análisis del histograma y del gráfico de normalidad; destacando dentro de los segundos los test de simetría, la kurtosis y las pruebas de Kolmogorov-Smirnov (K-S) y Shapiro-Wilks (S-W), siendo esta última más adecuada que la primera para muestras pequeñas ($n < 30$). En caso de que las variables no presenten normalidad pueden ser transformadas empleando la raíz cuadrada, logaritmos o la inversa o el cuadrado. Normalmente, las distribuciones con asimetría positiva (a la derecha) se transforman de forma más efectiva con logaritmos, mientras que las que tienen asimetría negativa (a la izquierda) lo hacen con la raíz cuadrada. De todos modos, se recomienda aplicar todas las transformaciones posibles para después seleccionar la variable transformada más apropiada (Hair *et al.*, 1999; Pardo y Ruiz, 2005).

Aunque la normalidad de las variables utilizadas ayuda a obtener normalidad en el modelo de regresión, ésta no queda garantizada, por lo que es necesario contrastarla a partir del estudio de la distribución de los residuos tipificados. Se considera bueno el modelo si estos residuos se ajustan a una distribución normal; para validar este extremo pueden usarse los mismos

métodos que con las variables individuales (Hair et al., 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

- **Supuesto de homocedasticidad.** Refiere al supuesto de que la variable dependiente exhiba igual nivel de varianza a lo largo del rango de las variables independientes. La mayoría de problemas de varianzas desiguales entre la variable dependiente y las dependientes (heterocedasticidad) se relaciona con diferencias en unidades entre ambas y/o a la ausencia de distribución normal en la dependiente, en las independientes o en ambos tipos (Hair et al., 1999).

La prueba de homocedasticidad entre la variable dependiente y cada una de las independientes que se van a utilizar en el modelo de regresión se hace mediante los gráficos de dispersión individuales que relacionan ambos tipos de variables. Este test gráfico también es útil para detectar el incumplimiento de este supuesto una vez ajustado el modelo, usándose en este caso para su edición los residuos tipificados frente a los valores pronosticados (Hair et al., 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

Los problemas de heterocedasticidad pueden solucionarse a través de la aplicación de las mismas transformaciones de datos que las usadas para conseguir la normalidad ya que, como se ha indicado, en muchas ocasiones la heterocedasticidad es resultado de la no-normalidad (Hair et al., 1999).

- **Supuesto de linealidad.** El cumplimiento de este supuesto entre la variable dependiente y las independientes es básico, ya que, si no se cumple, carece de sentido utilizar el método de regresión lineal. La forma más común de evaluar la linealidad entre variables es el gráfico de dispersión, siendo también este método adecuado para evaluar este supuesto en el modelo de regresión obtenido mediante el uso de los valores tipificados de los residuos y de los valores pronosticados (Hair et al., 1999; Etxeverría, 1999).

Las transformaciones comentadas pueden resolver el problema de la ausencia de linealidad entre las variables, siendo también posible la utilización de variables adicionales polinómicas que representan los componentes no lineales, aunque su creación está condicionada a la existencia de una explicación teórica, ya que si no se corre el riesgo de encontrar buenos resultados que sean poco generalizables (Hair et al., 1999; Etxeverría, 1999).

- **Supuesto de independencia.** Este supuesto refiere a que cualquiera de los errores obtenidos en la predicción no debe estar relacionado con el resto; es decir, los residuos constituyen una variable aleatoria que no responde a ningún patrón. Si esto sucede, significa que existe alguna relación sistemática en la variable dependiente que no ha sido explicada con el conjunto de independientes utilizadas (Hair *et al.*, 1999; Etxeverría, 1999).

Para identificar este hecho se utiliza el gráfico de dispersión de los residuos tipificados frente a los valores pronosticados o frente a cualquier variable de secuencia habitual como, por ejemplo, el tiempo (Hair *et al.*, 1999; Etxeverría, 1999). Otra forma de evaluación es mediante la utilización del estadístico Durbin-Watson (Etxeverría, 1999; Pardo y Ruiz, 2005).

- **Supuesto de no-colinealidad.** Refiere a la inexistencia de altas correlaciones entre las variables independientes utilizadas en el modelo. El incumplimiento de este supuesto es grave y da origen a modelos afectados por colinealidad o multicolinealidad (Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

Los efectos de la multicolinealidad se pueden clasificar en términos de explicación y estimación. Los primeros conciernen principalmente a la capacidad del procedimiento de regresión y a la capacidad del investigador para representar y comprender los efectos de cada variable en el valor teórico de regresión. Así, la presencia de multicolinealidad limita el tamaño del R^2 y hace más difícil añadir una predicción explicativa extra con variables adicionales. Además, la explicación del efecto que las variables independientes tienen en la dependiente se hace difícil debido a que sus efectos son mixtos o se confunden (niveles altos de varianza compartida y niveles bajos de varianza única). Por su parte, los efectos sobre la estimación refieren al cálculo incorrecto de los coeficientes de regresión y de sus pruebas de significación estadística, hasta el punto de que resulte imposible calcular ningún coeficiente de correlación, de equivocarse el sentido de la relación entre las variables independientes y la dependiente o de hacerlos altamente inestables (pequeños cambios en los datos producen cambios muy grandes) (Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

El método más simple de identificar la colinealidad es el examen de la matriz de correlación de las variables independientes. La existencia de una

elevada correlación entre dos de ellas indica que, si se utilizan juntas en el modelo, se incumplirá el supuesto (Hair *et al.*, 1999). A este respecto se debe señalar que no existe consenso acerca del grado máximo de correlación permisible entre variables independientes (Pardo y Ruiz, 2005).

Aunque se lleve a cabo este análisis, un modelo de regresión múltiple puede violar el supuesto de no-colinealidad, ya que la ausencia de correlación entre dos variables no garantiza la no-colinealidad en el modelo, que puede deberse a los efectos combinados de dos o más variables independientes. Para evaluar la colinealidad del modelo de regresión ya ajustado se pueden utilizar tres estadísticos: el valor de tolerancia, el factor de inflación de la varianza (*FIV*) y los índices de condición (Hair *et al.*, 1999; Etxeverría, 1999; Pardo y Ruiz, 2005).

Si se detecta colinealidad en el modelo a pesar de haber introducido variables independientes poco correlacionadas, existen varias opciones: (i) omitir una o varias correlacionadas e identificar otras⁶; (ii) utilizar el modelo con las variables correlacionadas sólo para predecir, sin interpretar los coeficientes; (iii) utilizar las correlaciones simples entre cada variable independiente y la variable dependiente para entender la relación entre ambas; (iv) utilizar un método más sofisticado, como la regresión bayesiana o una regresión de componentes principales; (v) utilizar métodos de búsqueda secuencial para ajustar el modelo (Hair *et al.*, 1999; Etxeverría, 1999).

Además de estos supuestos, hay que tener en cuenta la influencia del tamaño de la muestra en la generalización de los resultados. Así, con el fin de que el modelo no esté sobre-ajustado a la muestra y sea generalizable a toda la población, se recomienda entre 15 y 20 observaciones por cada variable independiente incluida (Hair *et al.*, 1999).

- *Métodos de selección de variables*

Cuando se dispone de varias variables independientes existen dos formas de especificar el modelo de regresión: mediante especificación confirmatoria o mediante métodos de búsqueda secuencial. El primero se presenta como adecuado cuando se quiere emplear el modelo de regresión desde una perspectiva confirmatoria, siendo el

⁶ Esta opción puede originar un problema de especificación en el modelo de regresión, obviando la entrada de variables que sean realmente útiles para la predicción de la variable dependiente.

investigador quien especifica las variables independientes a incluir; se debe tener seguridad de que el conjunto de variables escogidas consigue la máxima predicción mientras se mantiene la parsimonia del modelo. Por su parte, los métodos de búsqueda secuencial permiten elegir entre el conjunto de variables independientes aquéllas que expliquen mejor la dependiente, por lo que tiene un carácter más exploratorio. Esta aproximación proporciona un método objetivo de selección de las variables que maximizan la predicción con el número más pequeño de las variables consideradas (Hair *et al.*, 1999), evitando incumplir el supuesto de no-colinealidad (Etxeverría, 1999). Dado que en este trabajo se pretende seleccionar, del conjunto de variables independientes creadas en el Capítulo 2 (radiométricas, topográficas y forestales), las que mejor estimen la cantidad de biomasa residual forestal, los métodos de búsqueda secuencial resultan más adecuados.

Son tres los métodos de búsqueda secuencial más habituales: *hacia delante (forward)*, *hacia atrás (backward)* y de *pasos sucesivos (stepwise)*. Basan la selección de variables en dos criterios estadísticos (Pardo y Ruiz, 2005):

- **Criterio de significación.** Se incorporan al modelo de regresión sólo las variables que contribuyen al modelo de forma significativa. El programa SPSS incluye dos criterios de significación:
 - o *Probabilidad de F.* Una variable entra a formar parte si el nivel crítico asociado a su coeficiente de correlación parcial al contrastar la hipótesis de independencia es $<0,05$, queda fuera si es $>0,10$.
 - o *Valor de F.* Una variable se introduce si el valor de F utilizado para contrastar la hipótesis de independencia es $>3,84$, queda fuera si es $<2,71$.
- **Criterio de tolerancia.** Superado el criterio de significación, sólo se integra una variable si su nivel de tolerancia es mayor que el establecido por defecto⁷ (0,0001) y si su incorporación al modelo no hace que una de las previamente seleccionadas pase a tener un nivel de tolerancia inferior al nivel establecido.

De los tres métodos enunciados, el de *pasos sucesivos* es el más completo y el que aporta una mayor información (Etxeverría, 1999), siendo ésta la aproximación más habitual para seleccionar variables independientes en los métodos multivariantes (Hair *et*

⁷ Este valor solamente puede cambiarse mediante programación.

al., 1999). Además, en la literatura científica son varios los autores que han utilizado esta técnica para relacionar datos espectrales con parámetros de la vegetación (Parra, 2005), motivo también por el que fue seleccionada en la presente investigación.

El método de *pasos sucesivos* puede considerarse como mezcla de los métodos *hacia delante* y *hacia atrás*. Comienza seleccionando, al igual que el método *hacia delante*, la variable independiente que -además de superar los criterios de entrada expresados- tiene el valor de correlación -absoluto- más alto con la dependiente. Posteriormente, si existe, se selecciona la variable independiente que, además de superar los criterios de entrada, posee el coeficiente de correlación parcial más alto (en valor absoluto). Cada vez que se incorpora una nueva variable, las previamente seleccionadas son, al igual que en el método *hacia atrás*, nuevamente evaluadas para determinar si siguen cumpliendo o no los criterios de salida, siendo expulsadas del modelo si los cumple. El proceso se detiene cuando no quedan variables independientes que superen los criterios de entrada y las seleccionadas no cumplen los criterios de salida (Etxeverría, 1999; Pardo y Ruiz, 2005). Por último señalar que, en este método de selección, el ratio entre observaciones y variables independientes para asegurar que el modelo no está sobre-ajustado y es generalizable es de 50 a 1 (Hair *et al.*, 1999).

1.4.3.2.2. Regresión curvilínea

La regresión curvilínea o regresión no lineal es una técnica estadística que permite predecir una variable dependiente a partir de una o varias independientes cuando la relación entre estos dos tipos de variables no se ajusta a una línea recta. Como en la regresión lineal, la variable dependiente y las independientes deben estar medidas en escala métrica, siendo posible incluir variables categóricas entre las independientes mediante procedimientos especiales. Como resultado de la regresión no lineal se obtiene una ecuación que predice la variable dependiente proporcionando información sobre las variables independientes que la explican (Ebdon, 1982; Etxeverría, 1999).

Encontrar una ecuación que describa una relación no lineal es bastante más complejo que en el caso de la regresión lineal simple o múltiple, resultando más sencillo aplicar transformaciones a los datos de ambas variables para "linealizar" la relación y proceder mediante el análisis de regresión lineal⁸ (Ebdon, 1982; Etxeverría, 1999). Es por

⁸ Aunque queda el problema de reformular la relación entre las variables transformadas en función de las originales; es decir, interpretar de forma correcta el modelo resultante (Ebdon, 1982).

ello que en la presente investigación solamente se ajustaron modelos univariantes a partir de la función “estimación curvilínea” integrada en SPSS. Este programa ofrece, al efecto, once modelos diferentes de estimación de una variable dependiente a partir del uso de una única variable independiente (Tabla 1.1), proporcionando todos los métodos gráficos y estadísticos necesarios para evaluar la bondad del ajuste obtenido y su significación estadística (Pardo y Ruiz, 2005).

Modelo de regresión	Expresión matemática
Lineal	$Y = \beta_0 + \beta_1 X$
Logarítmico	$Y = \beta_0 + \beta_1 \ln(X)$
Inverso	$Y = \beta_0 + \beta_1 (1/X)$
Cuadrático	$Y = \beta_0 + \beta_1 X + \beta_2 X^2$
Cúbico	$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \beta_3 X^3$
Potencia	$Y = \beta_0 (X^{\beta_1})$
Compuesto	$Y = \beta_0 (\beta_1^X)$
S	$Y = e^{\beta_0 + \beta_1 (1/X)}$
Logístico	$Y = 1 / (1/c + \beta_0 \beta_1^X)$
Crecimiento	$Y = e^{\beta_0 + \beta_1 X}$
Exponencial	$Y = \beta_0 e^{\beta_1 X}$

Tabla 1.1. Modelos de regresión incluidos en la función “Estimación curvilínea” de SPSS. Fuente: Pardo y Ruiz (2005)

donde Y es la variable dependiente, X la independiente, β_0 la constante, β_1 el coeficiente de regresión y c el parámetro que refiere al límite superior de la función logística.

- Valoración de la exactitud de la predicción

Para comprobar la bondad del ajuste obtenido mediante la regresión curvilínea se utilizan los mismos estadísticos que en el caso de la lineal. Así, para cuantificar la proporción de la variable dependiente explicada por la independiente se utiliza R^2 (Ecuación 5), mientras que S_e , $RMSE$ y $RMSE_r$ ofrecen una visión global de la exactitud de la predicción (Ecuación 7, 8 y 9, respectivamente).

El examen de la significación estadística del modelo se hace también mediante el cálculo del estadístico F (Ecuación 10) y el contraste de su significación ($p < 0,05$), mientras que el estadístico t (Ecuaciones 11 y 12) y su prueba de significación se utilizan para contrastar la validez del coeficiente de regresión y de la constante del modelo ajustado.

- Método de ajuste del modelo

Al tratarse de modelos univariantes, la especificación del modelo de regresión se puede hacer únicamente de forma confirmatoria, de tal manera que la única cuestión a resolver es qué tipo de modelo curvilíneo se adapta mejor para describir la relación entre la variable dependiente y la independiente. Para ello resulta fundamental el análisis del patrón de puntos del gráfico de dispersión definido por las dos variables que previamente habían mostrado la existencia de una relación no lineal. En función de este patrón se explora la utilidad de dos o tres de los modelos recogidos en la Tabla 1.1. Los resultados obtenidos son analizados y comparados utilizando para ello los estadísticos señalados en el anterior punto (R^2 , S_e , etc.). Finalmente, el modelo propuesto es aquel que, siendo significativo a todos los niveles, explica la mayor cantidad de varianza de la variable dependiente y presenta el error de estimación menor.

1.4.3.2.3. Regresión logística

La regresión logística es un tipo especial de regresión que se utiliza para estimar la probabilidad de ocurrencia de una variable dependiente categórica binaria (dos grupos, 0/1), en lugar de una medida dependiente métrica, permitiendo la entrada de variables explicativas continuas y/o categóricas sin que tengan que cumplir el supuesto de normalidad, siendo el único requisito que no estén altamente correlacionadas entre sí. El resultado es una relación multivariante con coeficientes como los de la regresión lineal múltiple, que indican la influencia relativa de las variables predictoras (Hair *et al.*, 1999; Silva y Barroso, 2004). Puede expresarse mediante la siguiente función:

$$\text{logit}(P) = \ln \frac{P}{1-P} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad \text{Ecuación 13}$$

donde P es la probabilidad de ocurrencia de la variable dependiente, β_0 es la constante del modelo y β_n es el coeficiente de la variable independiente X_n (adaptado de Silva y Barroso, 2004). Formas equivalentes de expresar el mismo modelo son:

$$P(Y = 1) = \frac{\exp(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}{1 + \exp(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)} \quad \text{Ecuación 14}$$

$$P(Y = 1) = \frac{1}{1 + \exp(-\beta_0 - \beta_1 X_1 - \beta_2 X_2 - \dots - \beta_n X_n)} \quad \text{Ecuación 15}$$

donde $P(Y=1)$ es la probabilidad de que la variable dependiente $Y=1$, β_0 es la constante y β_n es el coeficiente de la variable independiente X_n (adaptado de Silva y Barroso, 2004).

Aunque la regresión logística incluya un único valor teórico, resumen de los coeficientes estimados para cada variable independiente al igual que en la lineal, su naturaleza no lineal requiere un método de estimación diferente al de mínimos cuadrados. Así, la regresión logística utiliza el criterio de la máxima verosimilitud, que busca la estimación más probable de los coeficientes. El resultado es una función continua cuyos valores de salida oscilan entre 0 y 1, de tal manera que los valores <0.5 se corresponden con la no ocurrencia de la variable dependiente y los valores >0.5 con la ocurrencia (Hair *et al.*, 1999; Silva y Barroso, 2004).

Los coeficientes estimados ($\beta_0, \beta_1, \beta_2, \dots, \beta_n$) son, en realidad, medidas de los cambios en el ratio de probabilidades (*odds ratio*), de tal manera que un coeficiente positivo aumenta la probabilidad, mientras que uno negativo la disminuye. Una interpretación más fácil de este hecho se obtiene a partir del cálculo del antilogaritmo de estos coeficientes ($\exp\beta_n$), que refiere al cambio predicho en el ratio de probabilidades por cada unidad de incremento en la variable independiente. Así, cuando β_n es positivo, $\exp\beta_n > 1$ y el ratio de probabilidades aumentará; por el contrario, si β_n es negativo $\exp\beta_n < 1$ y el ratio disminuirá (Hair *et al.*, 1999).

- Valoración de la exactitud de la predicción

La medida global de cómo se ajusta el modelo viene dada por el valor de la verosimilitud ($-2LL$), que queda definido por la siguiente expresión:

$$-2LL = -2 \ln V \quad \text{Ecuación 16}$$

donde $-2LL$ es el valor de la verosimilitud y V es el producto de todas las probabilidades predichas por el modelo de que los sujetos de la muestra tengan la condición que realmente tienen (adaptado de Hair *et al.*, 1999 y Silva y Barroso, 2004).

El valor mínimo para $-2LL$ es 0, de tal manera que cuanto más pequeño sea el valor de este parámetro, mejor será el ajuste (Hair *et al.*, 1999).

Otra forma de evaluar la bondad del modelo es cotejar y evaluar la concordancia entre lo predicho y la ocurrencia-no ocurrencia real de la variable dependiente (Silva y Barroso, 2004), pudiendo ser utilizada para ello una matriz de confusión⁹ y el estadístico

⁹ La matriz de confusión es una tabla de doble entrada en la que se comparan los hechos reales con los predichos, de obteniéndose el porcentaje de acierto global del modelo (Hair *et al.*, 1999).

$Kappa^{10}$ (Pérez-Cabello *et al.*, 2006).

El test de *Hosmer-Lemeshow* proporciona una medida final del ajuste que se basa también en la predicción real de la variable dependiente. Para ello, primeramente se dividen los casos en 10 clases aproximadamente iguales, siendo comparado después el número de sucesos reales y predichos en cada clase con el estadístico *chi-cuadrado* (χ^2 Ecuación 17). Para que el modelo sea dado como bueno, la prueba de significación aplicada a este parámetro tiene que ser negativa; es decir, el valor obtenido tiene que superar el nivel crítico fijado (en nuestro caso, $p > 0,05$) (Hair *et al.*, 1999).

$$\chi^2 = \sum_{i=1}^{10} \frac{(O_i - E_i)^2}{E_i} + \sum_{i=1}^{10} \frac{(O_i^* - E_i^*)^2}{E_i^*} \quad \text{Ecuación 17}$$

donde O_i son los valores observados dentro de cada grupo, E_i son los valores esperados dentro de cada grupo, O_i^* es la frecuencia de ocurrencia de ese grupo menos los valores observados y E_i^* es la frecuencia de ocurrencia de ese grupo menos los valores esperados (adaptado de Silva y Barroso, 2004).

Por último, señalar que se han diseñado varias medidas para representar el ajuste global del modelo de forma semejante a como lo hace el R^2 en la regresión lineal como, por ejemplo, la R^2 de Cox y Snell, la R^2 de Nagelkerke y el pseudo- R^2 (Ecuación 18) (Hair *et al.*, 1999). Los dos últimos devuelven un valor que entre 0 y 1, de tal manera que se obtiene el valor máximo cuando el modelo asigna correctamente todos los casos en su respectivo grupo, aproximándose a 0 cuando la asignación sea peor. Sin embargo, debe advertirse que el test de *Hosmer-Lemeshow*, la matriz de confusión y el estadístico *Kappa* son más adecuados que R^2 para medir la bondad del ajuste, reservándose el uso de este último estadístico para valorar globalmente la capacidad explicativa de los modelos (Hair *et al.*, 1999; Silva y Barroso, 2004).

$$R_{logit}^2 = \frac{-2LL_{base} - (-2LL)}{-2LL_{base}} \quad \text{Ecuación 18}$$

donde R_{logit}^2 es el pseudo- R^2 , $-2LL_{base}$ es el valor de verosimilitud de referencia obtenido

¹⁰ El estadístico *Kappa* mide la diferencia entre el acuerdo valor predicho-valor observado y el que cabría esperar simplemente por el azar. Así, este parámetro delimita el grado de ajuste debido sólo a la exactitud del modelo, desechando el causado por efectos aleatorios, variando entre 0 (acuerdo debido al azar) y 1 (acuerdo perfecto) (Chuvieco, 1996; Erdas Field Guide, 1999).

sin la inclusión de ninguna variable dependiente en el modelo y $-2LL$ es el valor de verosimilitud final del modelo (adaptado de Hair *et al.*, 1999).

Al igual que en los otros dos modelos de regresión, la comprobación de la significación estadística del modelo de regresión logística se hace a nivel de modelo y a nivel de las variables independientes incluidas. A nivel de modelo se aplica un contraste *chi-cuadrado* (similar al estadístico F de la regresión lineal) para comprobar que el cambio del valor $-2LL$ respecto a $-2LL_{base}$ es significativo ($p < 0,05$). Para los coeficientes estimados de las variables dependientes y para la constante se utiliza el estadístico de Wald (similar al estadístico t) (Ecuación 19) y su prueba de significación, dándose por válidos si su significación estadística se sitúa por debajo del nivel crítico ($p < 0,05$) (Hair *et al.*, 1999; Silva y Barroso, 2004).

$$W_{\beta_n} = \frac{\beta_n}{S_{\beta_n}} \quad \text{Ecuación 19}$$

donde W_{β_n} es el estadístico de Wald del coeficiente de regresión de la variable independiente n (β_n) y S_{β_n} es el error estándar de β_n (adaptado de Silva y Barroso, 2004).

- Método de selección de variables

Como en la regresión lineal, el método aplicado para el ajuste de los modelos logísticos ha sido el de búsqueda secuencial de *pasos sucesivos* mediante SPSS, utilizando en los criterios de significación y tolerancia los parámetros específicos de este tipo de regresión, que sustituyen a los propios de la lineal.

1.4.3.3. Validación de los modelos

Para validar cada modelo de regresión, el total de la muestra compuesta por las parcelas del IFN-2 seleccionadas sobre las que se tiene información de biomasa residual forestal se divide al azar en dos grupos: el 80% se utiliza para el ajuste, el 20% restante se reserva para la validación. Esta división de la muestra se hace de forma aleatoria para que cualquier ordenación de los datos no afecte a los procesos de estimación y validación. Además, para valorar la robustez de los modelos, esta división aleatoria se realiza en cinco ocasiones, calculándose el respectivo modelo y la validación en cada una de ellas. La repetición de las variables seleccionadas en cada modelo, la similitud de sus coeficientes y de los estadísticos usados para valorar la exactitud del modelo serán los indicadores de que el modelo es independiente de la selección aleatoria de los datos.

Todos los modelos de regresión ajustados son analizados para valorar la exactitud de la predicción, utilizando para ello sus correspondientes estadísticos. Así mismo, se valora también la significación estadística global del modelo y de las variables que lo integran. Por último, se comprueba que, a pesar de las precauciones adoptadas, ninguno de ellos incumpla los supuestos subyacentes en los que se basa.

Por su parte, las muestras de validación también se utilizan para valorar la exactitud de la predicción, calculándose el *RMSE* (expresado en tons/ha) y el *RMSE_r* (en porcentaje) a partir de las diferencias entre los valores observados en estas muestras y los predichos en los modelos de regresión simples y múltiples, siendo calculado con estos datos el estadístico *Kappa* en el caso de los modelos de regresión logística.

1.5. El área de estudio: delimitación y presentación general

La provincia de Teruel tiene una superficie total de 14804 km² y se encuentra situada en el cuadrante noreste de la Península Ibérica, próxima al Mediterráneo (Figura 1.12). La elección de esta área de estudio se debe a que éste fue el territorio seleccionado por el proyecto LIGNOSTRUM para la validación de la metodología en él propuesta. Dos son las características de esta provincia que la convierten en un escenario ideal para verificar las hipótesis de los beneficios del empleo de los residuos forestales y agrícolas con fines energéticos: la presencia de una gran superficie agrícola y forestal y la existencia de espacios rurales económicamente desfavorecidos.

Los datos del *Anuario Estadístico Agrario de Aragón de 2003, 2004, 2005* (Departamento de Agricultura y Alimentación, 2007) indican que en 2005 la superficie catalogada como tierras de cultivo era de 442.490 ha, mientras que la correspondiente a terreno forestal era de 405.502 ha. La superficie forestal -donde se generan los residuos que se evalúan en este trabajo- supone el 27% del total de territorio provincial, poniendo de manifiesto su importancia. Pero, como veremos más adelante, su distribución no es uniforme, concentrándose la mayor parte de la riqueza forestal en las sierras ibéricas.

Por otra parte, desde el punto de vista socio-económico, la provincia de Teruel es una de las más desfavorecidas del territorio español. De forma sintética puede definirse como una provincia poco poblada, envejecida y que, económicamente, conserva un marcado carácter agrario con escaso desarrollo del sector industrial y de servicios. En las

siguientes páginas se presentan sus principales caracteres físicos y socio-económicos, con especial atención a los primeros e incluyendo una descripción de la cubierta forestal.



Figura 1.12. Localización del área de estudio: la provincia de Teruel

1.5.1. Caracterización física de la provincia de Teruel

En este apartado se van a analizar los diferentes aspectos ecogeográficos que condicionan la existencia, las características y el desarrollo de los paisajes forestales de Teruel: fisiográficos y lito-geológicos, climáticos, edáficos y biogeográficos. Las múltiples y complejas interrelaciones de todos ellos, junto con la acción antrópica ejercida a lo largo del tiempo, han configurado los bosques actuales que serán objeto de nuestra atención.

1.5.1.1. Aspectos fisiográficos y lito-geológicos

La fisiografía de un territorio es un factor fundamental condicionante del desarrollo y distribución de las masas forestales. La altitud, la pendiente y la orientación son características topográficas que definen un territorio y le confieren unas determinadas propiedades para el desarrollo de la vegetación. Pero el papel del relieve va mucho más allá, ya que influye directamente en la configuración de topoclimas al modificar elementos como las temperaturas, las precipitaciones y los vientos, además de otras características derivadas de éstos (iluminación, humedad, aridez...). Por su parte, la naturaleza litológica del sustrato condiciona en gran medida el tipo de suelo, si bien la formación final de éste depende de una gran cantidad de agentes que intervienen en la edafogénesis (clima,

cubierta vegetal, pendiente...). El suelo es un factor ecológico de primer orden para la actividad vegetal, siendo a la vez sujeto agente y paciente de la misma.

La provincia de Teruel queda enmarcada casi en su totalidad en el sector centrorienta de la Cordillera Ibérica, situándose solamente fuera de él su parte más septentrional, que forma parte de la Depresión del Ebro. Además, también en la parte norte, en la zona de los Puertos de Beceite, se produce el enlace con las alineaciones orográficas de la Cordillera Costero-Catalana (Gutiérrez y Peña, 1990).

Esta localización en la zona central del Sistema Ibérico explica sus rasgos topográficos: un terreno bastante accidentado que se sitúa a una elevada altitud media, con el 60% de su territorio por encima de los 1000 m de altitud sobre el nivel del mar. A pesar de esto, la energía del relieve no es muy importante y el aspecto general es macizo y pesado, rasgo agudizado por la planitud de sus cumbres. Estas características dotan al relieve de la provincia un carácter de altiplano que sólo se rompe por algunas incisiones fluviales, generándose en ellas los mayores valores de pendiente (Lozano, 2005a).

Atendiendo a su fisiografía, la provincia puede dividirse en tres sectores (Figura 1.13):

- **Sector meridional.** En esta zona se localizan las principales elevaciones montañosas: la Sierra de Javalambre (2.020 m), situada en el extremo sur, y la Sierra de Gúdar (2.019 m), emplazada en el sureste, estando separadas ambas por la Depresión del Mijares. Estos dos conjuntos montañosos se encuentran caracterizados por presentar un relieve masivo y alomado, obedeciendo sus contrastes al fuerte encajamiento de los ríos que las rodean. La Sierra de Gúdar se prolonga al oeste en la Sierra del Pobo, cuya cima se sitúa por encima de los 1.700 m. Finalmente, en el extremo sureste, separado de la Sierra del Pobo por la depresión del Alfambra-Turia, aparece el conjunto de la Sierra de Albarracín, cuya cima se sitúa en los 1920 m., siendo su relieve más enérgico que el de los anteriores conjuntos montañosos (Gutiérrez y Peña, 1990; Querol, 1995; González *et al.*, 2001).
- **Sector central.** Esta zona está caracterizada por la presencia de relieves amesetados que apenas producen la sensación de relieve, a pesar de que el rango altitudinal se sitúa entre los 1000 y los 1.500 m (Gutiérrez y Peña, 1990). Las formaciones montañosas que aparecen en esta área son, de oeste a este: Sierra Menera, Sierra de Cucalón, Sierra Palomera y Sierra de San

Just. Estas sierras aparecen individualizadas por los ríos que forman las cuencas del Jiloca, Alfambra, Martín y Guadalope.

- **Sector nororiental.** El relieve está compuesto por las sierras ibéricas más marginales, de menor altitud que las nombradas anteriormente e intersectadas por los ríos Martín, Guadalope, Matarraña y sus afluentes, formándose depresiones de menor entidad que en el sector central y meridional. Paulatinamente, el relieve va disminuyendo hacia el norte, hasta alcanzar la Depresión del Ebro, que presenta en esta zona altitudes inferiores a los 400 m (Gutiérrez y Peña, 1990).

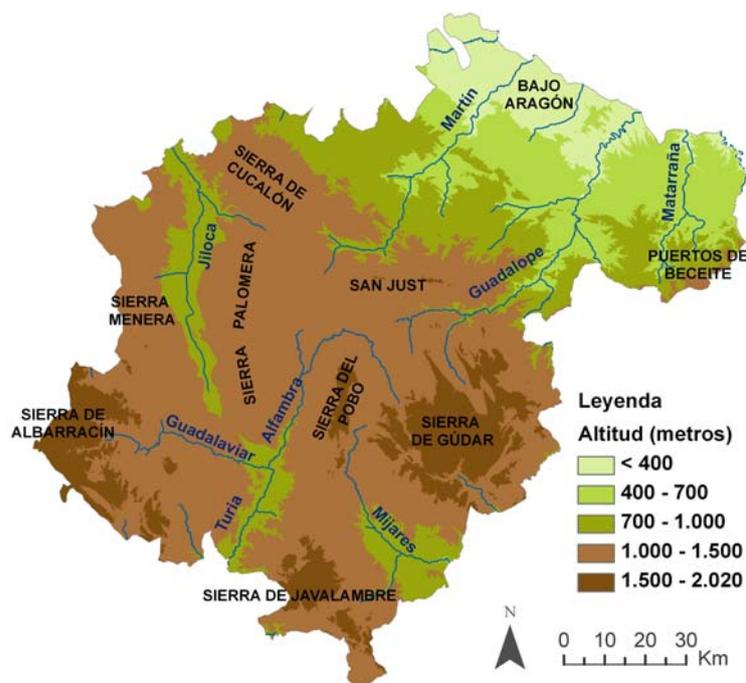


Figura 1.13. Mapa fisiográfico de la provincia de Teruel

Este territorio se constituye como un nudo hidrográfico de primer orden en la Península Ibérica, ya que en él se localiza la cabecera del río Tajo que establece la divisoria entre la vertiente atlántica y mediterránea. Además, dentro de esta última se distinguen los límites de la Cuenca del Ebro (ríos Jiloca, Huerva, Aguasvivas, Martín, Guadalope, Matarraña y Algás) y los de las cuencas de pequeños ríos que vierten directamente al Mediterráneo (Cabriel-Júcar, Guadalaviar-Turia y Mijares). Todos estos ríos se caracterizan por tener un escaso caudal, marcados contrastes estacionales y una

importante irregularidad interanual producto de un régimen pluvial mediterráneo. Otro hecho destacable es la presencia de zonas endorreicas, como las saladas de Alcañiz, en el Bajo Aragón, y la Laguna de Gallocanta, cerca de la depresión del Jiloca (Lozano, 2005a).

El sustrato geológico se caracteriza por su variedad litológica y cronoestratigráfica. Existen diversos afloramientos paleozoicos de cuarcitas y pizarras que se localizan en la mitad occidental (Sierra de Carbonera, Sierra de Tremedal, Sierra Menera, Sierra de Cucalón), aunque los materiales más representativos pertenecen al Mesozoico. De este grupo de materiales destacan, dentro del Triásico, las areniscas y conglomerados del Rodeno y las barras dolomíticas y de arcillas yesíferas que orlan los macizos paleozoicos o afloran en núcleos anticlinales; por su parte, el Jurásico está ampliamente representado en la Sierra de Albarracín, Javalambre y en las sierras del Bajo Aragón; por último, los materiales cretácicos están bien representados en el área de Gúdar-Maestrazgo. Todos estos afloramientos están afectados por la tectónica Alpina en varias fases, adaptándose a dos direcciones dominantes: NO-SE (*dirección ibérica*) y la NE-SO (*dirección catalana*). Las depresiones tectónicas que se generaron durante las fases distensivas (Depresión del Ebro, Alfambra-Teruel, etc.) se rellenaron principalmente de materiales terciarios de carácter detrítico y lacustre, la mayoría de ellos neógenos. Estas cuencas y otras más recientes -como las del Jiloca, Mijares y Gallocanta- presentan también formaciones de edad pliocuaternaria y cuaternaria (Gutiérrez y Peña, 1990; Lozano, 2005a).

En cuanto a la geomorfología, es de destacar la variedad de formas presentes en sus paisajes como fruto de la diversidad estructural y del modelado de los agentes erosivos, que se han dado en situaciones muy contrastadas a lo largo de su historia geológica, destacando la huella de los climas cálidos que se dieron en el Terciario y las fases frías del Cuaternario. Entre las distintas geoformas destacan tres: (i) las superficies de erosión de edad terciaria, responsables de las altiplanicies ya comentadas; (ii) los paisajes kársticos, modelados principalmente en época pliocena sobre las planicies de rocas carbonatadas; y (iii) el modelado cuaternario presente en las zonas de depresión (mantos aluviales modelados en glacis, glacis de acumulación, sistemas de terrazas...) y en las zonas de sierra (procesos periglaciares en las zonas más elevadas y presencia de estrechas gargantas modeladas por la erosión fluvial). En la actualidad los procesos geomorfológicos presentes son los propios de medios semiáridos en la mayor parte de la provincia, manifestándose procesos periglaciares en los macizos más elevados durante los meses más fríos (Gutiérrez y Peña, 1990; Peña *et al.*, 2002a; Lozano, 2005a).

1.5.1.2. Aspectos climáticos

La provincia de Teruel tiene un tipo de clima mediterráneo que se encuentra matizado por su elevada altitud media y la continentalidad. Ésta viene definida por su situación geográfica y por el efecto de barrera de sus relieves, que aíslan la mayor parte del territorio de la influencia de los vientos húmedos atlánticos y mediterráneos, existiendo algunos focos de humedad en las sierras que componen esta barrera (Sierra de Albarracín, Gúdar, Javalambre, Cucalón...). Estas características configuran un clima que puede adjetivarse como frío, seco y soleado. Sin embargo, la existencia de contrastes altitudinales muy marcados y la presencia de un relieve compartimentado originan una gran variedad de matices climáticos (Peña *et al.*, 2002b; Lozano, 2005b).

Aunque, como se ha indicado, el régimen térmico se puede definir como frío, existe una variedad térmica ocasionada por las variaciones de altitud y los matices que introducen las depresiones topográficas. Así, las temperaturas medias más altas se sitúan en la zona septentrional, coincidiendo con el territorio incluido en la Depresión del Ebro. En esta zona del Bajo Aragón, se dan valores promedio de 14-15 °C, alcanzándose los 16 °C en lugares concretos de la Cuenca del Matarraña. Con el ascenso altitudinal, en el sector central las temperaturas medias van descendiendo, lentamente al principio, hasta los 700-800 m, y más intensamente al aproximarse a los mayores conjuntos montañosos del sur y a las depresiones intraibéricas (Jiloca, Alfambra-Teruel y Mijares), donde se registran temperaturas medias entre 10,5 y 8,5 °C. Las temperaturas medias anuales más frías se localizan en las áreas de montaña del sector meridional (Sierra de Albarracín, Javalambre y Gúdar) situándose por debajo de los 8 °C.

En el régimen anual de temperaturas destaca la presencia de fuertes contrastes, conformándose un verano caluroso y un invierno intensamente frío, si bien las diferencias internas son importantes. Así, tomando las temperaturas medias del mes más caluroso en la provincia (julio), el sector nororiental, correspondiente a la Depresión del Ebro, presenta valores superiores a los 25 °C, mientras las sierras meridionales se quedan por debajo de los 17 °C. Si nos fijamos en las diferencias en el mes más frío (enero) los contrastes entre ambas zonas se mantienen, presentando el sector nororiental temperaturas entre 6-8 °C y valores inferiores a 0 °C en las sierras del sector meridional a partir de los 1500 m, situándose en el rango intermedio el resto del territorio. En relación con las temperaturas mínimas, es de destacar que el periodo de heladas en este sector meridional abarca de octubre a inicios de junio, siendo casi diarias en los meses de invierno, pudiendo aparecer en algunos puntos incluso en verano. Este periodo de

heladas es algo más corto en las sierras que aparecen en el sector central y en las depresiones intraibéricas, de tal manera que las primeras heladas suelen registrarse a mediados de octubre y las últimas en mayo. En el sector nororiental las heladas son menos frecuentes, produciéndose entre finales de noviembre y marzo, siendo raramente su frecuencia mensual superior a 10 días (Peña *et al.*, 2002b).

El efecto de barrera de sus relieves respecto de la influencia de los vientos húmedos atlánticos y mediterráneos explica la debilidad de las precipitaciones y su desigual reparto espacial. Así, el promedio está por debajo de los 400 mm en el sector nororiental del Bajo Aragón y en el fondo de la depresión del Jiloca, situándose entre los 400-600 mm en sector central y en las depresiones intraibéricas meridionales. Sólo en las sierras del sector meridional las precipitaciones pueden superar los 600 mm, produciéndose el máximo en la Sierra de Albarracín, en cuyo extremo más occidental se superan los 1000 mm. El reparto anual de estas precipitaciones está sometido a un régimen mediterráneo de máximos equinocciales y mínimos en los meses estivales e invernales, siendo en estos últimos cuando se produce el periodo seco más prolongado. Esta caracterización general se ve matizada, una vez más, en función de la disposición orográfica; así, por ejemplo, en el interior de la provincia, dado su carácter continental, las tormentas estivales pueden llegar a causar precipitaciones importantes. Por el contrario, frente al marcado periodo seco de los meses de invierno, la zona de los Montes Universales en la Sierra de Albarracín registra en esta estación sus precipitaciones más importantes debido a su altitud y mejor exposición a las borrascas atlánticas. Las precipitaciones en forma de nieve hacen presencia entre 2 y 15 días al año, siendo mayor la probabilidad en las sierras del sector meridional. Finalmente, destacar la elevada variabilidad interanual de las precipitaciones en toda la provincia, aunque la tónica dominante es la sequía y la excepción son los años húmedos (Peña *et al.*, 2002b).

Por último, debe subrayarse entre los caracteres climáticos el elevado porcentaje de insolación (53% de la posible) y las dos componentes dominantes del viento, fruto de la disposición orográfica: la O-NO del cierzo y la E-SE del bochorno (Peña *et al.*, 2002b).

1.5.1.3. Aspectos edáficos

El sustrato edáfico es uno más de los factores ecogeográficos que condicionan la cubierta vegetal, ya que actúa a la vez como fuente de nutrientes y como soporte físico (Querol, 1995; de la Riva, 1997). Para describir brevemente la edafología de la provincia de Teruel se utiliza la cartografía de suelos de la Comunidad Autónoma de Aragón

elaborada por Badía *et al.* (2007), que adopta la nomenclatura de la FAO. Dos tipos de unidades de suelo destacan a escala provincial: los Cambisoles y los Calcisoles.

Los Cambisoles son suelos caracterizados por su edad limitada y por estar en proceso de cambio de color, estructura, consistencia... que resultan de la edafización *in situ* de los componentes del suelo y que están medianamente desarrollados. El perfil de este suelo es A-B-C, siendo el B un horizonte cámbico; las propiedades de este horizonte determinan el tipo de Cambisol (eútrico, calcárico, etc.). Debido a que son suelos de corta edad, conservan muchos rasgos directamente heredados del material original a partir del cual se han formado. Los Cambisoles pueden desarrollarse sobre topografías llanas hasta en fuertes pendientes, pero mayoritariamente sobre pendientes suaves. Son suelos buenos para la agricultura bien planificada y, con fuerte pendiente, constituyen buenos suelos forestales, presentando fuerte riesgo de erosión ante la deforestación. En la provincia de Teruel, dentro del denominado anteriormente como sector meridional, este tipo de suelo aparece localizado principalmente en la Sierra de Albarracín, en la del Pobo y en Javalambre. Dentro de los sectores central y nororiental este tipo de suelo vuelve a ser el predominante en las principales sierras (Menera, Cucalón, San Just, Sierra de los Arcos, Puertos de Beceite) y en sus estribaciones.

Los Calcisoles están caracterizados por tener en los primeros 125 cm uno o más horizontes cálcicos, petrocálcicos y/o acumulaciones importantes de carbonato cálcico pulverulento. El proceso fundamental que se da en estos suelos es la calcificación (translocación de carbonatos de calcio o de magnesio a los que luego puede afectar un proceso de cementación). En ambientes semiáridos, como los del área de estudio, la alta evaporación hace subir los carbonatos presentes en el material original de estos suelos a las partes superiores, produciendo deposiciones en estas capas. Además de los cálcicos o petrocálcicos que definen este tipo de suelos, pueden aparecer horizontes cámbicos e incluso árgicos. Los Calcisoles se caracterizan por ser suelos relativamente buenos para los cultivos, especialmente para el cereal. Dentro de la provincia, este tipo de suelos aparece en las principales depresiones, como en la del Mijares y en la parte norte de la de Alfambra-Teruel (sector meridional), en la del Jiloca (sector central) y en la Depresión del Ebro (sector nororiental), aunque puede aparecer también en algunas estribaciones montañosas del sector central, como en la Sierra Palomera.

Los Leptosoles están también bien representados. Se caracterizan por ser suelos muy superficiales y poco evolucionados debido a que se desarrollan sobre una roca dura

masiva o material altamente calcáreo cementado o endurecido que queda expuesto en superficie. Así, son suelos muy simples que tienen un perfil A-C o A-Roca madre, pudiendo presentar un horizonte orgánico en la parte superior. Generalmente son muy pedregosos (menos de un 20% de materia fina en los primeros 75 cm), pudiendo constituir las etapas previas o iniciales de otros tipos más evolucionados. Son los suelos predominantes en la Sierra de Gúdar, en las zonas más elevadas de la Sierra de Javalambre y en las estribaciones montañosas de los Puertos de Beceite. Por último, señalar la presencia de otros tipos de suelos que están más escasamente representados a escala provincial y que tienen un carácter muy local; es el caso de algunos suelos tipo Luvisol, Regosol y Umbisol.

1.5.1.4. Aspectos biogeográficos

Según las unidades corológicas definidas por Rivas Martínez (1987), la provincia de Teruel se incluye dentro del Reino Holártico, como el resto de la Península Ibérica, y concretamente en la Región Mediterránea. De los seis pisos bioclimáticos que se distinguen en esta región, en la provincia de Teruel están presentes tres: Oromediterráneo, Supramediterráneo y Mesomediterráneo.

- **Piso Oromediterráneo.** Se caracteriza por una temperatura media anual entre 4 y 8 °C. Otros criterios termoclimáticos que lo definen son la media de las mínimas del mes más frío, que oscila entre -7 y -4 °C, y la media de las máximas de ese mismo mes, que va de 0 a 2°C. El Índice de Termicidad¹¹ (It) oscila entre -30 y 60. Este piso aparece aproximadamente por encima de los 1400 m en la sierras de Albarracín, Gúdar, Javalambre y del Pobo.

La vegetación que aparece está bien adaptada a periodos de fríos largos e intensos y es capaz de completar su actividad (ciclo vegetativo y reproductor) en un corto periodo de tiempo que coincide con los meses más cálidos. Las especies forestales dominantes son las coníferas, que son las que mejor se adaptan a las condiciones descritas. Destacan las superficies de matorral achaparrado y pastizal, adaptadas también a los caracteres del piso.

- **Piso Supramediterráneo.** Definido por una temperatura media anual que oscila entre 8 y 13 °C. En cuanto al mes más frío, la media de las mínimas va

¹¹ El índice de termicidad se calcula a partir de la suma de la temperatura media anual (T) en décimas de °C, la temperatura media de las mínimas del mes más frío (m) y la temperatura media de las máximas del mes más cálido (M): $It = (T+m+M)*10$ (Rivas Martínez, 1987).

de -4 a -1 °C y la media de las máximas de 2 a 9 °C. El It se sitúa entre 60 y 210 . Este piso es el que ocupa mayor extensión en la provincia, en todo el sector central y las depresiones intraibéricas, a excepción del fondo de la depresión del Mijares donde aparece representado el piso Mesomediterráneo.

Su vegetación se encuentra muy adaptada a las condiciones climáticas, siendo las especies de hojas aciculares y coriáceas las dominantes: pinos, sabinas, quejigos, carrascas... En las zonas de degradación aparecen matorrales espinosos y xerófilos entre los que dominan las aliagas. También hay zonas de pastizal.

- **Piso Mesomediterráneo.** Caracterizado por una temperatura media anual de 13 a 17 °C. La media de las mínimas del mes más frío oscila entre -1 y 4 °C y la media de las máximas de ese mes va de 9 a 14 °C. El It se sitúa entre 210 y 350 . Se extiende por las zonas de menor altitud, ocupando todo el sector nororiental y el fondo de la depresión del Mijares.

Este piso tiene una vegetación natural que en su estrato arbóreo está dominada por carrascales, pinares de *P. halepensis* y coscojares, considerándose los primeros como el bosque maduro y los otros dos como estadios de degradación, si bien poseen una gran estabilidad. En las zonas más degradadas dominan los matorrales de romero, tomillo, espliego y salvia, dando paso a pastizales donde destacan los lastonares.

Esta variedad de pisos bioclimáticos, junto con las interacciones de los factores ecogeográficos anteriormente descritos (fisiografía, litología, clima y suelos), da lugar a que la provincia de Teruel posea una gran heterogeneidad botánica y ecológica.

1.5.1.4.1. La cubierta forestal de Teruel

La variedad botánica y ecológica aludida se pone de manifiesto en la diversidad de especies forestales presentes: pino moro (*Pinus uncinata*), pino silvestre (*Pinus sylvestris*), sabina albar (*Juniperus thurifera*), carrasca (*Quercus ilex rotundifolia*)... Los bosques más extensos y mejor conservados de la provincia son los pinares de silvestre localizados al sur, en las sierras de Albarracín y Gúdar. También son importantes, aunque menos extensos, los pinares de silvestre de Javalambre y, en el sector central, los de las sierras de Cucalón, San Just y, en el sector nororiental, los de los Puertos de Beceite. Muchos de estos pinares son sustitutos de los rebollares (*Quercus pyrenaica*) y quejigares (*Quercus faginea*), aunque en algunas zonas se conservan bosques de estas

frondosas, sobre todo en las sierras centrales. Conforme se desciende en altitud -y en las zonas de borde- aparecen pinares de laricio (*Pinus nigra*) y de pinaster (*Pinus pinaster*), siendo el primero frecuentemente utilizado en repoblaciones. En las elevadas parameras calcáreas del sector meridional dominan las formaciones adhesionadas de sabina albar. En las zonas más bajas de la provincia se entra en el dominio del carrascal somontano, que ha sufrido un intenso proceso de degradación antrópica, por lo que en la actualidad sólo se conservan pequeños bosquetes donde el porte arbustivo o de monte bajo es lo más común. La etapa serial de pinares de sustitución está dominada por el pino carrasco (*Pinus halepensis*), que en gran medida ha sido introducido por la acción antrópica; estos pinares alcanzan su máxima expresión en el sector nororiental, en el Bajo Aragón. Finalmente destacar la presencia del chopo (*Populus spp.*) en las zonas de ribera y como cultivo forestal, sobre todo en el Bajo Aragón (Querol, 1995; Ministerio de Medio Ambiente, 1996; González *et al.*, 2001).

La estadística disponible sobre usos del suelo por delimitaciones comarcales permite caracterizar la distribución de la cubierta forestal provincial de forma más detallada. Así, las comarcas situadas al sur –Sierra de Albarracín, Gúdar-Javalambre y Comunidad de Teruel– son las de mayor riqueza, ocupando las dos primeras, desde la perspectiva forestal, un lugar muy destacado a escala regional (de la Riva, 1997). En segundo lugar, aunque con un número de hectáreas forestales bastante inferior, destacan las comarcas situadas al este –Matarraña y Maestrazgo– y oeste –Jiloca–. Las comarcas septentrionales son las menos forestales, tanto en términos absolutos como relativos, destacando el Bajo Aragón y el Bajo Martín (Departamento de Agricultura y Alimentación, 2007).

La calidad de la madera de los montes de Teruel es alta, superando a la del Pirineo, aunque no alcanza a la del Sistema Central –Segovia y Soria–. En el contexto regional, su explotación es más sencilla de realizar y más económica que la de Huesca, lo que hace que las subastas de madera de los Montes de Utilidad Pública (MUP) de Teruel alcancen precios más altos. Un porcentaje elevado de la madera es utilizado para construcción encofrado, apuntalamientos, etc. siendo menor el volumen de madera destinado a carpintería; la procedente de los cultivos de chopo encuentra aplicaciones en embalajes, listones para muebles, etc. (Ministerio de Medio Ambiente, 1996).

La explotación forestal en la provincia apenas ha avanzado en la introducción de innovaciones tecnológicas, exceptuando el uso de la motosierra, el tractor forestal o la

grúa integrada en la caja del camión; otro factor de mejora es la construcción de una red de vías de saca. La difícil orografía, la estructura de la propiedad y la forma de aprovechamiento de los montes han hecho que no se incorporen sistemas más modernos de explotación. Así, los trabajos forestales siguen siendo duros, a lo que se une la escasa consideración social dada a los trabajos forestales. Esto conlleva una falta de personal cualificado y la desaparición de autónomos y pequeñas empresas especializadas que, tradicionalmente, realizaban los procesos de explotación forestal. Al igual que en el resto de España, en las últimas décadas se ha producido una constante disminución del volumen de maderas aprovechadas cada año en los bosques de montaña. La presión existente contra las cortas de madera y el descenso de los precios de la madera en pie hace que apenas se ejecuten los aprovechamientos previstos, poniendo en riesgo el cumplimiento de los objetivos de regeneración. Todas estas circunstancias hacen que la explotación de los bosques sea cada vez menos rentable, por lo que los trabajos de poda, clareo, etc., tan importantes para la eliminación del peligro de incendios y plagas, son cada vez menos abundantes (Ministerio de Medio Ambiente, 1996).

Aun así, el bosque continúa siendo fuente de riqueza para el medio rural turolense, manteniéndose la explotación directa de su madera en las zonas de sierra del sector meridional e incrementándose otros usos y aprovechamientos a escala provincial, como la caza o la recolección de setas. Con vistas al futuro, la gestión y conservación del monte por los habitantes de estos territorios es una de sus principales alternativas económicas (Guillén, 2005a). Por último, recordar en este punto los beneficios socio-económicos (aumento de las rentas agrarias, aparición de empresas, mejora de las infraestructuras, fijación de población...) y medioambientales (disminución del riesgo de incendio, mejora del estado de las masas, etc.) que a escala local podría generar el aprovechamiento energético de los residuos forestales de estos bosques.

1.5.1.4.2. Otras formaciones vegetales

Aproximadamente una cuarta parte de la provincia está ocupada por matorrales de sustitución y pastizales xerófilos, incluyendo formaciones gipsófilas y matorrales de cumbre y parameras. Precisamente en esta zona de las altas parameras predominan caméfitos almohadillados que alternan con la presencia de sabina rastrera (*Juniperus sabina*), enebro (*Juniperus communis communis*) y sabina albar (*Juniperus thurifera*). En las zonas más pobres y secas de la provincia, sobre litologías calcáreas, predominan formaciones de matorral de aliaga (*Genista scorpius*), tomillo (*Thymus vulgaris*), romero (*Rosmarinus officinalis*) y lastón (*Brachypodium retusum*). En cambio, bajo estas mismas

condiciones, pero sobre yesos, aparecen algunos endemismos como el asnallo (*Ononis tridentata*), la albada (*Gypsophila hispanica*) y el albardín (*Lygeum spartum*). Por último, destacar la existencia de ambientes azonales, como las reducidas formaciones de ribera compuestas principalmente por chopos (*Populus nigra*), que aparecen acompañados por especies del género *Tamarix* en el caso de formaciones de ribera en zonas endorreicas con acumulación de sales, como la Laguna de Gallocanta, apareciendo también sosas (*Suaeda vera*) y salicornias y pastos halófilos (*Puccinellia*) (Longares, 2005).

1.5.2. Caracterización socio-económica de la provincia de Teruel

La provincia de Teruel puede considerarse como uno de los territorios más representativos de los medio rurales europeos de carácter marginal. Como se ha señalado anteriormente, se trata de un territorio muy diverso, circunstancia ésta que le concede ser una tierra con muchas posibilidades, pero que se encuentra afectado por muchas desigualdades que amenazan su porvenir (Guillén y Lozano, 2005).

1.5.2.1. Modelo territorial y aspectos demográficos

El modelo territorial actual de la provincia de Teruel se enmarca en el contexto de la crisis demográfica y funcional que ha afectado a numerosos territorios europeos desde la Segunda Guerra Mundial. El origen de esta crisis hay que buscarlo en el masivo éxodo rural, movimiento debido a la atracción que los centros urbanos producían -y producen- sobre la población del medio rural, dada la mayor concentración de capital existente en ellos, hecho que conlleva un mayor crecimiento económico y, por consiguiente, la generación de mayores oportunidades de empleo y bienestar social. El vaciado demográfico producido en la provincia de Teruel por el éxodo rural no fue compensado por el saldo natural, produciéndose un vaciado poblacional del territorio que llevó a la consiguiente pérdida del tejido económico y de servicios (Rubio, 2005a). En concreto, la provincia de Teruel perdió entre 1900 y 2004 un 45% de su población inicial, existiendo algunos municipios con pérdidas poblacionales superiores al 95% (Guillén, 2005b).

En 2004 la provincia de Teruel contaba con un total de 139.333 habitantes, lo que la convertía en la segunda provincia menos poblada de España, siendo tan sólo superada por la provincia de Soria (Guillén, 2005b). Considerando sus más de 14.000 km² de superficie, la densidad de población es inferior a 10 hab/km², por lo que se puede hablar casi de “desierto demográfico” (Rubio, 2005a). En cuanto al reparto de la población en ese mismo año, el 34% se asentaba en los dos únicos centros urbanos de la provincia (Teruel y Alcañiz), encontrándose el resto de la población en municipios que no

sobrepasaban los 10.000 habitantes, siendo importante el número de los de menos de 500 habitantes (80% del total de municipios). De esta manera, las densidades de población más importantes se encuentran en la capital y en la zona del Bajo Aragón, siendo las áreas de montaña las que presentan valores de densidad de población menores (<1 hab/km²).

Los datos anteriores señalan dos aspectos fundamentales del sistema de poblamiento provincial: la excesiva atomización de la red de asentamientos y la inexistencia de una adecuada estructura jerárquica, definida por el predominio de los núcleos con escasa población y por la ausencia de asentamientos de carácter intermedio capaces de vertebrar el territorio. Otros dos rasgos definitorios son el progresivo envejecimiento en la estructura demográfica provincial, siendo este proceso mucho más acusado en aquellos municipios de carácter más rural, y la alta tasa de masculinidad, rasgo este último característico de territorios rurales poco dinámicos. Para finalizar este esbozo de la situación demográfica de la provincia, destacar el horizonte esperanzador abierto por la llegada de población extranjera en la segunda mitad de los 90, que hizo que en 1998 se alcanzara, por primera vez en 100 años, un saldo migratorio positivo. La importancia de la llegada de población extranjera radica, más que en su número (sólo representan el 5% del total de población), en las características de los recién llegados: jóvenes en edad laboral y con capacidad de aumentar la natalidad (Guillén, 2005b).

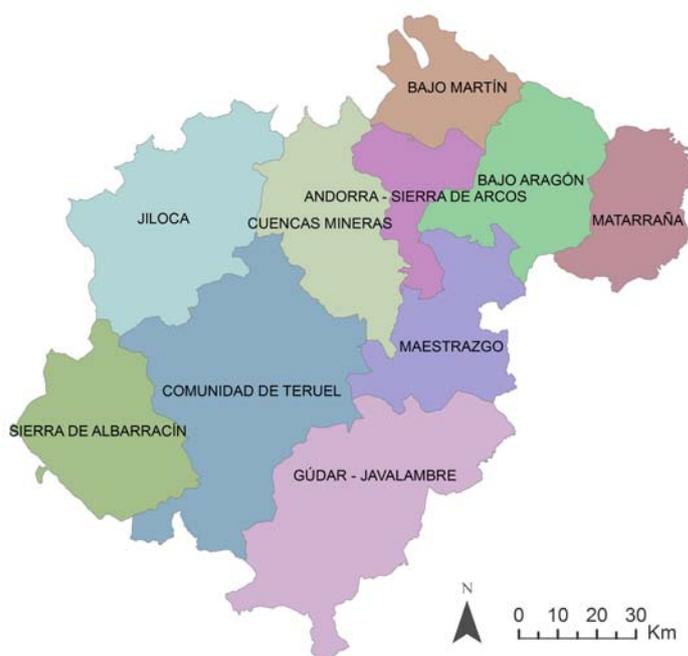


Figura 1.14. División comarcal de la provincia de Teruel

La provincia de Teruel se divide administrativamente en 236 municipios que se integran en 10 comarcas (Figura 1.14), que se han ido creando en distintas fechas a partir de la Ley 10/1993, de 4 de noviembre, de Comarcalización de Aragón (BOA núm. 133 de 19/11/1993): Andorra–Sierra los Arcos, Bajo Aragón, Bajo Martín, Comunidad de Teruel, Cuencas Mineras, Gúdar–Javalambre, Jiloca, Maestrazgo, Matarraña y Sierra de Albarracín.

1.5.2.2. Actividades económicas

El envejecimiento en la estructura poblacional es un grave problema social y económico para la provincia de Teruel que afecta de forma decisiva a su potencial de desarrollo. Así, el porcentaje de población activa provincial en 2001 era del 47%, inferior tanto a la media de Aragón (54%) como a la española (56%), existiendo municipios con tasas inferiores al 30%. Por su parte, la tasa de paro provincial, tomando los datos del cuarto trimestre de 2004, puede considerarse como baja, ya que se situaba en el 5% de la población activa, por debajo de la mitad de la tasa registrada en el conjunto nacional (10%); las razones son dos: la baja tasa de actividad y el carácter de la estructura económica de la provincia, ya que las actividades agrarias y de servicios, caracterizadas ambas por un importante porcentaje de autoempleo, aportan un alto grado de estabilidad al conjunto del mercado laboral (Guillén, 2005b).

La economía de la provincia es cada vez más abierta, aunque con una tendencia a la especialización espacial. Las actividades agrarias siguen siendo la principal forma de uso del territorio, aunque su papel es decreciente en cuestiones como la generación de rentas y la participación en el mercado de trabajo, pudiéndose hablar incluso de una “desagrarización” de la provincia (Rubio, 2005a). Algunos de los aspectos que caracterizan al sector agrario turolense son: (i) el bajo porcentaje de Superficie Agraria Útil (SAU), en torno al 50% de la superficie, lo que indirectamente señala la importancia de otros usos del suelo (forestal, erial-pastos...); (ii) la extensión de los cultivos herbáceos, fundamentalmente el cereal extensivo de secano (52% de la SAU), aunque la variedad climática permite la existencia de otros cultivos como los frutales, la vid y el olivo; (iii) la baja productividad como resultado de la elevada media de edad de la población activa en este sector, su escasa cualificación, la atomización de las explotaciones, la escasez de tierras de regadío y los rigores del medio físico; (iv) la escasa competitividad de las explotaciones con tierras, tanto por su tamaño (74 ha de media) como por su alto grado de parcelación (31 parcelas por explotación), siendo la extensión media por parcela solamente de 0,79 ha; (v) la elevada edad de los jefes de

explotación y la falta de formación agraria, que constituyen una barrera fundamental a la hora de aplicar innovaciones; (vi) la escasa capacidad del sector a la hora de crear empleo, más allá del autoempleo; y (vii) el auge de la agricultura a tiempo parcial.

Pese a los anteriores condicionantes, la actividad agraria concentraba en 2001 alrededor de un 14% de los ocupados totales de la provincia. Otro hecho importante a destacar es que el agrícola, junto con el ganadero, sigue siendo un sector estratégico para la provincia, ya que en muchas localidades rurales es su único motor económico (Guillén, 2005c). Una de cada tres explotaciones agrarias mantiene una orientación ganadera, siendo la presión ganadera provincial de 0,44 Unidades de Ganado Mayor (UGM) por hectárea de SAU y de 51,4 UGM por explotación. El ganado porcino (en régimen intensivo) constituye un 57% del censo, siendo el ovino (semiextensivo) el segundo más importante con un 29%. La explicación del predominio de estas dos cabañas ganaderas se encuentra en el empuje dado por las denominaciones de origen Jamón de Teruel y Ternasco de Aragón, que aseguran a los ganaderos rentas superiores a las obtenidas cuando se trabaja con producciones no certificadas (Rubio, 2005b).

Al contrario que la agraria, las actividades industriales y terciarias se encuentran en crecimiento (Rubio, 2005a). Entre las primeras se incluye el sector minero-energético, de gran tradición dada la existencia de importantes reservas mineras, sobre todo de carbón. A pesar de la pérdida de importancia, desde mediados de los 50, del carbón como fuente energética a escala nacional y de los diversos procesos de reconversión sufridos en el sector, la actividad minero-energética sigue siendo de gran importancia para la economía turolense, especialmente por cuanto su impacto económico se localiza sobre todo en dos comarcas: Andorra-Sierra los Arcos y Cuencas Mineras. En la actualidad, la producción de carbón se destina a alimentar las dos centrales termoeléctricas emplazadas en la provincia, en Andorra y en Escucha. El futuro de este sector en la provincia depende de los cambios en la política energética nacional y comunitaria, siendo una de las principales alternativas la reorientación del actual sector hacia la producción de energías renovables (Rubio y Royo, 2005a). Procede destacar una vez más en este punto las posibilidades que tendría el aprovechamiento de la biomasa residual forestal, dada la existencia de una importante masa forestal y la tradición que la provincia tiene en el sector energético.

El peso de actividad industrial no es tan notable como en otras provincias, aportando el 38% del Valor Añadido Bruto (VAB) y el 31% del empleo. Tres son las

ramas industriales que destacan en la provincia de Teruel: (i) la agroalimentaria, con presencia en todas sus comarcas y con un futuro asegurado gracias a las cuatro denominaciones de origen existentes; (ii) la de transformados metálicos, compuesta por grandes empresas concentradas en la zona de la capital y en la comarca de Cuencas Mineras y por pequeños talleres dispersos por toda la provincia; y, finalmente, (iii) la construcción, que es la principal actividad secundaria en todas las comarcas. La actividad industrial ha mejorado progresivamente sus cifras en la economía provincial, adsorbiendo las dificultades generadas por el proceso de reconversión del sector minero-energético (Rubio y Royo, 2005b).

Dentro del sector terciario, el comercio es la rama más importante, ya que tan sólo las actividades agrarias superan el número de personas empleadas en esta actividad. Además de por este dato, el comercio también es importante porque contribuye a dinamizar económicamente otras actividades y garantiza la calidad de vida de la población. Existe un dominio de establecimientos comerciales de pequeño tamaño y carácter familiar, con una tendencia a la concentración de bienes y servicios ofertados, destacado el porcentaje de comercios clasificados como mixtos por secciones, similares a los supermercados. En cuanto a su distribución territorial, como es lógico, existe una mayor concentración en las comarcas en las que el volumen de población es mayor (comarca de Teruel y Bajo Aragón) (Guillén, 2005d).

Por último, puede destacarse la importancia del turismo, considerado tradicionalmente como uno de los puntos fuertes de la provincia para potenciar su desarrollo económico. Para ello, la provincia de Teruel cuenta con los tres elementos necesarios: (i) existencia de unos recursos atractivos, tanto cuantitativa como cualitativamente, basados en su diversidad natural y cultural (ciudad de Albarracín, arte Mudéjar, Dinópolis...), destacando su alto grado de conservación, sobre todo de los naturales; (ii) existencia de una demanda interesada en conocer esta oferta, básicamente formada por una sociedad urbana que demuestra un creciente interés por disfrutar su tiempo libre en el medio rural; y (iii) existencia de una infraestructura y gestión turísticas adecuadas, basadas en la calidad pero sin descuidar el mantenimiento del carácter de ruralidad que atrae a la demanda. En este sentido las instituciones implicadas deben centrar sus esfuerzos en acciones encaminadas al fomento de la calidad, la profesionalización del sector y su ordenación territorial (Guillén, 2005e).

1.5.2.3. Infraestructuras, transporte e infoestructuras

La carencia de infraestructuras de la provincia de Teruel es el principal factor limitante de cara al desarrollo económico territorial. La ausencia de vías de gran capacidad y de conexiones ferroviarias de alta velocidad supone una deficiencia estructural que afecta a todos los componentes de su organización territorial y que sitúa a esta provincia -a pesar de su interesante posición geoestratégica- en una clara desventaja competitiva respecto de otras. Esta carencia de infraestructuras se manifiesta tanto en la cantidad como en la calidad y afecta a la movilidad intraprovincial e interprovincial. Dos hechos que ponen de manifiesto estas afirmaciones son que hasta 2001 no había ningún kilómetro de autovía construido y que, aún en la actualidad, Teruel capital sigue siendo la única capital provincial peninsular sin conexión ferroviaria con Madrid. Respecto de la movilidad intraprovincial, las limitaciones impuestas por el medio físico no han sido superadas por las infraestructuras viarias presentes, lo que ha impedido la completa vertebración de la provincia; sólo 100 de los 3.000 km de red viaria existentes son de vía rápida (Autovía Mudéjar, A-23), correspondiendo un 50% de las carreteras a vías de una sola calzada con menos de 7 m de anchura (Guillen, 2005f).

Esta realidad tan desfavorable para la provincia está intentando ser corregida por las diferentes Administraciones; de esta manera dos mejoras sustanciales en materia de infraestructura y transportes que se han ejecutado en los últimos años son la Autovía Mudéjar y la renovación de la vía férrea Zaragoza-Valencia. En cuanto a actuaciones futuras, el *Plan Estratégico de Infraestructuras y Transportes* (PEIT) pretende convertir la capital provincial en un centro intermodal de transporte, importante a escala regional, aprovechando la Autovía Mudéjar y el desarrollo de una conexión férrea entre el Cantábrico y el Mediterráneo. Otras actuaciones en esta materia no contempladas y demandadas por los agentes sociales provinciales son el desdoblamiento de la carretera que comunica Zaragoza con el Mediterráneo por el Bajo Aragón (N-232) y la conexión directa entre Teruel y Madrid mediante alta velocidad. Estas obras, junto con las previstas por el PEIT, permitirían que Teruel no quede definitivamente fuera de las redes internacionales de transporte en los próximos años, lo que de producirse sería un serio lastre para el futuro socio-económico de la provincia (Guillén, 2005f).

Finalmente, comentar la situación de las infoestructuras de la provincia, entendidas éstas como “el conjunto de elementos y servicios que, estrechamente relacionados con las nuevas Tecnologías de la Información y la Comunicación (TIC), permiten el desarrollo social y económico de todo grupo humano” (Guillén, 2005g). Las

características de la provincia de Teruel hasta ahora comentadas (difícil medio físico, baja densidad de población, carácter rural de los asentamientos, deficiencia de infraestructuras de transporte) convierten a las infoestructuras como Internet en una herramienta fundamental para el desarrollo del potencial económico del territorio y para elevar la calidad de vida de sus habitantes. Sin embargo, a pesar de los esfuerzos realizados por las distintas Administraciones (programas “Teruel Digital” e “Internet Rural”), las cifras que se tienen sobre el acceso y uso de las TIC en la provincia están todavía lejos de las registradas a nivel regional (Guillén, 2005g).

***CAPÍTULO 2:
OBTENCIÓN DE LAS VARIABLES A
EMPLEAR EN EL MODELO DE
ESTIMACIÓN DE LA BIOMASA RESIDUAL
FORESTAL POTENCIAL DE LA
PROVINCIA DE TERUEL***

2.1. Los datos de biomasa residual forestal

Como se ha señalado en el apartado 1.4, dedicado a las fases y metodología de esta tesis, el presente apartado se identifica con la primera de las actividades de la fase 1. Se aborda, por tanto, la obtención de los datos de biomasa residual forestal que, posteriormente, serán relacionados con las variables radiométricas, topográficas y forestales para elaborar el modelo de estimación de la biomasa residual forestal.

La metodología aquí empleada sigue el criterio de muestreo en dos fases de Parresol (1999). En este tipo de muestreo, la primera fase consiste en la selección de un gran número de árboles sobre los cuales se miden diferentes propiedades o características (*dbh*, altura...). En la segunda se toma una muestra mucho más reducida de ejemplares para desarrollar funciones alométricas que permitan modelar la variable que se quiere estimar. Estas funciones o ratios son posteriormente aplicadas a todos los árboles de la primera fase y se obtiene la variable deseada para todo el territorio previamente inventariado.

En esta investigación, la primera fase de este muestreo en dos fases se corresponde con trabajo realizado en el IFN-2 de la provincia de Teruel (Ministerio de Medio Ambiente, 1996). Se trata, por tanto, de aprovechar información preexistente de los bosques del área de estudio, ya que gracias a este inventario se dispone de las variables dendrométricas de un gran número de árboles distribuidos por todo su territorio. Por el contrario, la segunda fase es realizada mediante trabajo de campo, consistente en el apeo de distintos ejemplares para conocer su cantidad de biomasa residual. A partir de los datos de campo se establecen unas ecuaciones que relacionan la biomasa residual pesada con alguna variable dimensional del árbol, con lo que estas ecuaciones pueden ser aplicadas a la información de las parcelas del IFN-2. Tal aplicación y la posterior espacialización de las mismas componen los últimos pasos del presente apartado, finalizándose así el proceso de obtención de los datos de biomasa residual forestal que intervendrán como variable dependiente en el modelo de estimación. La Figura 2.1 representa de manera esquemática este proceso metodológico, que fue desarrollado conjuntamente con el personal de CIRCE que participaba en el proyecto LIGNOSTRUM, siendo éstos los responsables de las tareas de diseño del trabajo de campo, ejecución del mismo, establecimiento de las ecuaciones alométricas y aplicación de éstas a las parcelas del IFN-2 de la provincia de Teruel.

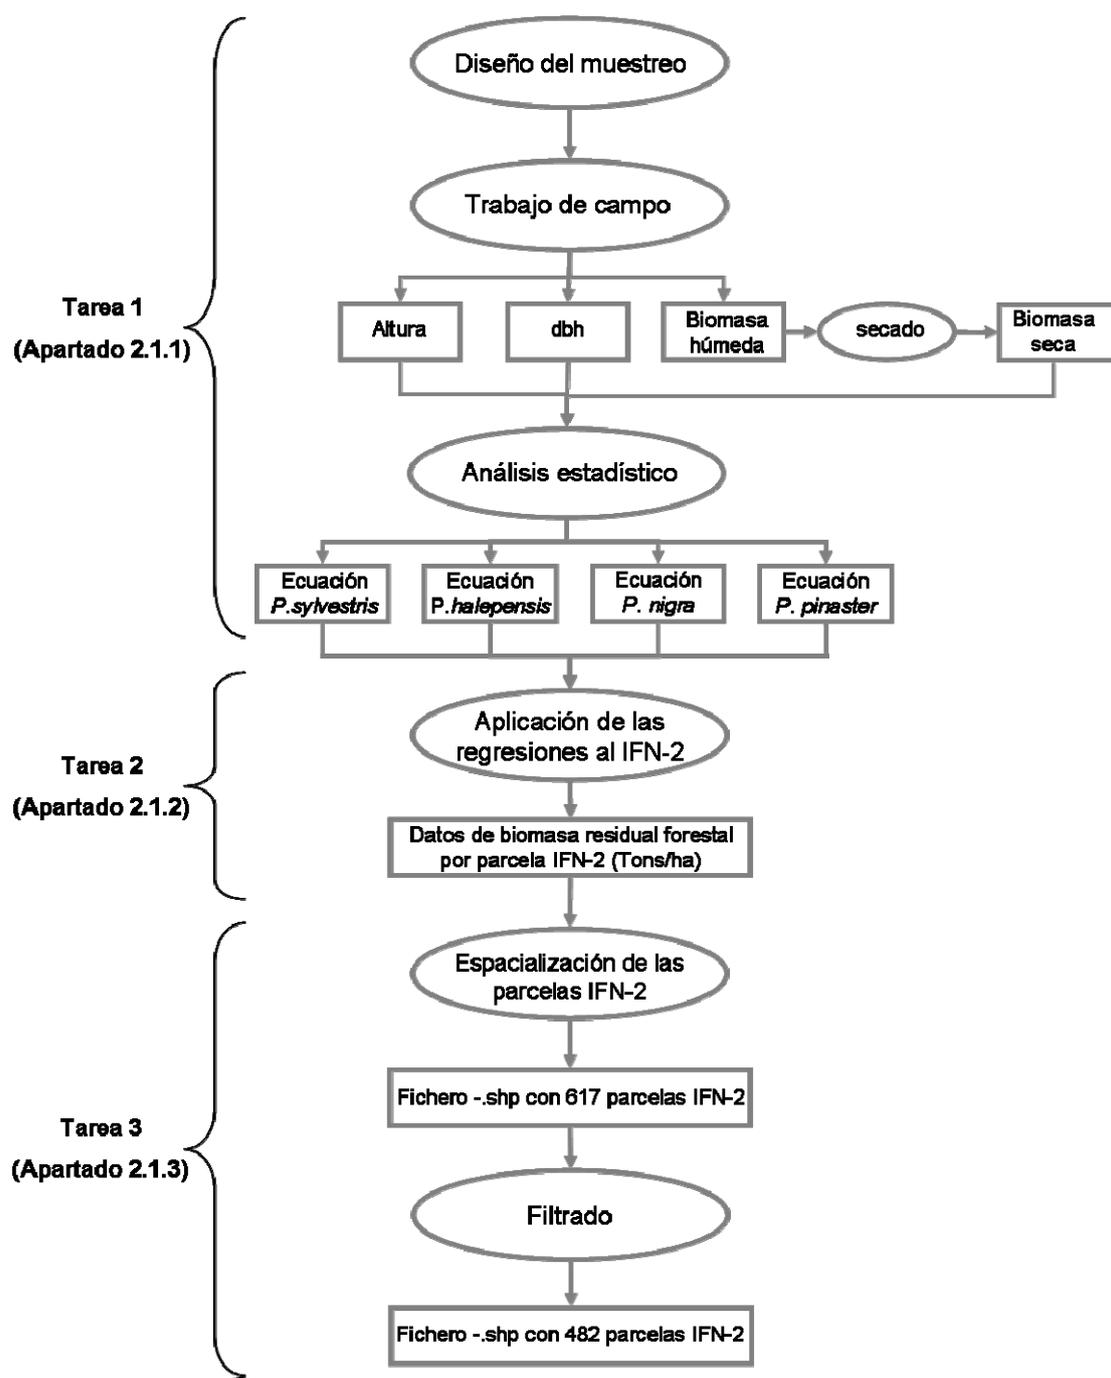


Figura 2.1. Diagrama de flujos del proceso metodológico seguido para obtención de los datos de biomasa residual forestal

Dada la inviabilidad económica de realizar la segunda fase para todas las especies forestales presentes en la provincia de Teruel, se decidió en el seno del proyecto LIGNOSTRUM seleccionar las especies que cumplieran un doble criterio: elevada presencia en el área de estudio según los datos del IFN-2 y alto potencial para la

generación de residuos aprovechables desde el punto de vista energético. Este doble criterio llevo a la selección de 4 especies: pino silvestre (*Pinus sylvestris*), pino carrasco (*P. halepensis*), pino laricio (*P. nigra*) y pino pinaster (*P. pinaster*). La suma de las superficies forestales en las que una de estas cuatro especies aparece como dominante más la superficie compuesta por mezcla de ellas supone el 19,1% de la total provincial y el 71,41% de su superficie forestal arbolada (Tabla 2.1). En relación con el segundo criterio, dada la dominancia de estas masas de pinar y su procedencia en muchos casos de repoblaciones, la mayor parte de las actuaciones selvícolas y de explotaciones madereras realizadas en la provincia de Teruel tienen lugar en estos bosques, por lo que es en ellos en los que se contabilizan las mayores cantidades de residuos.

Especie	Hectáreas	% sobre el total de superficie forestal	% sobre la superficie total provincial
<i>Pinus sylvestris</i>	81.447	20,56	5,50
<i>Pinus halepensis</i>	77.169	19,48	5,21
<i>Pinus nigra</i>	47.782	12,06	3,23
<i>Pinus pinaster</i>	29.032	7,33	1,96
Mezcla de pinos	47.429	11,98	3,20
<i>Juniperus thurifera</i>	57.646	14,56	3,89
<i>Quercus ilex</i>	42.773	10,80	2,89
<i>Quercus faginea</i>	11.860	2,99	0,80
<i>Populus sp.</i>	911	0,23	0,06

Tabla 2.1 Superficie forestal arbolada por especie dominante en la provincia de Teruel. Fuente: IFN-2

2.1.1. Trabajo de campo y obtención de las regresiones de biomasa residual forestal por árbol

En la literatura científica, la biomasa total área de un árbol (*Aboveground biomass –AGB–*, en la bibliografía anglosajona) se estima mediante dos métodos: (i) la utilización de factores de expansión de la biomasa (*Biomass Expansion Factors*), que son ratios que relacionan la cantidad de biomasa de una determinada fracción del árbol con el volumen en metros cúbicos del fuste (p.e. Schroeder *et al.*, 1997; Brown *et al.*, 1999; Lehtonen *et al.*, 2004) ; y (ii) mediante la utilización de regresiones alométricas, que, como se ha indicado, relacionan la cantidad de biomasa de un árbol con variables dimensionales del mismo (generalmente con el *dbh* y/o la altura) (p.e. Ketterings *et al.*, 2001; Porté *et al.*, 2002; Zianis y Mencuccini, 2004; Montero *et al.*, 2005; Wang, 2006; Pilli *et al.*, 2006;). El segundo de estos métodos fue el elegido para la estimación de la biomasa residual forestal de las especies de pináceas consideradas.

Dos fueron los motivos que llevaron a desarrollar ecuaciones de regresión

específicas para cada una de las cuatro especies seleccionadas en el área de estudio:

- Las ecuaciones alométricas para estimar biomasa total muestran una gran variación, no sólo dependiendo de la especie, sino también de otros factores como la zona geográfica (Ketterings *et al.*, 2001), la calidad de estación, el clima y la edad de población (Zianis y Mencuccini, 2004).
- Hasta la aparición del trabajo de Montero *et al.* (2005) (posterior a la fecha de inicio-desarrollo del proyecto LIGNOSTRUM), las funciones alométricas desarrolladas en España eran escasas, no existiendo ninguna ecuación específica para la estimación de la fracción de biomasa considerada en este trabajo para cada una de las especies del género *Pinus* existentes en Teruel.

2.1.1.1. Diseño, métodos de muestreo y composición de la muestra

Teniendo en cuenta que el número de muestras debe ser el mayor posible, se diseñó un muestreo estratificado por especies. Dentro de cada una, la distribución del muestreo se hizo de forma proporcional al número de pies, al volumen de leñas y al área basimétrica, datos todos ellos recogidos en el IFN-2. El rango de *dbh* considerado fue de 7,5 a 40 cm, ya que los valores extremos de este rango coinciden, respectivamente, con el diámetro mínimo recogido en la mayor parte de los inventarios forestales y con los diámetros medios de las cortas finales que aparecen en las tablas de producción para las calidades más habituales en la provincia de Teruel.

Debido al carácter destructivo del muestreo (pesado de la biomasa residual húmeda del pie arbóreo después de su apeo y desramado), las áreas muestreadas se limitaron a montes gestionados por el Servicio Provincial de Medio Ambiente de la provincia de Teruel en los que se realizaron tareas de tratamiento selvícola coincidentes con la época prevista en LIGNOSTRUM para la realización del trabajo de campo (noviembre de 2003 a junio de 2004) (Figura 2.2). Este hecho, junto a factores climatológicos adversos para la realización de tareas de campo, impidió el desarrollo del trabajo conforme a lo planificado, quedándose sin muestrear la totalidad del rango previsto en alguna de las especies. Aun así, el número de pies muestreados por especie se consideró *a priori* satisfactorio¹², con la única excepción de *P. pinaster* ya que, como

¹² Esta afirmación se hace en función de la bibliografía referida al cálculo de ecuaciones alométricas. Sirva como ejemplo el trabajo de Termikaelian y Korzukhin (1997), en el cual se recopilan ecuaciones para estimar diferentes compartimentos de biomasa. En este trabajo, de las

veremos más adelante, requiere la separación de su muestra en dos sub-poblaciones a la hora de ajustar las ecuaciones alométricas (*P. pinaster* de origen natural y de origen artificial), lo que hace que el número de ejemplares en cada uno de los grupos resultantes se sitúe por debajo de 30 (28 y 12 árboles, respectivamente)¹³ (Tabla 2.2).

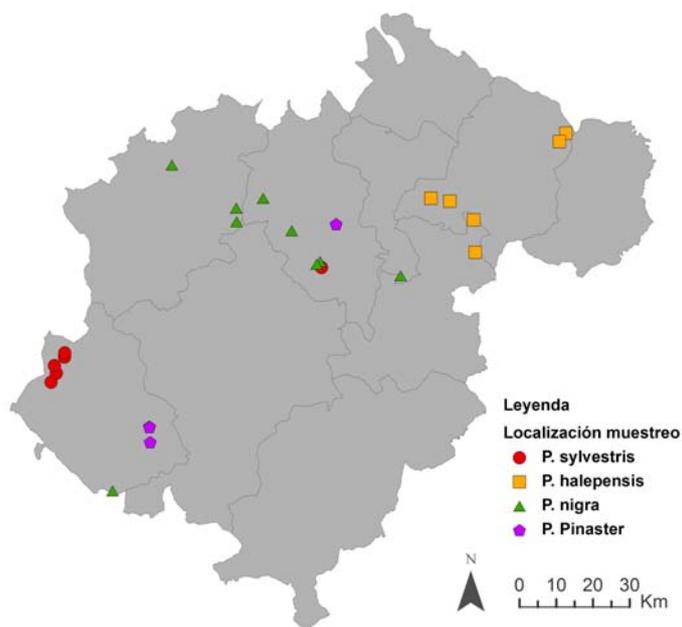


Figura 2.2. Localización de las zonas donde se realizó el muestreo de campo

La forma de proceder en el trabajo de campo fue la siguiente:

- Antes de ser apeado el pie arbóreo, se midió su *dbh* mediante una forcípula (dos diámetros perpendiculares a 130 cm del suelo con precisión milimétrica) y se tomó la densidad del rodal (*DENS*) mediante el conteo del número de pies incluidos en una parcela de 100 m².
- Una vez apeado, la altura total (*ALT*) fue medida mediante una cinta métrica, con lo que se obtuvo esta variable con una precisión centimétrica.
- Tras las operaciones de desramado y despunte llevadas a cabo por los operarios forestales, el peso de la biomasa residual húmeda fue obtenido mediante la

133 regresiones que explican la biomasa aérea total, casi el 50% se realizan con menos de 28 ejemplares, mientras que el 12% se ajustan con menos de 12.

¹³ Aunque hubiera sido deseable contar con un mayor número de pies muestreados en el caso de *P. pinaster* (sobre todo en el subgrupo de origen artificial), este problema es considerado menor ya que es la especie de pino menos representada en la provincia (Tabla 2.1).

utilización de una báscula romana que permitió una precisión de 250 gramos.

- Se procedió entonces a recoger en cada árbol una muestra de acículas y otra de ramas, procurando extraer fracciones en las diferentes orientaciones y alturas.
- Cada una de las muestras fue guardada herméticamente y llevada al laboratorio, donde fueron sometidas a un proceso de secado a 105 °C hasta llegar a un peso constante (Ketterings *et al.*, 2001; Joosten *et al.*, 2004).
- Finalmente, el peso en seco de la biomasa residual forestal (BT) se calculó a partir del peso en húmedo, la humedad de las muestras y la proporción de acículas y ramas para cada especie. Esta última variable se obtuvo mediante la información existente en el *Inventari Ecologic y Forestal de Catalunya* (CREAF, 2000), comprobándose que, dadas las pequeñas diferencias en la humedad de las acículas y las ramas muestreadas, pequeñas variaciones en las proporciones de éstas no influían apenas en el peso seco de la biomasa residual de cada árbol.



Figura 2.3. A) Materiales utilizados en el trabajo de campo; B) pie arbóreo apeado desramado y despuntado; C) medición de la altura posterior al apeo; D) pesada de la biomasa en húmedo

La Figura 2.3 muestra el instrumental utilizado y distintas fases del proceso; la Tabla 2.2 ofrece una descripción estadística de la muestra obtenida mediante trabajo de campo.

Especie	Muestreado		Repoblación	dbh rango (cm)	Biomasa residual (peso en seco)		
	Nº pies	(%)	Nº pies y (%)		Media (kg)	Desv. est. (kg)	Error est. Media (kg)
<i>P. sylvestris</i>	30	15,7%	--	10,5-38,6	59,73	46,71	8,52
<i>P. halepensis</i>	59	31,1%	34 (57,6%)	7,7-34,2	54,30	54,20	7,05
<i>P. nigra</i>	57	30,0%	47 (82,5%)	9,7-39,9	54,39	50,59	6,70
<i>P. pinaster</i>	40	23,2%	12 (27,3%)	7,8-41,7	42,77	39,83	6,00
Total	186	100,0%	--	7,7-41,7	52,51	48,87	3,54

Tabla 2.2. Composición de la muestra por especies: nº de pies y % sobre el total muestreado, nº y % de pies procedentes de repoblaciones, rango de los diámetros muestreados, desviación estándar y error estándar de la media de la biomasa residual forestal (peso en seco). Fuente: Alonso *et al.* (2005)

2.1.1.2. Análisis estadístico y ajuste de las regresiones de estimación de biomasa residual forestal por árbol

2.1.1.2.1. Análisis estadístico

Para cada una de las especies muestreadas se realizó un análisis estadístico individualizado, seleccionándose en cada caso la forma de la ecuación de regresión óptima que minimizara la variabilidad no explicada.

El procedimiento comenzó con un análisis gráfico de la respuesta (*BT*, peso de la biomasa residual forestal a humedad cero) frente a las dos potenciales covariables numéricas más influyentes en los trabajos de biomasa (*dbh* y *ALT*). En esta aproximación las cuatro especies mostraron una relación no lineal entre la respuesta y el diámetro. Además, en este primer análisis, también se detectó la existencia de dos sub-poblaciones dentro de la muestra de *P. pinaster*, ya que para un mismo valor de *dbh* se observó una mayor *BT* en los pies procedentes de repoblaciones que en los de origen natural.

En segundo lugar, teniendo en cuenta las conclusiones extraídas del análisis gráfico, se propuso un modelo de regresión no lineal siguiendo una forma ampliada del modelo alométrico tradicional (Ecuación 20); esta forma aparece en los trabajos de Bartelink (1997) y Esteban y Carrasco (2001). Una de las características importantes de este modelo es ser lo suficientemente plástico para mostrar relaciones directas (valores positivos de *b* o *c*) o inversas (valores negativos) con las covariables.

$$BT = a \cdot dbh^b \cdot ALT^c \quad \text{Ecuación 20}$$

donde *a* es el coeficiente de la variable *dbh* (diámetro medio medido a 1,30 cm del suelo), *ALT* es la altura, *b* y *c* son los exponentes modificadores de las variables *dbh* y *ALT*.

En este paso se obtuvieron, además de la estimación puntual, intervalos de confianza al 95% para los exponentes b y c . Esto permitió contrastar la hipótesis de si el exponente c era nulo, situación que, de producirse, era indicadora de que la covariable ALT no era útil para la regresión, con lo que la Ecuación 20 perdería su segundo término y coincidiría con la alométrica citada con frecuencia en la bibliografía científica (Termikaelian y Korzukhin, 1997; Zianis y Mencuccini, 2004).

Para analizar la influencia del origen de la masa forestal (natural o repoblada) se propuso una modificación de la Ecuación 20 que estribaba en la inclusión de un factor binario ($ORIGEN$), que distingue entre los árboles muestreados que proceden de masas repobladas ($ORIGEN=0$) y los de masas forestales de origen natural ($ORIGEN=1$). Este factor binario se aplicó sobre los exponentes que acompañan a ambas covariables (Ecuación 21).

$$BT = a \cdot dbh^{b+d*ORIGEN} \cdot ALT^{c+e*ORIGEN} \quad \text{Ecuación 21}$$

donde a es el coeficiente de la variable dbh (diámetro medio medido a 1,30 cm del suelo), ALT es la altura, b y d son los exponentes que modifican a la variable dbh , c y e son los exponentes que modifican a la variable ALT y $ORIGEN$ es el factor binario que controla la influencia de la procedencia de la masa forestal.

Sobre la base de estas dos ecuaciones se llevó a cabo el paso de crítica del modelo de regresión. Para ello, en primer lugar, se analizó la presencia de datos atípicos, que correspondían a casos aislados que no eran representativos de la población o que resultaban en exceso influyentes en el proceso de estimación y producían una deformación en los parámetros estimados. Para identificarlos se utilizó el criterio de la distancia de Cook, eliminándose aquellas observaciones cuyas distancias superaban en más de tres veces la segunda distancia de Cook más grande. En segundo lugar, se procedió a la verificación de los supuestos estadísticos básicos relativos a la influencia de las covariables: la normalidad de los residuos (test de Kolmogorov-Smirnov; $p>0,05$), su homocedasticidad (test de Levene aplicado a los grupos establecidos en función de la clase diamétrica; $p>0,01$) y, por último, la independencia estadística de las muestras, la cual, en principio, estaba asegurada por el procedimiento de muestreo seguido. Cuando los residuos mostraron heterocedasticidad -situación bastante común de acuerdo con la bibliografía (Crow y Laidly, 1980; Parresol, 1999)- se procedió a rehacer la regresión con pesos X^k , que ponderaban cada observación inversamente respecto a la variabilidad que

presentaba en el modelo de regresión, estudiándose qué pesos eran los que resuelven correctamente el problema de heterocedasticidad (Ecuación 22). A este respecto, señalar que las regresiones con pesos se han mostrado como alternativa aceptable, incluso ventajosa, a las transformaciones logarítmicas para solventar el problema de heterocedasticidad de los residuos, evitando el sesgo incurrido en la transformación del modelo logarítmico para realizar predicciones (Crow y Laidly, 1980).

$$BT \cdot X^{-k} = (a \cdot dbh^b \cdot ALT^c) \cdot X^{-k} \quad \text{Ecuación 22}$$

donde a es el coeficiente de la variable dbh (diámetro medio medido a 1,30 cm del suelo), ALT es la altura, b es el exponente que modifica a la variable dbh , c es el exponente que modifica a la variable ALT y X^k es el peso que homogeniza adecuadamente la varianza de los residuos.

Al final del proceso, se consideró satisfactoria para cada especie la ecuación de las expresadas que superó el paso de crítica del modelo de regresión, siendo utilizado el procedimiento por pasos *hacia delante* del programa estadístico SPSS para determinar los modelos idóneos. En el caso de que más de un modelo superara la fase crítica, se seleccionó, tal y como se ha señalado más arriba, el que más minimizaba el error estándar asociado a la respuesta (BT).

Aunque las ecuaciones descritas en este subapartado sólo tienen en cuenta las variables dimensionales dbh y ALT , es conveniente señalar que también se estudió la introducción en ellas de la variable $DENS$, así como la posibilidad de utilizar modelos de tipo polinómico, logarítmicos y exponenciales, siendo utilizado, como veremos más adelante, uno de estos últimos para la estimación de la biomasa residual de *P. nigra*. Más detalles sobre este análisis estadístico pueden encontrarse en Alonso *et al.* (2005).

2.1.1.2.2. Ajuste de las regresiones de estimación de biomasa residual forestal por árbol

La Tabla 2.3 muestra las ecuaciones de estimación de biomasa residual forestal por árbol obtenidas para cada especie; dos en el caso de *P. pinaster*. Junto a las expresiones matemáticas se incluye información estadística sobre su fiabilidad e información sobre la eliminación de casos y pesos aplicados.

La regresión obtenida para *P. sylvestris* resultó especialmente sencilla. Para su ajuste no fue necesario eliminar ninguna de las observaciones de la muestra, ya que ninguna de ellas presentaba valores atípicos en función del criterio expresado. Así

mismo, tampoco fue necesaria la aplicación de pesos X^k , dado que los residuales no mostraban indicio alguno de heterocedasticidad. El ajuste obtenido se consideró muy satisfactorio, ya que la desviación típica inicial de la respuesta (46,71 kg) se ha reducido a una variabilidad aleatoria de 12,30 kg por árbol.

El modelo ajustado para *P. halepensis* es muy similar al anterior. Aunque en principio los exponentes b y c tomaron los valores de 2,92 y -0,92, respectivamente, éstos fueron remplazados por los valores enteros 3 y -1, dado que sus intervalos de confianza contienen estos valores, por lo que son compatibles con la información muestral. Esta regresión sí que requirió el uso de un peso X^k , dado por el inverso del diámetro ($1/dbh$), en los árboles procedentes de repoblaciones y la mitad para los de origen natural ($1/2 \cdot dbh$), puesto que se observó una variabilidad creciente con el diámetro, más acentuada en los pies de origen natural. Por último, este modelo de regresión, al igual que el de *P. sylvestris*, también proporciona una fuerte reducción de la variabilidad no explicada, ya que la desviación típica de la biomasa residual en la muestra era de 54,20 kg, mientras que el valor estimado en un pie tiene una desviación típica de sólo 13,06 kg.

Aunque el modelo de Ecuación 20 para *P. nigra* mostró resultados satisfactorios, el ajuste de un modelo exponencial presentó un error estándar de la respuesta menor, por lo que este último fue el seleccionado. Además de esta particularidad respecto a las dos especies anteriores, otra diferencia es la ausencia de la variable ALT en la ecuación. Por otra parte, la creciente variabilidad de los residuos de este modelo con el diámetro obligó a realizar una ponderación para verificar la hipótesis de homocedasticidad, usando para ello el inverso del diámetro.

Por último, como se detectó desde un principio en el análisis gráfico, fue necesario ajustar dos ecuaciones distintas para *P. Pinaster*: una para los pies de origen natural y otra para los pies de origen artificial. La Ecuación 21 indicó que había diferencias significativas entre los parámetros de ambos grupos, confirmando lo ya observado en el análisis gráfico. Aunque el rango de valores de diámetro muestreado en las tareas de campo fue bastante menor en los pies artificiales, el rango de estos pies en la provincia, según los datos del IFN-2, es bastante reducido (7,75-31,65), por lo que está bien cubierto a pesar de que no fue una covariable considerada al diseñar el muestreo. La principal diferencia en las ecuaciones de regresión de ambas subpoblaciones se encuentra en la relación biomasa-altura, que es directa para los pies artificiales (exponente positivo, 0,33) e inversa para los naturales (exponente negativo, -1). Esta

última relación inversa ha sido también observada en el resto de las especies y en otros estudios (Perala y Alban, 1994), mientras que el exponente positivo solamente aparece para la subpoblación de artificiales, aunque con un valor muy bajo, por lo que la ecuación resultante es bastante similar a la alométrica. A pesar de esto, la covariable *ALT* se termina incluyendo en la ecuación de regresión porque minimiza en mayor medida el error asociado a la respuesta que el uso de la alométrica. Sin embargo, es necesario señalar que el pequeño tamaño muestral de esta subpoblación (12 pies) condiciona la validez del análisis. Por otra parte, dos observaciones fueron retiradas de la muestra correspondiente a los pies naturales por considerarse atípicas. La ecuación resultante fue aceptada a pesar de que el *p-valor* de Levene, que valida la hipótesis de homocedasticidad, rozaba el valor crítico. Finalmente señalar que, como en los casos anteriores, la reducción de la desviación típica de la biomasa residual lograda por las dos ecuaciones es importante, ya que, frente a los 39,83 kg de la muestra total de *P. Pinaster*, la desviación típica es de 12,18 kg para los pies artificiales y 6,00 kg para los naturales.

Especie	Modelo	R ² adj	Desv. (kg)	Casos elimin.	Peso (X ^k)	p-KS	p-Lev
<i>P. sylvestris</i>	$BT=0,064 \cdot dbh^{3,3}/ALT^{1,5}$	0,974	12,30	-	-	0,682	0,122
<i>P. halepensis</i>	$BT=0,067 \cdot dbh^3/ALT$	0,969	13,06	-	$1/(dbh \cdot (1+ORI))$	0,689	0,061
<i>P. nigra</i>	$BT=338,416 \cdot e^{-35,116/dbh}$	0,910	18,84	2	$1/dbh$	0,814	0,031
<i>P. pinaster</i> Artificial	$BT=1,97 \cdot 10^{-4} \cdot dbh^{3,823} \cdot ALT^{0,337}$	0,974	12,18	-	-	0,116	0,056
<i>P. pinaster</i> Natural	$BT=1,101 \cdot 10^{-3} \cdot dbh^4/ALT$	0,973	6,00	2	-	0,174	0,013

Tabla 2.3. Modelos de regresión ajustados para la estimación de biomasa residual, R² ajustado, desviación típica, nº de casos eliminados, expresión de los pesos utilizados y p-valor de los estadísticos de Kolmogorov-Smirnov y Levene. Fuente: Alonso et al. (2005)

Como último paso para validar la bondad de los modelos de regresión propuestos, éstos fueron comparados con la forma que hubieran adquirido si se hubiera ajustado un modelo alométrico tradicional. La Tabla 2.4 muestra cómo el R² ajustado es siempre mayor en las regresiones aquí ajustadas que en sus respectivos modelos alométricos, mientras que la desviación típica de la biomasa residual es siempre menor. Así pues, la utilización de la forma alométrica ampliada de la Ecuación 20 ha sido positiva, ya que se han mejorado las estimaciones que se hubieran obtenido siguiendo la forma tradicional.

La Tabla 2.4 recoge también una ecuación de regresión única ajustada para estimar conjuntamente la biomasa residual de las cuatro especies de pinos consideradas, así como su respectiva forma alométrica. Tal y como indican el coeficiente de

determinación y el error estándar, estas dos ecuaciones únicas ofrecen peores resultados que considerando cada especie por separado, por lo que su uso fue desechado.

Especie	Modelo ajustado	R ² adj	Desv. (kg)	Modelo alométrico	R ² adj	Desv. (kg)
<i>P. sylvestris</i>	BT=0,064·dbh ^{3,3} /ALT ^{1,5}	0,974	12,30	BT=0,049·dbh ^{2,2}	0,945	17,97
<i>P. halepensis</i>	BT=0,067·dbh ³ /ALT	0,969	13,06	BT=0,055·dbh ^{2,36}	0,939	18,95
<i>P. nigra</i>	BT=338,416·e ^{-35,116/dbh}	0,910	18,84	BT=0,131·dbh ²	0,895	24,18
<i>P. pinaster Artificial</i>	BT=1,97·10 ⁻⁴ ·dbh ^{3,823} ·ALT ^{0,337}	0,974	12,18	BT=0,00022·dbh ⁴	0,971	12,73
<i>P. pinaster Natural</i>	BT=1,101·10 ⁻³ ·dbh ⁴ /ALT	0,973	6,00	BT=0,014·dbh ^{2,47}	0,945	10,15
Total <i>Pinus</i>	BT=0,148·dbh ^{2,66} /ALT	0,882	24,46	BT=0,167·dbh ^{1,9}	0,850	27,63

Tabla 2.4. Comparación de los modelos de regresión por especie propuestos con sus respectivas formas alométricas. Fuente: Alonso *et al.* (2005)

2.1.2. Aplicación de las regresiones de biomasa residual forestal por árbol a las parcelas del IFN-2

Una vez ajustadas las ecuaciones de estimación de biomasa residual de cada una de las especies seleccionadas se dio por cerrada la segunda fase del muestreo en dos fases. Tal y como indica la Figura 2.1, el siguiente paso es la aplicación de aquéllas a los datos del IFN-2 de la provincia de Teruel, que constituyen la primera fase del muestreo en dos fases. En el siguiente subapartado se hace una presentación de este IFN-2, centrándonos especialmente en la metodología de muestreo seguida: las parcelas de inventario. Acto seguido se muestra, en otro subapartado, la metodología seguida para el cálculo de la biomasa residual forestal en cada una de las parcelas del IFN-2 seleccionadas usando las regresiones calculadas en el anterior apartado.

2.1.2.1. El IFN-2 de la provincia de Teruel

El IFN-2¹⁴ nació de la necesidad de actualización del *Primer Inventario Forestal de España* (IFN-1), cuya fase de toma de datos sobre el terreno tuvo lugar entre 1965 y

14 El proyecto del IFN-2 formó parte de otro mayor, Inventariación de Recursos Naturales Renovables, del Ministerio de Medio Ambiente y se integró dentro del programa Protección y Mejora del Medio Natural. Desde el punto de vista administrativo dependió de la Subdirección General de Protección de la Naturaleza del extinto ICONA (perteneciente al Ministerio de Agricultura, Pesca y Alimentación, MAPA) y de la Subdirección General de Espacios Naturales y Vida Silvestre (también dependiente del MAPA). Al desaparecer el ICONA se hizo cargo del proyecto la Dirección General de Conservación de la Naturaleza del Ministerio de Medio Ambiente (Ministerio de Medio Ambiente, 1996).

1974. El IFN-1 informó por primera vez sobre la situación global de los montes de España, con datos a escala comarcal, provincial y regional, cubriendo el vacío de información entonces existente, cuando sólo se tenían conocimientos parciales. La tecnología que se empleó fue muy novedosa y similar a la de los países más avanzados en la materia en aquella época. En 1984, la Administración Forestal, consciente de que estaba manejando datos, en algunas zonas, con casi 20 años de antigüedad, comenzó el diseño y la programación del IFN-2, que debía ser la herramienta base para una mejor planificación y gestión del sector forestal, teniendo en cuenta la nueva situación institucional de España (Estado de las Autonomías, futura entrada en la Comunidad Económica Europea...) y los últimos avances científicos de la dasometría. El periodo de ejecución del trabajo de campo se proyectó para el decenio 1986-1995, estableciéndose como atributo básico que el inventario sería continuo (nuevo ciclo cada diez años) y que la unidad básica de información debía ser la provincia. Para cumplir con el objetivo de periodicidad, el IFN-2 fue diseñado como un muestreo sistemático sobre los vértices de la cuadrícula UTM de 1 km, de manera que en los sucesivos inventarios el seguimiento y la comparación de los datos estuvieran asegurados. La adopción de los adelantos técnicos de la época, especialmente en informática, dio lugar a un inventario de estructura y características bastante diferentes de las del anterior, siendo los resultados obtenidos superiores en cantidad, calidad y facilidad de manejo que los de su antecesor. En la actualidad, se está terminando el *Tercer Inventario Forestal Nacional* (IFN-3) (1997-2007) que, como es lógico, incorpora las mejoras tecnológicas acaecidas en estos últimos años, adoptando también las perspectivas sociales, económicas, ecológicas, etc. que actualmente se proyectan sobre el ámbito forestal. Entre los objetivos de este último inventario se destaca el estudio de la evolución de los montes españoles mediante la remediación de las parcelas del IFN-2 y la comparación entre los nuevos datos obtenidos y los del IFN-2 (Ministerio de Medio Ambiente, 1996, 2007; Del Río *et al.*, 2002).

Centrándonos en el IFN-2 de la provincia de Teruel, el trabajo de campo destinado a la recogida de datos se realizó entre marzo y agosto de 1994, las tareas de comprobación tuvieron lugar también ese mismo año y las de cálculo de las tablas en 1995 (Ministerio de Medio Ambiente, 1996).

Al igual que en el resto del territorio español, los contactos fotográficos empleados en las labores de campo y en la modernización de la cartografía de ecosistemas forestales fueron los del *Vuelo General de España* (1:30.000), que en la provincia de Teruel fue realizado entre 1984 y 1985. Para las tareas de recogida de datos sobre el

terreno se diseñó un muestreo estratificado de asignación proporcional al tamaño de los estratos y una distribución sistemática constituida por los puntos de cruce de las rectas kilométricas de las hojas 1:50.000 del *Mapa Topográfico Nacional* (MTN) clasificados como forestal arbolado. En estos puntos de intersección es donde se levantó la parcela de inventario, produciéndose en ella el arranque de los elementos. Con el fin de disminuir los costes se redujo el tamaño de la muestra de forma aleatoria, centrándose esta reducción en los estratos con valores de volumen con corteza (VCC) previsiblemente pequeños. De esta manera, el total de parcelas de muestreo a apearse se elevó a 2.250, resultando útiles un total de 2.083 para la realización de los cálculos de las tablas de resultados. Con esta última cifra se obtuvo una intensidad de muestreo de 1 parcela por cada 216 ha de forestal arbolado (Ministerio de Medio Ambiente, 1996).

A continuación se detallan algunos aspectos interesantes de la metodología seguida para la localización, delimitación y apeo de las parcelas del IFN-2 de la provincia de Teruel, análogos a los llevados a cabo en otras provincias. Estos aspectos son importantes en la presente tesis ya que, una vez que se apliquen sobre los datos de estas parcelas las ecuaciones de estimación de biomasa residual previamente ajustadas, éstas se convertirán en la “verdad terreno” que será relacionada con los registros de las imágenes de satélite y con la información auxiliar topográfica y forestal. Así pues, las características originales de estas parcelas de inventario controlaran una parte de los aciertos y errores en la consecución del objetivo marco de esta investigación.

- Localización y delimitación de la parcela en el campo

Como se ha indicado con anterioridad, las parcelas del IFN-2 se situaron en los puntos de cruce de la malla kilométrica UTM 1:50.000 del MTN que estaban dentro de zonas clasificadas como arboladas. La fuente que se empleó para determinar si una zona era -o no- arbolada fue el *Mapa de Cultivos y Aprovechamientos* (MCA) 1:50.000 del Ministerio de Agricultura Pesca y Alimentación de 1974. Una vez determinadas las parcelas que constituyeron la muestra, éstas fueron localizadas en las fotografías 1:30.000 del *Vuelo General de España*, siendo suministradas estas fotografías a los operadores de campo (Ministerio de Medio Ambiente, 1996).

El protocolo de actuación de estos operadores para localizar y delimitar la parcela sobre el terreno fue el siguiente (Ministerio de Medio Ambiente, 1996): (i) utilización de planos generales de la zona, de las fotografías y de otras informaciones ya acopiadas para desplazarse en vehículo hasta las proximidades del punto que marca la parcela en cuestión; (ii) observación estereoscópica de los pares de contacto para identificar la

ubicación exacta de la parcela y recorrer a pie el camino que lleva hasta ella; cuando esta parcela se encuentra en un área con un entorno homogéneo sin características diferenciadoras identificables en las fotos, se emplaza midiendo rumbo y distancia en el contacto fotográfico desde un accidente geográfico cercano y visible, con posterior replanteo sobre el terreno; (iii) el emplazamiento del punto central de la parcela se materializa clavando un rejón metálico tubular de aproximadamente 15 cm de longitud y 3 cm de diámetro que debe quedar oculto una vez terminados los trabajos de inventario (el punto exacto de pinchado del rejón se determina siguiendo una decisión aleatoria, sin que influyan en ella la topografía, vegetación, preferencias, etc.); (iv) levantamiento de la parcela, que, tiene forma circular y un diámetro variable; y, finalmente, (v) búsqueda fuera del perímetro de la parcela de un detalle natural o artificial resistente al paso del tiempo (por lo menos 10 años) que es marcado con pintura resistente a los elementos. Seguidamente se procede a la medición del rumbo y la distancia entre el elemento marcado y el centro de la parcela, procurándose la máxima exactitud. Esta última fase se suprime cuando la localización es muy clara, aun teniendo en cuenta los posibles cambios temporales. De esta manera, mediante este protocolo de actuación, se aseguró la exacta localización geográfica de la parcela para las futuras tareas de remediación, pudiéndose localizar el centro exacto de la parcela mediante la utilización de un detector de metales.

Las parcelas que se levantaron fueron circulares, siendo dependiente su radio final del diámetro normal¹⁵ de los pies mayores que se encontraban en el entorno del centro de la parcela. El procedimiento que dio lugar al radio final de la parcela fue el siguiente (Ministerio de Medio Ambiente, 1996): (i) el operario se sitúa en el centro de la parcela y mira con la brújula en dirección norte; (ii) inicia entonces un giro en sentido de las agujas del reloj, escogiendo todos los pies mayores (diámetro normal ≥ 75 mm) que, según las instrucciones que lleva en el estadillo de campo (ver Tabla 2.5), son incluibles en la parcela. Así pues, un pie de cualquier especie forestal entra o no en la parcela a inventariar en función de su diámetro normal y de su distancia al centro de la parcela con arreglo a la norma recogida en la Tabla 2.5. Como resultado de este procedimiento, el IFN-2 está compuesto por un sistema de parcelas circulares de radio variable, que en las más pequeñas es de 5 m (cuando no existen pies mayores o éstos tiene un diámetro

¹⁵ El diámetro normal considerado en el IFN-2 se obtiene de la misma forma que el *dbh* utilizado en las ecuaciones de regresión ajustadas para la estimación de la biomasa residual (medición del tallo a 1,30 m del suelo en dos direcciones perpendiculares con una forcípula de precisión milimétrica), por lo que ambas medidas son equivalentes.

normal <125 mm) y en las mayores de 25 m (cuando los pies mayores comprendidos en esa distancia tienen un diámetro normal >425 mm) (Ministerio de Medio Ambiente, 1996).

Diámetros (rango, mm)	Clase diamétrica	Radio de la parcela (m)
24 - 75	0	5
75 - 125	1	5
125 - 225	2	10
225 - 425	3	15
> 425	4	25

Tabla 2.5. Radio de las parcelas del IFN-2 según diámetros de los pies encontrados. Fuente: Ministerio de Medio Ambiente (1996)

- Apeo de la parcela

Los árboles que entraron en la parcela fueron señalados de tal manera que, al terminar el levantamiento, no quedara ninguna señal. Sobre todos estos árboles se procedió a medir un total de 9 parámetros que se enumeran a continuación, siendo los 3 primeros tomados para identificar los árboles en futuras remediciones y los 4 últimos para caracterizarlos (Ministerio de Medio Ambiente, 1996): (i) identificación del ejemplar en la parcela mediante asignación de un número correlativo (se empieza el conteo mirando al norte y se sigue en el sentido de las agujas del reloj); (ii) rumbo del pie con respecto al centro de la parcela; (iii) distancia entre el centro de la parcela y el pie; (iv) especie botánica; (v) diámetro normal (medición del tallo a 1,30 m del suelo con una forcípula de precisión milimétrica en dos direcciones perpendiculares de manera que, en la primera de ellas, el eje de la forcípula esté alineado con el centro de la parcela); (vi) calidad del árbol; (vii) forma de cubicación; (viii) altura total (mediante el uso de un hipsómetro y con una precisión de hasta medio metro); y (ix) parámetros especiales (ver pág. 61 de Ministerio de Medio Ambiente, 1996).

Terminada esta fase se procedió a la selección de “árboles tipo”, normalmente 4, sobre los que se midieron los 7 parámetros siguientes (Ministerio de Medio Ambiente, 1996): (i) diámetro de la copa; (ii) espesor de la corteza; (iii) crecimiento radial; (iv) diámetro del tronco a 4 metros de altura; (v) diámetro del fin de fuste (únicamente a los árboles de forma de cubicación 3 ó 4); (vi) altura de fuste (solamente a los árboles de forma de cubicación 3 o 4); y (vii) altura del primer verticilo vivo importante (para los pies de forma 3).

Finalizadas estas mediciones se procedió a realizar otras sobre pies menores, regeneración, matorral leñoso, etc. que no se refieren aquí por carecer de importancia para la metodología empleada en este trabajo.

2.1.2.2. Metodología para el cálculo de la biomasa residual forestal en las parcelas seleccionadas del IFN-2

El proceso metodológico que se siguió requiere los siguientes materiales:

- Regresiones de estimación de la biomasa residual forestal a nivel de árbol (apartado 2.1.1.2.2; Tabla 2.3).
- Datos de las parcelas del IFN a nivel de árbol en formato digital.
- Aplicación informática *BASIFOR*.
- Programa Microsoft EXCEL.

El objetivo final es obtener una tabla en formato *dBase IV* (compatible con ArcGIS) en la que, junto a otras columnas, aparezca una dedicada a recoger el identificador de las parcelas del IFN contenidas en la provincia de Teruel y otra para recoger el valor de la biomasa residual forestal de esa parcela expresada en toneladas por hectárea (tons/ha).

Para conseguir este objetivo, los pasos realizados fueron los siguientes:

- Utilización de la base de datos alfanumérica incluida en el IFN-2 en la aplicación informática *BASIFOR* para generar unas tablas que contienen las principales variables dasométricas y dendrométricas tanto a nivel de parcela como a nivel de los pies que componen esa parcela.
- Importación de estas tablas al entorno de trabajo de Microsoft EXCEL.
- Obtención del diámetro normal medio (cm) a partir de los dos diámetros (mm) recogidos para cada pie en el IFN-2.
- Dado que las parcelas son de radio variable, asignación a cada pie de su correspondiente radio según las instrucciones del IFN-2 (Tabla 2.5); este paso es imprescindible para la posterior conversión de los datos en toneladas por parcela a unidades superficiales (tons/ha).
- Asignación a cada parcela de la especie principal en función de la más abundante anotada, sin eliminar la información del resto de las contenidas.
- Utilizando la columna PARCELA como identificador, vinculación a la tabla sobre la que se está trabajando de toda la información generada por la aplicación *BASIFOR* a nivel de parcela (coordenadas UTM, fracción cabida cubierta, densidad, diámetro cuadrático medio, altura dominante, volumen con corteza, incremento anual del volumen con corteza, etc.).

- Aplicación, sobre la tabla resultante, de un doble filtro mediante una macro diseñada en *Microsoft Visual Basic* con el objetivo de:
 - o Seleccionar las parcelas en las que el 100% de los pies son pinos.
 - o Seleccionar, dentro de las parcelas resultantes del anterior filtro, aquéllas en que los pinos que las componen tienen un diámetro normal y una altura que se encuentra dentro del rango de validez de las ecuaciones de estimación de biomasa residual ajustadas.

Un total de 617 parcelas superaron este doble filtro, lo que representa un 37,88% del total de las del IFN-2; el resto fueron eliminadas de la tabla.

- Cálculo de la biomasa residual forestal de cada pie en kilos de materia seca mediante una nueva macro que utiliza la regresión ajustada para cada especie (Tabla 2.3). Considerando el radio de la parcela que contiene cada árbol, la misma macro transforma la biomasa residual de kg/pie a tons/ha.
- Asignación a cada parcela -mediante una nueva macro- del valor del sumatorio de la biomasa residual de cada pie perteneciente a la misma. La tabla resultante es exportada a formato *dBase IV*.

Por tanto, el resultado final es una tabla que contiene información de la biomasa residual forestal en unidades superficiales (tons/ha) para cada una de las parcelas del IFN-2 de la provincia de Teruel que cumplen los rangos de aplicación de las ecuaciones de regresión obtenidas mediante trabajo de campo. Junto a esta información aparece también toda la contenida en el inventario (coordenadas UTM, fracción cabida cubierta, composición específica, densidad, diámetro cuadrático medio, altura dominante, volumen con corteza, etc.).

2.1.3. Espacialización de las parcelas del IFN-2 con información de biomasa residual forestal.

Las coordenadas UTM -contenidas en la tabla preparada en *dBase IV*- de cada una de las parcelas hacían posible su importación en el entorno ArcGIS para crear una cartografía de tipo puntual. Sin embargo, antes de realizar esta operación, fue necesario homogeneizar la información de las coordenadas de estas parcelas a un solo huso UTM, ya que mientras que la gran mayoría de ellas estaban referidas al huso 30, un total de 80 parcelas lo estaban al 31. Esto se debe a que la provincia de Teruel se encuentra dividida entre las zonas 30 y 31 de la cuadrícula UTM, perteneciendo a esta última sólo el cuadrante nororiental (Figura 2.4). Se decidió re proyectar las parcelas de la zona 31 a la

30, utilizándose el modulo de transformación de coordenadas implementado en ERDAS Imagine 8.7. Hecha esta operación, se incorporó la tabla modificada a ArcGis mediante la herramienta *Add XY Data*, creándose un fichero de puntos en formato *shape*, al que se le asignó la proyección cartográfica que va a ser utilizada en toda esta tesis. El fichero de puntos recoge la localización geográfica exacta de las parcelas sobre las que se dispone de información de biomasa residual forestal de las cuatro pináceas seleccionadas, presentando además una tabla asociada con la información sobre la cantidad de biomasa y todas las variables recogidas en el IFN-2 (Figura 2.5).

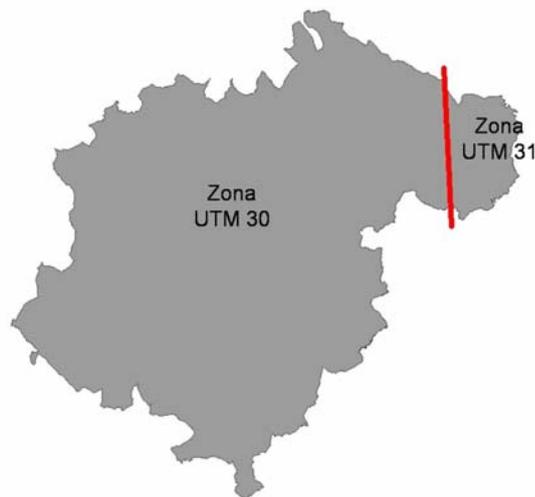


Figura 2.4. Zonas de la cuadrícula UTM en que se divide la provincia de Teruel

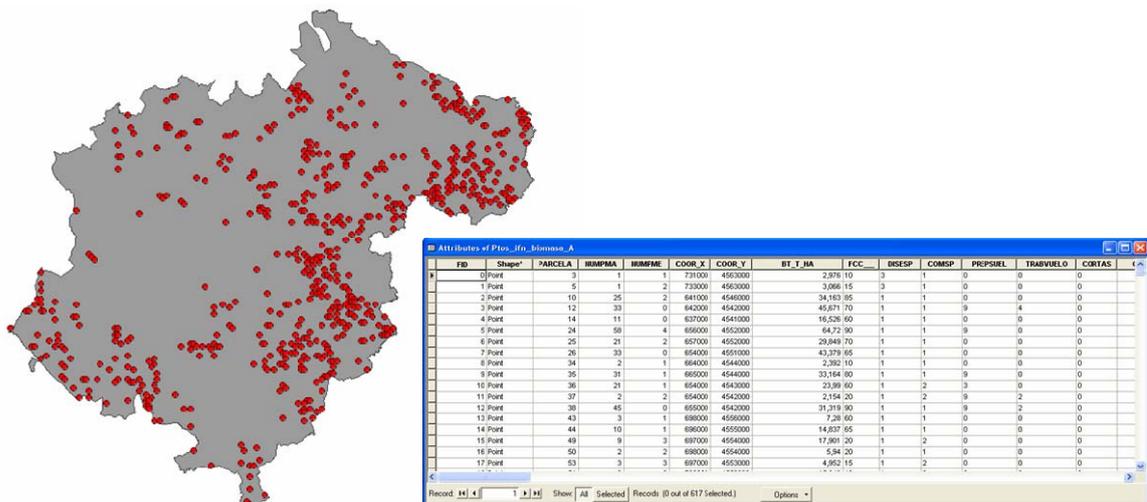


Figura 2.5. Representación del fichero *shape* que contiene las 617 parcelas del IFN-2 con información de biomasa residual forestal y su tabla alfanumérica

Sin embargo, no todas estas parcelas (617) serán utilizadas en el Capítulo 3 para establecer los modelos de estimación de la biomasa residual potencial mediante el uso de imágenes de satélite e información auxiliar. Esto se debe a dos motivos:

- En primer lugar, porque para evitar la complejidad debida a la mezcla de signaturas espectrales de distintas especies en la información espectral proporcionada por la imagen Landsat (Salvador y Pons, 1998b), sólo las parcelas monoespecíficas fueron seleccionadas, eliminándose de la muestra todas aquellas en las que aparecían dos o más tipos de pino.
- En segundo lugar, porque no todas estas parcelas quedan dentro de la superficie recogida por las escenas Landsat utilizadas en esta investigación. Las escenas utilizadas (*Path 131/Row 32*) no cubren la totalidad de la provincia de Teruel, dejando fuera un pequeño sector situado al noreste. La exclusión de esta zona es poco relevante, ya que en ella la cubierta forestal es muy escasa. Además, la superposición de las parcelas sobre las imágenes Landsat reveló la conveniencia de eliminar algunas –pocas- localizadas en zonas afectadas por incendios y sobre pequeñas nubes y sus sombras.

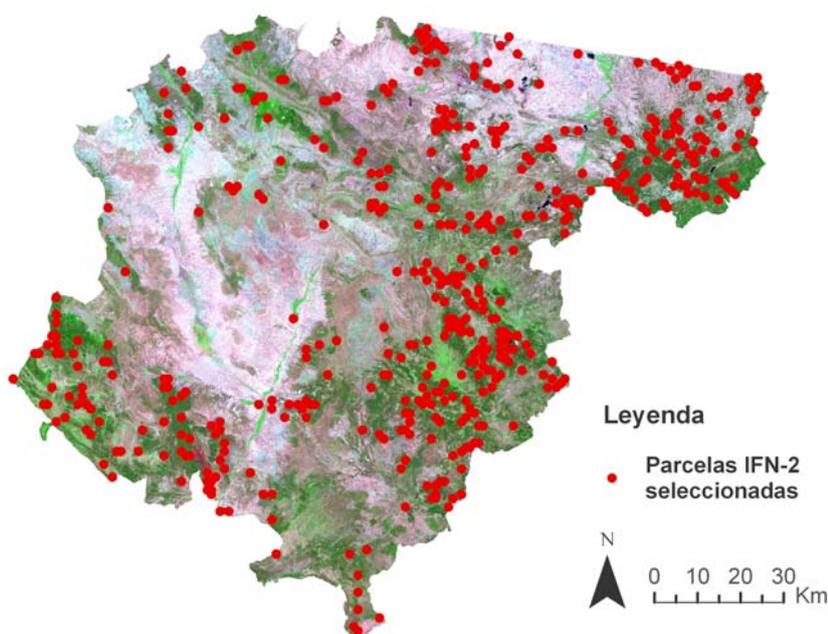


Figura 2.6. Localización de las 482 parcelas del IFN-2 utilizadas sobre una composición RGB 7-4-3 de la imagen Landsat TM de 29 de junio de 1994

Tras este doble proceso de eliminación, el número de parcelas del IFN-2 utilizadas en los análisis llevados a cabo con la escena Landsat de junio de 1994 asciende a un total de 482 (Figura 2.6). La biomasa residual forestal estimada en estas parcelas varía entre 0,107 y 64,720 tons/ha. Este amplio rango se relaciona con la elevada heterogeneidad, ya comentada, de los bosques mediterráneos. La Tabla 2.6 muestra algunas estadísticas básicas de estas parcelas para cada especie considerada.

Especie	Nº parcelas	Biomasa residual (tons/ha)			
		Media	Desv. Est.	Mínimo	Máximo
<i>P. sylvestris</i>	134	19.910	12.859	1.208	53.374
<i>P. halepensis</i>	183	14.698	10.741	0.763	54.200
<i>P. nigra</i>	129	12.712	13.563	0.412	64.720
<i>P. pinaster</i>	36	12.760	10.776	0.107	33.902
TOTAL	482	15.470	12.453	0.107	64.720

Tabla 2.6. Composición de la muestra de parcelas monoespecíficas del IFN-2 por especies para las que se tiene información de biomasa residual forestal: número de parcelas, valor medio, desviación estándar, valor mínimo y valor máximo

Las parcelas monoespecíficas de *P. halepensis* son las más numerosas, representando un 37,97% del total de la muestra. Les siguen en importancia las de *P. sylvestris* y las de *P. nigra* (27,80% y 26,76%, respectivamente), siendo las de *P. pinaster* las menos representadas (7,47%). Esta distribución de la muestra por especies difiere de la importancia superficial de cada una en la provincia (Tabla 2.1.), encontrándose *P. sylvestris* en segundo lugar en lugar de en primero. El motivo de este descenso relativo de la importancia de esta especie en la muestra se debe a que el 59% de las parcelas eliminadas por presentar más de una especie contenían *P. sylvestris* como especie principal o secundaria, mientras que sólo el 29% contenían *P. halepensis*. La media más alta de biomasa residual por parcela corresponde a *P. sylvestris* (19,910 tons/ha), mientras que la más baja está en las de *P. nigra* (12,712 tons/ha), aunque seguidas de cerca por las parcelas de *P. pinaster* (12,760 tons/ha). Son las parcelas de *P. nigra* las que presentan una mayor variabilidad por parcela, con una desviación estándar de 13,563 tons/ha. Por el contrario, las parcelas de *P. pinaster* y de *P. halepensis* presentan la menor variabilidad interna, aunque ésta puede considerarse como elevada en ambas al superarse las 10 tons/ha (10,776 y 10,741 tons/ha, respectivamente). En cuanto a los valores mínimos de biomasa residual por parcela, todas las especies presentan, al menos, una parcela con valores realmente bajos, siendo *P. pinaster* la que marca el valor menor de las cuatro especies (0,107 tons/ha). Con respecto al máximo de biomasa residual por parcela, éste aparece en *P. nigra* con 64,720 tons/ha; valor que se sitúa a

una distancia relativamente alta respecto de los dos siguientes máximos marcados por *P. halepensis* y *P. sylvestris* (a más de 10 tons/ha) y puede deberse una vez más a que *P. nigra* es la especie más utilizada en las repoblaciones.

El elevado número de parcelas (482) y su distribución espacial (Figura 2.6) garantizan la inclusión de las diferentes condiciones medioambientales del área de estudio en las que aparecen las cuatro especies seleccionadas, evitándose el establecimiento de modelos de regresión no robustos y sobre-ajustados (Salvador y Pons, 1998b). Además, este alto volumen de parcelas permite la inclusión de un importante número de variables independientes, siguiendo el criterio de Hair *et al.* (1999). Estos autores afirman que, si se utiliza un proceso por pasos en el ajuste del modelo de regresión (el más restrictivo), es posible introducir una variable independiente por cada 50 observaciones de la variable dependiente sin comprometer la calidad del modelo en la generalización de los resultados. Así, teniendo en cuenta este criterio sobre el tamaño muestral a la hora de ajustar una regresión múltiple, aun reservando el 40% de las parcelas para tareas de validación, el 60% utilizado para ajustarlo (289 parcelas) permite la inclusión de un total de 5 variables independientes, respetando este supuesto básico y garantizándose una buena *potencia estadística*¹⁶ del modelo de regresión, considerando un nivel de significación (*p-valor*) de 0,05 (Hair *et al.*, 1999). Aun así, como se verá más adelante, se procurará que el número de variables independientes sea el menor posible, evitándose los problemas de sobre-ajuste ya aludidos. Junto a esto, también se velará porque las variables independientes consideradas para la edición del modelo sean todas relevantes para la estimación de la biomasa residual forestal, basándonos principalmente en fundamentos conceptuales y teóricos. Se intenta así respetar el supuesto más problemático en la selección de variables independientes, el *error de especificación*, que alude a la inclusión de variables irrelevantes o a la omisión de variables relevantes del conjunto de las independientes (Hair *et al.*, 1999).

De acuerdo con este último principio, los siguientes apartados están dedicados a la obtención y modelado de las variables independientes que, *a priori*, son útiles para la estimación de la biomasa residual forestal desde el punto de vista teórico.

¹⁶ La *potencia* de la regresión múltiple se refiere a la probabilidad de detectar como estadísticamente significativo un nivel específico de R^2 o un coeficiente de regresión para un nivel de significación y un tamaño de muestra específicos. El tamaño muestral tiene un impacto directo y cuantificable sobre esta potencia (Hair *et al.*, 1999).

2.2. El modelo digital de elevaciones de la provincia de Teruel

Los MDE¹⁷ proporcionan información sobre la altitud (z) de cada localización (x,y) de un plano, utilizando para ello diferentes estructuras de representación y siendo las más comunes las vectoriales (contornos y redes de triángulos irregulares –TIN) y las raster (matrices regulares y jerárquicas) (Felicísimo, 2003). Para el correcto desarrollo de esta investigación se hizo necesario contar con un MDE suficientemente preciso del área de estudio en formato raster de matriz regular por tres motivos:

- Porque, como se ha visto en el apartado dedicado a la caracterización física del área de estudio, la provincia de Teruel presenta una fisiografía bastante irregular y accidentada, lo que invita a la utilización de un MDE en la georreferenciación de las imágenes de satélite para mejorar su precisión.
- La misma complejidad fisiográfica obliga a la realización de una normalización topográfica en la corrección radiométrica aplicada a las imágenes Landsat, para lo cual resulta imprescindible contar con un MDE.
- Por último, como ya se ha apuntado, se van a considerar diferentes variables topográficas (elevación, pendiente, etc.) como independientes en proceso de ajuste del modelo de estimación de biomasa residual forestal; su obtención requiere la utilización de un MDE como fuente de información base.

La inexistencia, en el momento de abordar estas tres cuestiones, de un MDE raster de matriz regular a escala provincial con una resolución de píxel semejante a la de las imágenes de satélite que se iban a utilizar exigió su creación. Para ello, la información de altitudes de la provincia de Teruel se obtuvo, de forma indirecta, mediante la utilización de la Base Cartográfica Numérica 1:25.000 (BCN25) elaborada por el Instituto Geográfico Nacional (IGN)¹⁸. Esta base de datos contiene la información representada en el Mapa Topográfico Nacional 1:25.000 (MTN25), a la que se le ha dotado de topología implícita, códigos y nombres (Figura 2.7). El hecho de que estos datos tengan topología implícita

¹⁷ Un modelo digital del terreno (MDT) es “una estructura numérica de datos que representa la distribución espacial de una variable cuantitativa”, mientras que un modelo digital de elevaciones (MDE) es “un MDT donde la variable representada es la altura o elevación del terreno” (Felicísimo, 2003).

¹⁸ La BCN25 es una base de datos bidimensionales y continuos, orientados a su utilización en los SIG, que cubre toda España, estando organizada en 4.123 unidades que se corresponden con las hojas del Mapa Topográfico Nacional 1:25.000 (MTN25).

supone que se han corregido todo tipo de errores geométricos y que la información está ya preparada para ser incorporada directamente en un SIG. La exactitud posicional estimada está entre 2,5 y 7,5 m, dependiendo del tipo de entidad. Para la elaboración del MDE del área de estudio se emplearon, junto a todas las hojas del BCN25 que contenían información de la provincia de Teruel, todas aquellas circundantes a los límites provinciales; se pretendía con ello asegurar la calidad del MDE resultante, ya que de esta forma los puntos de ruptura del modelo quedan fuera del área de estudio, evitándose dentro valores extraños.

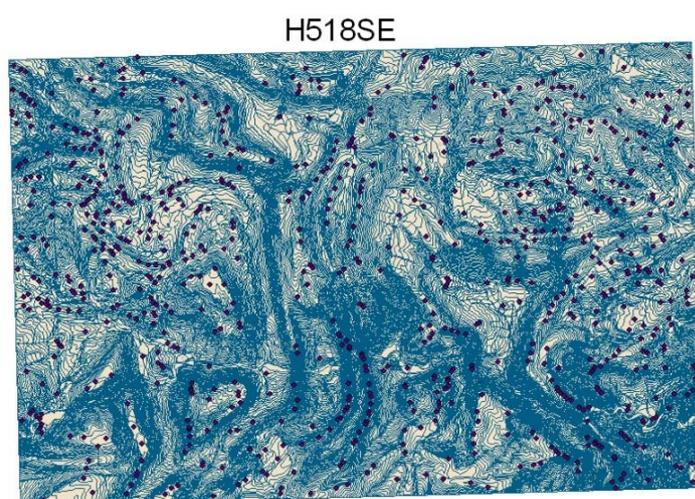


Figura 2.7. Ejemplo de hoja de la BCN25: los puntos representan cotas de altitud, las polilíneas azules son curvas de nivel con equidistancia de 10 m

Existen dos tipos de métodos para la construcción de un MDE mediante información de carácter vectorial como la obtenida en las hojas de la BCN25: los de interpolación en función de la distancia y los basados en triangulaciones (Felicísimo, 2003). Los primeros se basan en estimar la altitud de los centros de los píxeles que componen la matriz resultante en función de los datos del entorno existentes, por lo que el resultado es un MDE raster. Para ello se pueden utilizar dos métodos: el *IDW* (*inverse distance weighting*, peso inverso a la distancia) y el geoestadístico *kriging*. Ambos métodos utilizan los puntos más cercanos al centro del píxel cuya altitud se quiere estimar, difiriendo en que en el *kriging* la altitud puede definirse como una variable *regionalizada*, es decir, la variación espacial de la altitud puede ser explicada, al menos parcialmente, mediante funciones de correlación espacial. El parámetro más importante a controlar en estos dos métodos es el radio de búsqueda de puntos cercanos que, en el

caso de ArcGIS-ArcINFO, puede estar definido en función de una distancia máxima o en función del número de puntos cercanos a considerar. Estos dos métodos de interpolación presentan dificultades a la hora de ser utilizados como método de construcción de un MDE, sobre todo cuando se intenta modelar una zona de relieve accidentado, no recomendándose su utilización (Felicísimo, 2003).

Los métodos basados en triangulaciones se fundamentan en el uso de una estructura vectorial especial: la red irregular de triángulos denominada comúnmente como *TIN* (*triangulated irregular network*). El modelo TIN, entendido como un conjunto de triángulos irregulares adosados que recubren el terreno de forma completa, posee varias cualidades que lo hacen muy útil para la generación de un MDE: (i) no presupone ni exige la continuidad estadística de la superficie objeto de representación; (ii) puede generarse incorporando una gran variedad de estructuras auxiliares como líneas estructurales y de rotura; (iii) tiene capacidad para adaptarse a la complejidad local del terreno, creando redes de triángulos localmente más densas; y (iv) respeta los valores originales exactos de los datos, los cuales son usados como vértices en los triángulos.

El método de triangulación Delaunay es el más habitual en los SIG (incorporado en ArcGIS-ArcINFO). Las propiedades principales de este método garantizan una forma idónea de los triángulos para la representación del terreno: (i) un punto P (cota) perteneciente a la red es siempre un vértice de un triángulo T ; (ii) dos triángulos de una red pueden estar conectados por un vértice o un lado común, es decir, no existe superposición; (iii) dado un triángulo T (P_i , P_j y P_k), no existe otro punto de triangulación interno al círculo que pase por P_i , P_j y P_k ; (IV) dados 4 puntos y el cuadrilátero definido por ellos, la diagonal que lo divide en dos triángulos es aquella que maximiza el menor de los triángulos internos, por lo que la triangulación de Delaunay tiende a crear triángulos lo más equiláteros posibles.

Otra característica importante del modelado de la variable altitud mediante el modelo TIN es que permite la introducción, junto a los datos puntuales de elevación, de líneas de inflexión o de rotura, que se utilizan para definir la posición de elementos lineales (por ejemplo ríos en valles en V) que rompen la continuidad de la superficie. Estos elementos, aunque no aportan valores de altitud, son utilizados en la triangulación como lados de los triángulos, evitándose el aspecto aterrazado y la aparición de concavidades o pozos en los fondos de valle. Todas estas características han convertido este método en la solución aparentemente más adecuada para la generación de un MDE (Felicísimo, 2003).

La Figura 2.8 muestra la utilización de la estructura TIN para la obtención de un MDE.

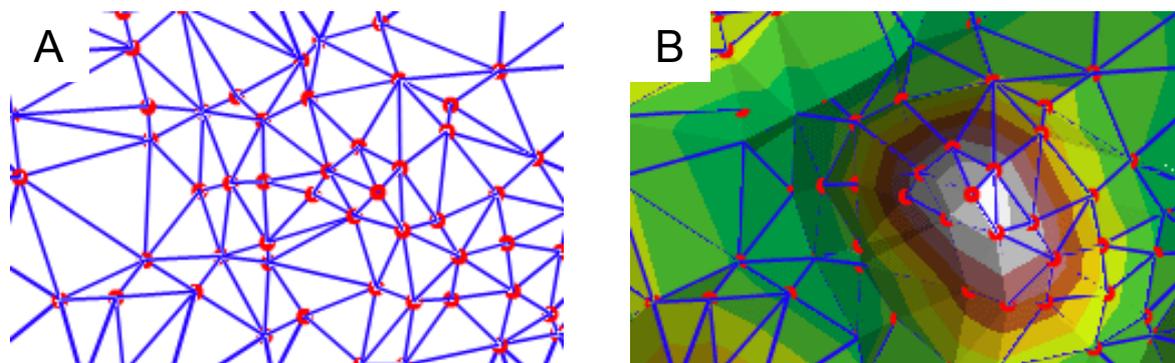


Figura 2.8. La estructura TIN para la obtención de un MDE: (A) nodos y ejes de la estructura TIN; (B) nodos, ejes y facetas triangulares de la estructura TIN. Fuente: Adaptado de ESRI ArcMap 9.1

El problema más importante relacionado con el uso de la estructura TIN para la generación de MDE's es que el uso del archivo resultante resulta más complejo que el de la matriz regular raster. Por ello, la estructura TIN es la más adecuada para construir un MDE, pero no es la más adecuada para ser usada en operaciones de modelización, análisis o simulación. Por ello la forma más habitual de trabajar es crear un MDE utilizando un modelo TIN para, posteriormente, generar un MDE con estructura raster mediante procesos de interpolación específicos (Felicísimo, 2003).

Considerando todo lo anterior, el método seleccionado para construir el MDE a partir de información vectorial de la BCN25 fue el modelado TIN disponible en el software ArcGIS-ArcINFO. Esta información sobre altitud fue complementada con la aportada por la red hidrográfica de la provincia disponible en Banco de Datos del Agua de Aragón (BADAAR, Pellicer y de la Riva, 1999), utilizada como líneas de rotura en la generación del MDE. La Figura 2.9 representa de manera esquemática el proceso seguido:

- Incorporación de las hojas BCN25 de la provincia de Teruel y de las circundantes a los límites provinciales al entorno ArcGIS-ArcINFO. Para ello se utilizó una herramienta en ArcCatalog que permite la incorporación de ficheros *.dxf* (formato en que fueron proporcionados las hojas) a dos geodatabases (GDB) previamente creadas: una para curvas de nivel, otra para cotas.
- A partir de estas GDB se creó un fichero *.shp* de curvas de nivel y otro de cotas topográficas para cada una de las hojas consideradas.
- Sobre estos ficheros *.shp* se ejecutaron las tareas de revisión de la calidad de los datos y se procedió a la depuración de errores: eliminación del marco perimetral de cada hoja, de las polilíneas sin información de elevación, etc.

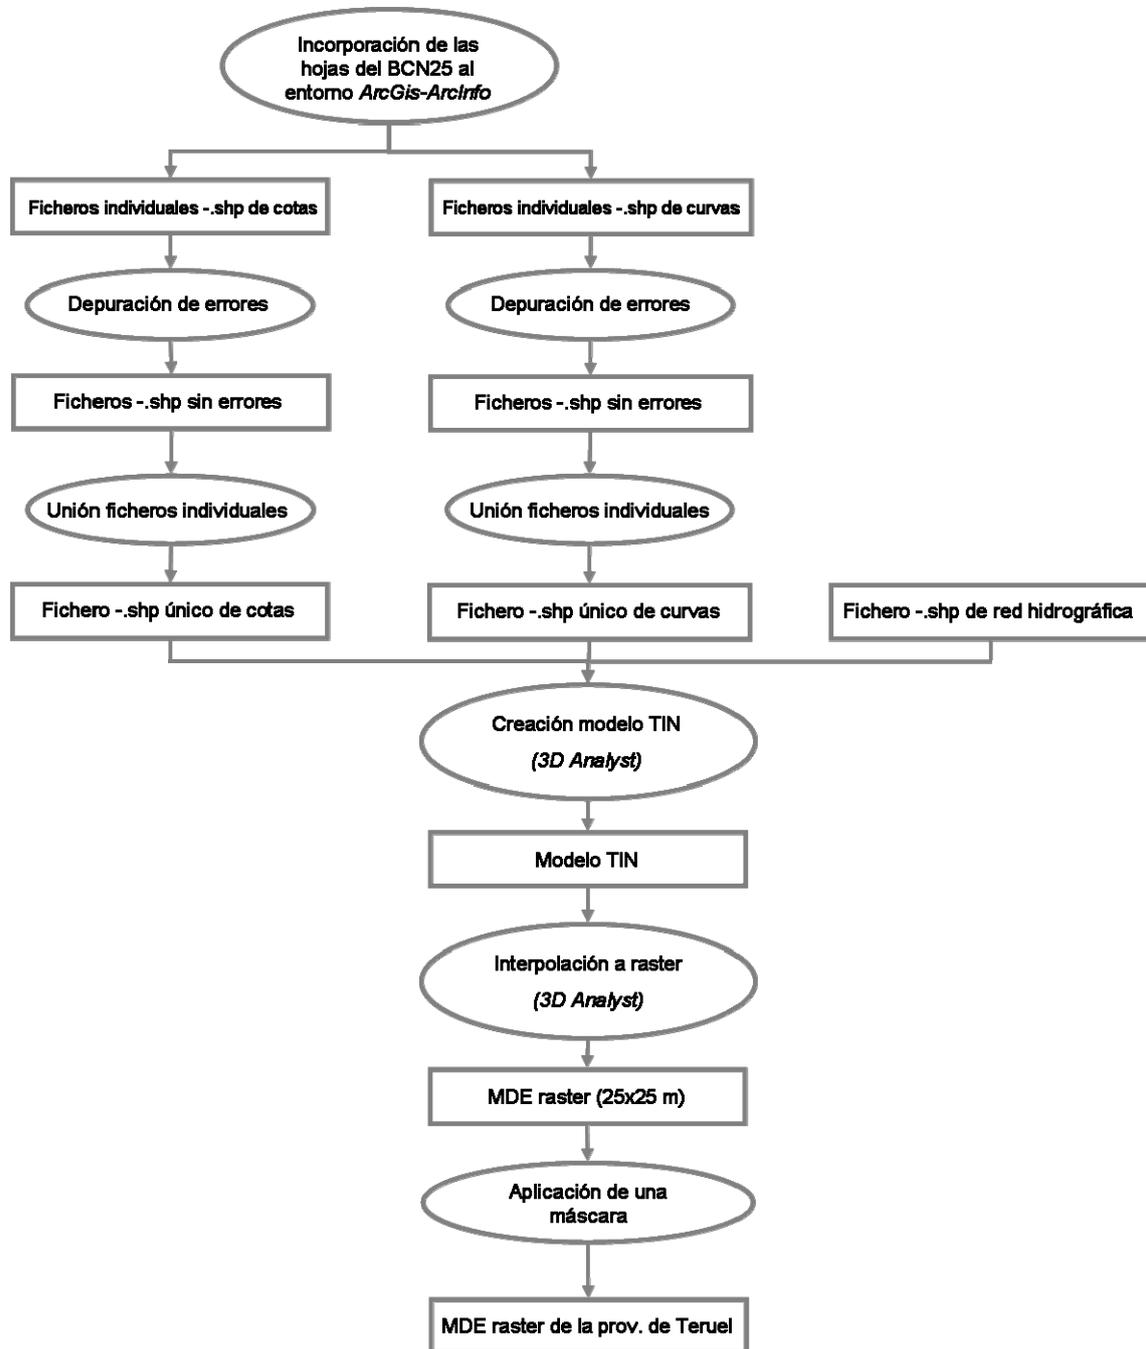


Figura 2.9. Diagrama de flujos del proceso seguido para la elaboración del MDE

- Estos ficheros depurados se utilizaron para crear –función *merge*- un *.shp* con las curvas de nivel y otro de cotas topográficas (Figura 2.10(A,B)).
- Creación del modelo TIN mediante la extensión *3D Analyst* (*Create TIN from features*), indicando que la triangulación fuera a partir de la utilización de puntos de masa (*mass points*). Antes de ejecutar la orden de creación se añadió un fichero *.shp* con la red hidrográfica, indicándose que actuara como líneas de rotura (*hard line*) (Figura 2.10(C)).
- El modelo TIN resultante (Figura 2.10(D)) fue interpolado a una estructura raster regular -25 m- mediante la orden *Convert TIN to Raster* de *3D Analyst*.
- Al MDE raster se le asignó la misma proyección UTM que se iba a utilizar en la georreferenciación de las imágenes de satélite y se le aplicó una máscara con los límites de la provincia de Teruel.

La Figura 2.11 muestra el resultado final de este proceso: un MDE raster adaptado a los límites del área de estudio, con una proyección cartográfica y una resolución espacial óptimas para la realización de las tres tareas para las que va a ser utilizado a lo largo de este trabajo de investigación.

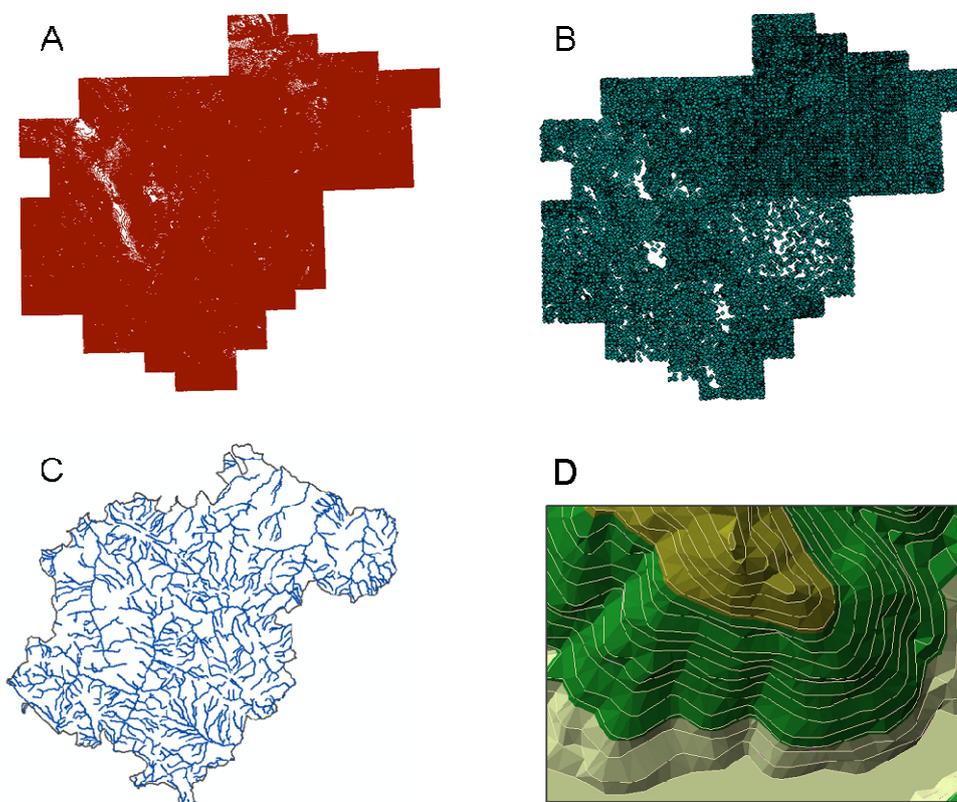


Figura 2.10. Generación del modelo TIN: (A) fichero *.shp* con las curvas de nivel utilizadas; (B) fichero *.shp* con las cotas topográficas; (C) fichero *.shp* con la red hidrográfica; (D) detalle del modelo TIN

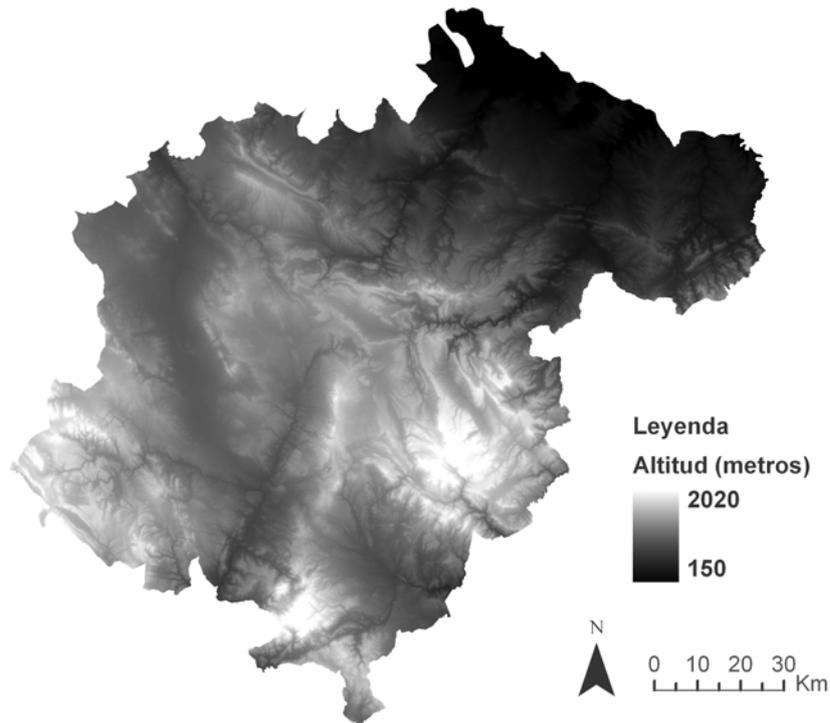


Figura 2.11. MDE raster de la provincia de Teruel con proyección cartográfica y resolución de 25 m

2.3. Las variables radiométricas derivadas de las imágenes ópticas

Como se ha visto en el Capítulo 1, las imágenes ópticas de Landsat TM y ETM+ son las más utilizadas en las aplicaciones de teledetección encaminadas a la estimación de biomasa a escala regional y local. Tal y como se indicaba en la metodología de este trabajo, este apartado está dedicado a la aplicación de una serie de tratamientos sobre las tres imágenes Landsat seleccionadas para obtener variables radiométricas susceptibles de ser relacionadas con los datos de biomasa residual obtenidos en el apartado 2.1. Antes de aplicar estos tratamientos se presentan brevemente las características de las imágenes Landsat utilizadas.

2.3.1. Características de las imágenes ópticas utilizadas

Las tres imágenes ópticas seleccionadas fueron adquiridas por el satélite Landsat 5, por lo que sus características generales están condicionadas por las propiedades de esta plataforma y su instrumento sensor.

2.3.1.1. Características generales

2.3.1.1.1. El programa Landsat

La familia de satélites Landsat comenzó con el lanzamiento al espacio, en julio de 1972, del satélite ERTS (*Earth Resources Technology Satellite*). La denominación de Landsat para esta serie de satélites se dio a partir del segundo lanzamiento, que se efectuó en enero de 1975 (Chuvienco, 1996). En total, el proyecto Landsat se compone de 7 satélites (Tabla 2.7), aunque Landsat 6 nunca llegó a ser operativo.

El programa Landsat ha recogido información de la superficie de la Tierra de forma continuada desde hace 36 años creando, en palabras de la NASA (*National Aeronautics and Space Administration*), “un archivo histórico incomparable en calidad, detalle, cobertura y cantidad” (NASA, 2008), siendo considerado como el proyecto más fructífero de los desarrollados en teledetección espacial (Chuvienco, 2002). Aunque en los últimos años se llegó a temer por su continuidad debido a fallos operativos en los dos satélites Landsat activos (5 y 7) y por la falta de un compromiso claro por parte de la Administración americana de continuar con este programa de observación espacial, en la actualidad la NASA están dando los pasos necesarios para la continuidad del mismo, estando ya seleccionada la empresa para la construcción del instrumento que continuará con la misión, denominado OLI (*Operational Land Imager*).

Satélite	Fecha de lanzamiento	Estado
ERTS	23 de julio de 1972	No operativo desde enero de 1978
Landsat 2	22 de enero de 1975	No operativo desde febrero de 1982
Landsat 3	5 de marzo de 1978	No operativo desde marzo de 1983
Landsat 4	16 de julio de 1982	No operativo para transmitir datos desde 1993
Landsat 5	1 de marzo de 1984	Operativo ¹⁹
Landsat 6	5 de octubre de 1993	Lanzamiento fallido
Landsat 7	15 de abril de 1999	Operativo ²⁰

Tabla 2.7. La familia de satélites Landsat. Fuente: NASA official website (<http://www.nasa.gov/>)

Es evidente que en el período de tiempo transcurrido entre el lanzamiento de ERTS 1 y Landsat 7 han sido muchos los cambios tecnológicos, lo que obviamente ha repercutido tanto en las características orbitales y fisonómicas de la plataformas como en

¹⁹ Desde el 6 de octubre de 2007, hasta el momento de escribir estas líneas, la toma de datos estaba suspendida por fallo en las baterías a bordo, estando prevista su reparación (NASA, 2008).

²⁰ Desde el 31 de mayo de 2003 persiste el mal funcionamiento del *Scan Line Corrector* (SLC), lo que produce replicación de datos y hace necesarias operaciones especiales de corrección.

sus instrumentos de observación para la captura de información. Los tres primeros Landsat tenían una fisonomía y unas características orbitales comunes y estaban equipados con un sensor MSS (*Multispectral Scanner*), con resolución radiométrica de 128 ND y tres cámaras de vídeo RBV (*Return Beam Vidicon*). Landsat 4 y Landsat 5 presentaban unas características diferentes de los tres primeros, pero la principal novedad fue la inclusión del sensor TM (*Thematic Mapper*), que proporcionaba una mayor resolución espectral (7 bandas), espacial (30 m. en las bandas reflectivas y 120 m. en la banda térmica) y radiométrica (256 ND) (Chuvienco, 1996). Landsat 7 respetó características orbitales similares a las de Landsat 4 y 5; su mayor novedad fue la inclusión del sensor ETM+ (*Enhanced Thematic Mapper Plus*), versión mejorada de TM. Las novedades de este sensor con respecto a su predecesor fueron la inclusión de 2 nuevas bandas, una pancromática y una térmica con una resolución espacial de 15 m y de 60 m, respectivamente, una mejor calibración radiométrica y la incorporación de un grabador de datos a bordo (Lillesand y Kiefer, 2000; NASA, 2008).

2.3.1.1.2. Características orbitales de Landsat 5

Al igual que el resto de las plataformas de la familia Landsat, se incluye dentro del grupo de los satélites heliosincrónicos, capaces de observar sistemáticamente distintas zonas del planeta. Las órbitas de estos satélites son normalmente circulares con el fin de mantener siempre la misma altura de observación, habitualmente polares (plano de la órbita aproximadamente perpendicular al Ecuador); esto es así para aprovechar el movimiento de rotación de la Tierra, a fin de que el satélite se sitúe sobre un mismo punto cada cierto tiempo (Chuvienco, 1996).

La órbita de Landsat 5 es circular y polar, ligeramente inclinada (98,2° respecto al Ecuador). La altura orbital media se sitúa en 705 km, circundando la Tierra cada 98,9 minutos (período orbital), con lo que cada día son completadas 14,5 orbitas. Debido al movimiento de rotación de la Tierra, la distancia entre las líneas de observación terrestre de dos orbitas consecutivas es de, aproximadamente, 2.752 km a la altura del Ecuador. De esta manera se consigue que el satélite vuelva sobre la misma porción cada 16 días (ciclo de recubrimiento). El momento de adquisición de imágenes en las latitudes medias se sitúan en torno a las 9,45 a.m. hora solar (Chuvienco, 1996; Lillesand y Kiefer, 2000).

2.3.1.1.3. Toma de datos en Landsat 5: el sensor TM

TM pertenece al grupo de sensores radiométricos denominados de “barrido” (*scanner*); para registrar la energía electromagnética proveniente de la superficie terrestre

utiliza un espejo con oscilación perpendicular a la trayectoria, lo que permite al sensor explorar una franja de terreno a ambos lados de su trayectoria (Chuvieco, 1996).

Como se ha señalado, la resolución espectral de este sensor es de siete bandas de observación (Tabla 2.8), siendo la resolución espacial de 30 m en las bandas reflectivas y de 120 metros en la térmica. Su resolución radiométrica es de 8 bits (256 ND). El sensor TM registra información en un campo de $15,4^\circ (\pm 7,7^\circ)$ desde el nadir), lo que, combinado con la altura de su órbita, da lugar a unas escenas de 185 km de lado, divididos a ambos lados de la vertical de la trayectoria (Lillesand y Kiefer, 2000). Cada oscilación del espejo supone 16 líneas de barrido, por lo que se necesitan 16 detectores por banda, menos en el caso del térmico, que por su menor resolución espacial, sólo precisa de 4.

Banda	Amplitud de la banda (μm)	Región espectro electromagnético
Banda 1	de 0,45 a 0,52	Espectro visible (Azul)
Banda 2	de 0,52 a 0,60	Espectro visible (Verde)
Banda 3	de 0,63 a 0,69	Espectro visible (Rojo)
Banda 4	de 0,76 a 0,90	Infrarrojo próximo
Banda 5	de 1,55 a 1,75	Infrarrojo medio
Banda 6	de 10,40 a 12,50	Infrarrojo térmico
Banda 7	de 2,08 a 2,35	Infrarrojo medio

Tabla 2.8. Bandas de registro del sensor TM: amplitud espectral y localización en el espectro electromagnético. Fuente: Chuvieco (1996) y Lillesand y Kiefer (2000)

2.3.1.1.4. Información de utilidad forestal proporcionada por las bandas de TM

Diseñado para generar cartografía temática, el sensor TM ha permitido el desarrollo de un gran número de aplicaciones medioambientales (Chuvieco, 1996), siendo, como se ha señalado en el apartado 1.3, las forestales unas de las más prolíficas. El diseño de TM se basó en la experiencia adquirida por el análisis de los datos MSS y por los resultados obtenidos a partir de extensas campañas de radiometría de campo. Estos conocimientos fueron los que determinaron la localización y la amplitud espectral de sus bandas, que fueron diseñadas para mejorar la discriminación espectral de las principales cubiertas de la Tierra. Como resultado, las bandas de TM son mucho más precisas que las de MSS para la discriminación de la vegetación (Lillesand y Kiefer, 2000) y, por lo tanto, más útiles para el estudio de las superficies forestales. A continuación se señalan algunas de las informaciones sobre vegetación que proporcionan cada una de las bandas TM (Lillesand y Kiefer, 2000):

- Banda 1 (0,45 – 0,52; azul): útil para la discriminación entre suelo y vegetación y para la cartografía de tipos de bosques. También puede ser utilizada para discriminación del estrés hídrico de la vegetación.
- Banda 2 (0,52 – 0,60 μm ; verde): diseñada para la medición del pico de reflectividad de la vegetación en el visible. Por lo tanto, es útil para la discriminación de la vegetación y la evaluación del vigor vegetal.
- Banda 3 (0,63 – 0,69 μm ; rojo): válida para la diferenciación de los distintos tipos de cubierta vegetal, esta banda fue diseñada para registrar la absorción de energía electromagnética debido a la acción de la clorofila.
- Banda 4 (0,76 – 0,90 μm ; infrarrojo próximo): útil para determinar los tipos de vegetación, el vigor vegetal y, en principio, el contenido de biomasa.
- Banda 5 (1,55 – 1,75 μm ; infrarrojo medio): indicativa del contenido de humedad de la vegetación y, por tanto, útil para el análisis del estrés hídrico.
- Banda 6 (10,4 – 12,5 μm ; infrarrojo térmico): útil para el análisis de estrés hídrico de la vegetación.
- Banda 7 (2,08 – 2,35 μm ; infrarrojo medio): como la banda 5 -ambas registran en la misma región del espectro- es sensible al contenido de humedad.

2.3.1.2. Características particulares de las imágenes utilizadas

Las imágenes Landsat 5 TM utilizadas en la presente investigación fueron registradas el 28 de julio de 1993 y el 29 de junio y el 16 de agosto de 1994. Las tres corresponden a la órbita (*track*) 199 y a la fila (*frame*) 32, estando situados sus centros de observación en posiciones ligeramente diferentes, lo que implica que el área registrada no sea exactamente la misma. Estas escenas cubren, individualmente, la práctica totalidad de la provincia de Teruel, dejando fuera sólo el sector noreste, poco importante para los objetivos del presente trabajo por su escasa cubierta forestal (Figura 2.12).

La elección de estas imágenes obedece a que son coetáneas a los trabajos de campo del IFN-2 de la provincia de Teruel²¹ y a que están libres de nubes en su mayor parte. Además, todas ellas pertenecen a la época estival, la más frecuentemente seleccionada en el campo de las aplicaciones forestales de la teledetección (de la Riva,

²¹ Aunque la imagen de julio de 1993 es anterior a la realización de las tareas de campo del IFN-2 en Teruel (marzo a agosto de 1994), fue adquirida por su proximidad en el tiempo y por la ausencia de mejores escenas, descontando las otras dos utilizadas de junio y agosto de 1994.

1997). Con la selección de imágenes de verano se intenta minimizar el efecto de las sobras en la respuesta radiométrica registrada, ya que en esta estación el ángulo de elevación solar presenta sus valores anuales máximos.

Adquiridas a *Eurimage* (www.eurimage.com), fueron proporcionadas en formato CEOS con un nivel de procesamiento 1G, considerado como el estándar para la mayoría de los usuarios, que incluye los siguientes tratamientos previos (*Eurimage*, 2008):

- Aplicación de algoritmos de corrección de la plataforma y del sensor basados en datos generados por los ordenadores a bordo durante la toma de la imagen. Tiene por objeto mejorar la precisión geométrica global de la imagen considerando la información recogida en el archivo de calibración de parámetros (CPF). Se eliminan las distorsiones sistemáticas de la imagen original, provocadas por la rotación y la curvatura terrestre, y las relacionadas con variaciones en la observación panorámica del sensor (desplazamiento de los píxeles, variación de su tamaño, etc.) (*Chuvieco*, 2002).
- Aplicación de algoritmos de transferencia de los ND originales a una matriz regular. De los dos tipos de algoritmos que emplea *Eurimage* -vecino más próximo (*nearest neighbour*) y convolución cúbica (*cubic convolution*)- las imágenes adquiridas obedecen al primero, garantizándose así la conservación de la gran mayoría de los ND originales. Esta condición es indispensable, ya que las imágenes van a ser relacionadas con datos de verdad terreno (parcelas del IFN-2), lo que exige que los valores espectrales de los píxeles no sean fruto de ningún promedio con los de su entorno. Durante este proceso de transferencia, se asigna a las imágenes un sistema de proyección que, en el caso de las tres imágenes adquiridas era la proyección UTM (zona 30), con elipsoide de referencia Clarke 1866.

Como resultado de lo anterior, se dispone de imágenes libres de errores sistemáticos, situándose el error geométrico residual en torno a los 250 m en áreas planas a nivel del mar, siendo necesaria la aplicación de un modelo empírico -basado en puntos de control- para alcanzar una mayor precisión geométrica. Así mismo, es importante señalar que durante este proceso 1G no se aplica ningún tipo de corrección atmosférica, lo que implica la necesidad de una corrección radiométrica para solventar los problemas de radiometría a partir de sus ND, eliminando la influencia atmosférica y el

efecto de la topografía. La aplicación de estos pretratamientos a las imágenes adquiridas (corrección geométrica y corrección radiométrica) ocupa el siguiente apartado.

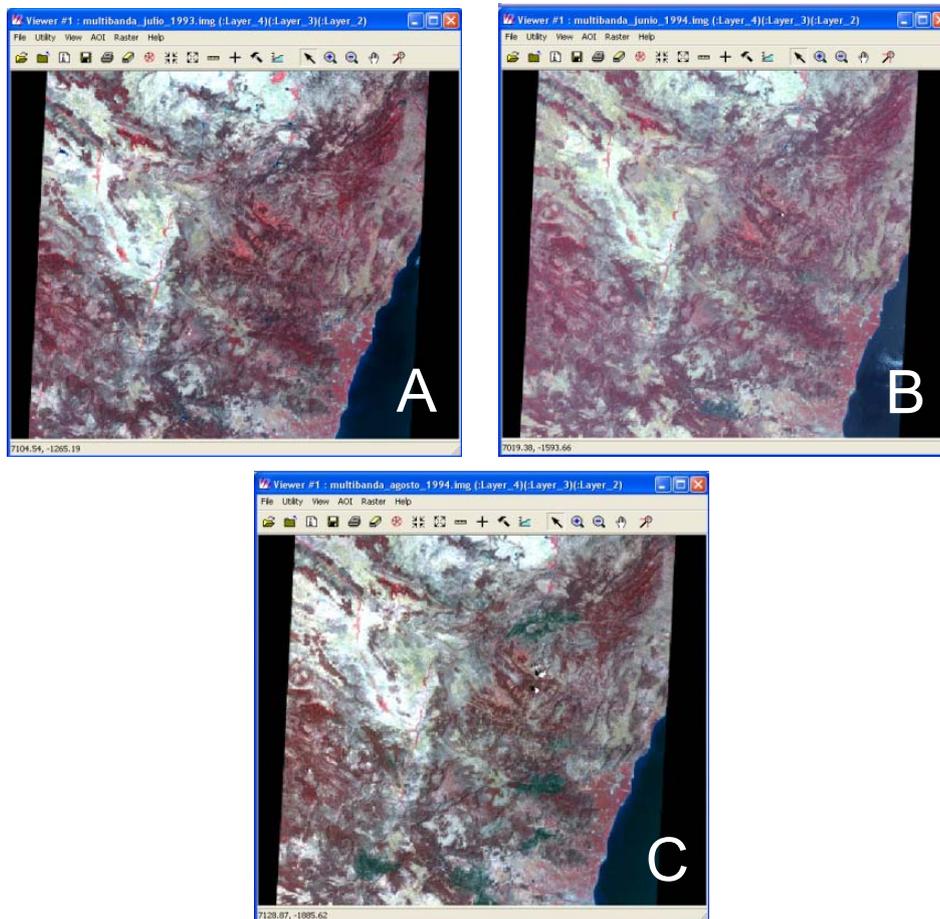


Figura 2.12. Las imágenes Landsat 5 TM adquiridas una vez eliminada la proyección cartográfica asignada en el nivel de procesamiento 1G: (A) imagen de 28 de julio de 1993; (B) imagen de 29 de junio de 1994; (C) imagen de 16 de agosto de 1994

2.3.2 Aplicación de pretratamientos: corrección geométrica y radiométrica

Toda imagen adquirida por un sensor remoto presenta una serie de alteraciones geométricas y radiométricas que pueden ser debidas a diversos factores: estabilidad de la plataforma, rotación terrestre, dispersión atmosférica, influencia de la topografía... Las alteraciones geométricas son aquellas que modifican la localización real de un píxel y las radiométricas las que modifican el valor de los ND registrados (Chuvieco, 2002).

La corrección de estas alteraciones es necesaria, pues suponen asociar a un determinado píxel un ND que no se corresponde con su realidad espacial y/o radiométrica, lo que puede generar errores graves en los resultados derivados de los análisis digitales. Por ello, la eliminación de errores geométricos es una tarea

imprescindible para que la imagen pueda relacionarse con datos de campo, para la correcta integración de la imagen en un entorno SIG y para la realización de análisis multitemporales (Chuvieco, 2002), tareas todas ellas que se van realizan en el contexto de la presente investigación. En la corrección radiométrica, además de eliminar las distorsiones que introducen la atmósfera y la topografía en la señal registrada, los ND originales serán convertidos a valores de reflectividad, tarea indispensable para el establecimiento de modelos empíricos y teóricos como el que aquí se persigue. En definitiva, estos dos pretratamientos son necesarios para convertir los datos originales a un formato adecuado para el análisis cuantitativo y para permitir la transferencia y la comparación entre modelos estimativos de áreas diferentes (Foody *et al.*, 2003).

2.3.2.1. Corrección geométrica

Las distorsiones que alejan la posición del píxel registrado de la localización que tendría si la captura se hubiese realizado correctamente se clasifican en dos tipos: (i) sistemáticas, provocadas principalmente por la rotación y la curvatura terrestre y por la observación panorámica del sensor, y (ii) no sistemáticas, las provocadas por variaciones en la orientación, altura y velocidad de la plataforma y/o introducidas por el relieve.

Como se ha señalado antes, las imágenes adquiridas se encuentran ya libres de distorsiones sistemáticas, que fueron eliminadas mediante el procesamiento 1G. Así, sólo fue necesario eliminar los errores no sistemáticos; para ello se procedió de la forma habitual, mediante la aplicación de un modelo empírico denominado comúnmente como “corrección o georreferenciación a partir de puntos de control”. Este método asume que no se conoce la fuente de los errores geométricos, pero que éstos pueden ser modelados a partir del ajuste de ecuaciones a un conjunto de puntos comunes entre la imagen y un documento auxiliar georreferenciado. El método consta de tres etapas (Chuvieco, 2002): (i) localización de puntos comunes entre la imagen original y el documento auxiliar de referencia (puntos de control); (ii) cálculo de las funciones de transformación entre las coordenadas de la imagen y las del documento de referencia; y (iii) transferencia de los ND originales a la nueva posición definida por las funciones de transformación.

Una variante de este método, que mejora los resultados en el caso de trabajar con imágenes de relieves quebrados, es la introducción de un MDE. Esta variante se basa en añadir puntos de referencia en el eje de las Z (altura), que complementa la información (X,Y) del método de los puntos de control. Para ello existen varios modelos, como el de Novak, en el que cada coordenada (X,Y,Z) del MDE se transforma a la imagen mediante

ecuaciones colineales, o el de Palà y Pons, que emplean un modelo polinómico donde la altitud se introduce como una nueva variable independiente. El MDE utilizado en esta variante del método de puntos de control debe tener una resolución espacial similar a la imagen de satélite y ser suficientemente preciso (Chuvienco, 2002), condiciones que cumple el creado en el apartado 2.2.

La banda 6 fue eliminada en el proceso de importación al software utilizado para la corrección. A pesar de que esta banda proporciona información sobre el estrés de la vegetación, su diferente resolución espectral con respecto a las demás de TM (120 m frente a 30 m) y su escaso uso en trabajos orientados a la estimación de parámetros forestales con imágenes Landsat, determinaron que no fuera considerada. También fue eliminada en este momento la proyección asignada por el procesamiento 1G.

A continuación se refiere el proceso de georreferenciación aplicado. Se utilizó la proyección cartográfica UTM, el elipsoide de referencia Internacional de 1909, el *datum* Europeo de 1950 referido a España y Portugal y se asignó la imagen a la zona 30 UTM. El *software* utilizado fue ERDAS Imagine 8.7, que incorpora la opción de utilizar un MDE.

2.3.2.1.1 Establecimiento de los puntos de control

La correcta localización de los puntos de control es básica para asegurar la exactitud del proceso, constituyendo su fase más crucial, además de la que demanda mayor tiempo de trabajo por parte del usuario (Chuvienco, 2002). Teniendo en cuenta tales premisas, se creó un documento auxiliar de referencia para localizar puntos de control que ofreciera las máximas garantías en términos de precisión y calidad. En concreto, se generó un mosaico utilizando las ortofotografías aéreas de 1 m de resolución espacial del *SIG Oleícola Español*, disponibles en el Departamento de Geografía y Ordenación del Territorio (Figura 2.13). La proyección cartográfica asignada fue la misma que la que se iba utilizar en el proceso de georreferenciación. Este mosaico fue de gran ayuda para la identificación de puntos de control, ya que la visualización y localización de los mismos resulta mucho más sencilla y exacta que utilizando cartografía topográfica. Además, el formato digital del mosaico permite la introducción de las coordenadas cartográficas correspondientes a cada punto de la imagen Landsat de manera automática, evitándose así los posibles errores mecánicos del procedimiento manual. Por último señalar que, aunque se disponía de otras imágenes Landsat de la zona, ya georreferenciadas con apoyo de cartografía topográfica analógica, no fueron utilizadas por su menor exactitud en comparación con la ofrecida por las ortoimágenes.

Para el establecimiento de los puntos de control se tuvieron en cuenta los tres aspectos básicos a considerar durante este proceso (Chuvieco, 1996): (i) número, (ii) localización y (iii) distribución.

El número de puntos necesarios es función del tamaño y de la complejidad geométrica de la imagen. Para una escena Landsat completa se recomienda utilizar entre 100 y 120 puntos (Chuvieco, 2002), cantidades que fueron asumidas en cada una de las tres imágenes con objeto de garantizar una buena consistencia geométrica (Tabla 2.9). En cuanto a la localización de los puntos, se siguieron las recomendaciones de situarlos en zonas claramente identificables en la imagen y en el documento de referencia, utilizando preferentemente rasgos humanos del paisaje no sujetos a dinamismo temporal (cruces de carreteras y caminos, líneas de ferrocarril, cortafuegos, parcelas agrícolas, etc.), aunque también se utilizaron rasgos naturales como confluencias de barrancos y rasgos destacados de la vegetación. Los puntos fueron distribuidos uniformemente por todo el área de estudio y en sus zonas adyacentes, evitándose así la comisión de errores por la ponderación excesiva de algún sector del área de estudio. La Figura 2.14 muestra los puntos de control utilizados en una de las imágenes; se observa su elevada cuantía y su distribución homogénea por toda el área de estudio.

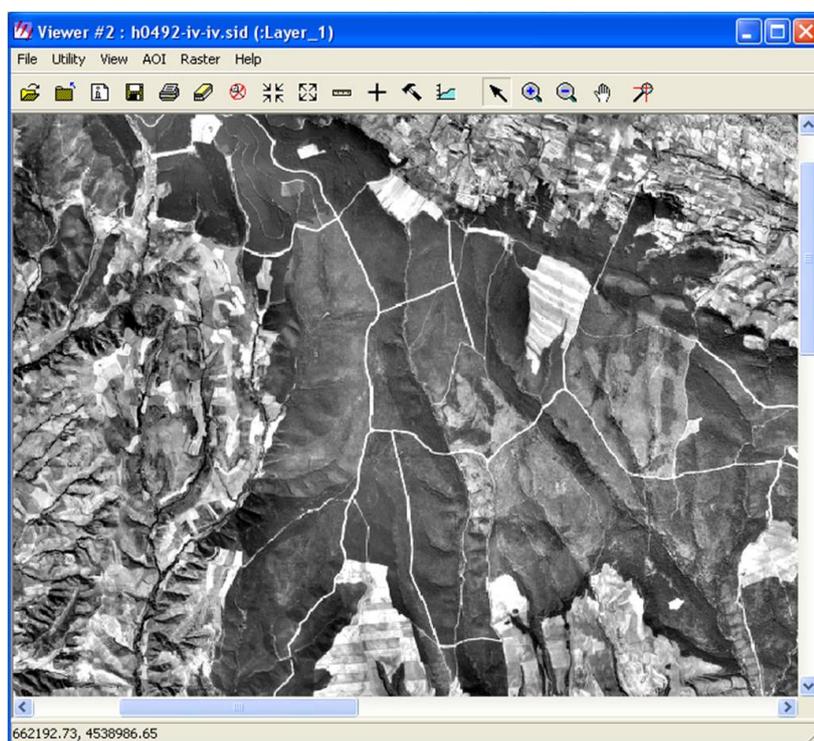


Figura 2.13. Detalle de las ortofotografías de 1 m de resolución espacial utilizadas para la localización de puntos de control

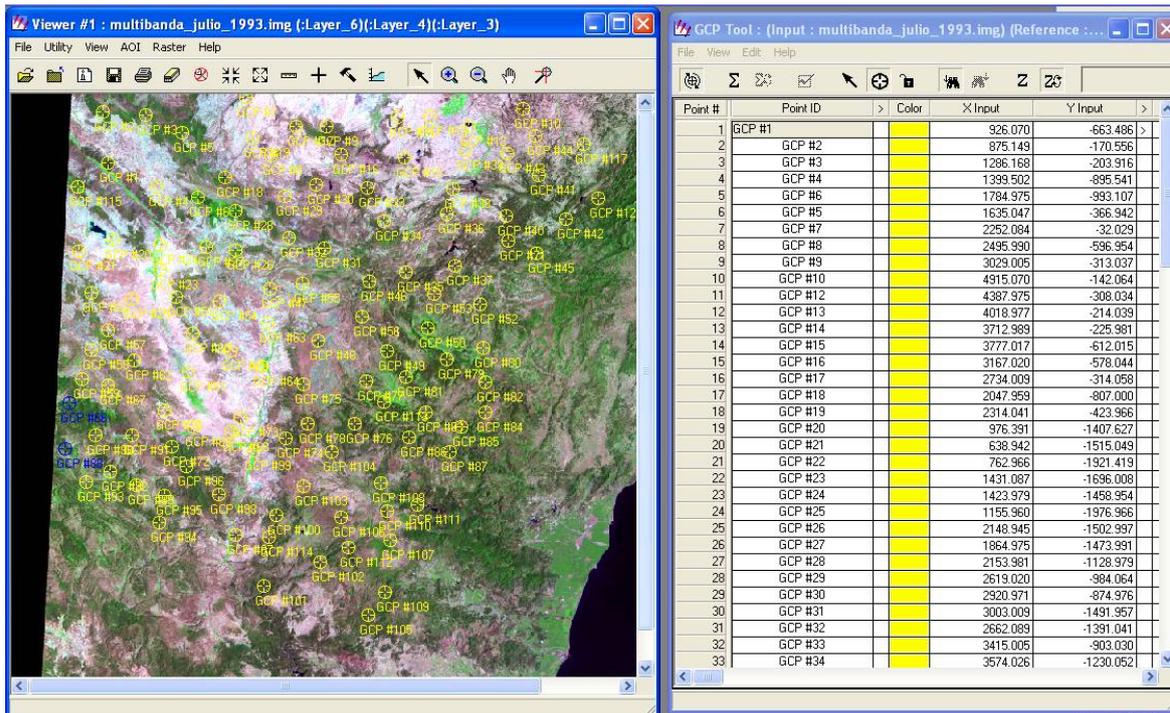


Figura 2.14. Puntos de control utilizados en el proceso de georreferenciación de la imagen de 28 de julio de 1993

2.3.2.1.2. Cálculo de las funciones de transferencia

Las funciones de transferencia son las funciones polinómicas de grado variable que ponen en relación las coordenadas imagen (fila / columna) con las del documento auxiliar de referencia (X,Y cartográficas). Estas funciones son las que determinan la nueva matriz georreferenciada a la cual se ajustarán los ND de la imagen original durante el proceso de transferencia. Estas funciones pueden expresarse como (Mather, 1987):

$$\hat{S} = \sum_{j=0,m} \sum_{k=0,m-j} a_{j,k} X^j Y^k \quad \text{Ecuación 23}$$

donde \hat{S} indica la coordenada estimada de la imagen corregida, X e Y son las coordenadas conocidas del documento de referencia y m indica el grado del polinomio de ajuste (Chuvieco, 1996).

El grado del polinomio depende de la complejidad topográfica de la zona, siendo recomendado el uso de un segundo o tercer grado en el caso de que sea elevada. En nuestro caso se aplicó uno de orden 2, siendo conscientes de que es más recomendable tolerar cierto nivel de error que seleccionar órdenes más altos de transformación (Chuvieco, 1996; Pérez-Cabello, 2002).

La bondad del grado de ajuste conseguido se mide por la importancia de los residuales, entendidos éstos como la diferencia entre el valor estimado y el observado para cada uno de los puntos de control. Para obtener una valoración global del ajuste en toda la imagen se emplea el error cuadrático medio (*Root Mean Squared Error, RMSE*), calculado mediante la raíz cuadrada de las desviaciones entre los valores observados y los estimados (Ecuación 24). EL RMSE también puede ser calculado para un solo punto, obteniéndose una valoración de la precisión de ese punto concreto (Chuvienco, 1996).

$$RMSE = \sqrt{\frac{\sum_{i=x,n} (y_i - y)^2 + (x_i - x)^2}{n}} \quad \text{Ecuación 24}$$

donde *RMSE* es el error cuadrático medio, y_i e x_i son las coordenadas estimadas; y e x son las coordenadas reales; n es el número de puntos de control (adaptado de Chuvienco, 1996).

En general, el nivel de tolerancia en el *RMSE* se sitúa en un valor igual o inferior a un píxel (Chuvienco, 1996), siendo éste el criterio adoptado, ya que las imágenes van a ser relacionadas con verdad terreno. La Tabla 2.9 recoge el *RMSE* alcanzado en el ajuste de cada imagen expresado en píxeles y en metros.

Imagen	Nº puntos de control	RMSE (en píxeles)	RMSE (en metros)
28 de julio de 1993	111	0,71	21,51
29 de junio de 1994	120	0,55	16,63
16 de agosto de 1994	121	0,59	17,89

Tabla 2.9. Número de puntos de control utilizados y RMSE obtenido en píxeles y en metros

2.3.2.1.3. Transferencia de los ND originales a la posición corregida

Esta última fase del proceso de georreferenciación reubica los píxeles de la matriz original en la nueva malla georreferenciada a partir de las funciones de transformación ajustadas. De los tres métodos más comúnmente aplicados - vecino más próximo, interpolación bilineal y convolución cúbica- se utilizó el del vecino más próximo. Este método sitúa en cada píxel de la nueva malla el ND del píxel más cercano en la imagen original. De esta forma, la práctica totalidad de los ND originales se conservan, ya que se transfieren sin realizar ninguna operación estadística (Chuvienco, 1996), lo que resulta fundamental cuando se va a utilizar la imagen en procesos de clasificación digital (Lillesand y Kiefer, 2000) o, como en nuestro caso, para ajustar modelos de estimación

de parámetros biofísicos. Su principal inconveniente es la distorsión que introduce en los rasgos lineales de la imagen, que adquieren un aspecto quebrado.

Simultáneamente a este proceso de transferencia de los ND, se procedió a la variación del tamaño del píxel de la nueva matriz, que pasó a ser de 25 m, frente a los 30 m originales de las bandas reflectivas TM. Esta transformación se abordó con el objeto de adecuar la geometría de las imágenes resultantes a una cadencia de valores más adecuada al sistema métrico decimal (Pérez-Cabello, 2002). Sobre las imágenes resultantes se aplicó la misma máscara que se había utilizado anteriormente sobre el MDE, delimitándose así de forma precisa el área de estudio (Figura 2.15). Es sobre estas imágenes ajustadas a los límites de la provincia de Teruel sobre las que se realiza a continuación el proceso de corrección radiométrica.

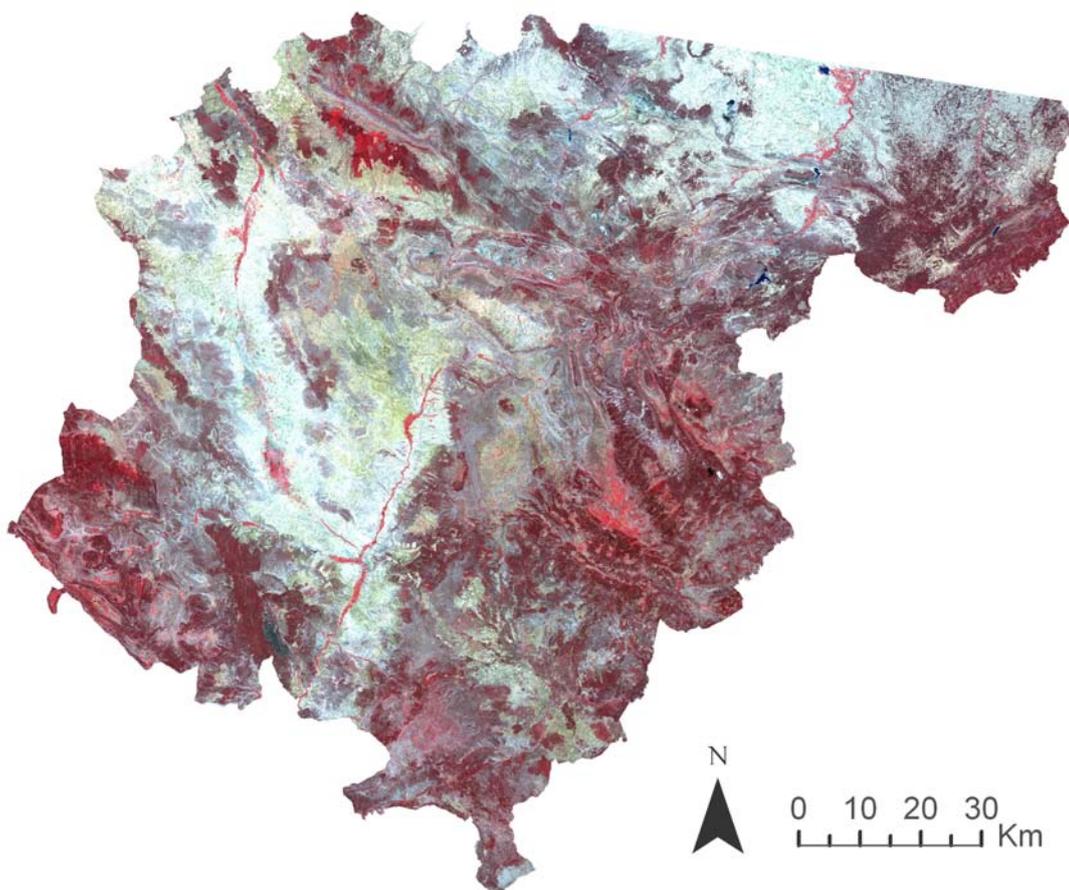


Figura 2.15. Composición RGB 4-3-2 de la imagen Landsat del 29 de junio de 1994 corregida geoméricamente y adaptada a los límites del área de estudio

2.3.2.2. Corrección radiométrica

La señal que recoge el sensor no es sólo función de las propiedades reflectivas de la superficie. Existen contribuciones adicionales y anomalías en la radiancia que pueden ser debidas a la calibración de los detectores, a las características de superficies vecinas, a la influencia de la atmósfera y a la geometría de la iluminación, en donde los efectos de la elevación solar y la pendiente tienen una influencia muy destacada.

El término corrección radiométrica alude a un conjunto de técnicas que se aplican para modificar los ND originales con objeto de acercarlos a los que se registrarían si la recepción fuera ideal. Dentro de este concepto se encuentran las técnicas destinadas a la restauración de líneas o píxeles perdidos, las de reparación del bandeo y las de corrección del efecto atmosférico y de las variaciones de iluminación debidas al relieve, estando estas dos últimas ligadas a la transformación de los ND originales a parámetros físicos como, por ejemplo, la reflectividad (Chuvieco, 1996).

Los errores debidos a un mal funcionamiento del sensor o de la antena receptora de la imagen y los relacionados con el mal calibrado de los detectores que forman el sensor, responsables de la pérdida de líneas o píxeles y del efecto de bandeo, respectivamente, son fácilmente identificables en la visualización de las imágenes. Ninguno de estos dos errores fue detectado en las imágenes aquí consideradas durante el proceso de corrección geométrica, en el cual se realizó una visualización exhaustiva de las mismas. Por el contrario, los errores introducidos por la atmósfera, la geometría de la iluminación y por el relieve no son detectables tan fácilmente, ya que responden a factores ambientales y astronómicos (Pérez-Cabello, 2002).

Entre el sensor y la superficie terrestre se interpone la atmósfera, que interfiere de tres formas diferentes en el flujo de radiación electro-magnética registrada: mediante la absorción, la dispersión y la emisión. Estas tres interacciones se producen de forma selectiva en función de la longitud de onda, provocando un desajuste entre la cantidad de energía reflejada por la superficie y la radiancia que capta el sensor. El efecto de la absorción atmosférica está minimizado por la ubicación de las bandas de observación del sensor en longitudes de onda donde la transmisividad atmosférica es alta (Chuvieco, 1996). La emisión atmosférica interfiere en longitudes de onda del infrarrojo térmico, no constituyendo un problema en este trabajo. Sin embargo, el efecto de la dispersión atmosférica sí que está presente, en mayor o menor proporción, en cualquier imagen

adquirida por sensores remotos (Chuvienco, 1996), afectando directamente a las información espectral recogida por el sensor.

La dispersión atmosférica es ocasionada por la interacción entre la radiación electromagnética que atraviesa la atmósfera y los gases y partículas que ésta tiene en suspensión. Estas partículas o gases (principalmente aerosoles y vapor de agua) reflejan o refractan la energía, variando su dirección y/o intensidad. De esta manera, la radiancia captada por el sensor desde el exterior de la atmósfera se ve incrementada por la debida a este fenómeno de dispersión (*luz atmosférica*). Se distinguen tres tipos de dispersión: *Rayleigh* (afecta a longitudes de onda inferiores al diámetro de la partícula), *Mie* (partículas de diámetro similar a la longitud de onda) y *no selectiva* (causada por partículas de mayor tamaño). La dispersión atmosférica es mayor en longitudes de onda más cortas.

La geometría de la iluminación también incide en la reflectividad captada. Así, el registro del sensor está condicionado por una serie de ángulos definidos por las posiciones relativas entre éste y el Sol en el momento de captura de la imagen. Los ángulos que definen la geometría de observación son, por un lado, los ángulos cenital y acimutal²², dependientes del momento de la toma de la imagen, y, por otro, del ángulo de observación del sensor, considerado nulo en TM al ser un sensor de observación cenital (Pérez-Cabello, 2002).

Por último, el efecto topográfico se define como la variación en la respuesta espectral de las superficies inclinadas respecto a las horizontales siendo ésta resultado directo de su orientación respecto a la fuente de iluminación y al sensor. La variación que introduce la topografía en las áreas de montaña con respecto a las llanas es doble: por un lado produce variaciones en la irradiancia recibida (tanto directa como difusa), lo cual está en función del ángulo del flujo incidente; por otro se producen procesos de ocultamiento topográfico, quedando algunas zonas de sombra debido a la altura y situación de relieves vecinos (y no a la exposición del píxel considerado) (de la Riva, 1997; Chuvienco, 2002). Así, en áreas con una topografía compleja como la nuestra, el relieve hace que exista una variación de la respuesta espectral de un mismo tipo de cubierta vegetal (Chuvienco, 2002; Riaño *et al.*, 2003;). En consecuencia, para eliminar este efecto topográfico debe considerarse el ángulo de incidencia, definido éste como el

²² El ángulo cenital se obtiene restando a un ángulo recto el de elevación solar; el acimutal se mide en la dirección norte en el sentido horario (Chuvienco, 1996; Pérez-Cabello, 2002).

ángulo entre el vector incidente y la normal de la superficie, el cual depende directamente de la orientación y de la pendiente del terreno (Pérez-Cabello, 2002).

La eliminación de estos efectos y la conversión de los ND originales a reflectividad es un paso previo fundamental al establecimiento de modelos empíricos como el que se persigue, ya que la reflectividad es una variable física comparable y extrapolable a otras zonas, lo que hace más sólida la interpretación de los datos y permite la comparabilidad multitemporal y el análisis integrado entre imágenes obtenidas con el concurso de otros sensores (Chuvienco, 1996; de la Riva, 1997; Cohen *et al.*, 2001; Pérez-Cabello, 2002; Foody *et al.*, 2003). De esta manera, la corrección radiométrica es una tarea previa fundamental para encarar con éxito la tarea de encontrar un modelo de estimación de biomasa residual del área de estudio mediante la utilización de información espectral que sea actualizable, pudiendo ser comparados los resultados obtenidos con los de otros trabajos similares que también hayan sido expresados en términos de reflectividad.

La metodología aplicada se divide en dos fases: en primer lugar se aborda la corrección del efecto de dispersión atmosférica y, en segundo, las imágenes son convertidas a reflectividad espectral eliminándose las distorsiones procedentes de la geometría de la observación y de la morfología del terreno.

2.3.2.2.1. Corrección del efecto de la dispersión atmosférica

Las correcciones atmosféricas pueden abordarse desde dos técnicas distintas: mediante la utilización de modelos físicos de transferencia radiativa o mediante la utilización de métodos empíricos (de la Riva, 1997). Los primeros, aunque más precisos, no pudieron ser considerados en la presente investigación, ya que para su elaboración se requieren datos sobre las condiciones de la atmósfera en el momento de tomar la imagen (Chuvienco, 1996; Foody *et al.*, 2003). De esta forma, la eliminación de la dispersión atmosférica de las imágenes fue abordada mediante la realización de un método empírico que asume que los efectos atmosféricos son constantes en toda la imagen y que existe una relación lineal entre los datos registrados y la reflectividad de los objetos (de la Riva, 1997). Aunque se trata de una forma de proceder más simple y los resultados son menos precisos que los obtenidos cuando se aplica un modelo físico, estos métodos se han mostrado como muy efectivos a para la eliminación de los efectos atmosféricos en las imágenes de satélite (de la Riva, 1997; Foody *et al.*, 2003).

El método aplicado ha sido el denominado como *corrección del histograma por*

sus valores mínimos (*Histogram Minimum Method*), el cual se basa en la utilización de los datos de la propia imagen para estimar y eliminar el efecto atmosférico. Este método presupone que las zonas de la imagen cubiertas por materiales de fuerte absorción (agua, sombra topográfica) deberían presentar una radiancia espectral muy próxima a cero o cero, con lo que la diferencia entre cero y el valor mínimo en cada banda constituirá el efecto dispersor de la atmósfera (Chuvienco, 1996; Pérez-Cabello, 2002).

La forma de proceder es sencilla: consiste en restar el ND mínimo de cada banda a todos los píxeles que la componen. De esta manera, se procedió al cálculo de los histogramas de cada una de bandas de las tres imágenes, identificándose el valor mínimo de cada una de ellas. Los ND mínimos identificados fueron confirmados como los presentes en las zonas de sombra topográfica, lo que validó la utilidad de los mismos para eliminar el efecto de la dispersión atmosférica. Además, tal y como se observa en la Tabla 2.10, el valor mínimo de los histogramas de las bandas que componen nuestras imágenes es mayor en las bandas con longitudes de onda más cortas (bandas 1 a 3), disminuyendo conforme aumenta de longitud de onda. Este hecho está en consonancia con la relación inversa existente entre dispersión atmosférica y longitud de onda.

	28 de julio de 1993	29 de junio de 1994	16 de agosto de 1994
Banda 1	42	45	36
Banda 2	13	14	12
Banda 3	11	11	9
Banda 4	6	6	8
Banda 5	3	1	4
Banda 7	1	1	1

Tabla 2.10. ND mínimos de cada una de las bandas de las imágenes Landsat utilizadas

Estos valores mínimos fueron restados a los ND de los píxeles de sus correspondientes bandas, obteniéndose unas imágenes libres del efecto de la dispersión atmosférica. A pesar de que este método puede ocasionar sobre-correcciones en algunas de las bandas, es considerado como un método válido para resolver la complejidad y laboriosidad que entrañan las correcciones atmosféricas (Pérez-Cabello, 2002).

2.3.2.2.2. Transformación de los ND originales a valores de reflectividad espectral

Para conocer la reflectividad de una superficie es preciso relacionar dos magnitudes: la energía reflejada y la incidente (Chuvienco, 1996). La reflejada se puede obtener a partir de la decodificación de los ND proporcionados por el sensor mediante la

utilización de sus coeficientes de calibración, obteniéndose de esta forma valores de radiancia espectral. La energía incidente es función de la irradiancia solar, la cual se puede conocer a partir de tablas solares, y de las condiciones de adquisición de la imagen y de los efectos originados por la topografía (Pérez-Cabello, 2002).

El proceso metodológico seguido consta de tres etapas: en primer lugar se obtienen los valores de radiancia espectral; en segundo lugar, se obtiene la reflectividad sin normalización topográfica; por último, se aplica un método de normalización topográfica para eliminar la dependencia de la reflectividad con respecto a la pendiente del terreno. Todo este proceso es creado mediante el modulo de ERDAS Imagine *Model maker*, que permite la integración de distintas capas de información y la realización de operaciones complejas entre ellas.

- Cálculo de la radiancia espectral

La radiancia espectral es la energía que capta el sensor y se define como “el total de energía radiada en una determinada longitud de onda por unidad de área y por ángulo sólido de medida” ($W\ m^{-2}\ sr^{-1}\ \mu m^{-1}$) (Chuvieco, 1996). La medición de la radiancia por el sensor se hace mediante su codificación en ND de acuerdo con unos coeficientes de calibración específicos para cada sensor. Si estos coeficientes son conocidos se puede realizar el proceso inverso; es decir, conocer la radiancia a partir de los ND proporcionados por el sensor (Chuvieco, 1996). Ésta es la operación que se lleva a cabo en nuestras imágenes Landsat mediante la siguiente ecuación:

$$L_{sen,k} = a_{0,k} + a_{1,k} ND_k \quad \text{Ecuación 25}$$

donde $L_{sen,k}$ es la radiancia espectral recibida por el sensor en la banda k (expresada en $W\ m^{-2}\ sr^{-1}\ \mu m^{-1}$), $a_{0,k}$ y $a_{1,k}$ son los coeficientes de calibración para esa banda (*offset* y *gain*, respectivamente, en el caso de Landsat TM), y ND_k cada uno de los ND originales de la banda considerada (adaptado de Chuvieco, 1996).

	$a_{0,k}$ (offset)	$a_{1,k}$ (gain)
Banda 1	-1,50	0,60235
Banda 2	-2,80	1,17490
Banda 3	-1,20	0,80588
Banda 4	-1,50	0,81451
Banda 5	-0,37	0,10808
Banda 7	-0,15	0,05698

Tabla 2.11. Coeficientes de calibración (*offset* y *gain*) de las imágenes Landsat 5 TM utilizadas

La Tabla 2.11 recoge los coeficientes de calibración de Landsat 5 TM extraídos de los ficheros de cabecera de cada una de las imágenes utilizadas. Las imágenes resultantes son utilizadas para calcular la reflectividad sin normalización topográfica.

- *Cálculo de la reflectividad sin normalización topográfica*

En este trabajo se entiende por reflectividad sin normalización topográfica a la calculada para una superficie sin tener en cuenta la influencia que el relieve tiene en ella. Para la obtención de la reflectividad es necesario tener en cuenta diversos factores que se relacionan entre sí mediante la siguiente expresión:

$$\rho_T = \frac{K \cdot \pi \cdot L_{sen,k}}{E_{0,k} \cdot \cos \theta_z \cdot T_{k,i}} \quad \text{Ecuación 26}$$

donde ρ_T es la reflectividad sin normalización topográfica en cada banda k , K es el factor corrector de la distancia Tierra-Sol, $L_{sen,k}$ es la radiancia espectral de esa banda (sin dispersión atmosférica), $E_{0,k}$ es la irradiancia solar en el techo de la atmósfera de esa banda, θ_z es el ángulo cenital solar y $T_{k,i}$ es la transmisividad del flujo incidente considerando la banda k (adaptado de Pérez-Cabello, 2003).

A continuación se detallan los valores que se han empleado para cada uno de los parámetros considerados en la Ecuación 26 (Pérez-Cabello, 2003):

- **K**. Se calcula a partir de la integración del día juliano en la siguiente expresión (medido en unidades astronómicas):

$$K = (1 + 0.01674 \cdot (\sin(\text{día juliano} - 93.5) / 365))^2 \quad \text{Ecuación 27}$$

- **$L_{sen,k}$** . Se utilizan los valores de radiancia espectral sin dispersión atmosférica obtenidos en el subapartado anterior.
- **$E_{0,k}$** . Las constantes de irradiancia solar son ($W \cdot m^{-2} \cdot \mu m^{-1}$): banda 1: 1954; banda 2: 1826; banda 3: 1558; banda 4: 1047; banda 5: 217,2; banda 7: 80,29.
- **θ_z** . Calculado como el ángulo complementario al de elevación solar, que viene recogido en los ficheros de cabecera de cada imagen. Se expresa en radianes.
- **$T_{k,i}$** . Se adoptan los siguientes valores estándar: banda 1: 0,70; banda 2: 0,78; banda 3: 0,85; banda 4: 0,91; banda 5: 1; banda 7: 1.

El resultado de aplicar la Ecuación 26 son unas imágenes en las que el valor de cada píxel representa la reflectividad de la cubierta presente, por lo que sus valores varían entre 0 (perfectamente absorbente) y 1 (totalmente reflectora). Para facilitar futuros análisis, el valor de cada píxel fue multiplicado por 100.

- Cálculo de la reflectividad con normalización topográfica

El término normalización topográfica hace referencia a la compensación de las diferencias de iluminación solar introducidas por la forma irregular del terreno (Riaño *et al.*, 2003). Como se ha comentado con anterioridad, este efecto causa una gran variación en la respuesta reflectiva de cubiertas vegetales similares, por lo que es imprescindible su eliminación en áreas de topografía compleja. Una normalización topográfica refinada reduce la variabilidad interna de cada tipo de vegetación, ya que la reflectividad corregida está más correlacionada con las propiedades geométricas o biofísicas de la vegetación que la obtenida sin tener en cuenta el efecto del relieve (Riaño *et al.*, 2003).

Aunque la aplicación de algunos ratios entre imágenes puede paliar este efecto, la utilización de un MDE preciso (misma resolución) y bien ajustado resulta mucho más eficaz, ya que permite modelar las condiciones de iluminación en el momento de toma de la imagen (Chuvieco, 1996; Pérez-Cabello, 2002; Riaño *et al.*, 2003). Dado que el MDE obtenido en el apartado 2.2 cumple con las características requeridas, es el utilizado para corregir de manera rigurosa los efectos topográficos de nuestras imágenes.

Los métodos que introducen un MDE en este proceso pueden ser divididos en dos categorías: (i) Lambertianos, aquellos que asumen que todas las superficies tienen un comportamiento reflectivo isotrópico, es decir, que reflejan la energía incidente por igual en todas las direcciones y en todas las longitudes de onda, por lo que son independientes del ángulo de observación; y (ii) no-Lambertianos, que asumen que las superficies tienen un comportamiento anisotrópico debido a su rugosidad, por lo que la reflectividad no se produce por igual en todas las direcciones y en todas las longitudes de onda, siendo necesario considerar el ángulo de observación. Aunque los primeros resultan más sencillos, los segundos son más exactos, ya que todas las cubiertas tienen una difusividad característica (Pérez-Cabello, 2003; Riaño *et al.*, 2003; Vincini y Frazzi, 2003).

Dentro de los modelos no-Lambertianos, han sido ampliamente utilizadas diferentes variantes del modelo de corrección de Minnaert y del modelo *C-correction* en trabajos orientados a la obtención de clasificaciones digitales y a la estimación de parámetros biofísicos. En la bibliografía existen diversos trabajos enfocados a comparar

los resultados obtenidos de aplicar uno u otro modelo, con objeto de determinar cuál de ellos minimiza mejor el efecto topográfico, conserva la variabilidad entre cubiertas y reduce la interna dentro de un mismo tipo de cubierta en imágenes Landsat; los resultados son dispares. Así, mientras que algunos autores destacan que las diferencias entre uno y otro método son mínimas (Meyer *et al.*, 1993; McDonald *et al.*, 2000; Twele y Erasmi, 2005), otros señalan al modelo de *C-Correction* como el más adecuado (Vincini y Frazzi, 2003; Riaño *et al.*, 2003). En todo caso, todos parecen ponerse de acuerdo en la idoneidad de contar con información sobre las distintas cubiertas presentes en la imagen a la hora de calcular el parámetro empírico que controla la difusividad de cada superficie, ya que, como se ha indicado, cada tipo de cubierta tiene un comportamiento reflectivo no-Lambertiano propio que es diferente en cada longitud de onda (McDonald *et al.*, 2000; Riaño *et al.*, 2003; Wu *et al.*, 2004; Twele y Erasmi, 2005).

Teniendo en cuenta estas premisas, el método que se aplicó fue el de Minnaert, utilizándose información pre-existente de las cubiertas vegetales presentes en el área de estudio para calcular la constante que en este método modela su difusividad específica. De las diferentes versiones de este método se utilizó la de Colby (1991):

$$\rho_H = \rho_T \cdot \cos \theta_p \left(\frac{\cos \theta_z}{IL \cdot \cos \theta_p} \right)^{K_k} \quad \text{Ecuación 28}$$

donde ρ_H es la reflectividad de una superficie horizontal (normalizada topográficamente), ρ_T es la reflectividad de una superficie sin normalización topográfica, θ_p es el ángulo de la pendiente, θ_z es ángulo cenital solar, IL es el coseno del ángulo de incidencia, y K es la constante de Minnaert para la banda k (adaptado de Riaño *et al.*, 2003 y de Twele y Erasmi, 2005).

A continuación se detalla cómo se han obtenido los parámetros involucrados:

- ρ_T . Valores de reflectividad sin normalización topográfica ya obtenidos.
- θ_p . A partir de la aplicación de un algoritmo sobre el MDE que devuelve un valor de pendiente; la información de este ángulo es expresada en radianes.
- θ_z Angulo complementario –expresado en radianes- al de elevación solar, que viene recogido en los ficheros de cabecera de cada imagen.
- IL . Expresado en radianes, se calcula mediante la siguiente expresión:

$$IL = \cos \theta_p \cdot \cos \theta_z + \sin \theta_p \cdot \sin \theta_z \cdot \cos(\phi_a - \phi_0) \quad \text{Ecuación 29}$$

donde ϕ_a es el ángulo acimutal solar (obtenido en los ficheros de cabecera de las imágenes y expresado en radianes) y ϕ_0 es el ángulo de orientación-exposición (obtenido de la aplicación de un algoritmo al MDE que devuelve un valor de orientación-exposición en grados, expresado después en radianes).

- **K.** La constante de Minnaert es el término que modela el comportamiento no-Lambertiano de una superficie o cubierta y varía entre 0 (si la superficie actúa como un reflector especular) y 1 (si la superficie se comporta como un reflector isotrópico o Lambertiano perfecto). Debe ser calculada de forma previa a la corrección, pudiéndose asumir un mismo valor para toda la imagen en cada banda o calcularse en función de las distintas cubiertas presentes en la imagen (Pérez-Cabello, 2003; Riaño *et al.*, 2003; Twele y Erasmi, 2005). Para obtener esta constante se ajusta una regresión lineal entre los términos de la Ecuación 30, siendo el valor K la pendiente de esa regresión ²³ (Pérez-Cabello, 2003; Twele y Erasmi, 2005).

$$\log(\rho_T \cdot \cos \theta_p) = \log \rho_H + K \cdot \log(IL \cdot \cos \theta_p) \quad \text{Ecuación 30}$$

Como ya se ha indicado, para el cálculo de K en cada banda se utilizó información pre-existente de las cubiertas vegetales del área de estudio. En concreto, se utilizó la reclasificación del *Mapa Forestal de Aragón* 1:50.000 en formato digital (MFA). El proceso metodológico que se siguió fue el siguiente:

- o Creación de un multibanda por imagen que incluye:
 - La reflectividad de las bandas TM sin normalización topográfica.
 - El coseno del ángulo de incidencia (IL), expresado en radianes.
 - El coseno de la pendiente ($\cos \theta_p$), expresado en radianes.
 - El índice NDVI (*Normalized Difference Vegetation Index*) (Rouse *et al.*, 1974) (Ecuación 31), calculado a partir de la reflectividad de las bandas 3 y 4 sin normalización topográfica.

$$NDVI = \frac{(B4 - B3)}{(B4 + B3)} \quad \text{Ecuación 31}$$

²³ Donde $\log(\rho_T \cdot \cos \theta_p)$ es la variable dependiente y $\log(IL \cdot \cos \theta_p)$ es la independiente.

- Una cobertura forestal resultado de la reclasificación del MFA.
 - Muestreo sistemático aleatorio en cada multibanda (>3500 píxeles).
 - Cálculo del NDVI promedio para cada tipo de cubierta (Tabla 2.12).

Tipo de cubierta	28 de julio de 1993	29 de junio de 1994	16 de agosto de 1994 ²⁴
Cultivos	0,27	0,28	0,23
Arbolado ralo	0,41	0,40	0,36
Forestal desarbolado	0,35	0,35	0,28
Improductivo	0,25	0,26	0,24
Pinar de <i>P. sylvestris</i>	0,59	0,57	0,53
Pinar de <i>P. halepensis</i>	0,46	0,44	0,38
Pinar de <i>P. nigra</i>	0,50	0,49	0,45
Pinar de <i>P. pinaster</i>	0,51	0,48	0,46
Sabinares albares	0,39	0,41	0,36
Quejigares	0,44	0,47	0,41
Encinares	0,46	0,44	0,42
Choperas	0,58	0,59	0,57

Tabla 2.12. NDVI promedio de las distintas cubiertas en las imágenes Landsat TM utilizadas

- Dada la dificultad técnica de calcular una constante K para cada tipo de cubierta y para evitar en lo posible la comisión de errores debida a posibles inexactitudes de la fuente cartográfica, se decidió utilizar los NDVI promedio para estratificar la imagen en tres tipos de cubiertas en función de la presencia, el grado de actividad y la estructura espacial de la vegetación. Así, se definieron tres categorías: (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa boscosa. La Tabla 2.13 muestra los umbrales de NDVI usados en cada una de las imágenes para definir estas categorías; el valor de NDVI de 0,2 ha sido utilizado para distinguir entre la categoría (i) y la (ii)²⁵, mientras que para discriminar entre la (ii) y la (iii) se ha utilizado los valores NDVI promedio de las categorías Arbolado ralo y Sabinares albares²⁶.

²⁴ El pronunciado descenso del valor promedio del NDVI en la imagen de agosto de 1994 en las categorías Arbolado ralo, Forestal desarbolado y Pinar de *P. halepensis* se debe a que en estas categorías se han promediado píxeles afectados por el gran incendio del Maestrazgo acaecido entre el 2 y 8 de julio de 1994.

²⁵ Este valor de NDVI -0,2- puede considerarse como umbral crítico de presencia de cubiertas vegetales (de la Riva. 1997).

²⁶ Elegido por cuanto esta formación se presenta en la zona principalmente en forma de bosque abierto poco denso (Querol, 1995; Ministerio de Medio Ambiente, 1996; González *et al.*, 2001).

Categoría	NDVI julio de 1993	NDVI junio de 1994	NDVI agosto de 1994
(i)	≤ 0,20	≤ 0,20	≤ 0,20
(ii)	0,21 -0,41	0,21 – 0,41	0,21 – 0,36
(iii)	> 0,41	> 0,41	>0'36

Tabla 2.13. Umbrales de NDVI usados en cada imagen para separar las categorías (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa en forma de bosque

- Se procedió después al cálculo de la constante K de Minnaert considerando estas tres categorías en cada una de las bandas (Tabla 2.14). Para ello se utilizó la misma muestra de píxeles utilizada para determinar el promedio de NDVI de cada cubierta.

	28 de julio de 1993			29 de junio de 1994			16 de agosto de 1994		
	(i)	(ii)	(iii)	(i)	(ii)	(iii)	(i)	(ii)	(iii)
Banda 1	0,782	0,758	0,706	0,612	0,799	0,702	0,991	0,671	0,510
Banda 2	0,913	0,903	0,790	0,668	0,952	0,778	1,000	0,924	0,745
Banda 3	1,000	1,000	0,912	0,674	1,000	0,836	1,000	0,982	0,790
Banda 4	1,000	0,878	0,748	0,636	0,938	0,784	1,000	0,901	0,722
Banda 5	1,000	0,967	0,913	0,567	0,951	0,881	1,000	1,000	0,943
Banda 7	0,987	1,000	0,997	0,645	1,000	0,926	1,000	1,000	1,000

Tabla 2.14. Valores calculados para la constante de Minnaert en función de las bandas de cada imagen y las categorías (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa en forma de bosque

- Finalmente, se procedió a aplicar la normalización topográfica en cada una de las imágenes siguiendo la expresión de la Ecuación 28.

Para validar que las correcciones efectuadas minimizaban la influencia de la topografía en la reflectividad se llevó a cabo, además del preceptivo análisis visual, una regresión entre los valores obtenidos en cada banda y el coseno del ángulo de incidencia (IL). Este método estadístico, utilizado en los trabajos de McDonald *et al.* (2000) y Twele y Erasmi (2005), se basa en que si la corrección ha sido efectuada correctamente, la pendiente y el coeficiente de determinación (R^2) resultantes al aplicar dicha regresión presentarán valores inferiores a los obtenidos si se utiliza la reflectividad previa a la normalización, ya que la relación directa entre reflectividad y ángulo de incidencia se habrá eliminado.

Este análisis estadístico se llevó a cabo considerando dos muestras de píxeles diferentes obtenidas a partir de un muestreo sistemático aleatorio: la primera quedó compuesta por >3500 píxeles procedentes de cualquier tipo de cubierta, mientras que en

la segunda sólo se consideraron los píxeles con NDVI >0,40 y <0,45 (≈200). Se pretendió así valorar tanto la incidencia de la normalización en toda la imagen como en un conjunto de píxeles con un comportamiento espectral similar. Las Tablas 2.15 y 2.16 muestran los parámetros pendiente y R^2 obtenidos antes (*sin N.T.*) y después de la normalización topográfica (*con N.T.*) en estos dos grupos de píxeles.

	28 de julio de 1993		29 de junio de 1994		16 de agosto de 1994	
	Pendiente	R^2	Pendiente	R^2	Pendiente	R^2
Banda 1 sin N.T.	9,458	0,071	8,874	0,065	8,153	0,081
Banda 1 con N.T.	4,808	0,015	4,015	0,011	2,775	0,006
Banda 2 sin N.T.	14,115	0,077	13,604	0,071	12,869	0,090
Banda 2 con N.T.	6'930	0,014	5,448	0,009	4,645	0,008
Banda 3 sin N.T.	17,864	0,073	17,801	0,070	16,383	0,084
Banda 3 con N.T.	9,484	0,015	8,323	0,012	6,334	0,008
Banda 4 sin N.T.	23,693	0,112	24,029	0,104	22,719	0,126
Banda 4 con N.T.	2,089	0,001	0,213	0,000	1,642	0,001
Banda 5 sin N.T.	33,117	0,127	32,958	0,121	31,717	0,150
Banda 5 con N.T.	12,289	0,013	9,876	0,009	9,613	0,010
Banda 7 sin N.T.	25,968	0,110	25,981	0,104	25,524	0,127
Banda 7 con N.T.	12,648	0,019	10,522	0,014	11,234	0,017

Tabla 2.15. Valores de la pendiente y del coeficiente de determinación obtenidos al aplicar la regresión entre la reflectividad y el coseno del ángulo de incidencia (IL) antes de realizar la normalización (*sin N.T.*) y después (*con N.T.*) utilizando píxeles de cualquier tipo de cubierta

	28 de julio de 1993		29 de junio de 1994		16 de agosto de 1994	
	Pendiente	R^2	Pendiente	R^2	Pendiente	R^2
Banda 1 sin N.T.	2,653	0,088	2,766	0,075	2,650	0,103
Banda 1 con N.T.	-1,391	0,014	-2,177	0,038	-1,380	0,019
Banda 2 sin N.T.	4,723	0,138	5,285	0,142	4,688	0,168
Banda 2 con N.T.	-1,535	0,008	-2,587	0,027	-1,996	0,021
Banda 3 sin N.T.	5,845	0,141	6,337	0,132	5,371	0,193
Banda 3 con N.T.	-1,680	0,006	-3,371	0,029	-2,444	0,028
Banda 4 sin N.T.	14,609	0,147	14,944	0,130	12,985	0,195
Banda 4 con N.T.	-4,345	0,007	-8,079	0,030	-6,271	0,031
Banda 5 sin N.T.	16,665	0,197	18,450	0,204	15,485	0,252
Banda 5 con N.T.	-2,663	0,003	-5,786	0,017	-1,656	0,002
Banda 7 sin N.T.	11,832	0,210	12,816	0,175	11,025	0,231
Banda 7 con N.T.	-0,884	0,001	-2,990	0,008	0,486	0,001

Tabla 2.16. Valores de la pendiente y del coeficiente de determinación obtenidos al aplicar la regresión entre la reflectividad y el coseno del ángulo de incidencia (IL) antes de realizar la normalización (*sin N.T.*) y después (*con N.T.*) utilizando píxeles con NDVI entre 0,40 y 0,45

Tal y como se observa en ambas tablas, la normalización topográfica se llevó a cabo con éxito, ya que en todas las bandas de las tres imágenes los parámetros pendiente y R^2 son muy inferiores tras la aplicación de la corrección. Por su parte, el análisis visual también permitió constatar la bondad de la normalización, aunque se detectaron algunas pequeñas zonas en las que se habían producido sobre-correcciones, identificándose éstas con las de máxima pendiente del área de estudio. En consecuencia, las imágenes obtenidas tras este proceso de normalización topográfica están listas para ser utilizadas como variables independientes en los modelos de estimación de biomasa que se desarrollarán en los capítulos 3 y 4. Sobre estas imágenes se aplican una serie de transformaciones en el apartado siguiente al objeto de aumentar el número de variables espectrales a considerar en la elaboración de estos modelos de estimación.

2.3.3. Aplicación de transformaciones y elaboración de neocanales

Aunque existen en la bibliografía trabajos orientados a la estimación de parámetros forestales utilizando únicamente las seis bandas reflectivas de Landsat (p.e. Fazakas *et al.*, 1999; Mäkelä y Pekkarinen, 2001; Mäkelä y Pekkarinen, 2004; Maselli y Chiesi, 2006), resultan recurrentes los trabajos que, además de éstas, utilizan nuevas bandas de información espectral obtenidas a partir de aquéllas (p.e. Roy y Ravan, 1996; Salvador y Pons, 1998b; Foody *et al.*, 2001; Labrecque *et al.*, 2003; Mallinis *et al.*, 2004; Lu *et al.*, 2004; Zheng *et al.*, 2004; Lu, 2005; Hall *et al.*, 2006; Labrecque *et al.*, 2006). Estos neocanales son fruto de transformaciones, más o menos complejas, aplicadas a las bandas originales al objeto de aprovechar toda la información contenida en ellas, obteniéndose nuevas dimensiones de la información espectral que pueden resultar útiles a la hora de estimar con mayor precisión el parámetro buscado o para resaltar diferencias entre cubiertas, eliminándose a su vez la fuerte correlación existente entre algunas bandas (especialmente en longitudes de onda próximas) por la presencia de información redundante (Chuvieco, 1996; de la Riva, 1997; Lillesand y Kiefer, 2000).

Dado que nuestro objetivo es encontrar el mejor modelo de estimación posible, se decidió considerar todos aquellos neocanales que en la bibliografía se han mostrado como significativos a la hora de estimar parámetros forestales mediante imágenes Landsat. A continuación se presentan cada uno de ellos agrupados según el tipo de transformación aplicada para calcularlos.

2.3.3.1. Análisis de componentes principales

El Análisis de Componentes Principales (ACP) es una técnica estadística entroncada en las multivariantes de síntesis de la información cuyo objetivo es resumir un amplio abanico de variables en un nuevo conjunto de menor tamaño, todo ello sin perder una parte significativa de la información original (Chuvienco, 1996; de la Riva, 1997).

La adquisición de imágenes de teledetección sobre bandas adyacentes del espectro implica, con frecuencia, información redundante, puesto que unos mismos tipos de cubierta suelen presentar un comportamiento espectral muy parecido en regiones próximas del espectro electromagnético. En este contexto, el ACP sintetiza las bandas originales dando lugar a otras nuevas, denominadas componentes principales (CP) (Chuvienco, 1996). Esto se consigue a partir de la definición de unos nuevos ejes (y por tanto, de unas nuevas coordenadas) en un espacio n -dimensional mediante la rotación y traslación de los originales de las bandas, de manera que cada uno de los CP recoge información no correlacionada con la de los restantes (anulándose la covarianza), y en cantidad decreciente (el primer componente -CP1- contendrá más información que CP2 y así sucesivamente) (Chuvienco, 1996; de la Riva, 1997; Lillesand y Kiefer, 2000).

La forma de operar para aplicar el ACP de forma individual en cada una de las imágenes es partiendo su respectiva matriz varianza-covarianza, de la que se obtienen los *autovalores* y los *autovectores*²⁷ (Chuvienco, 1996). Esta operación se encuentra incluida en ERDAS Imagine 8.7, siendo necesario indicar el número de CP que se desean obtener. En nuestro caso se eligió crear tantos componentes como bandas se utilizaban para calcularlos, es decir, seis.

Componente	Porcentaje de información original que contienen		
	28 de julio de 1993	29 de junio de 1994	16 de agosto de 1994
CP1	91,19	95,04	95,56
CP2	4,72	3,08	2,27
CP3	3,54	1,39	1,65
CP4	0,42	0,38	0,37
CP5	0,11	0,10	0,12
CP6	0,01	0,01	0,03

Tabla 2.17. Autovalores (porcentaje de información original que contiene cada CP) de las imágenes utilizadas

²⁷ Los autovectores son los coeficientes que indican la ponderación que se aplica a cada una de las bandas originales para obtener el nuevo CP.

Para seleccionar los CP que se utilizarían en la elaboración de los modelos de estimación se tuvo en cuenta la varianza original asociada a cada componente obtenido, es decir, el porcentaje de información original que contienen (*autovalor* o *eigenvalor*); la Tabla 2.17 recoge estos porcentajes para los 6 CP de cada imagen.

Más de un 90% de la información original quedó sintetizada en sus respectivos CP1, siendo también significativa, aunque a gran distancia, la participación de CP2 y CP3 en todas ellas. De acuerdo con el criterio expresado, se seleccionaron los tres primeros CP, obteniéndose de esta forma más del 99% de la información original contenida en cada imagen. La Figura 2.16 muestra los tres primeros CP de la de junio de 1994.

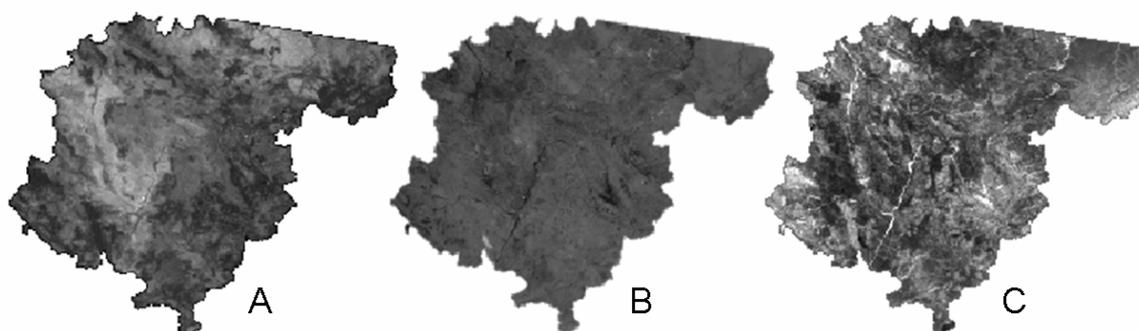


Figura 2.16. Componentes principales seleccionados de la imagen de junio de 1994: A) CP1; B) CP2; C) CP3

2.3.3.2. Transformación Tasseled-Cap

Al igual que el ACP, la *Transformación Tasseled-Cap* (TTC) se dirige hacia la obtención de neocanales por combinación lineal de las bandas originales. Sin embargo, a diferencia de aquella, el resultado de aplicar TTC son unos componentes que sí tienen un significado físico preciso (Chuvieco, 1996; de la Riva, 1997; Lillesand y Kiefer, 2000).

Como se ha visto al comentar la técnica de ACP, las señales recibidas de un sensor se consideran como definidoras de un espacio n -dimensional en el que cada banda se corresponde con una dimensión. El hecho de que las diferentes cubiertas presenten comportamientos característicos (signatura espectral), lleva a suponer que no todas las combinaciones de valores tienen la misma probabilidad de ocurrencia. De esta manera, la información tiende a concentrarse en el espacio multidimensional descrito, generándose unas “estructuras” estrechamente relacionadas con las características físicas de las categorías de la imagen. La TTC define unos nuevos ejes que intentan adoptar la mejor perspectiva para poder observar tales características en la imagen. Los

tres ejes principales son (Chuvieco, 1996; de la Riva, 1997; Lillesand y Kiefer, 2000)²⁸:

- **Brillo** (primer eje, *brightness*): resultado de la suma ponderada de todos los canales reflectivos, expresa la reflectividad global de la imagen.
- **Verdor** (segundo eje, *greenness*): básicamente un contraste entre las bandas visibles (alta absorción por los pigmentos foliares) y el infrarrojo próximo.
- **Humedad** (tercer eje, *wetness*): fruto del contraste entre la suma de las bandas visibles y el infrarrojo próximo, frente al infrarrojo medio.

Los coeficientes específicos para Landsat 5 TM, que fueron aplicados, se presentan en la Tabla 2.18 (Crist *et al.*, 1986). Los tres primeros ejes obtenidos para cada imagen fueron escogidos para ser incorporados como variables independientes en los modelos de estimación de biomasa. La Figura 2.17 representa los ejes de brillo-verdor-humedad de la imagen de junio de 1994, así como su composición RGB.

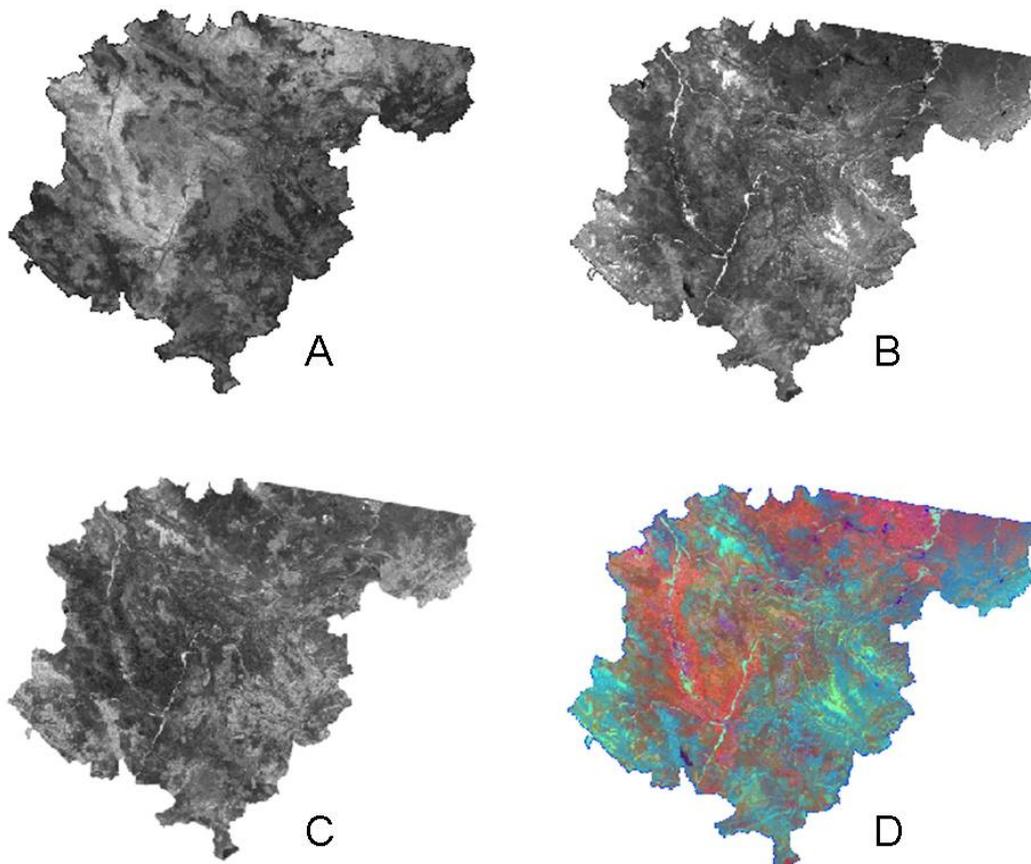


Figura 2.17. Ejes TTC de brillo (A), verdor (B) y humedad (C) y composición RGB TTC de la imagen de junio de 1994 (D)

²⁸ Además de estos tres ejes, la TTC genera otros tres, cuya asociación con características físicas es más compleja, que no se tendrán en cuenta en este trabajo.

Eje	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7	Aditivo
Brillo	0,2909	0,2493	0,4806	0,5568	0,4438	0,1706	10,3695
Verdor	-0,2728	-0,2174	-0,5508	0,7221	0,0733	-0,1648	-0,7310
Humedad	0,1446	0,1761	0,3322	0,3396	-0,6210	-0,4186	-3,3828
Cuarto	0,8461	-0,0731	-0,4640	-0,0032	-0,0492	0,0119	0,7879
Quinto	0,0549	-0,0232	0,0339	-0,1937	0,4162	-0,7823	-2,4750
Sexto	0,1186	-0,8069	0,4094	0,0571	-0,0228	-0,0220	-0,0336

Tabla 2.18. Coeficientes utilizados para la aplicación de la TTC. Fuente: Crist *et al.* (1986)

2.3.3.3. Índices de vegetación

Un índice de vegetación puede definirse como “un parámetro calculado a partir de los valores de la reflectividad a distintas longitudes de onda que pretende extraer de los mismos la información relacionada con la vegetación minimizando la influencia de perturbaciones como las debidas al suelo y a las condiciones atmosféricas” (Gilbert *et al.*, 1997).

La mayoría de los índices de vegetación propuestos en la literatura se basan en el contraste que la signatura espectral de la vegetación presenta entre la zona del rojo (entre 0,6 y 0,7 μm) y la del infrarrojo cercano (entre 0,7 y 1,3 μm). Esto se debe a que la vegetación verde o sana presenta un mínimo relativo de reflectividad en el rojo debido a la absorción de la clorofila y un máximo absoluto en el infrarrojo cercano, consecuencia de las dispersiones de la radiación por el interior de la estructura celular. Este contraste espectral permite separar, de forma relativamente clara, la vegetación sana de otras cubiertas como, por ejemplo, el suelo, ya que aunque el suelo también presenta una tendencia ascendente entre estas dos partes del espectro electromagnético, ésta es mucho más suave. Además, este contraste también permite estudiar la dinámica de la vegetación dado que, cuando la vegetación sufre algún tipo de daño (sequía, plagas, etc.), la reflectividad en el rojo aumenta y la del infrarrojo próximo desciende, por lo que la diferencia es menor. De esta manera, se asume que altos contrastes de reflectividad entre las bandas roja e infrarroja corresponden a zonas de alto vigor vegetal, siendo bajos contrastes indicativos de escasa actividad vegetal; en las cubiertas sin vegetación este contraste prácticamente desaparece (Chuvienco *et al.*, 1996; Gilbert *et al.*, 1997).

Entre los índices de vegetación más empleados destaca el NDVI (Ecuación 31), que ha sido profusamente utilizado en la estimación de diversos parámetros de la cubierta vegetal (biomasa, LAI, porcentaje de cubierta verde, flujo neto de CO₂, productividad neta de la vegetación...), lo que le confiere un papel destacado de cara a la

evaluación ambiental considerando un enfoque global (Chuvienco, 1996). Sin embargo, la influencia que el suelo presenta en este índice, sobre todo en medios semiáridos, ha llevado a la formulación de otros semejantes que intentan corregir esta circunstancia, destacando el SAVI (*Soil Adjusted Vegetation Index*) (Huete, 1988) y otra serie de índices derivados de este último²⁹: TSAVI (*Transformed Soil Adjusted Vegetation Index*; Baret y Guyot, 1991), MSAVI (*Modified Soil Adjusted Vegetation Index*; Qi, et al., 1994), OSAVI (*Optimized Soil Adjusted Vegetation Index*; Rondeaux et al., 1996).

Además de los índices de vegetación basados en el contraste entre el rojo y el infrarrojo próximo, existen otros que se basan en la utilización de combinaciones de otras bandas como, por ejemplo, los que se sirven del infrarrojo medio, que son útiles para estudiar la variación en el contenido de agua de las hojas y, por tanto, del estrés hídrico (Chuvienco, 1996) o los que emplean la banda del verde en lugar de la del infrarrojo cercano, que muestran una mejor sensibilidad para la estimación de porcentaje de cubierta vegetal en situaciones de recubrimiento medio o alto (Gitelson et al., 2002).

El uso de los índices de vegetación para la estimación de biomasa es recurrente en la bibliografía, siendo el NDVI el más utilizado de todos ellos (p.e. Roy y Ravan, 1996; Todd et al., 1998; Foody et al., 2001; Foody et al., 2003; Labrecque et al., 2003; Mallinis et al., 2004; Lu et al., 2004; Zheng et al., 2004; Mutanga y Skidmore, 2004; Labrecque et al., 2006). La revisión de estos trabajos muestra una gran disparidad en los resultados, tanto en las estimaciones obtenidas, como en los índices utilizados para ello. Teniendo en cuenta esta circunstancia, la elección de los índices seleccionados para ser empleados como variables independientes respondió a un doble criterio:

- En primer lugar se seleccionaron índices comúnmente utilizados en trabajos enfocados a la estimación de parámetros de la cubierta vegetal en general. Bajo este criterio se introdujeron el NDVI, distintos índices de la familia SAVI (SAVI, MSAVI, OSAVI, GESAVI –*Generalized Soil-Adjusted Vegetación Index*; Gilabert et al., 2002), el MSI (*Moisture Stress Index*; Rock et al., 1986) y el *VI green* (*Vegetation Index green*; Gitelson et al., 2002).
- En segundo lugar se seleccionaron otros índices menos recurrentes en la bibliografía, pero que se han mostrado altamente significativos a la hora de

²⁹ Los índices obtenidos a partir de las modificaciones de SAVI se denominan comúnmente como “índices de la familia SAVI” (Gilabert et al., 1997).

estimar la variable biomasa forestal, utilizando para ello el trabajo de Lu *et al.* (2004). Estos autores se valieron de un elevado número de índices de vegetación derivados de imágenes Landsat para estudiar cuáles presentaban relaciones significativas con la biomasa en tres áreas distintas de la cuenca del Amazonas. Concluyeron que, además de los primeros componentes de ACP y TTC, sólo los índices obtenidos a partir de la suma de las bandas del visible (VIS123), de las bandas del infrarrojo medio (MID57) y de la suma de todas ellas (ALBEDO) generaban altas correlaciones significativas ($p < 0,05$). Por la solidez mostrada en la estimación de biomasa –aunque en ámbito tropical- se seleccionaron estos tres índices para nuestro estudio.

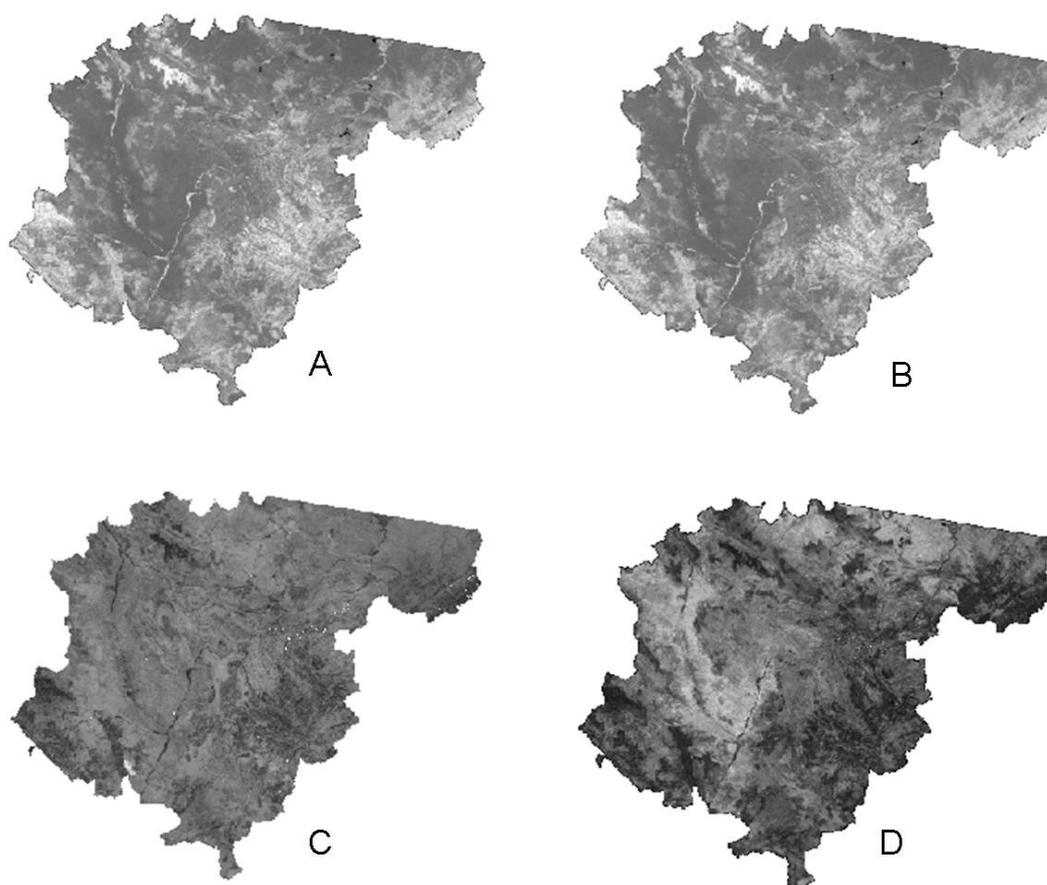


Figura 2.18. Distintos índices de vegetación obtenidos de la imagen de junio de 1994: (A) NDVI; (B) SAVI; (C) MSI; y (D) MID57

La Tabla 2.19 recoge las expresiones matemáticas de cada uno de los índices de vegetación seleccionados en su adaptación a las bandas Landsat. La Figura 2.18 muestra cuatro de estos índices obtenidos con la imagen de junio de 1994.

Índice	Expresiones matemáticas
NDVI	$(B4 - B3) / (B4 + B3)$
SAVI ³⁰	$((B4 - B3) / (B4 + B3 + L)) * (1 + L)$
MSAVI	$(2 * B4 + 1 - ((2 * B4 + 1)^2 - 8 (B4 - B3))^{1/2}) / 2$
OSAVI ³¹	$(TM4 - TM3) / (TM4 + TM3 + Y)$
GESAVI ³²	$(B4 - b * B3 - a) / (B3 + Z)$
VI green	$(B2 - B3) / (B2 + B3)$
MSI	$B5 / B4$
VIS123	$B1 + B2 + B3$
MID57	$B5 + B7$
ALBEDO	$B1 + B2 + B3 + B4 + B5 + B7$

Tabla 2.19. Índices de vegetación calculados

2.4. Obtención de la información radiométrica de las imágenes radar

Tal y como se ha señalado en el primer capítulo, las imágenes radar utilizadas para cumplir el objetivo de la presente tesis fueron las proporcionadas por el sensor ASAR, situado en la plataforma satelital Envisat, en banda C. Al igual que las ópticas, estas imágenes fueron sometidas a una serie de pretratamientos, necesarios para obtener correctamente la variable que va a ser relacionada con la información de biomasa residual forestal, en este caso, el coeficiente de retrodispersión. En las siguientes páginas se presentan las características generales y particulares de las imágenes utilizadas.

2.4.1. Características de las imágenes radar empleadas

Las nueve imágenes radar utilizadas fueron adquiridas por el sensor ASAR del satélite Envisat. Las características generales de las mismas dependen directamente de esta plataforma y de este sensor

2.4.1.1. Características generales

2.4.1.1.1. El satélite Envisat

Envisat (*Environmental satellite*) es resultado del proyecto de observación de la Tierra más ambicioso de la Agencia Espacial Europea (ESA – *European Space Agency*).

³⁰ L = 0,5, valor adecuado para densidades de vegetación intermedias (Gilabert *et al.*, 1997, 2002).

³¹ Y = 0,16, recomendado para densidades de vegetación intermedias (Gilabert *et al.*, 1997, 2002).

³² Z = 0,35, óptimo para normalizar el efecto del suelo en un amplio rango de situaciones de distinta densidad de cubierta vegetal (Gilabert *et al.*, 2002).

Lanzado en marzo de 2002, además de continuar con las observaciones de los satélites de esta agencia -ERS (*European Remote Sensing Satellite*) y ERS-2, puestos en órbita en 1991 y en 1995, respectivamente- pretendió poner a Europa en la vanguardia de las misiones de observación global (Chuvienco, 2002; ESA, 2009). Para ello, Envisat fue equipado con un total de 10 instrumentos dedicados a obtener información sobre la superficie terrestre, los océanos y la atmósfera, entre los cuales está ASAR (*Advanced Synthetic Aperture Radar*), sensor activo radar que opera en banda C y que fue pensado para asegurar la continuidad de las imágenes SAR y los datos de velocidad y dirección del viento en el océano proporcionados por el sensor AMI (*Active Microwave Instrument*), que equipaban ERS y ERS-2³³.

La simple descripción de los dispositivos con los que está equipado Envisat da idea de la cantidad de aplicaciones, investigaciones y trabajos que se han llevado a cabo en los últimos años con datos obtenidos por este satélite, constituyendo una de las herramientas básicas para el estudio científico del cambio climático o calentamiento global (ESA, 2009).

2.4.1.1.2. Características orbitales de Envisat

Envisat opera en una órbita heliosincrónica polar levemente inclinada (98,55°) a 800 km de altitud media; su periodo orbital es de 100,59 minutos y el ciclo de repetición de la órbita de referencia es de 35 días, si bien, con los sensores situados a bordo de mayor amplitud de observación, se consigue una cobertura completa de todo el planeta en un periodo de 1 a 3 días. La retícula de recubrimiento sobre la superficie del planeta

33 Otros instrumentos a bordo de ENVISAT (ESA, 2009):

- MERIS (*ME*diuM *R*esolution *I*maging *S*pectrometer): Sensor hiperespectral con rango de observación de 390 a los 1040 nm y 15 bandas con una anchura variable entre los 2,5 y 30 nm.
- AATSR (*A*dvanced *A*long *T*rack *S*canning *R*adiometer): Equipo de barrido térmico para la temperatura del mar con precisión mínima de 0,3 K, continuación de ATSR-1 -2 de ERS-1 y -2.
- RA-2 (*R*adar *A*ltimeTer 2): Radar activo de doble frecuencia (Ku y S) para el estudio de la topografía marina y terrestre, los vientos y cartografiar y monitorear el hielo marino.
- MWR (*M*icrowave *R*adiometer): Radiómetro de microondas para la medición de la columna de vapor de agua en la atmósfera y el contenido de agua en las nubes.
- GOMOS (*G*lobal *O*zone *M*onitoring *b*y *O*ccultation *o*f *S*tars): Para el estudio de los componentes atmosféricos, con bandas espectrales en 250-675 nm, 756-773 nm y 926-952 nm.
- SCIAMACHY (*S*canning *I*maging *A*bsorption *s*pectro*M*eter for *A*tmospheric *C*hartography): Espectrómetro para medir los gases que constituyen <1% del volumen total atmosférico.
- MIPAS (*M*ichelson *I*nterferometer for *P*assive *A*tmospheric *S*ounding): Espectrómetro de alta resolución para la medición de la emisión de gases, que opera en el infrarrojo medio.
- DORIS (*D*oppler *O*rbitalography and *R*adiopositioning *I*ntegrated by *S*atellite): sistema localizador de microondas utilizado para determinar la localización precisa de la plataforma ENVISAT.
- LRR (*L*aser *R*etro-*R*eflector): instrumento para determinar de forma precisa la órbita del satélite y para la calibración de los datos tomados con RA-2.

sigue el mismo patrón que el establecido para ERS y ERS-2, con lo que se garantiza la continuación de la serie multitemporal de datos iniciada por estos satélites.

2.4.1.1.3. Toma de datos con el sensor ASAR

Como se ha indicado con anterioridad, el sensor ASAR pertenece al grupo de los sensores activos, denominados así por su capacidad de emitir un haz de energía que, con posterioridad, es recogido por ellos mismos tras su reflexión sobre la superficie de la Tierra. Dentro de esta categoría, el sensor ASAR pertenece a los sistemas radar, debido a que el haz de energía emitido se encuentra en la región de las micro-ondas, comprendida entre 0,1 cm y 1 m (Lillesand y Kiefer, 2000; Chuvieco, 2002). Una última característica, contenida en su nombre, es que se trata de un radar de apertura sintética (SAR, *Synthetic Aperture Radar*).

El principal problema de los sistemas radar es que la resolución de las imágenes depende directamente del tamaño de la antena, estando esta relación controlada por la expresión de la Ecuación 32. Así, por ejemplo, la resolución espacial de un sensor con una longitud de antena de 20 m que opera con una longitud de onda de 3 cm (banda X) a bordo de un satélite a una altitud media de 800 km sería de 1200 m. Para conseguir imágenes de resolución media, con píxeles entre los 10 y los 100 m, serían necesarias antenas de inmensas proporciones, lo que resulta del todo inviable. La solución pensada a este problema tiene su fundamento en el efecto *Doppler*, que establece que, cuando existe un movimiento relativo entre la fuente de ondas y el objeto observado, la frecuencia de las ondas observadas es diferente a la frecuencia de las emitidas. Basándose en este principio, los SAR registran los ecos del haz energético reflejado de un mismo punto en dos momentos diferentes de la trayectoria, con lo que la resolución obtenida es la misma que la que se obtendría con una antena de un tamaño equivalente a la distancia existente entre esos dos momentos. De esta manera, siguiendo la Ecuación 32 y suponiendo una distancia de 1200 m entre los dos momentos diferentes en que se registra el eco recibido del mismo punto, la resolución espacial lograda sería de 10 m (Henderson y Lewis, 1998; Lillesand y Kiefer, 2000; Chuvieco, 2002).

$$R_{\text{espacial}} = \frac{A_0 \cdot \lambda}{L} \quad \text{Ecuación 32}$$

donde R_{espacial} es la resolución del píxel de la imagen obtenida, A_0 es la altura orbital, λ es la longitud de onda del flujo energético emitido y L es la longitud de la antena (adaptado de Henderson y Lewis, 1998).

El flujo de energía es emitido por los sensores radar con una amplitud y fase controlada en una longitud de onda y una polarización determinadas. Este flujo atraviesa la atmósfera, siendo ésta transparente (en general) a estas longitudes de onda y, al llegar a la superficie observada, se dispersa dentro del objeto-superficie observado o se refleja hacia la atmósfera. El sensor recoge la parte de la energía que es reflejada en su dirección en diferentes momentos, que recibe el nombre de coeficiente de retrodispersión (*backscatter coefficient*), versión modificada del pulso transmitido debido a la interacción con la superficie terrestre (menos energía, diferente polarización, etc.). El sensor mide la cantidad de energía y sus características, así como el tiempo transcurrido entre la emisión y la recepción, información empleada para formar imágenes, con lo que el contenido de las mismas se relaciona con las características de dispersión de los objetos-superficies y su distancia al sensor (Henderson y Lewis, 1998; Lillesand y Kiefer, 2000; Woodhouse, 2006).

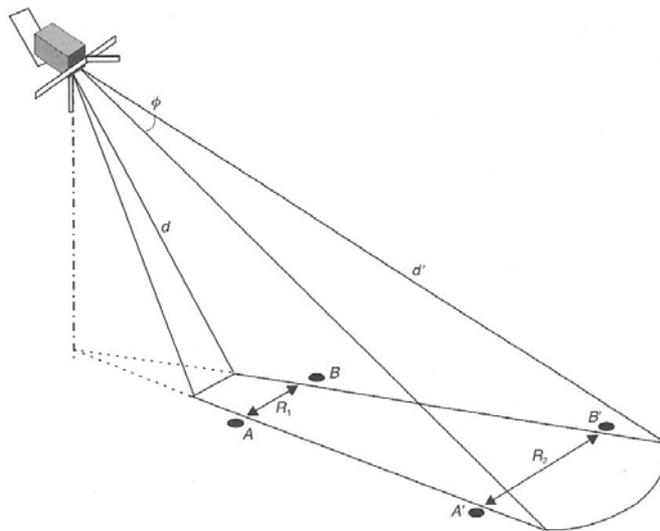


Figura 2.19. Resolución en el acimut en la misma línea de observación. Fuente: Chuvieco (2002)

Los sensores radar observan la superficie terrestre siempre de forma lateral. Este hecho determina dos de las características principales de estas imágenes (Henderson y Lewis, 1998; Lillesand y Kiefer, 2000; Chuvieco, 2002):

- La resolución espacial es distinta en la dirección paralela a la trayectoria de la plataforma (denominada acimut, *azimuth*) que la obtenida en la perpendicular (denominada como distancia en profundidad, *range*). En el caso de la resolución en acimut, la anchura horizontal del haz emitido y la distancia entre

la antena y la superficie determinan la distancia mínima en el terreno para que dos objetos se diferencien en la imagen resultante (Figura 2.19). Por ello, y dado que la distancia objeto-antena cambia desde el extremo más cercano de la superficie observada hasta el más lejano, la resolución del píxel varía a lo largo de una misma línea de observación. Por tanto, son necesarias correcciones posteriores sobre los datos adquiridos para homogeneizar el tamaño de píxel en este vector.

La resolución en profundidad está relacionada con la duración de los pulsos energéticos emitidos. Para que dos objetos puedan ser diferenciados en la imagen resultante, la distancia en el terreno entre ellos ha de ser superior a la mitad de la longitud del pulso. Asimismo, hay que considerar que la distancia aparente al radar entre los objetos está en relación directa con el ángulo de incidencia (θ) (Figura 2.20).

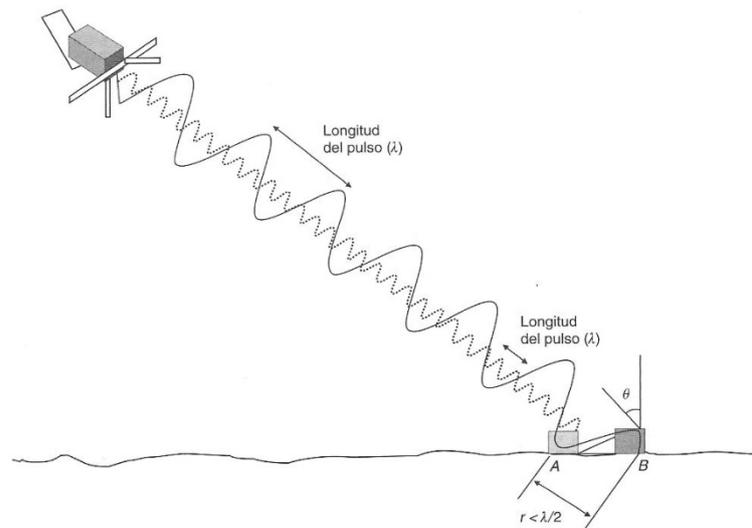


Figura 2.20. Resolución en profundidad. Fuente: Chuvieco (2002)

- Las imágenes obtenidas presentan importantes deformaciones geométricas debido a las variaciones que la pendiente y la orientación introducen en el ángulo de incidencia local del pulso; por ello, la superficie que se obtiene en la imagen no coincide con la real. Son tres los efectos del relieve:
 - o Efecto de recorte (*foreshortening*). Dado que en las imágenes radar se muestran las distancias entre la antena y el objeto, cuando la pendiente del terreno es menor que el ángulo de incidencia la imagen ofrece

como acortadas las distancias reales. Ello hace que en la imagen las vertientes orientadas hacia la antena aparezcan como inclinadas en esa dirección, dando un aspecto de compresión de las características topográficas de la escena (Figura 2.21(A)).

- Efecto de repliegue (*layover*). Es el caso extremo del efecto de recorte, que se produce cuando el ángulo de incidencia es mucho menor que la pendiente topográfica. Esta situación, propia de relieves extremos, provoca una “inversión” del relieve debido a que el eco procedente de la parte superior de la ladera llega antes que el de la base, generándose en la imagen resultante una modificación de la posición real de los objetos-superficies (Figura 2.21(B)).
- Efecto de sombra (*shadow*). Refiere a las zonas que no han sido iluminadas con el flujo energético del radar y se produce en las laderas opuestas a la dirección de observación del radar; su importancia está en función directa de la altitud del terreno y del ángulo de incidencia. Dependiendo de estos dos parámetros la respuesta de estas vertientes tiene un coeficiente de retrodispersión más o menos bajo, llegando a ser nulo en situaciones extremas (Figura 2.21(C)).

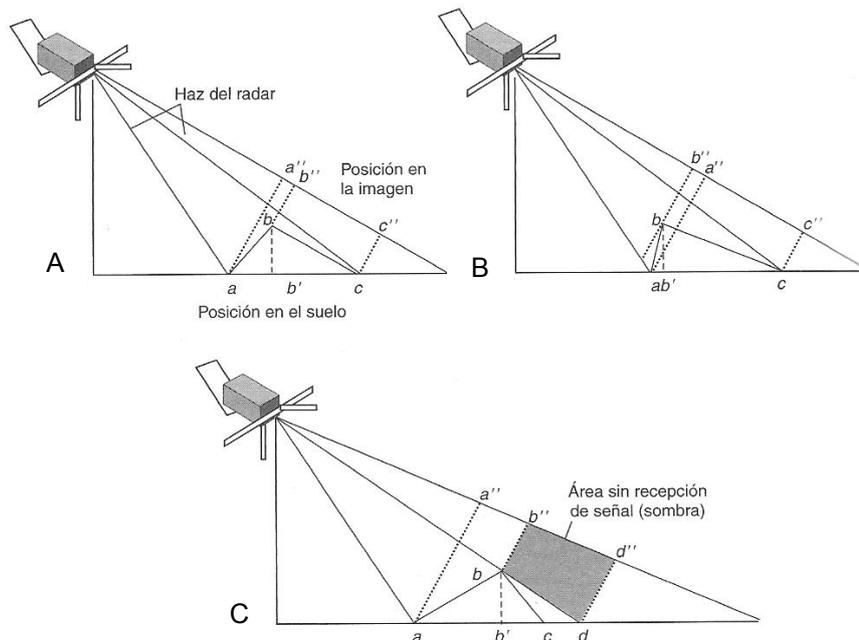


Figura 2.21. Efectos del relieve que deforman la imagen radar: (A) efecto de recorte; (B) efecto de repliegue; (C) efecto de sombra. Fuente: Chuvieco (2002)

Estas deformaciones, además de modificar la posición real de los elementos de la superficie en la imagen, también modifican el valor de la señal devuelta, haciendo que una superficie homogénea presente distintos valores según sea la posición relativa de cada uno de sus sectores con respecto al pulso radar. Así, por ejemplo, la Figura 2.22 modela las distorsiones que se producen en el coeficiente de retrodispersión de las laderas homogéneas de un volcán debidas a su diferente posición respecto del sensor.

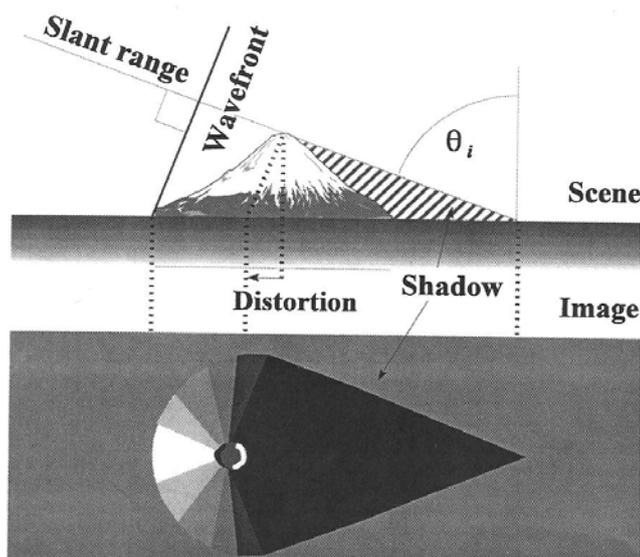


Figura 2.22. Variación del coeficiente de retrodispersión de un área homogénea debido a la topografía. Fuente: Henderson y Lewis (1998)

Los efectos de recorte y de repliegue pueden corregirse con posterioridad a la formación de la imagen mediante la utilización de un MDE preciso y de la misma resolución espacial en el denominado proceso de normalización topográfica. La corrección del efecto de sombra requiere imágenes de la misma zona y sensor con ángulos de observación distintos, que -como en el caso de ASAR- suelen ser proporcionadas mediante pasadas ascendente y descendente sobre el mismo lugar.

Además de estos dos factores principales, existen otros que también determinan el coeficiente de retrodispersión que finalmente se obtiene en cada uno de los píxeles de las imágenes radar. Estos factores se pueden clasificar en dos grupos, dependiendo de si están relacionados con las características del sensor o con las del los objeto-superficie observado, si bien todos están íntimamente interrelacionados (Henderson y Lewis, 1998; Lillesand y Kiefer, 2000). A continuación se describen brevemente estos factores:

(i) Parámetros relacionados con el sensor:

- Frecuencia/longitud de onda. Determina aspectos varios como la capacidad de la señal para atravesar la lluvia, la profundidad de la penetración del flujo energético en el suelo o en la vegetación, qué sensibilidad tiene a la rugosidad de la superficie, qué componente de los árboles contribuye más al coeficiente de retrodispersión, etc. (Tabla 2.20). En general, la selección de una u otra banda para abordar un trabajo se debe basar en la correspondencia del tamaño de las ondas con las dimensiones de los materiales a estudiar.

Denominación	Anchura (en cm)		Valor típico (en cm)	Anchura (GHz)	
Ka	0,75	1,10			
K	1,10	1,67	1,0	10,9	36
Ku	1,67	2,40			
X	2,40	3,75	3,0	5,75	10,90
C	3,75	7,50	5,6	3,90	5,75
S	7,50	15,00	10,0	1,55	3,90
L	15,00	30,00	23,0	0,39	1,55
P	30,00	100,00		>0,39	

Tabla 2.20. Bandas de frecuencia normalmente utilizadas en la región de las micro-ondas. Fuente: Chuvieco (2002)

- Polarización. La señal puede ser transmitida y recibida en diferentes polarizaciones, siendo las más comunes la vertical (V) y la horizontal (H). Para conseguir esta polarización la señal se filtra para que el plano de vibración sea sólo uno. Teniendo en cuenta el filtrado que se hace sobre las ondas emitidas y sobre las recibidas, hay cuatro combinaciones posibles: polarización semejante (HH y VV) y cruzada (HV y VH); si bien es posible conjugarlas (por ejemplo VV/HH o HV/HH). Las ondas polarizadas verticalmente interactúan con los elementos dispuestos en la vertical y viceversa. Las polarizaciones cruzadas son sensibles al volumen del reflector de interés y pueden serlo menos a los efectos de los surcos o hileras de siembra de la vegetación.
- Ángulo de incidencia (θ). Refiere al ángulo formado entre el vector de emisión del radar y la normal de la superficie de la Tierra. Dependiendo de la altura del radar sobre ésta, el ángulo de incidencia cambia a lo largo de la dirección del alcance. Por lo tanto, la geometría de visualización en una misma imagen es diferente de punto a punto en la dirección del alcance; además, la retrodifusión

difusa disminuye con el incremento de este ángulo. Otro efecto importante es qué objeto-superficie contribuye más al coeficiente de retrodifusión; así, por ejemplo, en una superficie boscosa observada con ángulos grandes, el principal elemento difusor será el follaje y las ramas, mientras que con ángulos pequeños la contribución del suelo será la más importante.

- Altura del sensor: condiciona la resolución espacial.

(ii) Parámetros relacionados con el objeto-superficie observado:

- Rugosidad de la superficie. Determina cómo se produce la reflexión de la onda radar en el terreno. Para definir si una superficie es rugosa o no a una determinada longitud de onda y con un determinado ángulo de incidencia se utiliza el criterio de Rayleigh. Cuando la rugosidad es pequeña o nula (lisa), se produce una reflexión de la onda especular con respecto a la dirección a la que ha llegado, por lo que el radar no registra información (sombra). Conforme aumenta la rugosidad, las ondas se reflejan en otras direcciones diferentes a la especular, siendo una de ellas la de la antena radar, por lo que se obtiene información de la retrodifusión. En general, a menor longitud de onda y menor ángulo de incidencia, menor probabilidad de que la superficie observada resulte especular, y viceversa.
- Constante dieléctrica. La propagación de las ondas electromagnéticas depende de la permeabilidad magnética y eléctrica del medio; la primera es la misma para todos los tipos de objetivos de interés para las aplicaciones radar; la segunda varía de un medio a otro y, además, para el mismo medio en función de la humedad. En este contexto, la constante dieléctrica (o permeabilidad compleja) es la descripción de la respuesta del medio a la existencia del campo eléctrico. En general, debido a esa constante, los materiales secos tienen una menor respuesta retrodifusora y en ellos la onda radar tiene una mayor capacidad de penetración que en los húmedos; por ello la vegetación con gran contenido de agua tiene alto potencial de retrodifusión.
- Geometría de la superficie. La pendiente y la orientación del terreno respecto al sensor radar modifica el ángulo de incidencia, lo que provoca los efectos de recorte, repliegue y sombra en las imágenes resultantes que, a su vez, modifican el coeficiente de retrodispersión dentro de áreas homogéneas.

Un último aspecto a subrayar que siempre está presente en las imágenes radar es el *speckle* (moteado), resultado de la interferencia coherente (constructiva y destructiva) de las ondas retrodispersadas de manera individual por los elementos del terreno, por lo que modula, de forma aleatoria, la intensidad de la señal de cada uno de los píxeles que componen la imagen (Henderson y Lewis, 1998). Este efecto da a las imágenes radar una característica apariencia granular de tipo “sal y pimienta”. Uno de los aspectos más importantes del *speckle* es que varía el coeficiente de retrodispersión de los píxeles que compone una superficie homogénea, como, por ejemplo, una superficie agrícola de gran extensión en barbecho, por lo que su suavizado es una tarea imprescindible. Para ello, deben aplicarse sobre la imagen filtros capaces de promediar las áreas relativamente homogéneas y de conservar las zonas de borde entre estas áreas (Woodhouse, 2006).

Comentadas todas estas características inherentes a los sensores de tipo SAR, señalar los parámetros específicos de ASAR. Este sensor, en modo imagen (*Image Mode –IM-*), trabaja en banda C (5,331 GHz), con polarización semejante VV o HH. El ángulo de incidencia varía dependiendo de la distancia del sensor con la franja de superficie terrestre observada (hasta 7 franjas perpendiculares a la dirección de la órbita), presentando un rango que varía de 15° a 45°. El área cubierta en cada escena también varía dependiendo de la franja observada: de algo más de 100 km de lado en la más cercana (con ángulos de incidencia de entre 14° y 22°), hasta unos 57 km de lado en la más lejana (ángulos de incidencia entre 42° y 45°). La resolución espacial de todas las escenas es de 30 m. Al igual que los sensores SAR con los que iba equipado ERS, debido a que el flujo de datos es muy elevado, sólo se emplea en modo imagen cuando se encuentra en zonas cubiertas por alguna antena de recepción terrestre. Una última característica a destacar es que sólo puede activarse en este modo durante un periodo de su órbita, concretamente durante algo más de 30 minutos (ESA, 2009).

2.4.1.1.4. Información de utilidad forestal proporcionada por el sensor ASAR

La utilidad del sensor ASAR en modo imagen para aplicaciones forestales se debe a la mencionada interacción que se produce entre las ondas radar emitidas en banda C y los elementos más pequeños de los árboles, es decir, las hojas y ramas que componen las copas. Así, las imágenes ASAR permiten continuar las líneas de trabajo de ámbito forestal iniciadas desde hace más de 15 años con los primeros sensores satelitales que operaban con esta banda como, por ejemplo, la delimitación de superficies forestales, la detección y seguimiento de zonas de corta y de áreas quemadas y la estimación de algunos parámetros forestales continuos, entre los que se encuentra la biomasa. Del

mismo modo, la utilización de imágenes ASAR en combinación con las de ERS-2 permite la aplicación de técnicas interferométricas para la estimación de biomasa, dada la relación inversa existente entre la cantidad de biomasa y la coherencia calculada con un par de imágenes SAR tomadas casi desde la misma posición y con un escaso intervalo temporal (Le Toan *et al.*, 2002,, 2004).

En este contexto, la principal aportación de ASAR en el ámbito de las aplicaciones forestales reside en las novedades técnicas que presenta respecto a sus antecesores en banda C situados sobre plataformas satelitales, como son la posibilidad de utilizar un amplio rango de ángulos de incidencia y la de obtener información multipolarimétrica. Así, la capacidad de ASAR de adquirir información a menores ángulos de incidencia que los anteriores sensores mejora la posibilidad de estimar la biomasa total presente en un bosque debido a que las ondas tienen mayor capacidad de penetración, mientras que el uso de ángulos mayores, por el efecto contrario, mejora la posibilidad de cartografiar zonas deforestadas. Por su parte, el hecho de obtener el coeficiente de retrodispersión de la misma zona en VV y en HH mejora la capacidad de discriminar entre diferentes tipos de bosque (ESA, 2009).

2.4.1.2. Características particulares de las imágenes utilizadas

Como se ha indicado, las 9 imágenes ASAR utilizadas fueron proporcionadas por CESBIO, que las obtuvo de forma gratuita de la ESA gracias a la existencia de un acuerdo de colaboración entre las dos instituciones. Dos fueron las razones por las que el personal de CESBIO decidió considerar este elevado número de imágenes: porque las escenas ASAR no cubren de forma individual la totalidad del territorio turolense y porque en el momento de realización de la estancia de investigación en CESBIO no era posible aplicar procesos de normalización topográfica sobre las imágenes radar. Con la utilización de varias escenas se pretendía, por un lado, abarcar la mayor parte posible del área de estudio y, por otro, considerar distintos ángulos de incidencia locales que permitiera utilizar el mayor número de parcelas posibles que en la imagen quedaran libres de las deformaciones geométricas introducidas por el relieve.

Las imágenes utilizadas fueron registradas en 2003, concretamente entre los meses de marzo y noviembre. Como recoge la Tabla 2.21, 5 de estas imágenes corresponden a pasadas ascendentes y 4 a descendentes, siendo 4 las orbitas (*track*) y 3 las filas de observación (*frame*) involucradas. Con independencia de la órbita utilizada, la franja perpendicular de superficie terrestre observada (*swath*) en todas estas imágenes

se corresponde con la segunda más cercana de las 7 posibles, lo que supone que cada una de ellas cubre un área de 107 km de lado, siendo el ángulo de incidencia en la parte más cercana a la órbita de 18,4° y en la más alejada de 26,2° (ESA, 2009). La polarización en todas las escenas es VV. La Figura 2.23 recoge la posición de cada una con respecto al área de estudio.

Imagen	Fecha de registro	Sentido de la órbita	Órbita (track)	Fila (frame)	Franja de observación (swath)
20030325	25 de marzo	Descendente	8	2781	2
20030505	5 de mayo	Ascendente	101	801	2
20030619	19 de junio	Descendente	237	2799	2
20030708	8 de julio	Descendente	8	2799	2
20030802	2 de agosto	Ascendente	373	801	2
20030818	18 de agosto	Ascendente	101	801	2
20031002	2 de octubre	Descendente	237	2799	2
20031011	11 de octubre	Ascendente	373	801	2
20031115	15 de noviembre	Ascendente	373	801	2

Tabla 2.21. Características de las imágenes ASAR utilizadas

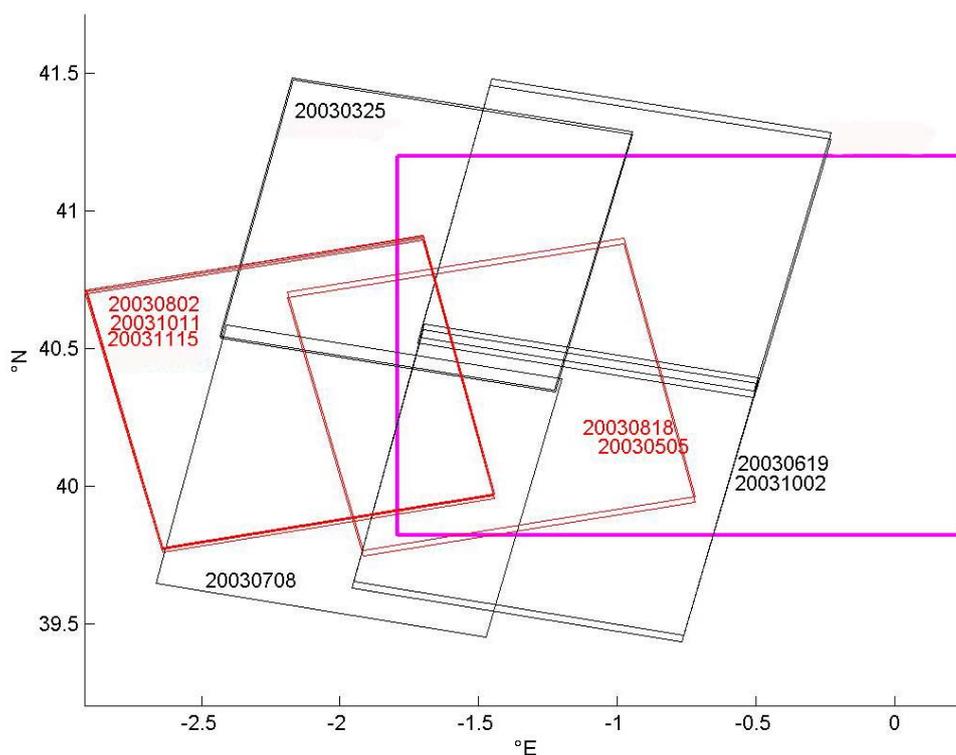


Figura 2.23. Localización de las imágenes ASAR utilizadas (en rojo las de órbita ascendente y en negro las de órbita descendente) respecto al área de estudio (en rosa)

Las imágenes fueron proporcionadas por la ESA en formato *ASAR Image Mode Precision Image* (ASA_IMP_1P). Este formato de procesado está pensado para ser utilizado directamente por la mayoría expertos de los distintos ámbitos de aplicación en los que la banda C ha mostrado su utilidad para realizar análisis espaciales concretos o multitemporales a partir del uso del coeficiente de retrodispersión. Este nivel de procesamiento implica que los datos captados por el sensor en modo imagen (*Imagen Mode*) han sido objeto de una serie de pretratamientos (ESA, 2009):

- **Procesamiento multi-look:** Pretratamiento destinado a reducir el *speckle*. Esto se consigue promediando diferentes sub-imágenes (*looks*) generadas durante el procesado SAR de la escena completa. Estas sub-imágenes se obtienen en la dirección del acimut dividiendo la señal en vez de utilizar toda la amplitud de observación del SAR en esa dirección. De esta manera, se obtienen varias observaciones independientes sobre cada punto del terreno. Así, la reducción del *speckle* en la imagen resultante es proporcional al número de sub-imágenes usadas, aunque siempre queda algo de varianza ligada a este efecto (Henderson y Lewis, 1998; Woodhouse, 2006).
- **Calibración radiométrica relativa:** En este pretratamiento se aplica el algoritmo de procesamiento alcance/*Doppler* mediante el cual el coeficiente de retrodispersión de la imagen se corrige teniendo en cuenta el patrón de la antena y la pérdida de potencia en el alcance. Para ello se hace uso de los parámetros auxiliares tomados en el momento de adquisición de la imagen, referentes a la posición relativa de la antena, y de una serie de algoritmos estandarizados para compensar las fuentes de variabilidad conocidas del sistema. El resultado es una imagen expresada en coordenadas terreno.

Dada la imposibilidad de realizar el proceso de normalización topográfica que hubiera permitido eliminar las deformaciones geométricas introducidas por la visión lateral del sensor ASAR, tras los pretratamientos anteriores, los dos únicos que restan por aplicar a cada una de las imágenes adquiridas son la calibración radiométrica absoluta - que permite la utilización de la información de retrodispersión en el establecimiento de modelos biofísicos- y la georreferenciación, que garantizara la correcta relación entre los valores de biomasa residual de las parcelas y el coeficiente de retrodispersión.

2.4.2. Aplicación de pretratamientos: calibración radiométrica absoluta y georreferenciación

La calibración absoluta y la georreferenciación de imágenes SAR son procesos laboriosos y complejos que requieren, para ser aplicados correctamente, de una rigurosa formación teórica y práctica. Dada la importancia de estos pretratamiento en la bondad de los resultados y la brevedad de la estancia realizada en CESBIO, este proceso fue aplicado bajo la supervisión directa de personal de este centro de investigación, concretamente por Alexandre Bouvet, Ingeniero Superior de Aeronáutica Espacial. El presente apartado apenas contiene una descripción de los fundamentos y los pasos principales a considerar en estos pretratamientos. El programa utilizado fue GAMMA, un software modular de alta calidad creado específicamente para el procesado completo de datos SAR (http://www.gamma-rs.ch/no_cache/software.html).

2.4.2.1. Calibración radiométrica absoluta

A pesar de que las imágenes resultantes del proceso de calibración relativa aplicado por la ESA están en coordenadas terreno, el coeficiente de retrodispersión de estas imágenes está expresado sobre la dirección del alcance (brillo), por lo que hay que normalizarlo por la unidad de superficie sobre el terreno. Para ello es necesario tener en cuenta la constante de calibración –proporcionada en los ficheros de cabecera de cada imagen- y el ángulo de incidencia en la mitad de la escena, que depende de franja perpendicular de superficie terrestre considerada al registrar la imagen (*swath*). Ambos parámetros se relacionan mediante la siguiente expresión:

$$\sigma^0(dB) = 10\log(DN^2) - 10\log(K \cdot \sin\theta) \quad \text{Ecuación 33}$$

donde σ^0 es el coeficiente de retrodispersión normalizado por unidad de superficie sobre el terreno en la horizontal (expresado en decibelios –dB), DN es el brillo de la imagen, K es la constante de calibración (expresada en dB)³⁴ y θ es el ángulo de incidencia medio de la escena³⁵ (Bouvet, comunicación verbal).

De esta manera σ^0 , que es la medida comúnmente usada como medida de “reflectividad” en los trabajos que hacen uso de imágenes radar, es la fracción que describe la cantidad media de energía retrodispersada con respecto a la señal emitida. A

³⁴ La contante de calibración de todas las escenas fue 54,429 dB.

³⁵ El ángulo de incidencia medio de todas las escenas fue 23°.

este respecto, es necesario subrayar que, al estar normalizada respecto a la unidad de área sobre el plano de superficie horizontal, su valor sigue estando influenciado por la pendiente de la superficie respecto al sensor radar (Henderson y Lewis, 1998; Woodhouse, 2006).

2.4.2.2. Georreferenciación de las imágenes radar

La georreferenciación de una imagen SAR, al igual que en las ópticas, consiste en la transformación de la imagen de coordenadas fichero (fila/columna) a una proyección cartográfica; para ello, dada la gran influencia que tiene la topografía en el coeficiente de retrodispersión, se recomienda utilizar un MDE (Henderson y Lewis, 1998). Esta transformación puede hacerse mediante el método de los puntos de control considerado en el apartado dedicado a la corrección geométrica de las imágenes Landsat. Sin embargo, el programa GAMMA incorpora una metodología más avanzada y precisa, basada en el uso de tablas de transferencia de valores entre la matriz de la imagen SAR y la matriz del MDE tomado como referencia tablas *lookup*. Este metodología se divide en cuatro etapas (Figura 2.24): (i) preparación de la imagen SAR y del MDE; (ii) determinación-aplicación de una primera transformación geométrica; (iii) mejora de la transformación geométrica inicial; (iv) remuestreo de la imagen SAR a la proyección cartográfica del MDE (GAMMA Remote Sensing AG, 2008). Los siguientes subapartados explican cada una de estas etapas.

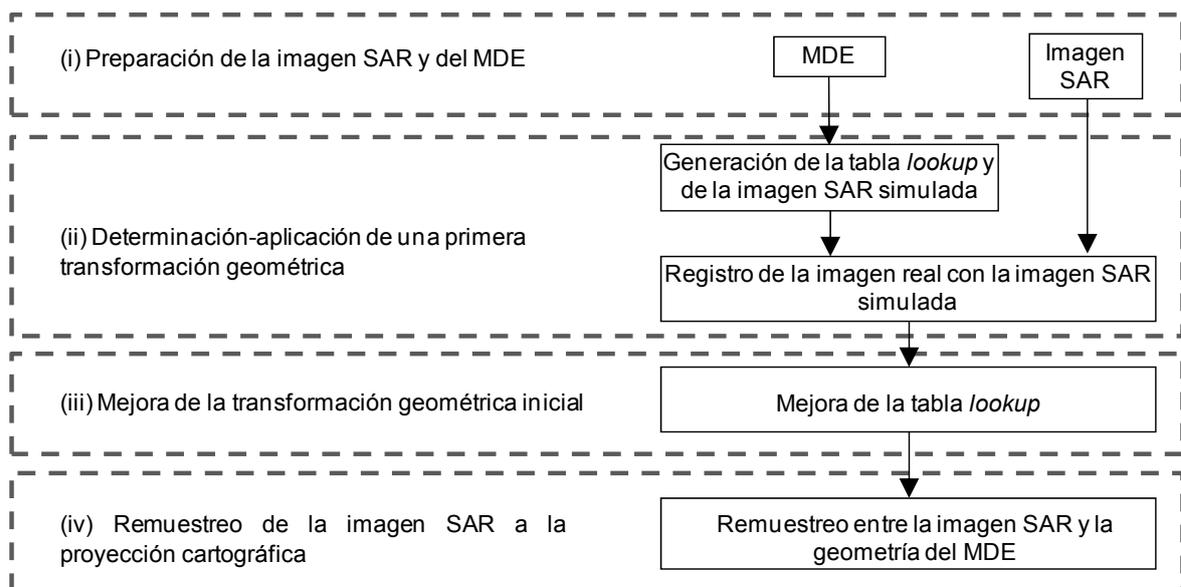


Figura 2.24. Proceso de georreferenciación de una imagen SAR con el método de tablas *lookup* del software GAMMA. Fuente: adaptado de GAMMA Remote Sensing AG (2008)

- Preparación de la imagen SAR y del MDE

Para que la imagen SAR pueda ser utilizada en este proceso de corrección geométrica tiene que haber sido calibrada radiométricamente de forma previa, siendo también recomendable que haya sido sometida a un procesado *multilook* para reducir el *speckle*. Dado que las imágenes utilizadas fueron adquiridas con estos dos pretratamientos y refinadas mediante la aplicación de una calibración radiométrica absoluta, el único paso previo que se aplicó fue el de crear para cada una de ellas un fichero de cabecera con la información solicitada por el *software* GAMMA para aplicar este proceso (formato de los datos, número de líneas y columnas, ángulo de incidencia, etc.) y convertirlas en el formato requerido por este programa.

El MDE utilizado en este proceso fue el creado en el apartado 2.2. Para ello, al igual que con las imágenes ASAR, fue también necesario crear un fichero de cabecera con una serie de parámetros específicos (información sobre la proyección, formato de los datos, tamaño del píxel, etc.) y convertirlo en el formato requerido por GAMMA. Es preciso señalar que el sistema de proyección con el que se encuentra este MDE determina la proyección de salida de las imágenes SAR resultantes de aplicar el proceso de georreferenciación. Así, en nuestro caso, las imágenes corregidas -que tendrán un tamaño de celda de 25 m- estarán reproyectadas en la proyección cartográfica UTM usada en todo este trabajo³⁶.

- Determinación-aplicación de la primera transformación geométrica

Como su nombre indica, esta fase consiste en obtener una primera aproximación de la transformación geométrica necesaria para proyectar la imagen SAR en coordenadas cartográficas. Más adelante, esta aproximación es mejorada mediante la aplicación de las dos siguiente etapas. Esta fase se inicia con la creación de una tabla *lookup* que, como se ha indicado, no es otra cosa que una tabla donde se produce la transferencia de valores entre la matriz de la imagen SAR y la matriz del MDE. En concreto, se crea una tabla con las dimensiones (filas y columnas) del MDE (el fichero que tiene proyección cartográfica) que contiene como valores de las celdas la posición fila/columna de los píxeles de la imagen SAR que corresponde a cada posición de la matriz.

En el segundo paso, sobre la base del MDE se genera una imagen SAR simulada

³⁶ Elipsoide Internacional de 1909, Datum Europeo de 1950 referido a España y Portugal y zona 30 de la cuadrícula UTM.

que se transforma en las coordenadas de la imagen SAR original mediante la tabla *lookup* generada. El resultado es una imagen que contiene errores de localización de algunos píxeles, ya que durante este proceso se conservan algunos errores de la geometría SAR relacionados con la posición exacta de la plataforma en la órbita. Este error es depurado en las dos siguientes etapas.

- Mejora de la transformación geométrica inicial

Esta etapa consiste en la creación de una nueva tabla *lookup* más precisa que la anterior. La imagen SAR simulada se compara con la imagen SAR original para examinar las distancias existentes entre la posición de los píxeles de ambas (*offsets*). Estas distancias se determinan de manera automática utilizándose mediante un análisis de correlación, de tal manera que los desplazamientos relativos quedan modelados como una función. Esta función se aplica a la tabla *lookup* inicial, con lo que se eliminan las imprecisiones originales.

- Remuestreo de la imagen SAR a la proyección cartográfica del MDE

Mediante la tabla *lookup* refinada se obtiene la imagen SAR proyectada en el mismo sistema de coordenadas cartográfico que el MDE siguiendo el procedimiento anteriormente descrito. En este proceso, el usuario puede tomar tres opciones para las áreas afectadas por efectos de recorte y sombra: (i) poner un valor fijo y único marcando los píxeles afectados como zonas perdidas; (ii) guardar el valor real, o (iii) interpolar valores de los píxeles vecinos. En nuestro caso se optó por la segunda opción.

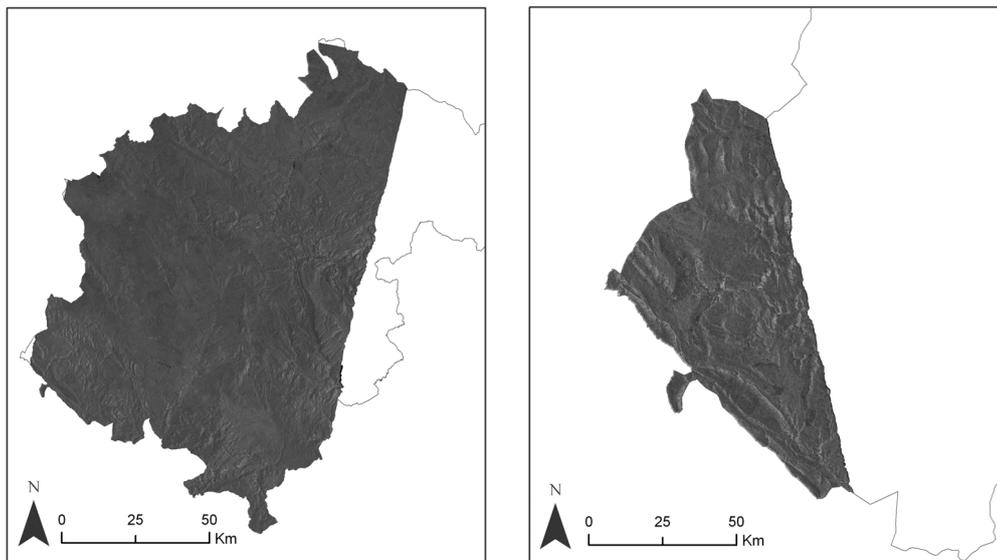


Figura 2.25. (A) imagen ASAR registrada el 19 de junio de 2003 (órbita descendente); (B) imagen ASAR registrada el 11 de octubre de 2003 (órbita ascendente)

Al igual que con las imágenes Landsat, sobre las imágenes resultantes se aplicó una máscara con los límites de la provincia de Teruel, obteniéndose escenas con distintos grados de recubrimiento del territorio turolense. La Figura 2.25 muestra las imágenes que mayor y menor superficie recogen de la provincia (de orbita descendente y ascendente, respectivamente), representando las demás situaciones semejantes o intermedias.

2.5. Las variables topográficas derivadas del MDE

Como se ha indicado en la caracterización física del área de estudio, el relieve es un parámetro fundamental que condiciona la existencia y la distribución de las masas forestales, ya que la altitud, la pendiente y la orientación afectan al sustrato sobre el que se asientan y matizan los parámetros climáticos generales, lo que introduce matizaciones importantes en la tipología y en el desarrollo de la vegetación forestal (Querol, 1995; Pérez-Cabello, 2002) y, por ende, en la cantidad de biomasa presente. Esta importancia del factor topográfico se ve realizada en zonas de montaña, donde adquiere un papel limitante para la vida vegetal, pudiéndose constatar la existencia de determinados umbrales, que pueden ser de carácter crítico (máximo o mínimo) u óptimo, en función de los cuales se definen los óptimos ecológicos de desarrollo forestal (de la Riva, 1997).

En este sentido, tal y como recoge ampliamente la bibliografía, la altitud es un condicionante de primer orden de la superficie forestal, ya que cada especie tiene unos umbrales de altitud mínimos y máximos dentro de los cuales aparece, distinguiéndose también determinados segmentos altitudinales en los que lo hace en forma de bosque compacto o de arbolado menos denso. Además de esta incidencia en la distribución espacial, el aumento de altitud impone unas condiciones cada vez más adversas y severas al desarrollo del pie arbóreo, que adquiere un porte más achaparrado y menudo. Teniendo en cuenta estas consideraciones, cabe esperar una relación inversa entre biomasa residual forestal y altitud.

La pendiente introduce modificaciones sustanciales en la significación de los efectos erosivos y, en consecuencia, en la existencia y pervivencia del soporte edáfico, limitando sus posibilidades de evolución y alterando su contenido de humedad y su escorrentía (de la Riva, 1997). Como consecuencia, fuertes valores de pendiente implican la inexistencia o el escaso desarrollo de suelos, lo que condiciona la presencia y el

desarrollo de vegetación forestal, circunstancia que, a su vez, repercute en la capacidad morfogenética del suelo. Por ello, la pendiente se erige en factor condicionante de primera magnitud de la presencia de masas forestales y de su desarrollo; como en el caso de la altitud, cabe esperar una relación inversa entre esta variable y la cantidad de biomasa residual.

La orientación determina las diferencias de radiación recibidas entre umbría y solana, lo que condiciona la temperatura y la evapotranspiración y repercute en la distribución de la vegetación (de la Riva, 1997). En general, en medios mediterráneos como el nuestro, las exposiciones norte disfrutan de condiciones más favorables para el desarrollo vegetal (Pérez-Cabello, 2002), por lo que *a priori* la biomasa residual forestal será mayor en estas laderas. Por último, la forma de la ladera (cóncava, convexa o plana) tiene también un papel importante en aspectos destacados como el comportamiento del suelo ante el agua o la acentuación de la variable exposición, influyendo también en el desarrollo de la cubierta vegetal (de la Riva, 1997).

La aplicación de una serie de algoritmos sencillos sobre el MDE raster permite disponer de todas las variables topográficas aludidas. El análisis de correlación entre estas coberturas y los datos de biomasa residual permitirá comprobar de forma cuantitativa si existen relaciones significativas entre ambas variables, así como el sentido de las mismas (directo o inverso) y su magnitud, características éstas que indicarán si estas variables son útiles o no para estimar la biomasa residual a escala regional. A continuación se recogen las variables topográficas derivadas del MDE –que, por lo tanto, tendrán su misma resolución- y el proceso seguido para su generación.

- *Mapa de pendientes.*

El mapa de pendientes se obtuvo a partir de una función implementada en el módulo *Spatial Analyst* de ArcGIS-ArcINFO que calcula el máximo ratio de cambio de elevación sobre la distancia entre cada píxel del MDE y sus 8 vecinos, pudiendo expresarse en porcentaje o en grados, siendo ésta la unidad utilizada (Figura 2.26).

- *Mapa de orientaciones.*

El mapa de orientaciones también fue obtenido mediante ArcGIS-ArcINFO, aplicando la función específica incorpora en su módulo *Spatial Analyst*, que calcula la dirección del máximo ratio de cambio en la elevación de cada píxel considerando sus 8 vecinos. El resultado es expresado en grados positivos de 0 a 359,9, medidos siguiendo

el sentido de las agujas del reloj desde el norte geográfico. Los píxeles sin cambio de elevación con respecto a sus vecinos son codificados con el valor -1 (Figura 2.27).

- Mapas de insolación potencial

La insolación potencial de un punto es el tiempo máximo que puede estar sometido a la radiación directa en ausencia de nubosidad. Así, la estimación de la insolación potencial puede considerarse como la generalización más directa del cálculo del sombreado topográfico y constituye la primera aproximación a la estimación de la radiación solar recibida por un punto en términos cuantitativos (Felicísimo, 2003). En un territorio concreto, con condiciones climáticas similares como el nuestro, puede asumirse que las diferencias de insolación entre dos puntos en el mismo día del año son función del relieve y, más concretamente, del ocultamiento topográfico, por lo que su análisis puede abordarse a partir del MDE. Esta hipótesis asume que las condiciones de nubosidad son similares en toda la zona de estudio (Felicísimo, 2003), premisa que asumimos en el presente trabajo a pesar de que su extensión pueda incumplirla.

La metodología seguida para conocer la insolación potencial de cada punto de la provincia de Teruel en un día concreto del año fue la siguiente (Felicísimo, 2003):

- En primer lugar se especificaron en una hoja EXCEL, preparada para el cálculo de las posiciones del Sol en cada hora a lo largo de un día, los parámetros latitud del área de estudio (centro de la Provincia) y declinación solar del día.
- Del cálculo de las posiciones del Sol en cada hora a lo largo de ese día se obtuvo un conjunto de 24 posiciones solares determinadas mediante coordenadas polares de acimut y elevación sobre el horizonte.
- Las posiciones solares con elevación angular negativa -indicadoras del periodo nocturno- fueron descartadas.
- Para cada posición solar se calculó la presencia o ausencia de sombras topográficas en cada píxel del MDE con la orden *Hillshade* en la calculadora de mapas (*Raster calculator*) de ArcGIS-ArcINFO. La sintaxis de la orden *Hillshade* permitió que la cobertura de salida pudiera ser expresada en dos unidades de medida: (i) como una matriz binaria en la que 0 representa píxeles en sombra y 1 píxeles iluminados; y (ii) como una matriz continua en la

que los píxeles quedan codificados con un valor entre 0 (sombra) y 255, dependiendo de la cantidad de iluminación que reciben³⁷.

- Se sumaron, por un lado, las matrices binarias obtenidas para cada posición angular positiva y, por otro, las matrices continuas, obteniéndose para ese día un modelo de insolación potencial con una resolución temporal de horas y otro en cantidad relativa de iluminación recibida, respectivamente.

Esta metodología implica que, para obtención de un modelo de insolación potencial anual, es necesario obtener la de cada día del año para, posteriormente, realizar su suma. Dado que esta tarea consumía mucho tiempo³⁸, se decidió calcular la insolación potencial media anual de la provincia (en horas y en cantidad de iluminación recibida) a partir de la suma de los equinoccios y de los solsticios anuales, siendo el resultado dividido por 4 (el número de días utilizados). Aunque esta forma de proceder da lugar a modelos simplificados, se consideró que éstos eran lo suficientemente útiles para valorar si esta variable podía resultar significativa a la hora de estimar la biomasa residual forestal, ya que recogía las cuatro situaciones solares más representativas. Finalmente, junto a los modelos anuales (Figuras 2.28 y 2.29), se decidió explorar también la utilidad para estimar biomasa residual forestal de los modelos obtenidos en los solsticios y en los equinoccios.

- *Mapa de curvatura.*

Como el resto de variables topográficas, el mapa de curvatura fue obtenido a partir de una función implementada en el módulo *Spatial Analyst* de ArcGIS-ArcINFO, denominada *Curvature*, que calcula la curvatura de la superficie píxel a píxel, utilizando para ello un polinomio de orden 4 que es aplicado a la superficie conformada por una ventana de 3x3 píxeles. El resultado es una cartografía en la que valores los positivos de indican una topografía convexa, los negativos identifican situaciones de concavidad y el valor 0 se asocia a superficies planas.

Todas estas variables serán consideradas como independientes en los modelos de estimación de biomasa residual que se ajustarán en el Capítulo 3, aportando una dimensión informacional independiente de la espectral de las imágenes de satélite.

³⁷ Esto se consigue porque esta función de *ArcGis-ArcInfo* tiene en cuenta la pendiente y orientación locales a la vez que los ángulos introducidos que definen la posición solar, lo que permite calcular el coseno del ángulo de incidencia, que es expresado en valores entre 0 y 255.

³⁸ Suponiendo una media de 8 horas de iluminación al día, serían necesarios 2920 mapas parciales para calcular un modelo de insolación potencial anual expresado en horas y otros tantos para expresarlo en cantidad relativa de iluminación recibida.

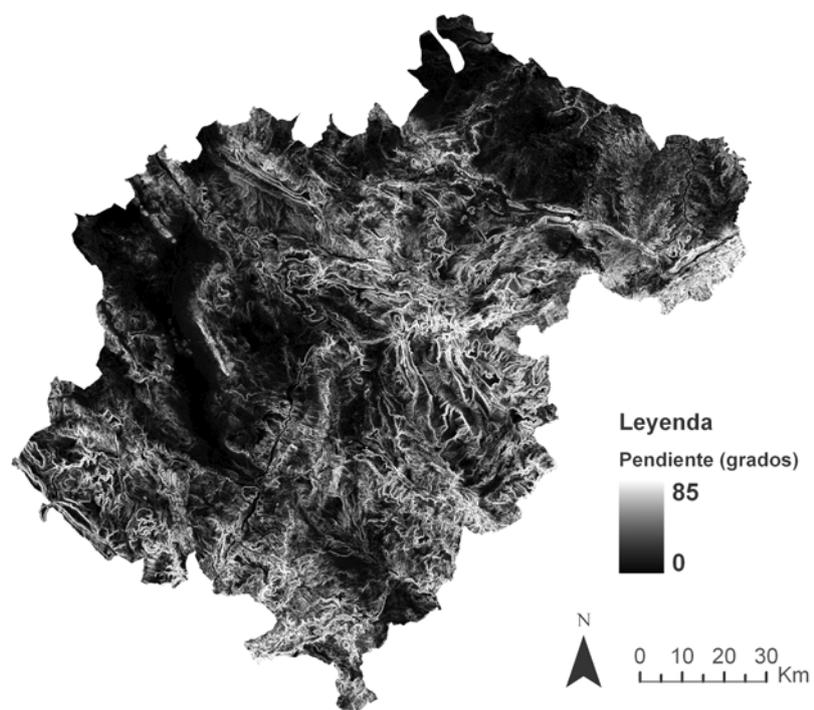


Figura 2.26. Mapa de pendientes de la provincia de Teruel

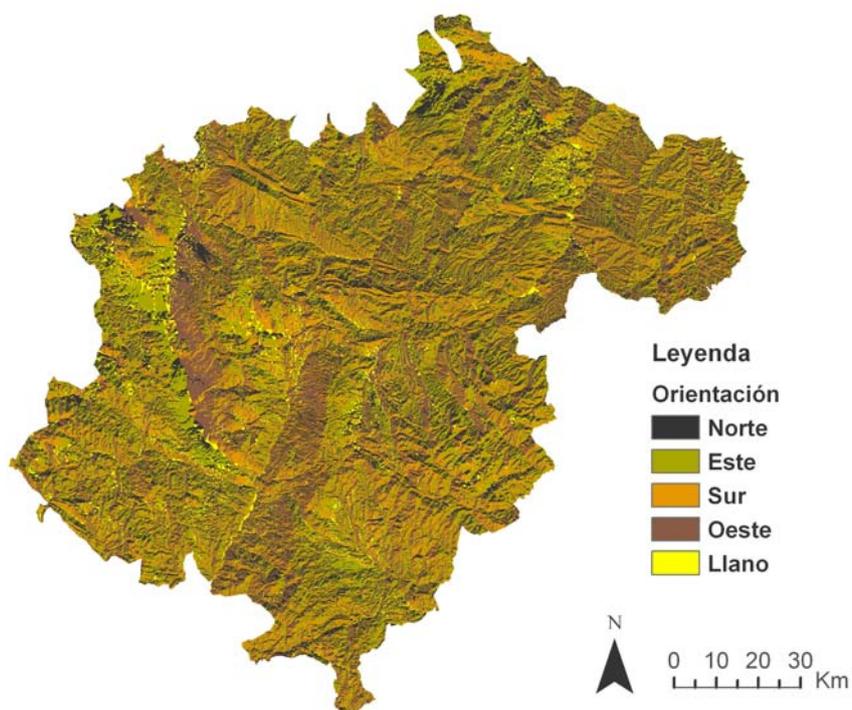


Figura 2.27. Mapa de orientaciones de la provincia de Teruel

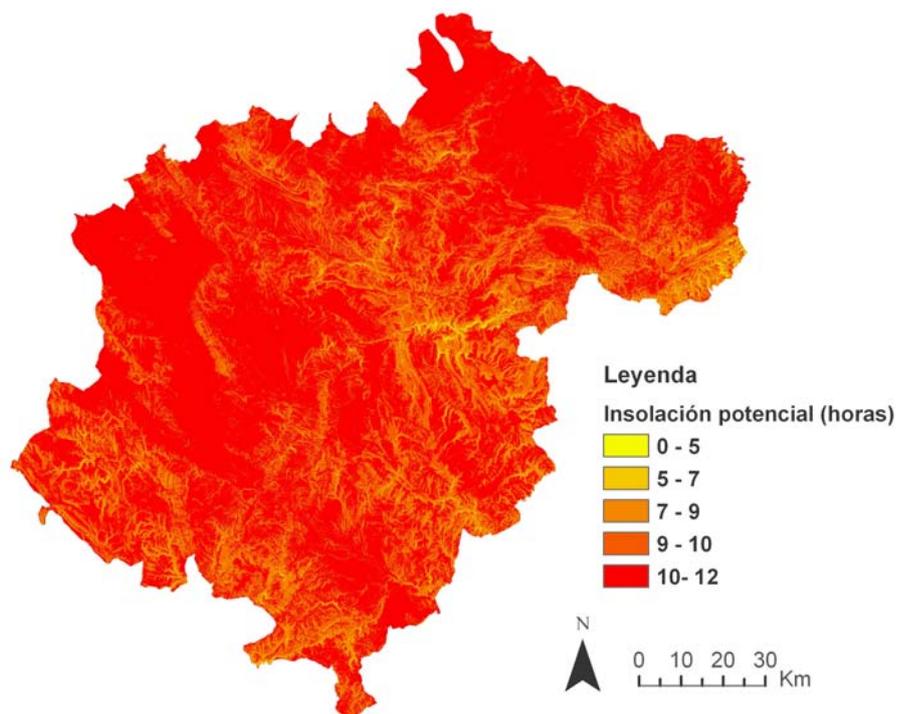


Figura 2.28. Mapa de insolución potencial anual en horas de la provincia de Teruel

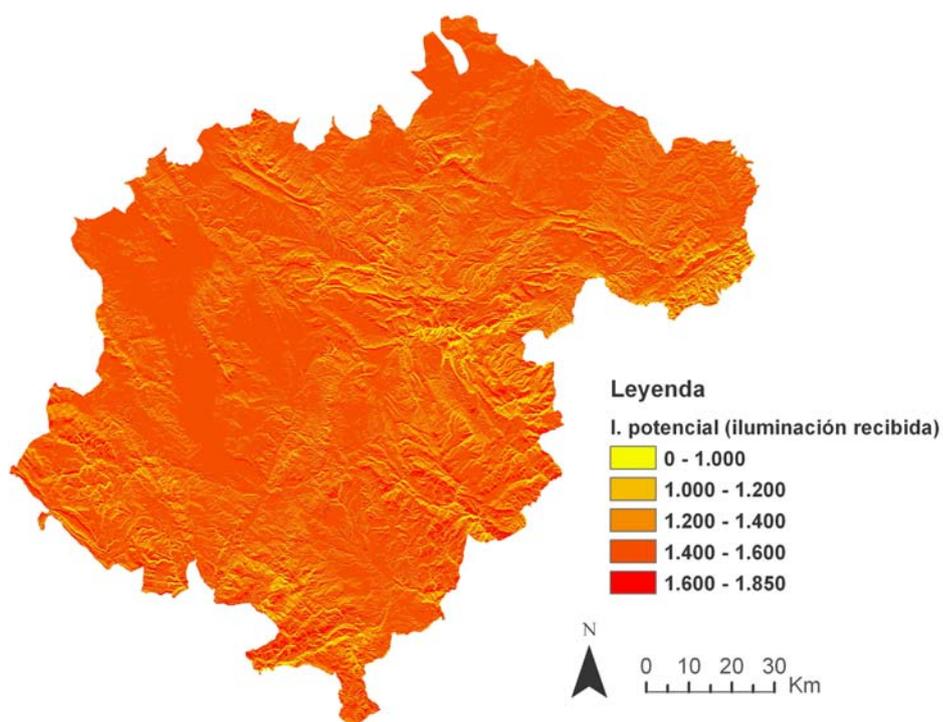


Figura 2.29. Mapa de insolución potencial anual en iluminación recibida de la provincia de Teruel

2.6. Las variables forestales derivadas del Mapa Forestal de Aragón

El *Mapa Forestal de Aragón* (MFA) es una cartografía promovida en 1991 por el Departamento de Medio Ambiente del Gobierno de Aragón ante la necesidad de contar con un documento sobre la vegetación de la Comunidad Autónoma y su distribución que sirviera como instrumento base a la hora de acometer proyectos de evaluación de recursos y de planificación, tales como inventarios forestales, planes de reestructuración de la cubierta vegetal, planes de ordenación de los recursos naturales (PORN), etc. Así pues, su finalidad última fue -y sigue siendo- ofrecer una herramienta de gestión del territorio forestal aragonés (Escudero y Franchès, 2004).

La escala elegida para su elaboración fue 1:50.000, considerada suficiente tanto para permitir la representación del mayor número posible de unidades de vegetación y su localización exacta, como para su utilización en estudios del medio físico. Adoptó como unidades de trabajo las 119 hojas del Mapa Topográfico Nacional 1:50.00 en las que quedaba incluido todo el territorio aragonés. Se siguió la metodología del *Mapa Forestal de España* escala 1:200.000, siendo varios los motivos: (i) por la sencillez de ésta a la hora de definir las distintas agrupaciones vegetales; (ii) por la posibilidad de incorporar información sobre estructura, fisionomía-fisiología y grado de evolución de las masas forestales mediante la utilización de los conceptos *Tipo Climático-Estructural (TCE)* y *Nivel de Madurez o Evolutivo*; (iii) por la capacidad de representar localizaciones puntuales de gran interés; y, finalmente, (iv) porque permitía estudios comparativos con otras Comunidades Autónomas. Por último, señalar como característica fundamental su formato digital, que permite su integración en entorno SIG (Escudero y Franchès, 2004).

En la presente investigación, el MFA fue empleado para dos cuestiones:

- **Como cartografía de referencia para realizar las estimaciones de biomasa residual forestal.** En concreto, se utilizó la reclasificación disponible en la aplicación BADAAR³⁹ para generar una máscara de las cuatro pináceas consideradas. De esta forma, la cartografía de estimación resultante quedará adaptada a los mismos límites que el principal documento de información forestal de la Comunidad Autónoma, facilitándose de esta manera su uso por parte de las distintas Administraciones.

³⁹ La misma reclasificación previamente utilizada en la corrección radiométrica de las imágenes Landsat para calcular el NDVI promedio de las distintas cubiertas de la Provincia.

- **Para derivar variables forestales susceptibles de ser utilizadas en los modelos de estimación de biomasa residual forestal.** Como se ha indicado, el TCE y el Nivel de Madurez ofrecen información muy interesante acerca de la estructura y el grado de evolución de las masas forestales, lo que puede resultar relevante a la hora de ajustar los modelos de estimación, ya que dan información complementaria de los bosques estudiados, independiente de las consideradas hasta el momento.

En este apartado se trata la segunda de estas dos cuestiones, dejando para el siguiente capítulo la primera de ellas. A continuación se describen las variables forestales seleccionadas como variables independientes y el proceso de obtención de las mismas.

- Mapa del Tipo Climático Estructural

Las distintas categorías del TCE hacen referencia al grupo dominante de formaciones vegetales que presenta el máximo aprovechamiento de los recursos naturales primarios (energía, agua y nutrientes), asignándose un área a un tipo cuando otro de superior exigencia en recursos no puede extenderse a la totalidad de esa área (Ruiz de la Torre, 1990; Escudero y Franchès, 2004). Se distinguen dos tipos de TCE:

- **Zonales:** cuando representan a las distintas comunidades vegetales que se escalonan en una cliserie altitudinal. De esta forma, las comunidades presentes en cada TCE son consecuencia de las variaciones de altitud, precipitaciones, continentalidad, etc. Existen seis categorías de TCE zonales: Alta Montaña o Pisos suprasilvicos (A), Bosques asimilables al tipo Taiga (T), Bosques Caducifolios Mesófilos (C), Bosques Subesclerófilos (S), Bosques Esclerófilos (E) y Vegetaciones Hiperxéricas (H).
- **Intrazonales:** se basan en características particulares que en determinadas zonas presenta el sustrato sobre el que se asienta la vegetación. Dentro de este grupo se distingue entre 7 categorías: Vegetaciones Glicohidrófilas (P), Vegetaciones Halohidrófilas (L), Vegetaciones Haloxerófilas (X), Vegetaciones Gipsófilas (G), Vegetaciones rupícolas sobre sustrato no kárstico (F), Vegetaciones sobre karst (K) y Vegetaciones Glareícolas (J).

La asignación del TCE en cada una de las teselas que componen el MFA se hace añadiendo la letra que se ha indicado entre paréntesis al final del nombre de la agrupación vegetal que la define.

Para la obtención de la cartografía de TCE de la provincia de Teruel en formato raster se siguieron los siguientes pasos:

- Incorporación de las hojas, disponibles en formato *.shp*, del MFA de Teruel al entorno ArcGIS-ArcINFO y generación de un único fichero *.shp*.
- Asignación de la proyección cartográfica usada para la georreferenciación de las imágenes y aplicación de una máscara con los límites del área de estudio.
- Aplicación de la función *Dissolve* de *Spatial Analyst* para unir espacialmente los polígonos de hojas distintas correspondientes a un mismo tipo de vegetal.
- Creación de un nuevo campo en la tabla alfanumérica asociada al fichero *.shp*, denominado *Cod_TCE*, con un código numérico en función de la letra del TCE que aparece al final del campo *Nombre* de la agrupación vegetal.
- Aplicación de la función *Dissolve* para unir espacialmente las teselas vecinas con el mismo código numérico en el campo *Cod_TCE*.
- Conversión a raster -celda de 25 m- del fichero *.shp* a partir del campo *Cod_TCE* mediante la orden *Convert features to raster* de *Spatial Analyst*.

El resultado de este proceso es una cartografía en formato raster en la que el valor de cada píxel está en función del TCE, siendo el tamaño de estos píxeles el mismo que el de las imágenes Landsat utilizadas (Figura 2.30).

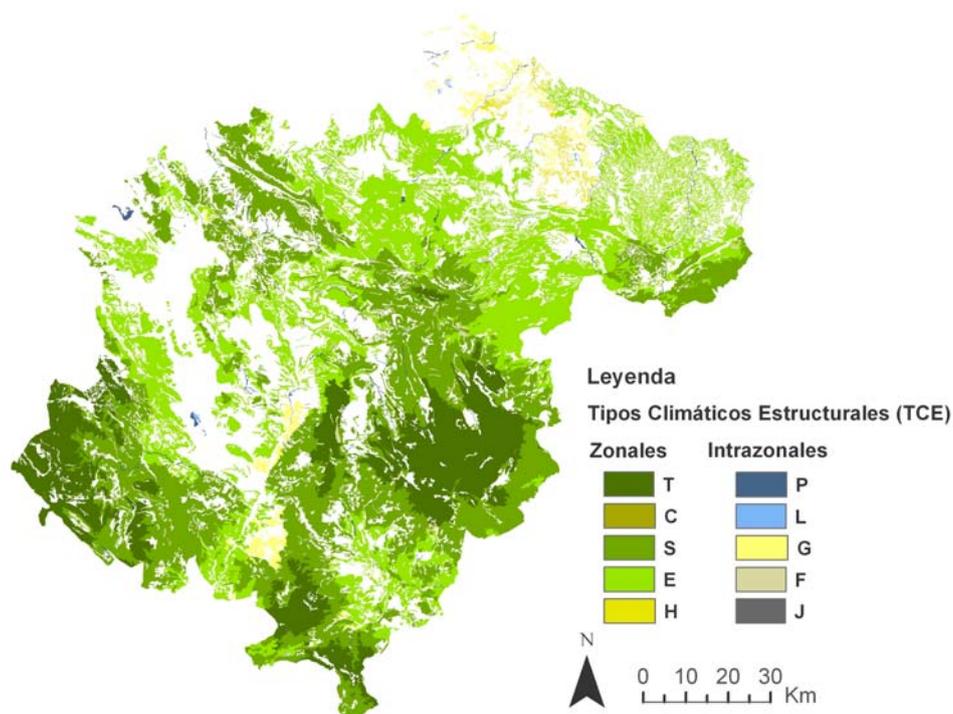


Figura 2.30. Mapa de Tipos Climático Estructurales (TCE) de la provincia de Teruel

- Mapa del Nivel de Madurez

El *Nivel de Madurez*, en el *Mapa Forestal de España*, refiere a la “calificación de la posición relativa de un tipo de cubierta real entre el desierto completo y una situación teórica estable de máxima adaptación a las condiciones del medio, máximo aprovechamiento de la potencialidad natural y máxima estabilidad por la adaptación de los componentes a la convivencia” (Ruiz de la Torre, 1990). Se relaciona, por tanto, con la estructura y con el valor protector de la vegetación (Escudero y Franchès, 2004).

En las formaciones vegetales zonales se diferencia un total de 10 niveles de madurez, que son designados mediante un código numérico que oscila de 0 a 9, de tal manera que la cifra aumenta conforme lo hace la madurez estimada. Los valores más bajos están reservados para desiertos y formaciones vegetales poco densas (herbazales, tomillares, matorrales), mientras que los más altos se asignan a formaciones de bosque (Escudero y Franchès, 2004).

Para la creación de la cartografía de este parámetro se empleó la misma metodología que para la elaboración de la cartografía de TCE. La Figura 2.31 muestra la cartografía obtenida.

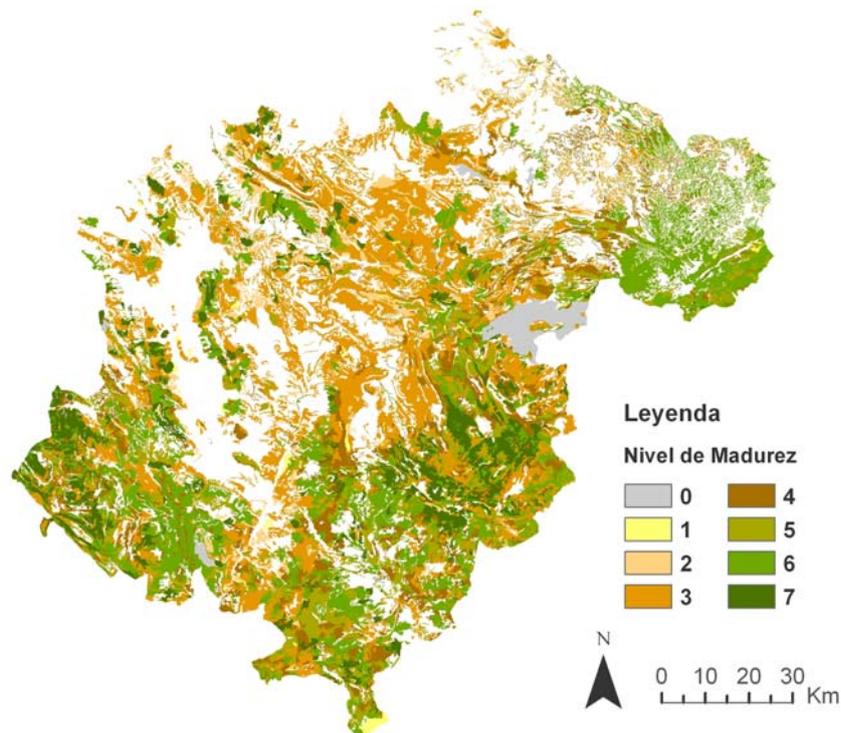


Figura 2.31. Mapa de Niveles de Madurez de la provincia de Teruel

CAPÍTULO 3
ESTABLECIMIENTO DE LOS MODELOS
DE ESTIMACIÓN DE LA BIOMASA
RESIDUAL FORESTAL DE LA PROVINCIA
DE TERUEL

En este capítulo se desarrollan las fases metodológicas IV y V, que están directamente relacionadas con sus correspondientes objetivos parciales. Así pues, este capítulo constituye el núcleo central de la presente tesis, ya que en él se formulan distintos modelos de estimación de la biomasa residual forestal del área de estudio utilizando las variables que se han obtenido en el Capítulo 2. Finalmente, se selecciona el mejor de ellos tanto en términos estadísticos como operativos.

Este capítulo se articula en dos apartados que son asimétricos en cuanto a su tamaño, de acuerdo con lo expresado en el apartado de metodología y fases de la investigación. El primero de ellos es el más extenso y está dedicado a la estimación de modelos operativos a escala regional-provincial, utilizando para ello las variables radiométricas derivadas de la imagen Landsat de junio de 1994 y de las variables auxiliares topográficas y forestales. El segundo apartado emplea exclusivamente la información derivada de las imágenes radar Envistat-ASAR para explorar las relaciones existentes entre la biomasa forestal y el coeficiente de retrodispersión proporcionado por la banda C de este satélite, no siendo formulado ningún modelo de estimación, ya que no se controlan todas las variables necesarias para asegurar la validez del mismo.

3.1. Modelos de estimación con variables radiométricas derivadas de imágenes Landsat y variables auxiliares topográficas y forestales

La obtención de los modelos operativos de estimación de la biomasa residual forestal se hace a partir de un proceso dinámico e interactivo que parte de la aplicación de métodos simples para, una vez analizados los resultados obtenidos, proponer métodos más complejos. Así pues, cada uno de los modelos que se proponen consta de los siguientes pasos:

- **Paso I:** Ensayo de un procedimiento de extracción de la información radiométrica y auxiliar utilizando como referencia la cartografía puntual de las 482 parcelas del IFN-2 con información de biomasa residual creada en el apartado 2.1.
- **Paso II:** Análisis de las correlaciones existentes entre la variable dependiente (biomasa residual forestal) y las variables dependientes (radiométricas, topográficas y forestales) y entre las dependientes.

- **Paso III:** Determinación, en función de los resultados obtenidos en el análisis de correlación, del método de regresión más adecuado.
- **Paso IV:** Reflexión sobre los resultados obtenidos en relación con el objetivo marco planteado. Formulación de una nueva aproximación para solventar los problemas o carencias detectados en el modelo.

Este proceso termina cuando se considera que no existen otras alternativas a las ya utilizadas que mejoren los resultados obtenidos. Es entonces cuando se discute cuál de los modelos creados se adapta mejor al objetivo marco expresado.

3.1.1. Estimación de la biomasa residual forestal a partir de la información de las variables independientes obtenida mediante ventanas fijas

3.1.1.1. Metodología para la extracción de la información y para evaluación de la heterogeneidad espacial interna de las parcelas del IFN-2

La utilización de ventanas fijas o *kernels* de tamaño superior a un píxel para la extracción de información espectral que posteriormente es relacionada con la variable a estimar es la forma de proceder más habitual en los trabajos de teledetección que utilizan imágenes ópticas de resolución media para la estimación de parámetros forestales (p.e. Roy y Ravan, 1996; Foody *et al.*, 2001; Eklundh *et al.*, 2001; Eklundh *et al.*, 2001; Labrecque *et al.*, 2003; Phua y Saito, 2003; Lu *et al.*, 2004; Lu, 2005; Lu y Batistiella, 2005; Labrecque *et al.*, 2006). La forma de proceder en los trabajos que utilizan estas ventanas es la siguiente:

- En primer lugar, las parcelas de campo que contienen la información del parámetro forestal son localizadas en la imagen utilizada. Esta imagen puede estar compuesta únicamente por las bandas originales o, más frecuentemente, por éstas y un conjunto de neocanales obtenidos a partir de ellas.
- A continuación se disponen sobre la imagen las ventanas fijas que, generalmente, tienen un tamaño de 3x3 píxeles. Estas ventanas se colocan de tal manera que el píxel central de las mismas se sitúa justo en el centro de la parcela de campo.
- Se extrae entonces la información radiométrica de todos los píxeles que componen la ventana, calculándose la media aritmética de cada una de las bandas que componen la imagen.
- Este valor promedio es el que se utiliza más tarde para formular los modelos de estimación del parámetro.

La utilización de este procedimiento en lugar del uso del píxel que contiene las parcelas de campo -o que se sitúa en el centro de éstas- trata de evitar la comisión de errores en la estimación del parámetro debidos a imprecisiones en el proceso de georreferenciación de la imagen, en la localización de las parcelas en el campo o en ambos. Cualquiera de estos errores espaciales puede hacer que se asocie a una determinada cantidad del parámetro estudiado una respuesta espectral que no le corresponde, por lo que se producirán errores en el modelo de estimación difícilmente solucionables.

Es necesario señalar en este punto que la localización en el campo de las parcelas del IFN-2, para las que se tiene información de biomasa residual forestal, dista de lo deseable en términos de precisión espacial para el establecimiento de modelos estimativos. Esto se debe a que, tal y como se ha recogido en el apartado 2.1, la localización en el campo de estas parcelas se realizó a partir de la utilización de fotografía aérea a escala 1:30.000 del *Vuelo General de España*, delimitándose el centro exacto de las mismas de forma aleatoria una vez reconocido el paraje en el cual se sitúa el punto de cruce de la malla kilométrica UTM de la cartografía 1:50.000 del MTN. Así pues, no existe garantía absoluta de que las parcelas fueran correctamente localizadas, por lo que la adopción de ventanas fijas para la extracción de la información espectral es obligada.

Aunque se valoró la utilización de ventanas fijas de mayor tamaño, finalmente el seleccionado fue el de 3x3, el más habitual recogido en la bibliografía. Esta decisión fue tomada teniendo en consideración la alta heterogeneidad espacial que caracteriza a los bosques mediterráneos, como los del área de estudio.

Como se ha señalado en el primer capítulo, la heterogeneidad de los bosques mediterráneos es una característica intrínseca de los mismos y es uno de los principales factores que dificulta la estimación de parámetros forestales en medios mediterráneos mediante el empleo de la teledetección. Esto es debido a que esta heterogeneidad espacial es acusada por la imagen de satélite, lo que se traduce en una elevada variabilidad espectral de las áreas ocupadas por estos bosques. Así pues, en el caso concreto de las parcelas de biomasa residual utilizadas, dos parcelas con una misma cantidad de recurso pueden presentar valores medios de reflectividad distintos debido a la presencia de otros elementos del paisaje (p. e. un cortafuego, una pista forestal), a su localización en el borde de otro tipo de cubierta (p. e. un área de matorrales, campos de

cultivo) o a una alta variabilidad interna de esa superficie forestal. Esta situación dificulta el establecimiento de modelos estimativos precisos. Así, el empleo de una ventana de mayor tamaño (por ejemplo, de 5x5) hubiera disminuido en mayor grado la incertidumbre asociada a la localización de la parcela de campo, pero, por el contrario, hubiera incrementado el riesgo de asociar a su respuesta radiométrica otras realidades espaciales distintas a las existentes en la parcela.

Por todo ello, para la extracción de la información radiométrica, topográfica y forestal de las 482 parcelas de biomasa residual forestal consideradas, se procedió de forma análoga a la descrita anteriormente:

- Las distintas variables radiométricas, topográficas y forestales derivadas, respectivamente, de la imagen Landsat 5 TM de junio de 1994, del MDE y del *Mapa Forestal de Aragón* 1:50.000 fueron integradas en un solo archivo multibanda de ERDAS Imagine, garantizándose la misma georreferenciación en todas las capas.
- Sobre este multibanda se superpuso la cartografía puntual de biomasa residual forestal obtenida en el apartado 2.1.
- Tomando como referencia estas parcelas se delimitaron las ventanas de 3x3 píxeles, de tal manera que el píxel central coincidiera con el punto central de la parcela. La creación de estas ventanas se hizo mediante herramientas de edición de ERDAS Imagine, concretamente mediante la utilización de AOI's (*Areas of Interest*) (ERDAS Imagine, 2001).
- Cada uno de los 482 AOI's nombrados con el número de parcela del IFN fueron almacenados en el *Editor de firmas* de ERDAS Imagine, a partir del cual se obtuvo información sobre la media, el valor mínimo, el máximo y la desviación estándar de cada una de las capas integradas en el multibanda.
- Esta información estadística fue exportada a EXCEL y, posteriormente, a SPSS, guardándose en un fichero con el formato específico de este programa (.sav).
- De forma paralela, se creó otro fichero SPSS a partir de la tabla .dbf de la cartografía de las parcelas de biomasa residual forestal. Este fichero contenía, además de la información de biomasa, toda la proporcionada por el IFN-2.
- Finalmente, estos dos ficheros se cruzaron en SPSS, utilizando como campo clave

común el número de parcela del IFN-2. De esta manera, se obtiene un fichero en el que aparece conjuntamente toda la información necesaria para elaborar los modelos de estimación, tarea que se aborda en los siguientes apartados.

Variable	Abreviatura	Tipo
Banda Thematic Mapper 1	TM1	Continua
Banda Thematic Mapper 2	TM2	Continua
Banda Thematic Mapper 3	TM3	Continua
Banda Thematic Mapper 4	TM4	Continua
Banda Thematic Mapper 5	TM5	Continua
Banda Thematic Mapper 7	TM7	Continua
Componente principal 1	CP1	Continua
Componente principal 2	CP2	Continua
Componente principal 3	CP3	Continua
Tasseled-Cap 1	TC1	Continua
Tasseled-Cap 2	TC2	Continua
Tasseled-Cap 3	TC3	Continua
Normalized Difference Vegetation Index	NDVI	Continua
Soil Adjusted Vegetation Index	SAVI	Continua
Optimize Soil Adjusted Vegetation Index	OSAVI	Continua
Generalize Soil Adjusted Vegetation Index	GESAVI	Continua
Vegetation Index Green	GI	Continua
Moisture Stress Index	MSI	Continua
Visible Wavelengths	VIS123	Continua
Middle Infrared Wavelengths	MID57	Continua
Albedo	ABD	Continua
Elevación	Elevación	Continua
Pendiente	Pendiente	Continua
Orientación	Orientación	Categórica
Insolación Potencial Anual (nº de horas)	INS_POT_HORAS	Continua
Insolación Potencial Anual (iluminación total)	INS_POT	Continua
Insolación Potencial Primavera (nº de horas)	PRI_POT_HORAS	Continua
Insolación Potencial Primavera (iluminación total)	PRI_POT	Continua
Insolación Potencial Verano (nº de horas)	VER_POT_HORAS	Continua
Insolación Potencial Verano (iluminación total)	VER_POT	Continua
Insolación Potencial Otoño (nº de horas)	OTO_POT_HORAS	Continua
Insolación Potencial Otoño (iluminación total)	OTO_POT	Continua
Insolación Potencial Invierno (nº de horas)	INV_POT_HORAS	Continua
Insolación Potencial Invierno (iluminación total)	INV_POT	Continua
Curvatura de la superficie	CURVA	Continua
Tipo climático estructural	COD_TCE	Categórica
Nivel de madurez	COD_MADUREZ	Categórica

Tabla 3.1. Variables independientes consideradas para la estimación de la biomasa residual forestal

La Tabla 3.1 recoge, a modo de recordatorio, el nombre de todas las variables independientes sobre las que se ha obtenido información a escala de parcela, indicándose la abreviatura que se utiliza para nombrarlas de aquí en adelante y la escala de medida en la que están expresadas.

Debido a la importancia que la heterogeneidad espacial de los bosques mediterráneos tiene en el establecimiento de modelos estimativos mediante teledetección, se decidió obtener una medida cuantitativa de este parámetro a escala de parcela y utilizarla para evaluar la influencia que esta característica tiene en el ajuste de modelos de regresión de la biomasa residual en nuestro área de estudio. En concreto, dado que la heterogeneidad espacial de cada parcela tiene su reflejo en la respuesta espectral extraída mediante la ventana 3x3, la medida de heterogeneidad fue calculada sobre esta última. Así, siguiendo la metodología expuesta en Labrecque *et al.* (2003, 2006), la variabilidad espectral de cada parcela fue calculada para las seis bandas reflectivas utilizando el coeficiente de variación de *Pearson*, que se define mediante la siguiente expresión:

$$CV = \frac{S}{|\bar{X}|} \quad \text{Ecuación 34}$$

donde *CV* es el coeficiente de variación de *Pearson*, *S* es la desviación estándar calculada en la ventana de 3x3 píxeles de cada parcela y \bar{X} es la media calculada para esa misma ventana de 3x3 píxeles.

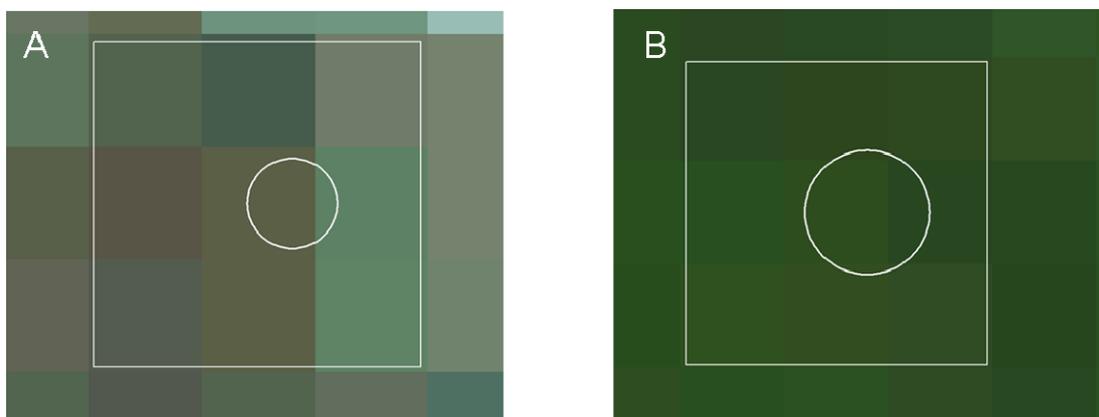


Figura 3.1. Utilización del CV para la determinación de la heterogeneidad de las parcelas: (A) parcela con un alto CV (alta heterogeneidad espacial); (B) parcela con un bajo CV (baja heterogeneidad espacial)

De esta manera se obtiene información sobre la heterogeneidad de las distintas parcelas; las que tienen un alto CV son parcelas que presentan una alta heterogeneidad espacial y espectral, mientras que las parcelas con un bajo CV son las más homogéneas. La Figura 3.1(A) muestra una ventana 3x3 situada sobre una parcela en la que se obtuvo un alto CV; la Figura 3.1(B) muestra una ventana 3x3 situada sobre una parcela con bajo CV.

Para determinar la influencia que tiene la heterogeneidad del entorno radiométrico de la parcela en el ajuste de modelos los estimación se definieron 10 grupos de parcelas utilizando los CV obtenidos en cada una de las bandas reflectivas, de tal manera que cada grupo fuera incluyendo un número menor de parcelas con un entorno radiométrico más homogéneo. Para ello se operó de la siguiente manera:

- En primer lugar se calcularon, para cada banda reflectiva, los umbrales de CV que permitían la separación de las parcelas en 10 percentiles (Tabla 3.2).
- Con posterioridad, esos umbrales fueron utilizados para la delimitación de los 10 grupos de parcelas, de tal manera que en el primero de ellos quedaron incluidas todas ellas, en el segundo solamente aquellas cuyos CV eran inferiores a los valores del percentil 9 en todas las bandas reflectivas, en el tercero aquellas cuyos CV estaban por debajo de los valores de CV del percentil 8 y así sucesivamente hasta llegar a delimitar los 10 grupos.

Percentil	CV TM1	CV TM2	CV TM3	CV TM4	CV TM5	CV TM7
9	0,264	0,273	0,304	0,138	0,215	0,287
8	0,216	0,228	0,255	0,104	0,173	0,228
7	0,186	0,194	0,217	0,084	0,152	0,199
6	0,158	0,167	0,188	0,073	0,134	0,172
5	0,135	0,144	0,160	0,062	0,120	0,154
4	0,119	0,128	0,143	0,053	0,105	0,135
3	0,103	0,108	0,120	0,045	0,090	0,121
2	0,088	0,086	0,098	0,037	0,073	0,098
1	0,071	0,064	0,072	0,029	0,058	0,074

Tabla 3.2. Umbrales de CV de cada una de las bandas reflectivas de la imagen de junio de 1994 utilizados para la delimitación de los 10 grupos de parcelas con distinto grado de heterogeneidad espacial-radiométrica

De esta forma, las parcelas incluidas en los primeros grupos son las que presentan mayor variabilidad espectral y las incluidas en los últimos las más homogéneas. A partir de ahora denominaremos a cada uno de estos diez grupos según

el percentil de CV empleado para delimitarlos. El análisis en cada uno de estos 10 grupos de parcelas de las correlaciones existentes entre la biomasa residual forestal y las variables independientes permite determinar la influencia que tiene la heterogeneidad del entorno radiométrico en el ajuste de los modelos de regresión.

3.1.1.2. Estudio de las correlaciones entre la biomasa residual forestal y las variables espectrales y topográficas continuas en los grupos de parcelas delimitados

La Tabla 3.3 muestra los coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual con las variables radiométricas en cada uno de los 10 grupos de parcelas. Como era esperado, en general, estas correlaciones son más altas a medida que los grupos contienen parcelas con una variabilidad espectral menor. Todos los grupos presentan correlaciones significativas con la gran mayoría de las variables consideradas (generalmente con valores $p < 0,01$), a excepción del grupo delimitado con el primer percentil del CV debido a que solamente contiene 3 parcelas.

Los mejores coeficientes de correlación, en todos los grupos, se obtienen con variables que ofrecen información sobre humedad (TM5, TM7, TC3, MSI, MID57) y algunos de los índices de vegetación tradicionales calculados (NDVI, SAVI, OSAVI, MSAVI). Dentro de este grupo se encuentra también CP3, que recoge información sobre humedad. Los coeficientes de estas variables aumentan progresivamente a medida que lo hace la homogeneidad radiométrica de los grupos, pasando de valores situados entre 0,4 y 0,5, en el grupo del percentil 10, hasta $>0,78$, en el grupo del percentil 3, donde CP3, TC3 y MSI alcanzan una correlación superior a 0,85, siendo todas ellas altamente significativas ($p < 0,01$). En un segundo nivel, con correlaciones algo inferiores a las anteriores en todos o en casi todos los grupos, aparecen una serie de variables entre las cuales están las tres bandas del visible (TM1, TM2 y TM3), la suma de éstas (VIS123), el componente principal CP1 –relacionado con el brillo de la imagen–, los neocanales TC1 y TC2, dos índices de vegetación (GESAVI y GI) y el ABD, presentando también todos ellos valores de significación por debajo del nivel crítico 0,01. Por último, las peor correlacionadas con la biomasa residual son la banda TM4, cuya correlación deja de ser significativa a partir del grupo del percentil 5 y el CP2, que solamente muestra una correlación significativa con la biomasa en el grupo del percentil 5.

	Percentil 10	Percentil 9	Percentil 8	Percentil 7	Percentil 6	Percentil 5	Percentil 4	Percentil 3	Percentil 2	Percentil 1
Nº Parcelas	482	381	285	208	149	111	68	36	14	3
TM1	-0,435**	-0,493**	-0,500**	-0,529**	-0,550**	-0,513**	-0,542**	-0,708**	-0,647*	-0,993
TM2	-0,409**	-0,468**	-0,470**	-0,484**	-0,499**	-0,454**	-0,495**	-0,713**	-0,638*	-0,962
TM3	-0,413**	-0,474**	-0,477**	-0,492**	-0,512**	-0,464**	-0,512**	-0,734**	-0,673**	-0,952
TM4	-0,199**	-0,257**	-0,232**	-0,189**	-0,163**	-0,110	-0,213	-0,267	-0,573*	-0,791
TM5	-0,451**	-0,524**	-0,521**	-0,552**	-0,576**	-0,552**	-0,641**	-0,793**	-0,791**	-0,995
TM7	-0,452**	-0,521**	-0,523**	-0,562**	-0,603**	-0,571**	-0,639**	-0,788**	-0,780**	-0,989
CP1	-0,429**	-0,498**	-0,493**	-0,509**	-0,528**	-0,489**	-0,560**	-0,737**	-0,743**	-0,975
CP2	-0,032	0,012	-0,037	-0,087	-0,153	-0,194*	-0,115	-0,213	0,410	0,707
CP3	0,421**	0,474**	0,508**	0,590**	0,656**	0,663**	0,754**	0,869**	0,853**	0,942
TC1	-0,414**	-0,482**	-0,475**	-0,483**	-0,493**	-0,451**	-0,521**	-0,707**	-0,721**	-0,966
TC2	0,310**	0,334**	0,371**	0,436**	0,494**	0,506**	0,546**	0,664**	0,425	0,758
TC3	0,453**	0,525**	0,541**	0,603**	0,654**	0,645**	0,750**	0,852**	0,852**	0,999*
NDVI	0,457**	0,510**	0,525**	0,587**	0,634**	0,605**	0,684**	0,807**	0,737**	0,991
SAVI	0,455**	0,507**	0,523**	0,585**	0,632**	0,603**	0,682**	0,805**	0,735**	0,990
MSAVI	0,448**	0,501**	0,518**	0,578**	0,626**	0,598**	0,669**	0,797**	0,713**	0,991
OSAVI	0,457**	0,509**	0,525**	0,587**	0,633**	0,604**	0,683**	0,806**	0,737**	0,991
GESAVI	0,410**	0,454**	0,467**	0,529**	0,560**	0,532**	0,635**	0,741**	0,736**	0,919
GI	0,307**	0,371**	0,391**	0,448**	0,528**	0,523**	0,655**	0,724**	0,814**	0,882
MSI	-0,458**	-0,518**	-0,540**	-0,618**	-0,669**	-0,674**	-0,772**	-0,883**	-0,864**	-0,902
VIS123	-0,422**	-0,482**	-0,486**	-0,505**	-0,523**	-0,477**	-0,517**	-0,728**	-0,662**	-0,981
MID57	-0,454**	-0,525**	-0,525**	-0,558**	-0,590**	-0,562**	-0,641**	-0,792**	-0,787**	-0,993
ABD	-0,430**	-0,497**	-0,493**	-0,509**	-0,526**	-0,486**	-0,551**	-0,735**	-0,732**	-0,976

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 3.3. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes radiométricas continuas en cada uno de los grupos delimitados usando el CV

Con referencia al signo de estos coeficientes de correlación, la biomasa residual presenta una relación inversa con todas las bandas reflectivas proporcionadas por el sensor TM, situación observada en otros trabajos que han estudiado las relaciones entre las bandas de este sensor y la variable biomasa (p.e. Jakubauskas, 1996; Steininger, 2000; Lu *et al.*, 2004; Lu y Batistella, 2005). En el caso de las bandas del visible y las del infrarrojo medio, esta situación era esperada ya que, normalmente, existe una relación inversa entre la cantidad de vegetación y la reflectividad en estas partes del espectro debido a la absorción de los pigmentos de la vegetación y a su contenido en agua, respectivamente. Así pues, dentro de este grupo llama la atención el comportamiento de TM4, ya que, habitualmente, a mayor cantidad de vegetación, mayor reflectividad en esta banda (Mallinis *et al.*, 2004). Esta relación inversa puede estar explicada por dos motivos: en primer lugar porque en bosques mediterráneos de estructura abierta la importante presencia de vegetación arbustiva hace que la respuesta espectral en esta banda aumente (Mallinis *et al.*, 2004), siendo responsable esta situación de altas reflectividades cuando la biomasa forestal es escasa; en segundo lugar porque debido a la influencia de las sombras, la reflectividad registrada en TM4 es menor a medida que el bosque va alcanzando un estado más maduro y los árboles alcanzan mayor porte (Gerylo *et al.*, 2002), lo que hace que en los lugares de mayor concentración de biomasa residual la respuesta sea baja.

En cuanto al signo de los coeficientes para los neocanales generados, las correlaciones son también inversas con las variables relacionadas con el brillo de la imagen (CP1, TC1 y ABD), ya que a mayor brillo en estos canales menor cantidad de vegetación, con los índices MSI y MID57, debido a que estos últimos están relacionados inversamente con el contenido de humedad de las masas forestales, y con VIS123, ya que, como hemos indicado, en estas bandas se produce la absorción de la energía por parte de los pigmentos fotosintéticos. Por el contrario, la biomasa residual tiene una relación positiva con TC2 (verdor), con TC3 y CP3, que están relacionados directamente con la variable humedad, y, finalmente, con todos los índices clásicos de vegetación calculados.

Con respecto a la correlación entre la biomasa residual y las variables topográficas cuantitativas, la Tabla 3.4 muestra los resultados obtenidos en cada uno de los 10 grupos delimitados.

	Percentil 10	Percentil 9	Percentil 8	Percentil 7	Percentil 6	Percentil 5	Percentil 4	Percentil 3	Percentil 2	Percentil 1
Nº Parcelas	482	381	285	208	149	111	68	36	14	3
Elevación	0,158**	0,131*	0,124*	0,136	0,122	0,055	0,004	-0,017	-0,693**	-0,887
Pendiente	-0,085	-0,044	-0,061	-0,041	-0,032	-0,002	0,008	0,009	0,136	-0,049
INS_POT_HORAS	0,072	0,035	0,066	0,056	0,045	0,060	0,064	0,133	0,109	0,180
INS_POT	-0,090*	-0,095	-0,089	-0,081	-0,058	-0,081	-0,061	-0,065	-0,024	0,019
PRI_POT_HORAS	0,071	0,028	0,072	0,067	0,038	0,025	0,012	0,095	0,000	0,123
PRI_POT	-0,094*	-0,097	-0,093	-0,085	-0,062	-0,088	-0,070	-0,077	-0,038	-0,011
VER_POT_HORAS	0,162**	0,118*	0,151*	0,120	0,103	0,139	0,154	0,218	-0,008	0,086
VER_POT	0,079	0,038	0,046	0,023	0,028	0,048	0,065	0,120	-0,025	0,221
OTO_POT_HORAS	0,071	0,028	0,072	0,067	0,038	0,025	0,012	0,095	0,000	0,123
OTO_POT	-0,094*	-0,097	-0,093	-0,085	-0,062	-0,088	-0,070	-0,077	-0,038	-0,011
INV_POT_HORAS	-0,003	-0,030	-0,025	-0,027	-0,036	-0,030	0,003	-0,005	0,045	0,100
INV_POT	-0,120**	-0,114*	-0,106	-0,091	-0,066	-0,091	-0,071	-0,081	0,001	-0,015
CURVA	0,035	-0,020	-0,034	-0,016	-0,039	0,117	0,143	0,113	0,070	-0,159

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 3.4. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes topográficas continuas en cada uno de los grupos delimitados usando el CV

Como se observa en esta tabla, solamente seis variables muestran correlaciones estadísticamente significativas cuando se considera el grupo que incluye todas las parcelas: Elevación, VER_POT_HORAS, INV_POT, INS_POT, PRI_POT y OTO_POT, siendo las tres primeras significativas con un nivel $<0,01$ y las tres últimas con un nivel $<0,05$. En el siguiente grupo de parcelas, el del percentil 9, sólo las tres primeras siguen manteniendo una relación significativa, pero con un nivel crítico $<0,05$, y en el grupo del percentil 8 sólo Elevación y VER_POT_HORAS logran superar este test estadístico. El resto de grupos de parcelas no presenta correlación alguna con las variables topográficas empleadas en este trabajo (a excepción de Elevación en el grupo del percentil 2, lo que se debe, sin duda, al azar estadístico).

El análisis de los signos en las correlaciones significativas más importantes muestra que la biomasa residual tiene una relación positiva con Elevación y VER_POT_HORAS, por lo que a mayor altitud y mayor cantidad de iluminación recibida en verano mayor cantidad de biomasa residual en las masas forestales. El signo negativo de INV_POT indica que a mayor iluminación recibida en invierno menor cantidad de biomasa residual.

Así pues, teniendo en cuenta los resultados obtenidos del análisis de correlaciones entre la biomasa residual y las variables radiométricas y topográficas, se desprende que las primeras son más útiles para el propósito de ajustar modelos de regresión, ya que los coeficientes obtenidos son más altos que los de las topográficas en todos los grupos delimitados y su significación estadística es más sólida. No obstante, las variables topográficas identificadas como significativas pueden ser incluidas en el ajuste de los modelos de los grupos en los que aparecen.

Para evitar ajustar un modelo para cada grupo de parcelas definido por su grado de heterogeneidad radiométrica se estudió si era posible definir clústeres con estos grupos que representaran situaciones similares. Para delimitar estos clústeres se determinó que lo más adecuado era considerar la variable independiente que apareciera como mejor correlacionada en el mayor número de grupos, ya que ésta es la que más relación presenta con la biomasa residual independientemente del grado de homogeneidad de la muestra. Esta variable resultó ser el índice MSI, debido a que es la que mejor coeficiente de correlación tiene en 7 de los 9 grupos en los que muestra correlaciones significativas.

La Figura 3.2 muestra las correlaciones en valores absolutos entre MSI y la biomasa residual en cada uno de los 10 grupos; sobre esta figura se han delimitado los clústeres que permiten concentrar los grupos de parcelas en unidades mayores que presentan un comportamiento similar en cuanto a grado de heterogeneidad-homogeneidad de las parcelas y valor de la correlación entre MSI y biomasa residual. Así, el primer clúster contiene los grupos de los percentiles 10, 9 y 8; estos grupos tienen en común el gran número de parcelas que compone cada uno de ellos (entre 482 y 285) y el bajo coeficiente de correlación (entre 0,400 y 0,600). El segundo clúster engloba a los grupos de los percentiles 7, 6 y 5, ya que tienen un tamaño muestral y unos coeficientes de correlación intermedios (entre 0,600 y 0,700). El tercer clúster está compuesto únicamente por el grupo del percentil 4, ya que -como se observa en la Figura 3.2- supone un paso intermedio entre el clúster 2 y 4; este tercer clúster está caracterizado por representar una muestra de parcelas muy homogénea pero con un número suficiente para establecer un modelo predictivo y por un coeficiente de correlación alto (>0,700). Por último, el clúster 4 incluye los grupos percentil 3, 2 y 1; este clúster representa los grupos con parcelas más homogéneas, aunque el número de parcelas que los componen es *a priori* pequeño para poder establecer modelos válidos para toda el área de estudio.

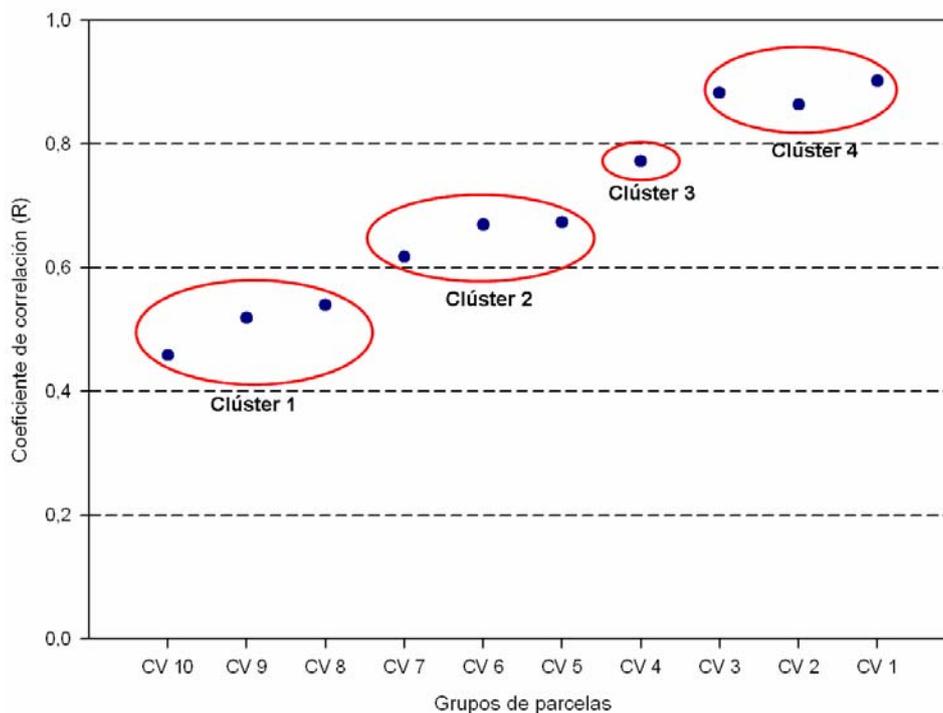


Figura 3.2. Clústeres de agrupación de grupos identificados sobre el gráfico de correlaciones entre MSI y la biomasa residual forestal para cada grupo de parcelas delimitado usando el CV en la imagen de junio de 1994

Teniendo en cuenta estos resultados, se decidió la conveniencia de establecer modelos de regresión para cada uno de los clústeres definidos. Se pretende así estudiar la influencia que tiene el grado de homogeneidad de la muestra y el tamaño de la misma en la calidad de la estimación de la biomasa residual forestal en la provincia de Teruel:

- (i) Para ajustar el modelo representativo del primer clúster se escogió el grupo de percentil 10, ya que de los tres incluidos es el que cuenta con un mayor número de parcelas. Así, este modelo tendrá en cuenta todas las parcelas disponibles (482) y mostrará la viabilidad de evaluar la biomasa residual del área de estudio sin eliminar los problemas de heterogeneidad radiométrica relacionada con la presencia de otros elementos del paisaje en la parcela, localización, etc.
- (ii) El mayor tamaño muestral es también el motivo de la elección del percentil 7 en el clúster 2. Este grupo está compuesto por 208 parcelas, lo que hace presumir que el resultado obtenido es válido para ajustar un modelo adecuado para todo el área de estudio, excluyendo para ello a las parcelas con mayores problemas.
- (iii) El modelo del clúster 3 utilizará las 68 parcelas del grupo del percentil 4; este modelo será representante de un elevado grado de homogeneidad, aunque el pequeño número de parcelas puede hacer que esté sobre-ajustado.
- (iv) Por último, siguiendo el criterio de seleccionar para cada clúster el grupo con mayor número de parcelas, el último de los modelos utilizará las del grupo del percentil 3; el modelo resultante será el máximo exponente de homogeneidad, pero la escasa muestra considerada para su ajuste indica que el resultado obtenido no podrá ser generalizable a todo el área de estudio; sin embargo, este modelo permitirá verificar cuál es la variable que mejor representa las relaciones biofísicas existentes entre la biomasa residual forestal y la información espectral suministrada por las imágenes de satélite Landsat.

3.1.1.3. Ajuste de modelos de regresión

En este apartado se aplican los tres tipos de regresión considerados a cada uno de los clústeres definidos en el apartado anterior. En primer lugar, se utiliza la regresión logística, el más simple de los modelos, ya que solamente expresa la probabilidad de ocurrencia de un fenómeno (en este caso la existencia de una determinada cantidad de

biomasa) y permite la entrada de variables explicativas continuas y/o categóricas sin que tengan que cumplir el supuesto de normalidad, siendo el único requisito que no estén altamente correlacionadas entre sí. Así pues, este método permite obtener una primera aproximación sobre la influencia que la heterogeneidad de los bosques mediterráneos tiene en el ajuste de modelos predictivos, identificándose a su vez las variables más útiles para acometer este propósito. En segundo lugar, se aplica la regresión simple, lineal o curvilínea. De esta forma se obtiene información sobre la forma de la relación existente entre la biomasa residual forestal y cada una de las variables independientes consideradas y una primera aproximación a la posibilidad real de encontrar modelos que permitan cuantificar de manera más precisa que los logísticos la cantidad de biomasa residual (tons/ha) existente en cada zona del territorio. Por último, teniendo en cuenta los resultados obtenidos con los dos primeros modelos y vigilando el estricto cumplimiento de todos los supuestos básicos que le afectan, se utiliza el modelo de regresión lineal múltiple que, en teoría, debe proporcionar la estimación de la biomasa residual forestal más precisa al considerar un mayor número de variables explicativas.

3.1.1.3.1. Modelos de regresión logística

- Modelo de regresión logística del primer clúster

El grupo del percentil 10, el de mayor número de parcelas (482), permite constatar la viabilidad de evaluar la biomasa residual forestal sin eliminar los problemas de heterogeneidad radiométrica. Tal y como se ha indicado anteriormente, el único requisito de la regresión logística es que las variables independientes consideradas para ajustar el modelo no estén auto-correlacionadas entre sí. Así pues, el primer paso que se impone para el ajuste del modelo es analizar cómo son las auto-correlaciones entre las variables independientes.

La Figura 3.3 muestra las auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual. En esta figura se observa cómo las correlaciones entre las variables radiométricas son muy altas, siendo bajas entre éstas y las topográficas y altas otra vez si solamente se consideran las de este último grupo. De esta manera, para dar estabilidad y robustez al modelo de regresión, se decidió seleccionar en primer lugar la variable más correlacionada con la biomasa residual forestal (MSI, $R=-0,458$) e incluir en el modelo de regresión por pasos el resto de variables independientes que, estando relacionadas con la biomasa, lo están menos con esta variable radiométrica.

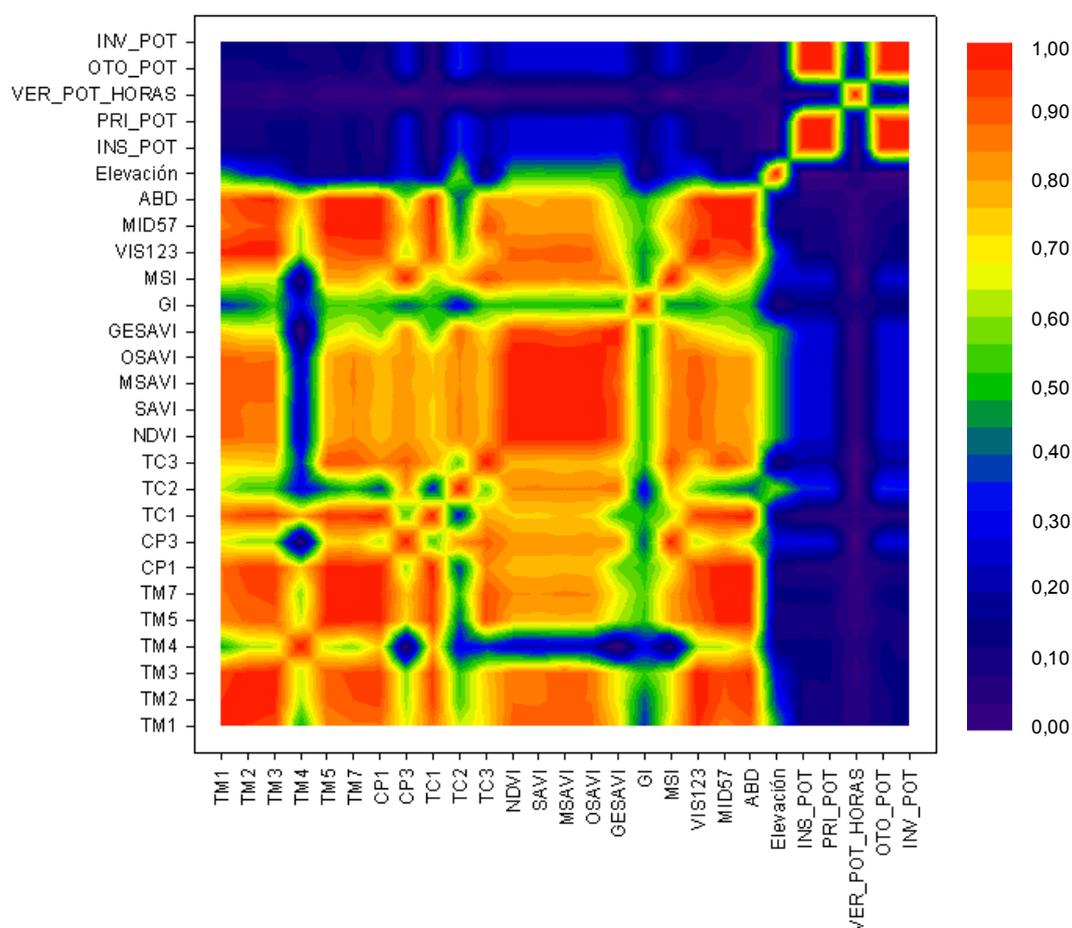


Figura 3.3. Auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual en el grupo del percentil 10 de la imagen de junio de 1994

En el análisis de las correlaciones parciales del MSI se detectó que este índice no presentaba correlación alguna con TM4 (0,076), existiendo una alta correlación con el resto de variables radiométricas. En cuanto a la correlación de MSI y TM4 con las variables topográficas, todas ellas muestran correlaciones bajas, por lo que pueden ser utilizadas en el modelo de regresión logística junto a las dos radiométricas seleccionadas. Sin embargo, la alta auto-correlación que existe entre las variables que modelan la insolación potencial en términos de iluminación recibida hizo que solamente se introdujera la variable INV_POT, ya que ésta es la que presenta una correlación más alta y más significativa con la variable dependiente.

Por último, para poder incluir en el modelo de regresión logística las variables categóricas forestales COD_TCE y COD_MADUREZ y la topográfica Orientación, todas ellas se reclasificaron como variables binarias. Esta reclasificación se hizo utilizando la información obtenida en las ventanas 3x3 de tal manera que, en cada una de ellas, el

valor 0 se asignó a aquellas categorías que contenían las parcelas con menores cantidades de biomasa residual, mientras que el valor 1 se reservó para las que presentaban mayores valores. Así, en el caso de la variable COD_TCE, las clases Esclerófilo y Subsclerófilo quedaron asignadas al grupo 0, mientras que la clase Taiga fue reclasificada como grupo 1. Por su parte, en la variable COD_MADUREZ, dentro del grupo 0 quedaron incluidas las masas forestales que tienen un nivel de madurez inferior al estadio 6, mientras que el grupo 1 quedó compuesto por las masas de nivel de madurez 6 y 7. Por último, las orientaciones Norte (NO, N y NE) fueron reclasificadas con el valor 0 y las de componente Sur (SO, S y SE) con valor 1.

Una vez determinadas las variables a introducir en el modelo de regresión logística, se procedió a la adaptación de la variable dependiente a las necesidades de este tipo de regresión; es decir, se procedió a la transformación de la variable continua biomasa residual a una variable categórica binaria (0/1), dividiéndose la variable en tres grupos iguales en función de la cantidad. El valor de corte para definir el grupo de menor cantidad de biomasa residual (grupo 0) fue 7,488 tons/ha, mientras que el valor para el grupo de mayor cantidad de biomasa (grupo 1) fue 18,865 tons/ha; el grupo de parcelas situado entre estos dos valores fue eliminado de la muestra, quedando 322 parcelas para el ajuste del modelo y su posterior validación.

Como se ha apuntado en el apartado de validación de los modelos de regresión, se calcularon un total de cinco modelos, utilizando para ello distintas divisiones aleatorias de la muestra en 2 grupos: 80% de las parcelas (cálculo del modelo) y 20% de las parcelas (validación de ese modelo). Este método de validación se repite también en los modelos de los siguientes subapartados.

En este caso, los cinco modelos obtenidos seleccionaron tres variables: MSI, TM4 y COD_MADUREZ, siendo todos ellos significativos con un $p < 0,05$, si bien es cierto que, en uno de ellos, la incorporación de la variable COD_TCE mejora ligeramente las estadísticas globales del modelo (el R^2 de Nagelkerque, el test de Hosmer-Lemeshow y los porcentajes de acierto en la tabla de clasificación). Sin embargo, dado que en los cuatro modelos restantes esta variable no fue incorporada y el escaso aporte explicativo que tiene en el que fue añadida, se concluye que la inclusión de la misma en uno de los modelos se debe a la selección azarosa de las parcelas para el ajuste de ese modelo, por lo que su consideración como variable explicativa fue descartada.

Así, los cuatro modelos que incorporan las variables MSI, TM4 y COD_MADUREZ ajustan adecuadamente los datos utilizados según el test de Hosmer-Lemeshow, ya que todos superan de forma clara el mínimo requerido ($p > 0,05$). Los R^2 de Nagelkerque obtenidos oscilan entre 0,429 y 0,473 y los porcentajes de acierto en la tabla de clasificación entre 77,8% y 79,4%.

Los coeficientes y estadísticos de las variables MSI, TM4 y COD_MADUREZ son casi idénticos en los cuatro modelos. La Tabla 3.5 recoge los coeficientes y estadísticos de uno de los modelos calculados. La interpretación de los valores de β y de $Exp(\beta)$ de cada una de las variables permite conocer la contribución que cada variable predictora tiene en el ajuste del modelo, así como la explicación física del mismo.

Así, en el análisis global del modelo, se observa cómo las variables MSI y COD_MADUREZ son las que tienen una mayor importancia, ya que sus $Exp(\beta)$ son los que están más alejados del valor 1 (0,002 y 2,910, respectivamente); la participación de TM4 es muy poco importante, tal y como indica su $Exp(\beta)$ (0,802). De esta manera, TM4 es, de las tres variables, la que menor carga explicativa aporta al modelo.

Variable	β	S_e	Wald	Sig.	$Exp(\beta)$
MSI	-6,379	0,998	40,840	0,000	0,002
TM4	-0,221	0,054	16,492	0,000	0,802
COD_MADUREZ	1,068	0,315	11,482	0,001	2,910
Constante	9,874	1,545	40,823	0,000	19412,957

Tabla 3.5. Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 1, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$

El análisis del signo de los coeficientes β ayuda en la interpretación física de cada una de estas variables. Como se ha apuntado con anterioridad, la variable MSI está relacionada de forma inversa con el contenido de humedad, de tal forma que cuanto menor es la humedad, mayor es el valor de MSI. En las cubiertas forestales, esta variable presenta valores bajos, ya que las masas forestales tienen un alto contenido de humedad; así, el signo negativo del coeficiente β indica que cuanto mayor sea la humedad de la masa forestal (menor valor de MSI), mayor cantidad de biomasa forestal.

Por su parte, el signo negativo del coeficiente de TM4 indica que cuanto mayor es la reflectividad en esta banda, menor es la cantidad de biomasa residual forestal; como se ha indicado más arriba, esta situación está relacionada con la estructura de los bosques mediterráneos. De esta manera, esta banda actúa como complementaria de la variable MSI e indica la existencia de parcelas heterogéneas típicas de los ambientes

mediterráneos.

Por último, el sentido positivo del coeficiente β de la variable COD_MADUREZ señala que si las masas de pináceas pertenecen al nivel de madurez 6 y 7 tienen más biomasa residual que las que se sitúan en niveles inferiores a éstos. Este resultado es coherente, ya que las masas forestales que presentan una mejor adaptación a las condiciones del medio, con un mejor aprovechamiento de la potencialidad natural, son las que producen mayor cantidad de biomasa residual.

Para la validación de cada uno de estos cuatro modelos se utilizó el estadístico *Kappa* con la muestra del 20% reservada a tal fin en cada uno de ellos. Los resultados de este estadístico varían entre 0,539 y 0,638.

La utilización de las variables de la Tabla 3.5 con sus respectivos coeficientes β permite cartografiar la probabilidad de biomasa residual forestal de los bosques de pináceas de la provincia de Teruel (Figura 3.4). En esta cartografía, el valor de cada píxel oscila entre 0 y 1, siendo 0,5 el umbral de probabilidad que determina si un píxel pertenece al grupo 1 (cantidad de biomasa residual $\geq 18,865$ tons/ha) o al grupo 0 (biomasa residual $\leq 7,488$ tons/ha).

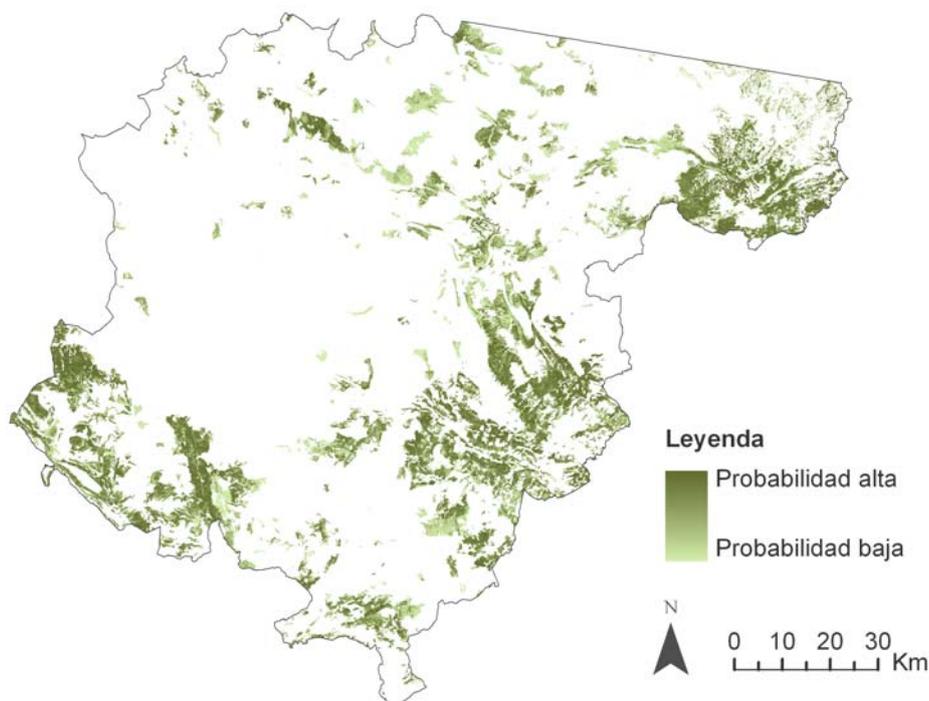


Figura 3.4. Cartografía de probabilidad de existencia de biomasa residual forestal con respecto a los umbrales de corte definidos usando las parcelas del primer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

- Modelo de regresión logística del segundo clúster

Como se ha indicado previamente, el mayor tamaño muestral del grupo delimitado por el percentil 7 es el motivo que lleva a seleccionar este grupo dentro del clúster 2. Compuesto por un total de 208 parcelas, es presumible la validez del resultado obtenido para ajustar un modelo adecuado para toda el área de estudio.

En este grupo, sólo las variables independientes radiométricas presentan correlaciones significativas con la variable dependiente biomasa residual forestal, por lo que ninguna de las topográficas continuas fue incluida para el ajuste del modelo. Las variables categóricas Orientación, COD_TCE y COD_MADUREZ sí que fueron incluidas en el modelo utilizando la reclasificación binaria de sus categorías mostrada en el anterior subapartado.

El análisis de correlaciones parciales entre las variables radiométricas volvió a mostrar la existencia de altas correlaciones entre todas ellas, siendo superiores a las observadas en el grupo del percentil 10. Sin duda, este hecho se debe al aumento de la homogeneidad radiométrica de las parcelas consideradas, lo que hace que las relaciones entre estas variables sean más consistentes.

Así, la forma de proceder fue igual que en el caso anterior: la variable radiométrica más correlacionada con la variable dependiente fue seleccionada en primer lugar, haciéndolo después las variables que, también relacionadas significativamente con la dependiente, lo estuvieran menos con la independiente escogida. De esta manera, MSI volvió a ser la variable más correlacionada con la biomasa residual forestal ($R=-0,618$) y TM4 la menos correlacionada con ésta que sí lo estaba con la biomasa.

En este caso, para binarizar la variable dependiente biomasa residual forestal, el umbral de corte para definir el grupo 0 fue 7,284 tons/ha, mientras que el valor para el grupo 1 fue de 18,213 tons/ha, quedando 138 parcelas para el ajuste del modelo y su posterior validación tras la eliminación de las situadas entre estos dos valores.

Los cinco modelos ajustados seleccionaron las variables MSI y COD_MADUREZ, siendo todos ellos significativos al nivel de $p>0,05$ y superando ampliamente el Test de Hosmer-Lemeshow ($p>0,05$). Los R^2 de Nagelkerque de estos modelos son superiores a los del anterior grupo y varían entre 0,574 y 0,605. El porcentaje de acierto en la tabla de clasificación superó en todos ellos el 80% (entre 82,9% y 85,1%). El estadístico *Kappa* obtenido con la muestra de validación superó en cuatro de los cinco modelos el valor

máximo obtenido considerando todas las parcelas (0,638), llegando a alcanzar uno de los modelos un *Kappa* de 0,690.

La Tabla 3.6 muestra los estadísticos de las variables seleccionadas en uno de los cinco modelos calculados. Como se observa en ella, los coeficientes β de MSI y COD_MADUREZ mantienen el mismo signo que los modelos que utilizaban todas las parcelas, por lo que su explicación física es la misma. Por su parte, el $Exp(\beta)$ indica que las dos variables son importantes en el modelo, ya que ambas se encuentran muy alejadas del valor 1. La Figura 3.5 muestra la cartografía de probabilidad de biomasa residual forestal utilizando los coeficientes y variables de la Tabla 3.6.

Variable	β	S_e	Wald	Sig.	$Exp(\beta)$
MSI	-9,314	1,922	23,491	0,000	0,000
COD_MADUREZ	1,344	0,561	5,739	0,017	3,835
Constante	8,003	1,864	18,433	0,000	2990,944

Tabla 3.6. Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 2, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$

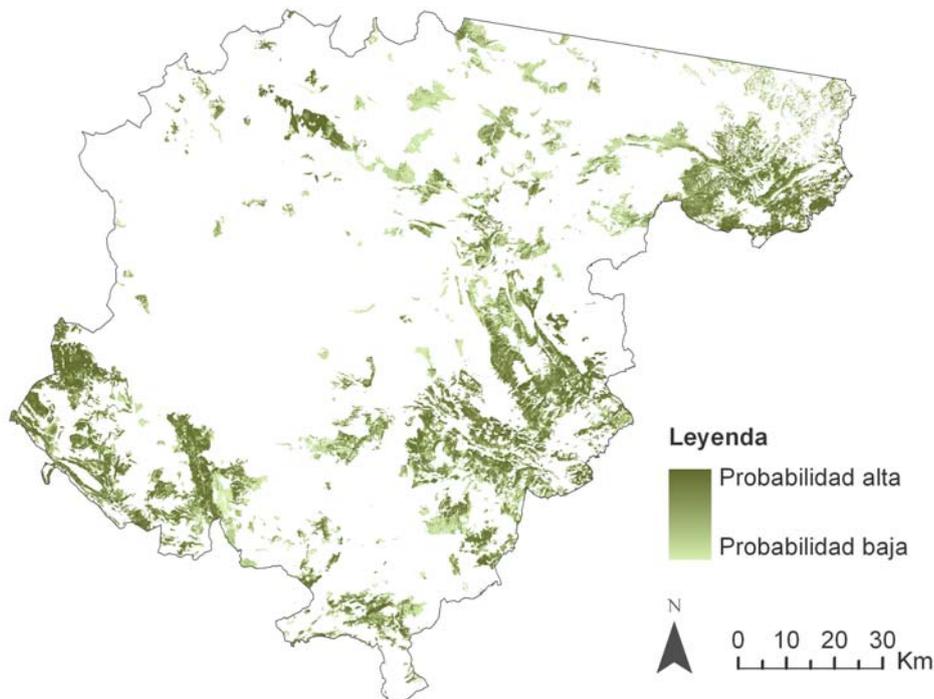


Figura 3.5. Cartografía de probabilidad de existencia de biomasa residual forestal con respecto a los umbrales de corte definidos usando las parcelas del segundo clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

- Modelo de regresión logística del tercer clúster

Este modelo utiliza las 68 parcelas del grupo del percentil 4, por lo que el modelo que se ajusta con ellas es representante de una situación de alta homogeneidad. Al igual que en los casos anteriores, la variable MSI es también la variable independiente radiométrica más correlacionada con las parcelas incluidas en este grupo ($R = -0,772$). En este caso, no se encontró ninguna otra variable radiométrica correlacionada con la biomasa residual que lo estuviera poco con el índice MSI. Debido a esto y a la inexistencia de correlaciones con las variables topográficas, solamente MSI y las tres variables categóricas son tenidas en cuenta para el cálculo del modelo de este grupo. Los umbrales utilizados para delimitar los grupos 0 y 1 de la variable dependiente fueron 6,295 tons/ha y 17,521 tons/ha, respectivamente, resultando 46 parcelas.

En los cinco modelos obtenidos, la única variable incluida fue MSI, resultando todos ellos significativos al nivel de $p < 0,05$. Además, los valores obtenidos en el test de Hosmer-Lemeshow indican que los datos han sido ajustados correctamente (valores de p siempre superiores a 0,700). Por su parte, los R^2 de Nagelkerque ascienden a valores por encima de 0,700 (entre 0,740 y 0,775), mientras que los porcentajes de acierto en las tablas de clasificación de estos modelos oscilan entre 88,9% y 90,5%. Por último, señalar que los valores del estadístico *Kappa* de la muestras de validación alcanzan el 1,000 en las cinco pruebas.

La Tabla 3.7 recoge los estadísticos de uno de los cinco modelos ajustados para este clúster. Al igual que en los anteriores, el signo del coeficiente β de MSI es negativo, por lo que la explicación física es la misma. La Figura 3.6 corresponde a la cartografía de la biomasa residual forestal obtenida con los coeficientes de esta última tabla.

Variable	β	S_e	Wald	Sig.	$Exp(\beta)$
MSI	-17,685	5,642	9,827	0,002	0,000
Constante	17,482	5,680	9,472	0,002	3,91E+07

Tabla 3.7. Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 3, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$

- Modelo de regresión logística del cuarto clúster

Una vez más, la variable más correlacionada con el grupo seleccionado en este clúster fue el índice MSI ($R = -0,883$). Al igual que en el caso anterior, la no existencia de otras variables correlacionadas con la biomasa residual que no lo estuvieran altamente con MSI y la falta de correlación entre la biomasa residual y las variables topográficas

hizo que en el modelo solamente se introdujeran el índice MSI y las variables categóricas. El valor de corte para definir el grupo 0 de biomasa residual fue 5,494 Ton/ha y el del grupo 1 fue 21,606 Ton/ha, quedando solamente 24 parcelas para ajustar el modelo de regresión logística.

Dado el bajo número de parcelas que compone la muestra seleccionada para trabajar en este clúster representante del máximo grado de homogeneidad, la división aleatoria de la misma para el ajuste de los modelos y su validación se modificó con respecto a los anteriores clústeres, utilizando el 70% para la calibración del modelo y reservando el 30% para la validación. Esto se hace para disponer de un número mayor de parcelas en el proceso de validación.

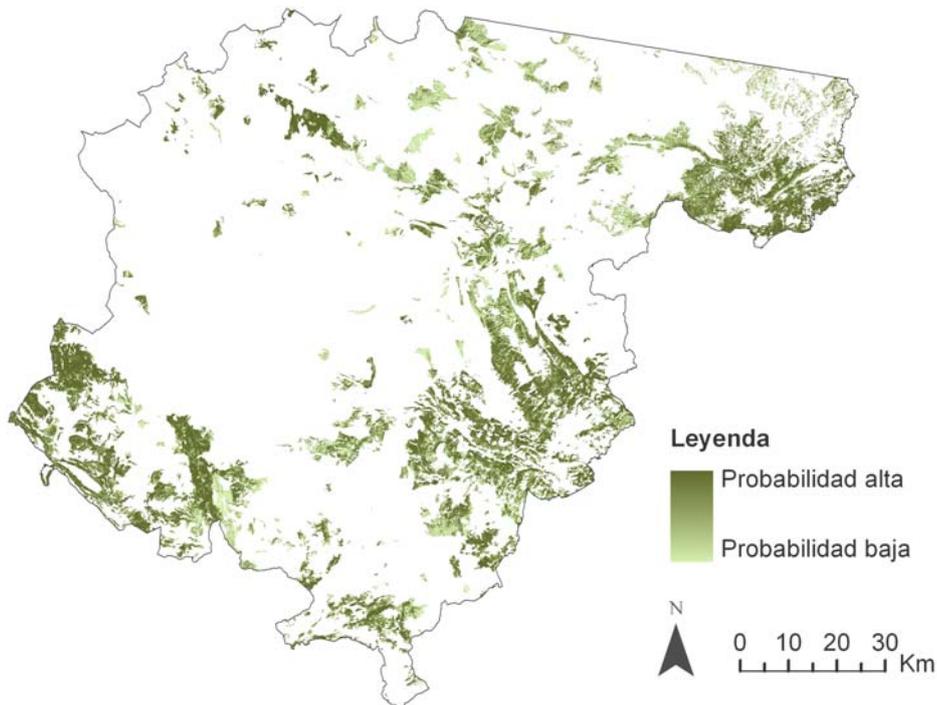


Figura 3.6. Cartografía de probabilidad de existencia de biomasa residual forestal con respecto a los umbrales de corte definidos usando las parcelas del tercer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

La variable MSI fue la única incluida en todos los modelos, resultando todos ellos significativos al nivel de $p < 0,05$, siendo también los valores obtenidos en el Test de Hosmer-Lemeshow muy superiores a este valor. Los R^2 de Nagelkerque son muy altos y varían entre 0,754 y 0,898.

Sin embargo, a pesar de estos buenos datos globales, dos de los cinco modelos ajustados no son válidos ya que sus estadísticos de significación de las variables (MSI y constante) indican que su significación está por encima del nivel de $p < 0,05$. En la Tabla 3.8 se reproduce uno de estos dos modelos. Además, el coeficiente Kappa de uno de estos dos modelos tampoco supera el test de significación.

Los otros tres modelos sí que pasan los niveles establecidos de significación estadística, obteniéndose en todos ellos valores *Kappa* de 1,000 en sus respectivas muestras de validación.

Variable	β	S_e	Wald	Sig.	$Exp(\beta)$
MSI	-19,275	12,095	2,540	0,111	0,000
Constante	18,995	12,597	2,274	0,132	1,78E+08

Tabla 3.8. Variables incluidas en uno de los cinco modelos de regresión logística calculados para el clúster 4, coeficiente β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$

Esta inestabilidad en el ajuste de modelos debida, como se discutirá más adelante, al pequeño tamaño muestral considerado en este grupo, desaconseja su utilización para elaborar cartografía de probabilidad de existencia de biomasa residual del área de estudio.

3.1.1.3.2. Modelos de regresión simple

Como se ha indicado en el apartado dedicado a explicar los modelos de regresión curvilínea, en el presente trabajo solamente se consideran modelos univariantes, ya que resulta muy complicado formular modelos multivariantes no lineales, prefiriéndose la alternativa de transformar las variables cuando éstas presentan relaciones no lineales y ajustar modelos de regresión lineal múltiple.

Para determinar la forma de las relaciones se generaron gráficos de dispersión individuales entre la variable biomasa residual forestal y cada una de las independientes consideradas que resultaron significativas en el análisis de correlación. El análisis de los patrones obtenidos en estos gráficos de dispersión no sólo sirve para detectar el tipo de relaciones, sino también para determinar el tipo de expresión curvilínea que mejor describe esta relación, evitándose así el ajuste de modelos no adecuados a pesar de que puedan ofrecer mejores predicciones. Además, mediante este método gráfico es posible detectar la presencia de observaciones atípicas que caen fuera de las pautas generales del conjunto de datos o que ejercen una fuerte influencia en los resultados de la

regresión. Por último, también se obtiene una primera información acerca de las variables que tendrán que ser transformadas en la regresión lineal múltiple, así como del tipo de transformación que habrá que aplicar.

- *Modelos de regresión simple del primer clúster*

Las bajas correlaciones que las variables independientes presentaban con la biomasa residual forestal en el grupo de parcelas seleccionado en este clúster (las 482 que componen la muestra) indicaban ya *a priori* la escasa capacidad predictiva de los modelos de regresión univariantes que se iban a obtener. Aún así, se ajustaron modelos con todas las variables correlacionadas con la biomasa residual para conocer la forma de cada relación (lineal o curvilínea) y cuáles eran las más precisas. Para cada una de estas variables independientes se calcularon un total de cinco modelos, utilizando para ello muestras aleatorias del 80% de la muestra.

La visualización de los gráficos de dispersión individuales utilizando todas las parcelas disponibles mostró que la biomasa residual forestal presentaba relaciones no lineales con la mayoría de las variables independientes, aunque en el caso de algunos índices de vegetación (NDVI, SAVI, MSAVI, OSAVI, GI y MSI) y la variable topográfica Elevación también se podía ajustar una relación lineal. La Figura 3.7 muestra los gráficos de dispersión obtenidos con la banda reflectiva, el componente principal, el eje *Tasseled-Cap* y tres de los índices de vegetación que mayor correlación presentaban con la biomasa residual forestal. En cada uno de estos gráficos se ha representado la recta o curva que mejor describe la relación.

Tal y como se observa en la figura, existe una gran dispersión de los puntos entorno a la línea que mejor describe la relación de la biomasa residual con las variables independientes. Esta dispersión está relacionada, sin duda, con la gran heterogeneidad radiométrica de las parcelas que componen la muestra que, como se ha señalado, puede deberse a múltiples factores (errores de localización, presencia de otros elementos del paisaje...), lo que impide el ajuste de buenos modelos de estimación. A este respecto, la Tabla 3.9 recoge información sobre el mejor modelo obtenido con cada una de las variables independientes correlacionadas con la biomasa residual forestal⁴⁰. Todos ellos son significativos a nivel de modelo y a nivel de los coeficientes de regresión ($p < 0,05$).

⁴⁰ Para las variables INS_POT, PRI_POT y OTO_POT no se encontraron modelos significativos.

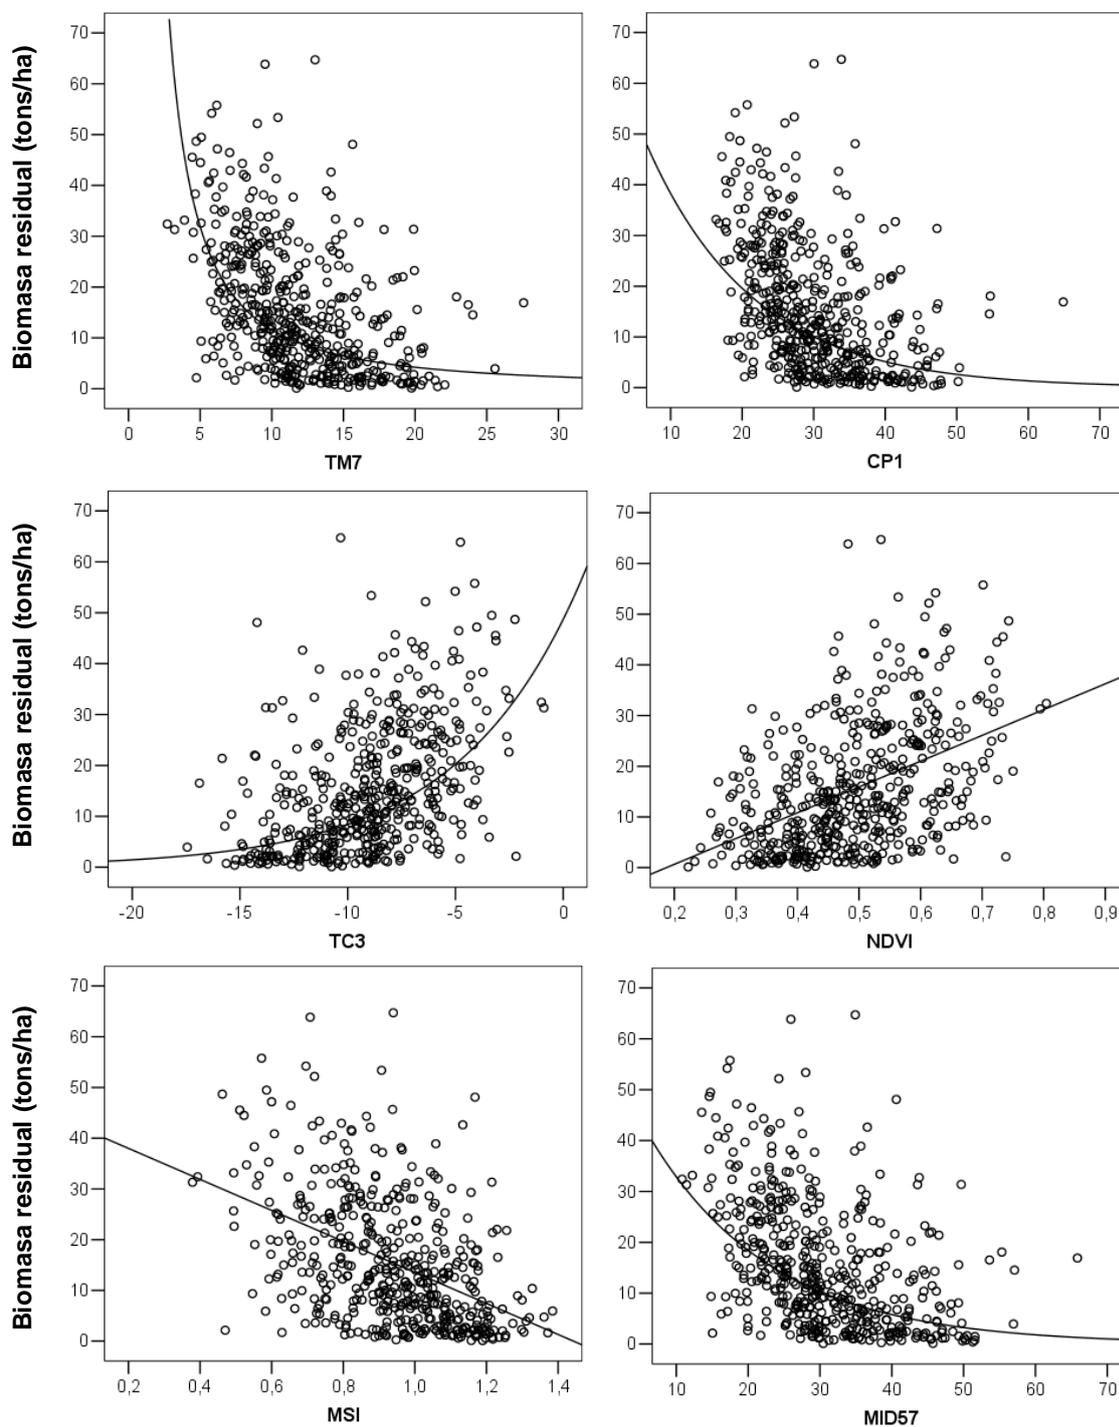


Figura 3.7. Gráficos de dispersión que relacionan la biomasa residual forestal con algunas de las variables independientes mejor correlacionadas usando las parcelas del clúster 1

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM1	Logarítmico	0,225	10,751	39,086	-16,457
TM2	Potencia	0,216	0,973	155,499	-1,560
TM3	Potencia	0,229	0,965	147,990	-1,448
TM4	Exponencial	0,060	1,065	59,895	-0,092
TM5	Exponencial	0,247	0,953	79,059	-0,113
TM7	Logarítmico	0,247	10,603	55,981	-17,063
CP1	Exponencial	0,231	0,963	88,660	-0,074
CP3	Exponencial	0,185	0,992	7,498	0,179
TC1	Exponencial	0,220	0,971	249,634	-0,086
TC2	Potencia	0,109	1,038	1,556	1,005
TC3	Exponencial	0,232	0,963	48,862	0,179
NDVI	Lineal	0,219	10,793	-10,334	51,469
SAVI	Lineal	0,217	10,808	-10,380	35,059
MSAVI	Lineal	0,212	10,843	-20,793	55,491
OSAVI	Lineal	0,219	10,798	-10,349	51,829
GESAVI	Logarítmico	0,189	11,005	13,102	10,431
GI	Lineal	0,094	11,627	20,337	102,943
MSI	Lineal	0,218	10,806	43,297	-30,089
VIS123	Potencia	0,229	0,965	743,092	-1,537
MID57	Exponencial	0,249	0,952	63,994	-0,062
ABD	Exponencial	0,232	0,963	85,747	-0,032
Elevación	Lineal	0,028	12,046	8,947	0,005
VER_POT_HORAS	Logarítmico	0,024	12,070	-48,952	24,555
INV_POT	Exponencial	0,012	1,092	12,878	-0,001

Tabla 3.9. Modelos de regresión simple calculados para el clúster 1: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

Como se observa en la tabla, los modelos ajustados presentan una capacidad predictiva muy baja, por lo que ninguno de ellos puede ser utilizado para la estimación de biomasa residual. Dentro de estos pobres resultados, los mejores son los obtenidos con las variables radiométricas relacionadas con el contenido de humedad de la vegetación MID57, TM5 y TM7 ($R^2 > 0,240$), siendo el modelo exponencial el que mejor describe la relación de la biomasa residual con las dos primeras y el logarítmico con la última. En el otro extremo, los peores modelos de estimación individuales se obtienen con las variables radiométricas GI y TM4 ($R^2 < 0,100$) y con las tres variables topográficas consideradas, no llegando a explicar ninguna de ellas más del 0,30% de la varianza de la variable dependiente, lo que confirma la escasa utilidad de este tipo de variables, ya detectada en los modelos de regresión logística.

En cuanto a los tipos de modelos ajustados, tal y como se había observado en los gráficos de dispersión, solamente en algunos de los índices de vegetación los modelos

lineales resultan más adecuados que los curvilíneos para predecir la biomasa residual. Este hecho señala que será necesario aplicar transformaciones para ajustar los modelos de regresión lineal múltiple del siguiente apartado si se quiere cumplir con los supuestos básicos de este tipo de regresión.

Dada la baja capacidad predictiva de los modelos ajustados, no se llegó a utilizar la muestra reservada para la validación de cada uno de ellos, ya que se sabía *a priori* que los errores iban a ser muy altos. Asimismo, siguiendo este criterio, no se elaboró ninguna cartografía de estimación de la biomasa residual del área de estudio.

- Modelos de regresión simple del segundo clúster

Los gráficos de dispersión obtenidos al utilizar el grupo de parcelas seleccionado para este segundo clúster (las 208 del grupo del percentil 7) volvieron a mostrar los mismos patrones que en el caso anterior, por lo que se confirma que las relaciones entre la biomasa residual y las variables independientes son predominantemente curvilíneas.

Como era esperado por los resultados alcanzados en el ajuste de los modelos de regresión logística, la dispersión de los puntos en estos gráficos es mucho menor que en el caso anterior debido a que las parcelas de esta muestra presentan un entorno radiométrico mucho más homogéneo, aunque ésta sigue siendo demasiado grande para poder ajustar modelos estimativos de precisión. El hecho de que las parcelas pertenezcan a entornos radiométricos relativamente homogéneos en comparación con la muestra anterior permite que en estos gráficos se empiece a identificar la presencia de parcelas atípicas que caen fuera de las pautas generales observadas en el conjunto de datos y/o de parcelas influyentes que determinan la forma de la relación. En este sentido, en la Figura 3.8 se destacan algunas de estas parcelas que presentan un comportamiento atípico (en rojo) o influyente (en azul) en las variables independientes consideradas.

La presencia de casos atípicos y/o influyentes en cualquier relación de dependencia como la aquí estudiada condiciona, en gran medida, los resultados que se obtienen en los modelos de regresión predictivos, por lo que se aconseja eliminarlos para evitar errores en el ajuste y en la generalización de los resultados. La única premisa que debe cumplirse para su eliminación es que sean de carácter realmente excepcional, es decir, que no sean representativos de la población (Hair *et al.*, 1999).

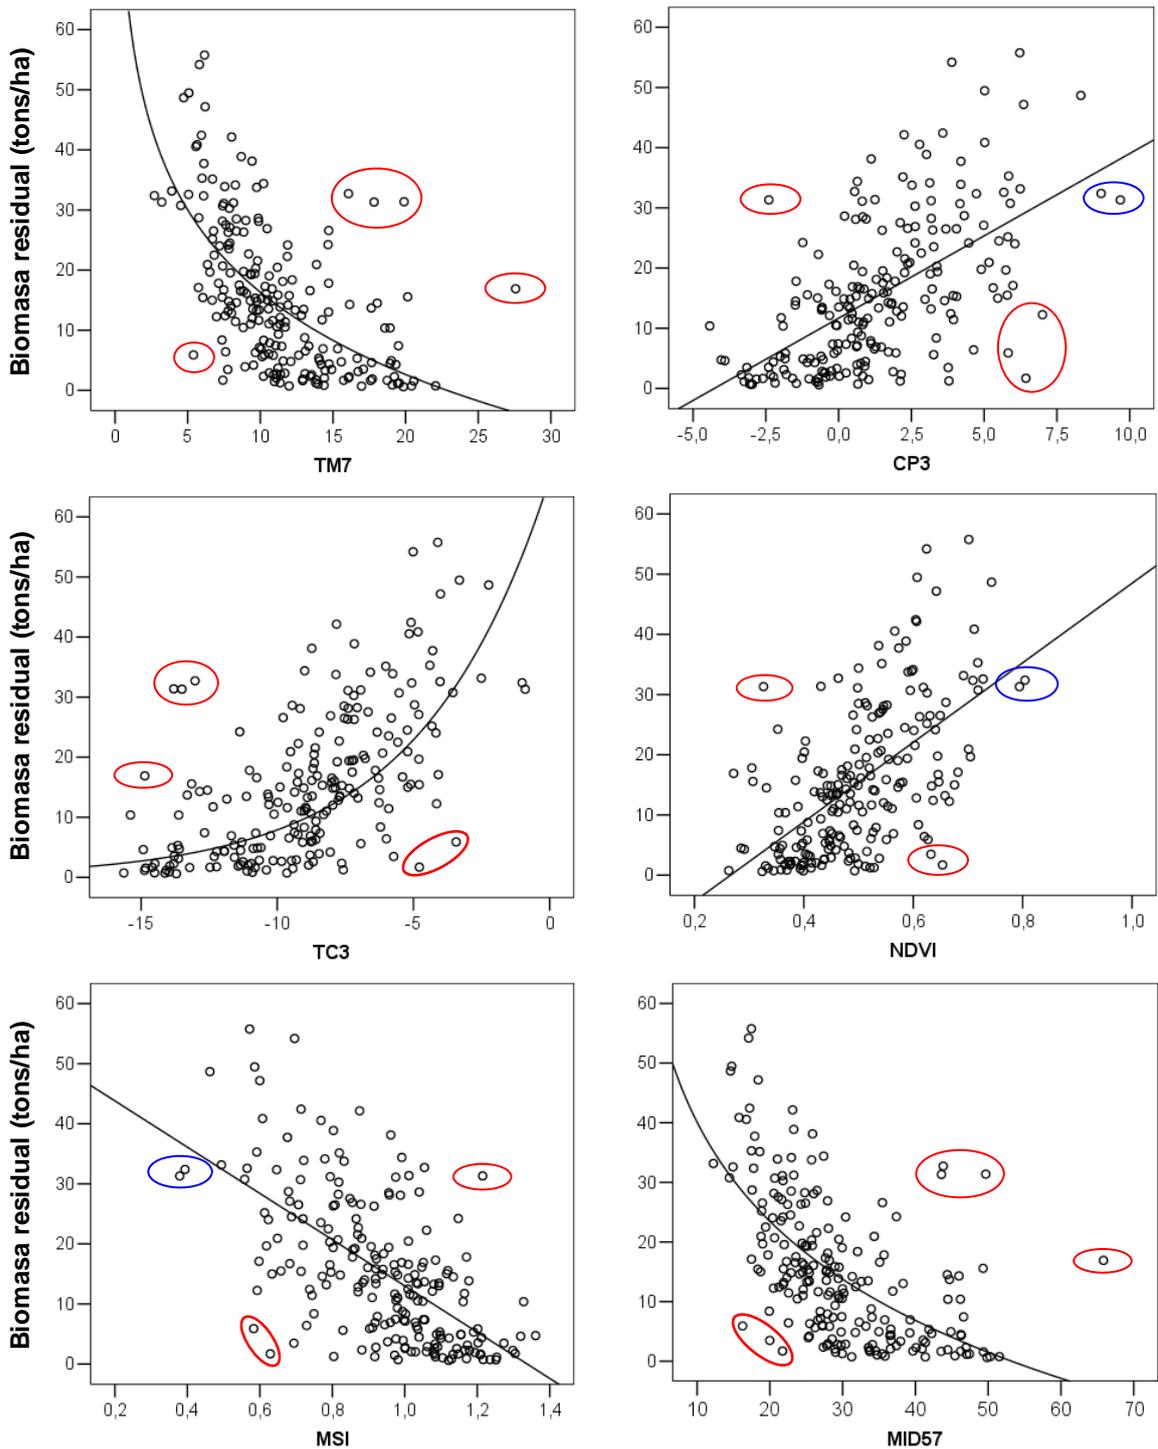


Figura 3.8. Gráficos de dispersión que relacionan la biomasa residual forestal con algunas de las variables independientes mejor correlacionadas usando las parcelas del clúster 2

Adoptando una posición prudente, las parcelas atípicas e influyentes detectadas en los gráficos de dispersión de este segundo clúster pueden ser debidas todavía a la heterogeneidad espacial-radiométrica propia de los medios mediterráneos, lo que hace

que se carezca de la seguridad necesaria para catalogarlas como extraordinarias y, por consiguiente, para proceder a su eliminación. Sin embargo, esta necesaria situación de certeza sí que se tendrá en el paso siguiente, cuando se utilicen las parcelas del clúster tres, ya que éstas representan un alto grado de homogeneidad.

Así pues, en el presente apartado se ajustan los modelos de regresión con el 80% de la muestra sin eliminar ninguna parcela (Tabla 3.10), teniendo en cuenta que, si se detectan parcelas atípicas extraordinarias con la muestra del tercer clúster, estos modelos deberían de ser recalculados sin su presencia.

Variable	Tipo de modelo	R²	S_e	β₀	β₁
TM1	Logarítmico	0,333	10,238	46,053	-21,348
TM2	Logarítmico	0,316	10,364	52,887	-21,537
TM3	Logarítmico	0,345	10,140	51,793	-19,855
TM4	Exponencial	0,077	1,056	63,506	-0,096
TM5	Logarítmico	0,380	9,866	93,187	-27,177
TM7	Logarítmico	0,400	9,708	64,508	-20,832
CP1	Logarítmico	0,336	10,212	112,531	-29,151
CP3	Lineal	0,362	10,013	11,712	2,867
TC1	Logarítmico	0,288	10,578	163,343	-41,091
TC2	Logarítmico	0,189	11,100	-15,487	16,954
TC3	Exponencial	0,386	0,869	71,479	0,222
NDVI	Lineal	0,354	10,077	-18,745	68,640
SAVI	Lineal	0,351	10,095	-18,897	46,904
MSAVI	Lineal	0,337	10,206	-33,240	74,704
OSAVI	Lineal	0,353	10,083	-18,795	69,191
GESAVI	Logarítmico	0,308	10,423	12,843	14,320
GI	Lineal	0,199	11,218	22,140	146,795
MSI	Lineal	0,390	9,788	52,961	-39,839
VIS123	Logarítmico	0,341	10,177	74,894	-21,369
MID57	Logarítmico	0,392	9,775	97,560	-24,629
ABD	Logarítmico	0,337	10,208	136,049	-29,027

Tabla 3.10. Modelos de regresión simple calculados para el clúster 2: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

Como se aprecia en la tabla, solamente se consideraron variables radiométricas, ya que, como se ha visto, no existen correlaciones significativas entre la biomasa residual y las variables topográficas consideradas en este grupo de parcelas. Los resultados obtenidos confirman los extremos antes resaltados cuando se consideraron todas las parcelas de la muestra. Así, las variables independientes relacionadas directa o inversamente con el contenido de humedad de la vegetación vuelven a erigirse como las

más adecuadas para predecir la variable dependiente, aunque solamente logran explicar entre el 36% y el 40% de su varianza. El tipo de relaciones de la biomasa con estas variables vuelve a ser curvilíneo de tipo logarítmico o exponencial, con las excepciones de MSI y CP3, que presentan una relación lineal que puede ser debida a la presencia de dos parcelas influyentes. En un segundo lugar aparecen los índices de vegetación NDVI, OSAVI y SAVI, que explican algo más del 35% de la variable biomasa residual, utilizando para ello un modelo lineal, determinado éste por la presencia de las dos mismas parcelas influyentes detectadas en los gráficos de MSI y CP3. El último lugar en cuanto a capacidad de predicción es nuevamente ocupado por las variables GI ($R^2=0,199$), TC2 ($R^2=0,189$) y TM4 ($R^2=0,077$).

De esta manera, la utilización de esta muestra más homogénea ha mejorado los resultados obtenidos previamente al considerar todas las parcelas, confirmándose las variables radiométricas que son más útiles para la estimación de biomasa. Pero los modelos predictivos ajustados vuelven a ser insuficientes para estimar de una forma precisa esta variable, por lo que no se consideró necesario validarlos mediante la muestra de parcelas reservada a tal efecto. Finalmente señalar que los gráficos de dispersión obtenidos con esta muestra permiten intuir la presencia de casos influyentes y atípicos cuya eliminación podría cambiar el tipo de modelo ajustado con algunos de los índices y/o mejorar la capacidad predictiva de los mismos. Sin embargo, a tenor de los bajos coeficientes de determinación obtenidos, esta mejora no parece que vaya a ser suficiente para dar lugar a modelos válidos para obtener una buena cartografía de estimación, por lo que no se considera necesario recalcularlos una vez que se identifiquen los casos atípicos en el siguiente clúster.

- Modelos de regresión simple del tercer clúster

La Figura 3.9 muestra los gráficos de dispersión obtenidos con la banda reflectiva, el componente principal, el eje *Tasseled-Cap* y tres de los índices de vegetación que mayor correlación presentan con la biomasa residual forestal utilizando las 68 parcelas que componen el grupo del percentil 4. En cada uno de estos gráficos se representan las líneas del modelo de regresión que mejor ajusta los datos y el R^2 alcanzado; además, se identifican las parcelas que presentan un comportamiento atípico.

La lectura de los gráficos de dispersión creados a partir de la utilización de parcelas con un entorno radiométrico altamente homogéneo permite extraer una serie de conclusiones a cerca de las cuestiones anteriormente apuntadas:

- En primer lugar se constata el hecho de que la capacidad predictiva de las variables radiométricas utilizadas aumenta a medida que lo hace la homogeneidad del entorno radiométrico de las parcelas del IFN-2, por lo que se puede concluir que existe una relación biofísica significativa y contrastada entre la biomasa residual forestal y estas variables.
- Permite la identificación de parcelas extraordinarias que no se ajustan a la forma de la relación y, por lo tanto, influyen negativamente en el ajuste del modelo de estimación. Los errores introducidos por estas parcelas atípicas ya no pueden ser achacados a la heterogeneidad de los bosques mediterráneos, sino que se deben a otros factores de error relacionados con las tareas del inventario forestal o del tratamiento de las imágenes que se desconocen y, en consecuencia, no se pueden resolver. Así pues, la única opción posible para garantizar la adecuación del modelo de regresión es eliminarlas de la muestra.
- En tercer lugar, las relaciones entre estos dos tipos de variables son predominantemente curvilíneas, constituyéndose como única excepción el índice NDVI y tres de los cuatro índices de la familia SAVI considerados (SAVI, MSAVI y OSAVI), por lo menos tomando como umbral las 50 tons/ha, que es el valor máximo de las parcelas incluidas en este grupo. Este hecho de que las relaciones sean curvilíneas indica que la capacidad predictiva de las variables derivadas de la imagen Landsat llega solamente hasta un determinado umbral; es decir, la señal proporcionada por el sensor se satura a una determinada cantidad de biomasa residual. A partir de ese umbral de saturación, los incrementos en las cantidades de biomasa no se corresponden con incrementos de la misma proporción en las variables radiométricas, pudiendo ser la variación de estas últimas incluso nula, por lo que dejan de ser útiles. Sobre esta cuestión se volverá más adelante una vez se hayan eliminado las parcelas atípicas.

De esta manera, la primera tarea que se impone antes del ajuste de los modelos de regresión en este tercer clúster es la identificación y eliminación de las parcelas atípicas. Según lo observado en la Figura 3.9, tres son las parcelas más repetidas que presentan un comportamiento más alejado de la tónica común: la 286, la 340 y la 426. Especialmente claro es el comportamiento extraordinario de la parcela 286, ya que es identificada como caso atípico en las 6 variables representadas, estando su posición muy

alejada con respecto a la mejor línea de regresión calculada en todas ellas. Por su parte, las parcelas 340 y 426 presentan exactamente este mismo comportamiento que la 286 en tres de las variables relacionadas con el contenido de humedad de la vegetación: TM5, MID57 y TC3.

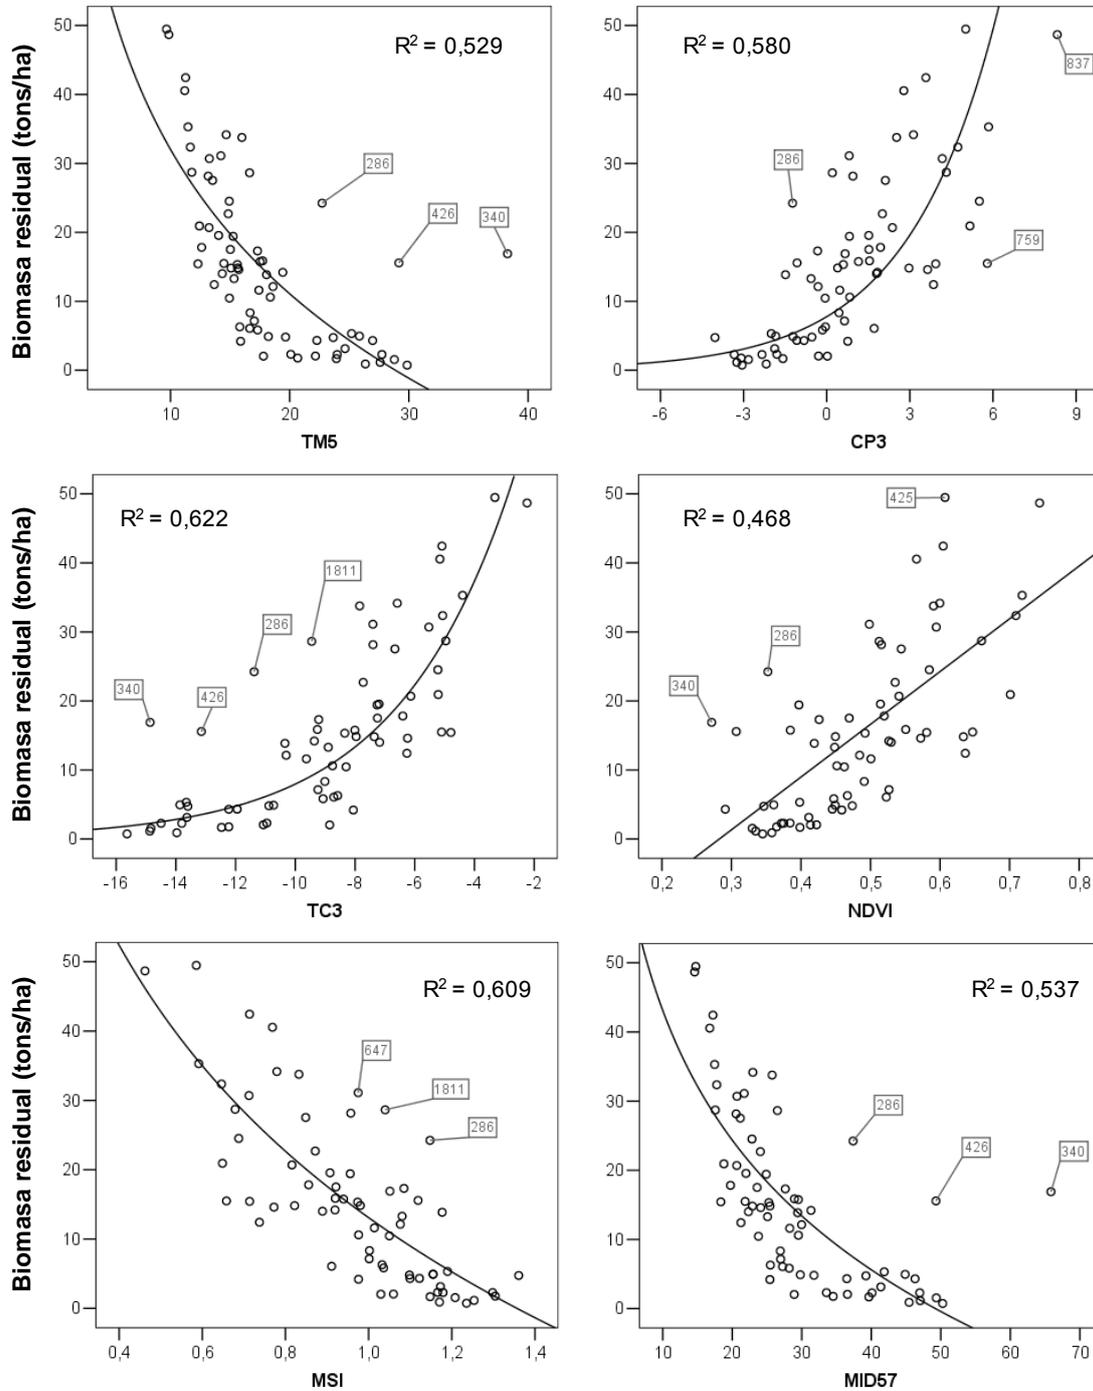


Figura 3.9. Gráficos de dispersión que relacionan la biomasa residual forestal con algunas de las variables independientes mejor correlacionadas usando las parcelas del clúster 3

El resto de parcelas señaladas en los gráficos como atípicos tienen un carácter más particular, ya que sólo aparecen identificados como tales en una o dos variables; así, por ejemplo, mientras que en la variable CP3 aparecen como atípicas importantes las parcelas 759 y 837, éstas no lo son en la variable MSI, siendo más importante la influencia de las parcelas 647 y 1811. Así pues, se vuelve a optar por una posición conservadora y solamente se consideran susceptibles de eliminar las tres parcelas indicadas que más claramente se han identificado como atípicas en un mayor número de variables.

Para tener una mayor certeza acerca del carácter erróneo de estas tres parcelas, se estudió la información que de ellas proporciona el IFN-2 (número de pies mayores y menores) en relación con lo que se observa en las ortofotografías aéreas de resolución espacial de 1 metro del SIG Oleícola Español, utilizadas para la georreferenciación de las imágenes Landsat, y con la signatura espectral obtenida a partir de las bandas reflectivas de la imagen de junio de 1994. Según los datos del IFN-2, la parcela 286 está compuesta por 15 pies mayores y 1 menor de *P. halepensis*, siendo su radio de 15 m. Sin embargo, tal y como se observa en la Figura 3.10(A), esta situación no coincide con la realidad observada en la ortofotografía, ya que la parcela está situada en una zona de bosque abierto con ejemplares aislados (1 ó 2), donde la presencia de sustrato arbustivo, herbáceo e incluso suelo desnudo es dominante. Esta situación real está más en consonancia con la respuesta reflectiva de esta parcela, que dista de la típica de una formación boscosa presentada por los datos del IFN-2 (Figura 3.11).

Por su parte, la parcela 340 está compuesta por un total de 13 pies de *P. halepensis*, 9 con un *dbh* >7,5 cm y 4 con un *dbh* <7,5 cm. Estos datos difieren totalmente con la realidad descrita en las ortoimágenes y en la imagen de satélite, ya que, como se observa en la Figura 3.10(B), la parcela está situada sobre una parcela de cultivos leñosos (seguramente olivos) en la que el suelo desnudo es claramente visible, situación que tiene su reflejo en la signatura espectral de la parcela (Figura 3.11).

Por último, la realidad espacial observada en la ortoimagen y la signatura espectral de la parcela 426 tampoco coincide con la información facilitada por el IFN-2. Esta parcela, que según los datos del inventario está compuesta por 9 pies mayores de *P. halepensis* y 3 menores, en realidad se sitúa en una zona de transición entre un bosque y una parcela de cultivo, ocupando esta última la mayor parte de la parcela (Figura 3.10(C)). La signatura espectral es reflejo de esta situación más que de la descrita en el inventario (Figura 3.11).

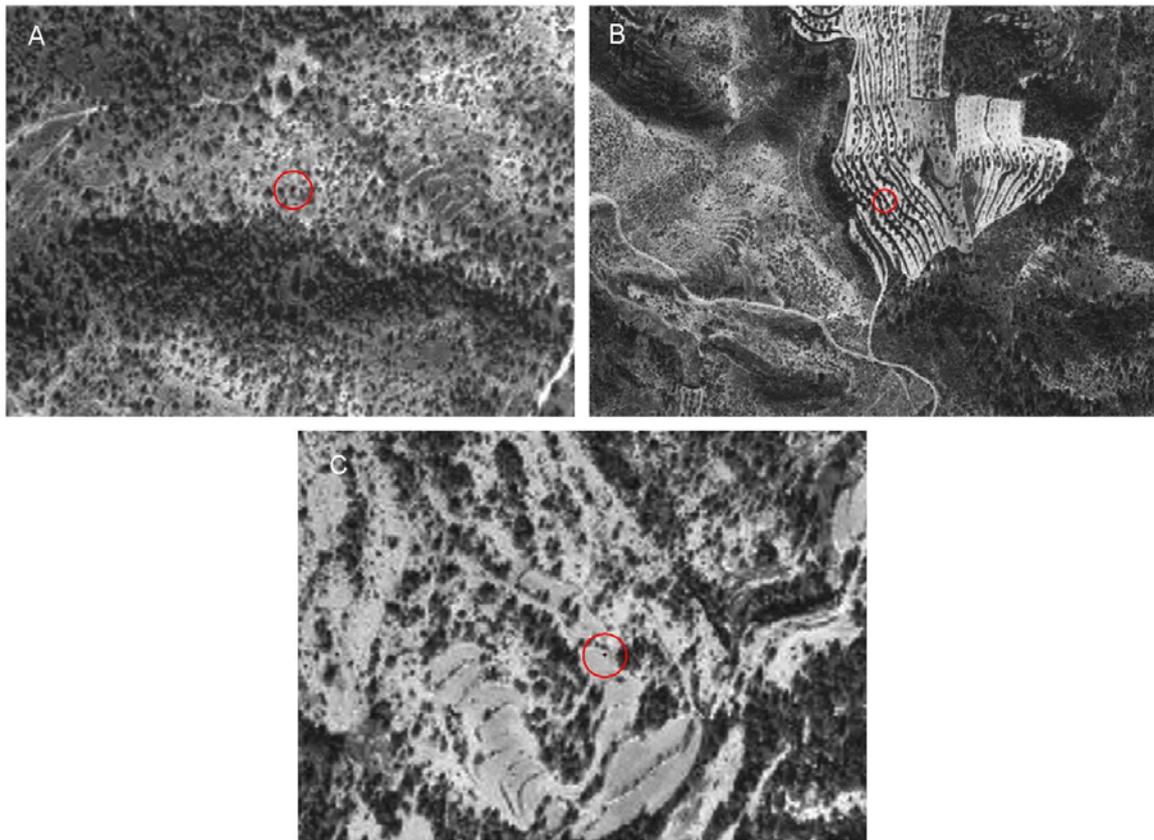


Figura 3.10. Parcelas del IFN-2 identificadas como erróneas: (A) parcela 286; (B) parcela 340; y (C) parcela 426

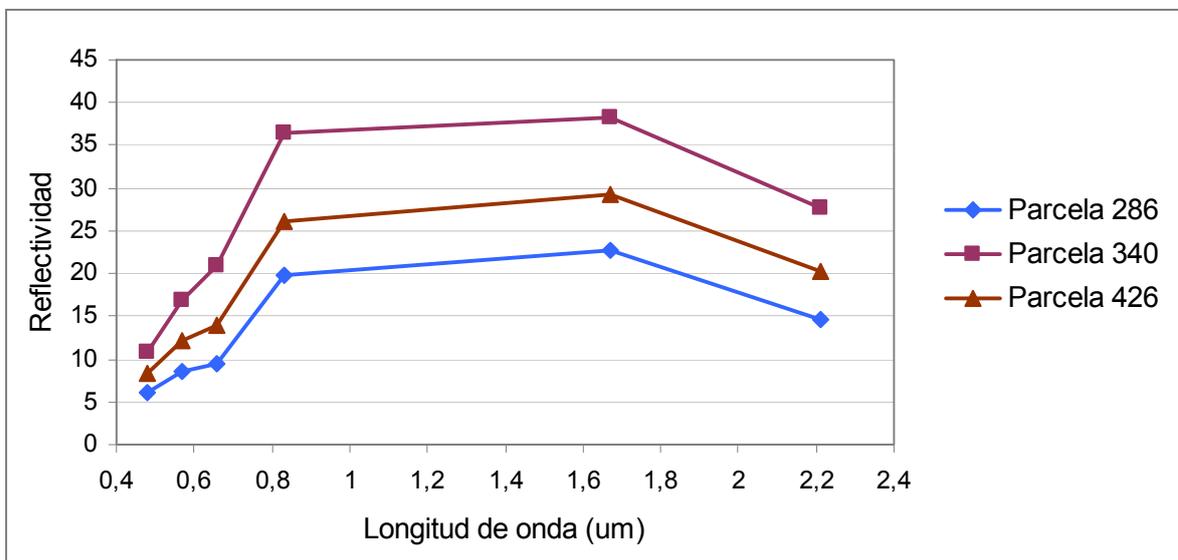


Figura 3.11. Signatura espectral de las parcelas identificadas como erróneas

Así pues, la discordancia entre los datos del IFN-2 y la realidad pone de manifiesto la existencia de imprecisiones en la localización de las parcelas, que pueden afectar al ajuste de los modelos estimativos que utilizan esta fuente de información

forestal. De esta manera, dos fuentes de información independientes entre sí confirmaron y explicaron el comportamiento atípico de estas parcelas en los gráficos de dispersión, por lo que definitivamente fueron eliminadas de la muestra. El hecho de que las tres parcelas se situaran en entornos espaciales homogéneos, aunque sobre realidades diferentes a las descritas en los datos del inventario, es la causa de que hayan permanecido en la muestra a pesar de ser equívocas para la estimación de la biomasa residual forestal.

La Tabla 3.11 recoge el mejor modelo de regresión ajustado en cada variable independiente con las cinco muestras del 80% de parcelas seleccionadas al azar. Cabe destacar la gran estabilidad de los modelos calculados ya que, a pesar de utilizar muestras diferentes, el tipo de modelo utilizado en cada variable es siempre el mismo y el R^2 obtenido varía muy poco.

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM1	Exponencial	0,649	0,653	191,198	-0,664
TM2	Exponencial	0,693	0,611	216,748	-0,535
TM3	Exponencial	0,735	0,568	151,174	-0,432
TM4	Logarítmico	0,080	12,871	92,520	-26,617
TM5	Exponencial	0,764	0,536	299,272	-0,194
TM7	Exponencial	0,766	0,533	130,640	-0,237
CP1	Exponencial	0,735	0,568	420,438	-0,136
CP3	Exponencial	0,643	0,655	7,112	0,314
TC1	Logarítmico	0,546	7,777	209,571	-54,712
TC2	Logarítmico	0,374	9,868	-25,184	22,785
TC3	Exponencial	0,743	0,559	147,034	0,300
NDVI	Potencia	0,640	0,662	226,067	4,269
SAVI	Potencia	0,633	0,668	43,983	4,281
MSAVI	Potencia	0,643	0,659	163,603	6,273
OSAVI	Potencia	0,637	0,664	233,399	4,273
GESAVI	Logarítmico	0,483	9,648	13,801	19,656
GI	Lineal	0,516	8,025	23,276	244,576
MSI	Logarítmico	0,672	7,686	13,328	-47,748
VIS123	Exponencial	0,715	0,589	193,759	-0,180
MID57	Exponencial	0,767	0,532	208,014	-0,107
ABD	Exponencial	0,738	0,565	434,858	-0,060

Tabla 3.11. Modelos de regresión simple calculados para el clúster 3: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

Como se observa en la tabla, un total de cuatro modelos presentan unos coeficientes de determinación superiores a 0,740, lo que los convierte en realmente

operativos para estimar la biomasa residual del área de estudio. Estos cuatro modelos presentan dos características comunes: (i) el empleo de una variable relacionada con el contenido de agua de la vegetación (MID57, TM7, TC3 y TM5); y (ii) el empleo de una función exponencial para describir la relación. Del resto de modelos obtenidos señalar que la gran mayoría permite explicar más de un 60% de la varianza de la variable dependiente, siendo solamente los modelos ajustados para TC1, GI, GSAVI y TC2 los que se sitúan por debajo de este umbral.

Así pues, la eliminación de las parcelas atípicas ha permitido el ajuste de modelos que siguen la tendencia marcada mediante la utilización de las anteriores muestras (mayor utilidad de las variables relacionadas con el contenido de agua de la vegetación y predominio de las relaciones no lineales, destacando dentro de éstas las exponenciales), pero con una mayor capacidad predictiva.

Para determinar cuál de los cuatro modelos con mayor capacidad predictiva es más útil a la hora de cartografiar la biomasa residual del área de estudio, se tiene en cuenta un doble criterio: (i) el error obtenido mediante la muestra reservada para la validación; y (ii) el grado de saturación de la función. A este respecto, la Figura 3.12 recoge los gráficos de dispersión de estos modelos, mostrándose el $RMSE$ y el $RMSE_r$, obtenidos con sus respectivas muestras de validación. En estos gráficos, con el objetivo de caracterizar mejor el grado de saturación de la función, el eje de ordenadas se prolonga hasta las 70 tons/ha, un poco por encima del valor máximo obtenido en las 482 parcelas del IFN-2 en las que se ha estimado la biomasa residual (64, 720 tons/ha; Tabla 2.6).

Las diferencias encontradas entre estos cuatro modelos en términos de error de predicción son mayores que las presentadas atendiendo únicamente al coeficiente de determinación. De esta manera, el $RMSE$ y el $RMSE_r$ menores se obtienen en los modelos que utilizan la banda original TM5 y el índice MID57, mientras que los más altos se dan en el que utiliza TC3, siendo la diferencia de casi 1,34 tons/ha y de un 9,81%, respectivamente. Así pues, los modelos ajustados con TM5 y MID57 se erigen como los mejores para la estimación de la biomasa residual, aunque seguidos de cerca por el de TM7.

Desde el punto de vista de la saturación de los modelos a altas cantidades de biomasa residual, todos ellos presentan un comportamiento bastante similar. Así, tal y como se observa en la Figura 3.12, ninguno presenta saturación para las cantidades

máximas consideradas en este trabajo, por lo que son válidos para el área de estudio.

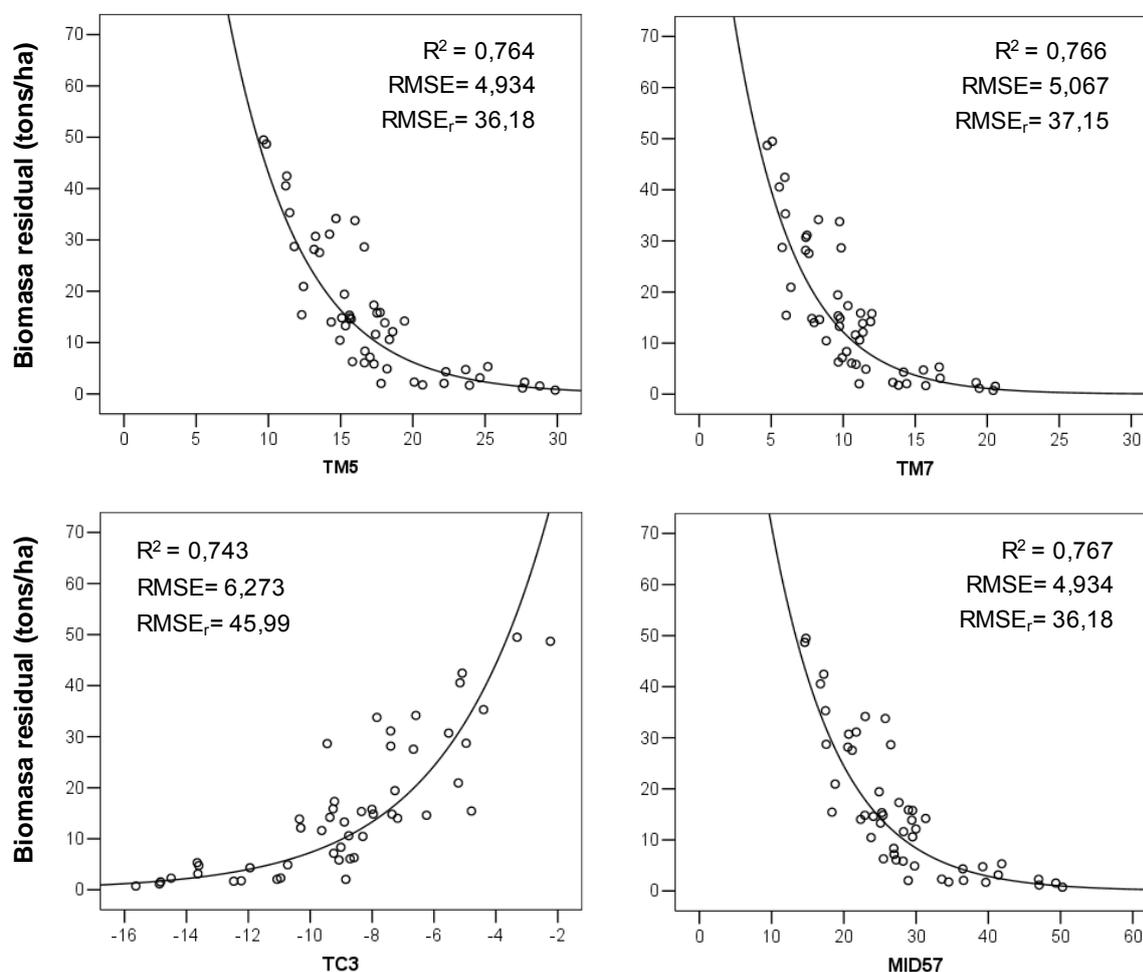


Figura 3.12. Gráficos de dispersión de los cuatro modelos con mayor capacidad predictiva de la Tabla 3.11

Por tanto, teniendo en cuenta los dos criterios señalados, los modelos ajustados a partir de TM5, TM7 y MID57 son igualmente adecuados para la obtención de la cartografía de la biomasa residual del área de estudio. Para seleccionar el mejor entre estos tres modelos, se estudia cómo es la distribución de los valores de la variable dependiente a lo largo de las variables independientes. Como es lógico, debido a que MID57 es la suma de TM5 y TM7, la varianza de la biomasa residual queda explicada a lo largo de un mayor rango de valores en esta variable (rango efectivo de 35,68 en el caso de MID57, frente a 20,19 y 15,84 de TM5 y TM7, respectivamente). De esta manera, este índice presenta mayor sensibilidad a cambios en la variable dependiente, por lo que resulta más adecuado.

Este hecho, junto a los ya comentados de que su utilización da lugar al ajuste con menor error y mayor coeficiente de determinación, hace que finalmente se aplique el modelo de la Tabla 3.11 calculado con MID57 para la obtención de la cartografía de la biomasa residual forestal del área de estudio (Figura 3.13).

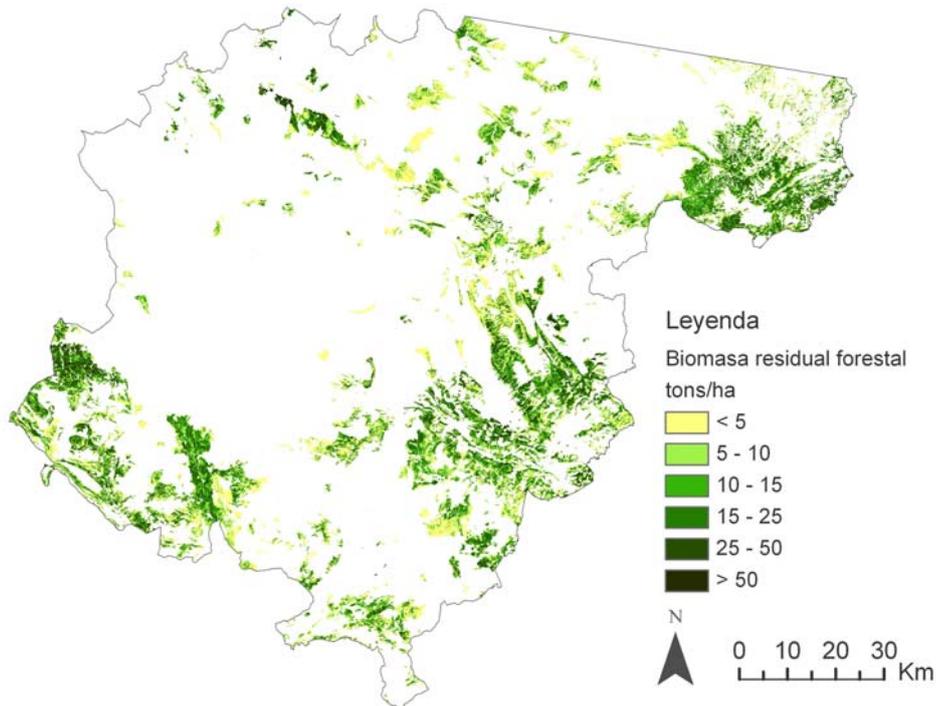


Figura 3.13. Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del tercer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

- Modelos de regresión simple del cuarto clúster

Al igual que en el apartado dedicado al ajuste de los modelos de regresión logística y con el objetivo de disponer de un número mayor de parcelas en el proceso de validación, el 70% de la muestra de este clúster fue utilizado para la calibración del modelo y el 30% para la validación.

La utilización del grupo más homogéneo y reducido de la muestra permite confirmar los extremos ya apuntados anteriormente acerca de la existencia de relaciones biofísicas significativas entre variables radiométricas y la biomasa residual forestal y el carácter no lineal predominante de estas relaciones. Así, tal y como se observa en la tabla que recoge los mejores modelos obtenidos (Tabla 3.12), un total de 13 variables de las 20 radiométricas que presentaban correlaciones significativas en este grupo dan lugar a ajustes con $R^2 > 0,8$, utilizándose predominantemente para ello funciones de tipo

exponencial (en 11 de los 13 casos). Sin embargo, es necesario señalar que los modelos aquí ajustados son más sensibles que los anteriores a la utilización de las distintas divisiones aleatorias de la muestra, existiendo diferencias a veces notables entre los R^2 obtenidos e incluso con el tipo de función utilizada.

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM1	Exponencial	0,846	0,497	341,662	-0,813
TM2	Exponencial	0,876	0,446	370,980	-0,627
TM3	Exponencial	0,867	0,460	199,150	-0,477
TM5	Exponencial	0,860	0,463	349,450	-0,196
TM7	Exponencial	0,854	0,483	154,344	-0,252
CP1	Exponencial	0,833	0,507	563,536	-0,141
CP3	Exponencial	0,837	6,422	13,025	4,782
TC1	Logarítmico	0,630	9,663	282,974	-73,974
TC2	Lineal	0,516	11,020	-15,931	5,589
TC3	Exponencial	0,840	0,496	155,963	,300
NDVI	Potencia	0,790	0,579	330,056	4,877
SAVI	Potencia	0,784	0,588	51,050	4,903
MSAVI	Potencia	0,800	0,566	236,137	7,239
OSAVI	Potencia	0,788	0,582	343,255	4,885
GESAVI	Potencia	0,683	8,918	13,758	24,731
GI	Lineal	0,554	10,610	26,502	268,741
MSI	Lineal	0,866	5,818	79,326	-64,706
VIS123	Exponencial	0,878	0,442	293,224	-0,206
MID57	Exponencial	0,856	0,471	241,295	-0,108
ABD	Exponencial	0,844	0,500	605,659	-0,065

Tabla 3.12. Modelos de regresión simple calculados para el clúster 4: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

En este sentido, cabe destacar el hecho de que, considerando solamente los mejores modelos obtenidos en las cinco subdivisiones, los calculados con las bandas originales TM, a excepción de TM4, presentan un $R^2 > 0,840$, lo que indica la adecuación de la información proporcionada directamente por este sensor para estimar este parámetro forestal, sin necesidad de calcular nuevos neocanales. Esta afirmación se ve reforzada por el hecho de que tres de los restantes índices con $R^2 > 0,840$ son el resultado de sumas simples de estas bandas originales (VIS123, MID57 y ABD), los tres índices seleccionados a partir de los resultados del trabajo de Lu *et al.* (2004).

En cuanto a los resultados obtenidos con la inclusión del resto de neocanales considerados, destacar que las variables CP1, CP3 y TC3 ajustan modelos con mayor

capacidad de predicción que la mayoría de los índices de vegetación más comúnmente considerados en los trabajos enfocados a la estimación de parámetros de la cubierta vegetal. Dentro de estos índices de vegetación destaca el MSI que, mediante una ecuación lineal, logra ajustar un modelo con un R^2 bastante superior al resto. Por último, reseñar que los peores ajustes vuelven a darse con las variables GI y TC2, aunque, en este caso, ambas logran explicar algo más del 50% de la varianza de la variable independiente.

La Figura 3.14 recoge los gráficos de dispersión de los 6 modelos con mayor capacidad predictiva obtenidos en este clúster ($R^2 > 0,855$). Al igual que en la Figura 3.12, se da información acerca del $RMSE$ y del $RMSE_r$ obtenidos en sus respectivas muestras de validación y el eje de ordenadas se prolonga hasta las 70 tons/ha para observar si existe saturación. Tal y como se observa en la figura, a pesar de que los modelos de las variables VIS123, TM2, TM3 y MSI presentan los mayores coeficientes de correlación, los errores de predicción menores se vuelven a registrar con los modelos que emplean TM5 y MID57. El error en estos dos modelos es notablemente inferior al de los otros cuatro representados (entre 4,67 y 2,59 tons/ha menos atendiendo al $RMSE$ y entre un 43,38% y un 20,51% inferior según el $RMSE_r$) y es muy parecido a los obtenidos con estas mismas variables con la muestra considerada en el anterior clúster. Además, al igual que ocurría anteriormente, las funciones ajustadas con estas dos variables no presentan problemas de saturación para las cantidades de biomasa más altas de la muestra, por lo que ambas pueden ser aplicadas al área de estudio.

Así, a pesar de que no presentan los R^2 más altos, los modelos obtenidos con TM5 y MID57 se erigen como los más adecuados para estimar la biomasa residual del área de estudio ya que, además de presentar el $RMSE$ y el $RMSE_r$ menores, son más coherentes con los resultados obtenidos en los análisis previos cuando la muestra empleada era mayor, siendo los coeficientes de regresión de ambos muy similares a los obtenidos en el clúster 3 después de eliminar los casos atípicos. El hecho de que 4 modelos presenten mayores R^2 se debe al escaso número de parcelas consideradas en este apartado y a la subdivisión de ésta en cinco muestras, lo que da lugar a modelos poco robustos que presentan malos resultados en la prueba de validación.

La Figura 3.15 muestra la cartografía de la biomasa residual obtenida mediante la utilización de los coeficientes de regresión del modelo ajustado para la variable TM5 (Tabla 3.12).

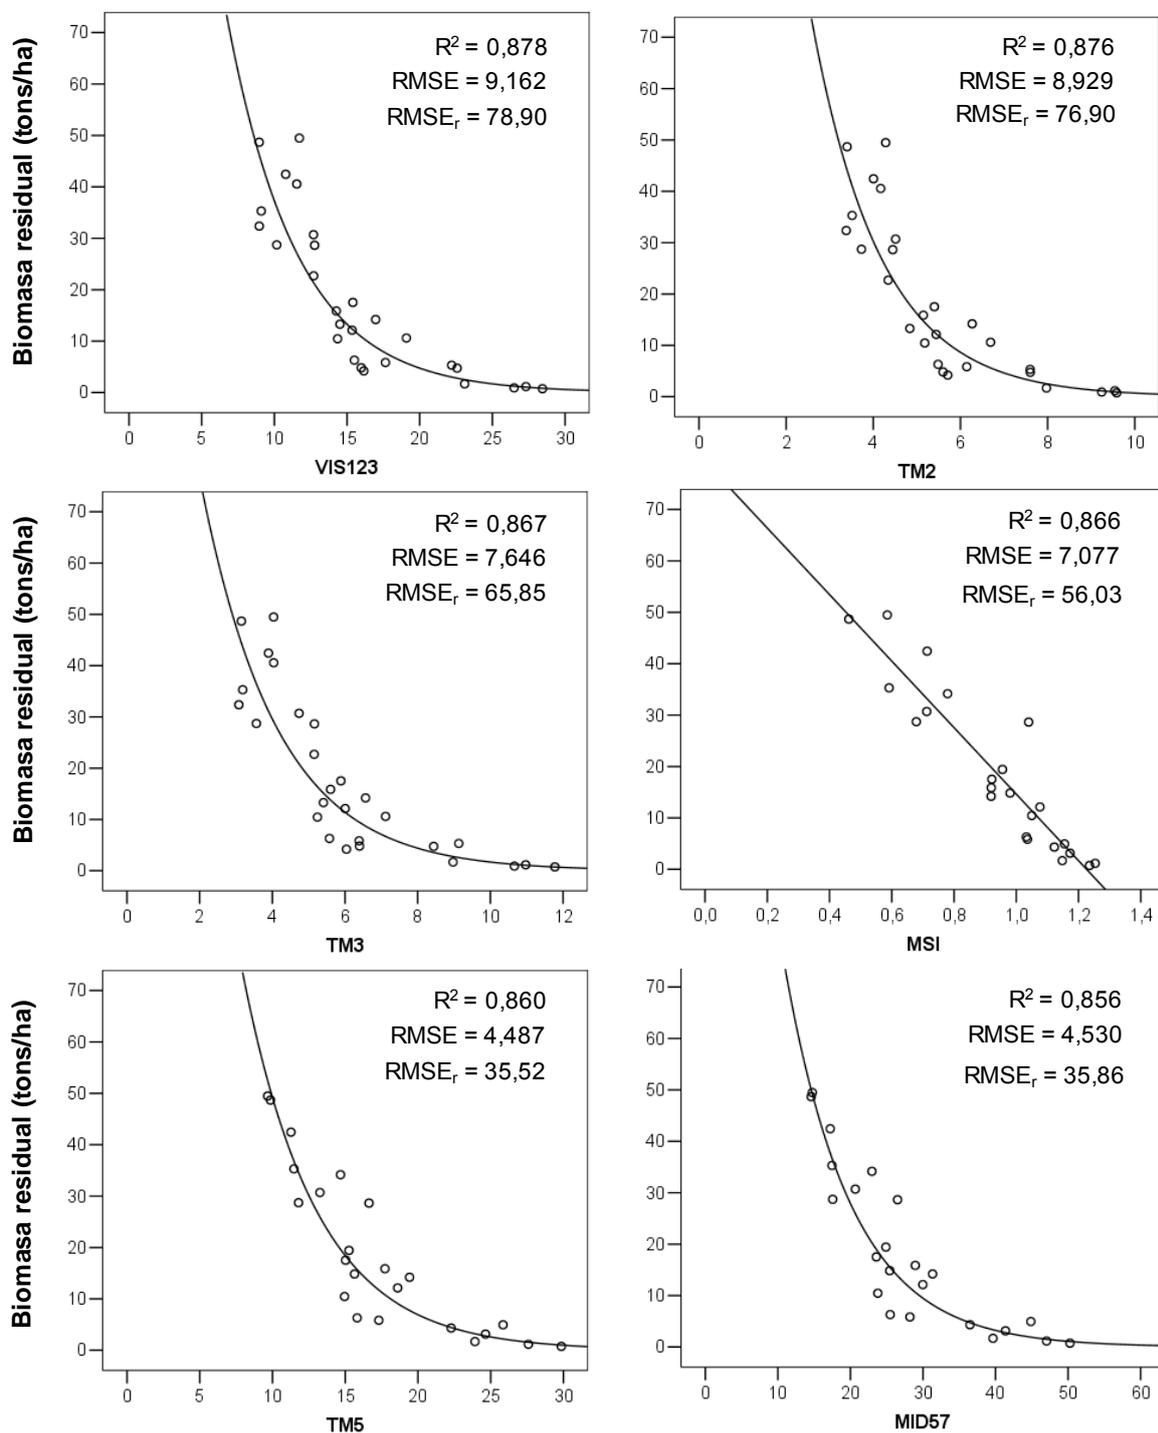


Figura 3.14. Gráficos de dispersión de los seis modelos con mayor capacidad predictiva de la Tabla 3.12

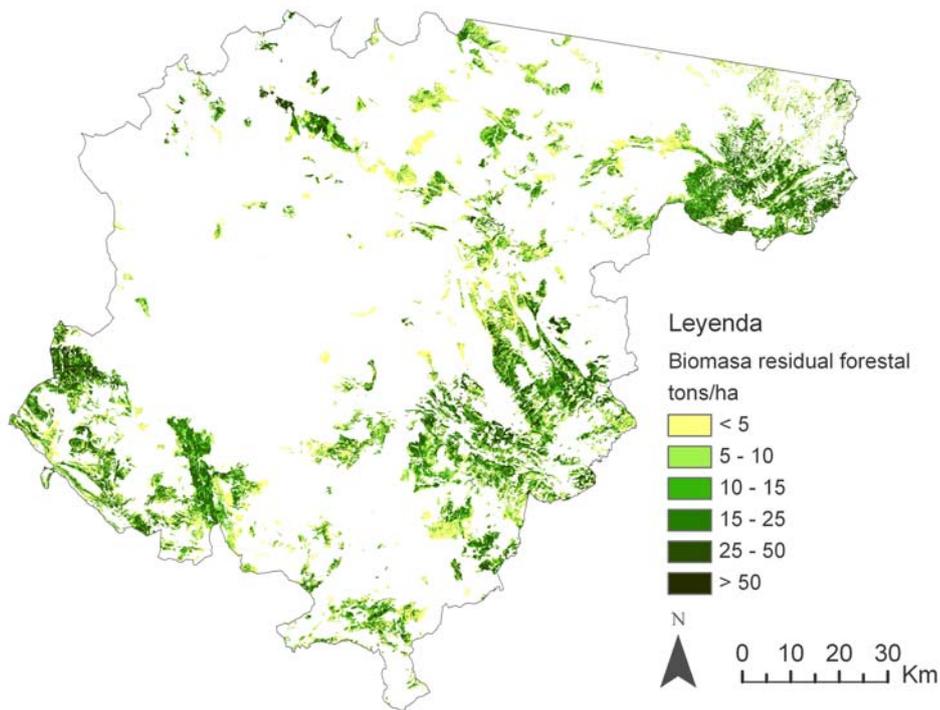


Figura 3.15. Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del cuarto clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

3.1.1.3.3. Modelos de regresión lineal múltiple

Como se ha visto a lo largo del anterior apartado, las relaciones existentes entre la biomasa residual y las variables independientes que mayor correlación presentan con esta variable biofísica son predominantemente de carácter curvilíneo. Esta situación hace que se incumpla de manera reiterada uno de los supuestos básicos del análisis de regresión lineal múltiple: el supuesto de linealidad. Aunque todavía no se ha comprobado el cumplimiento de otros supuestos fundamentales de este método de regresión, esta situación de partida indica que va a ser necesario aplicar una serie de transformaciones sobre las variables al objeto de garantizar la validez del resultado final. La comprobación de los supuestos y la aplicación de estas transformaciones se hacen de manera independiente en cada uno de los clústeres de homogeneidad definidos, ya que los grupos de parcelas que los integran y los modelos resultantes son autónomos de los demás⁴¹.

⁴¹ Se recuerda que las parcelas 286, 340 y 426 han sido eliminadas de la muestra por que la descripción dada por el IFN-2 no concuerda con las características observadas en las fotografías aéreas y en la imagen Landsat de junio de 1994, por lo que no forman parte de los análisis llevados a cabo en este apartado.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Raíz cuadrada	Casi normal
TM1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TM4	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal
TM5	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP3	Casi normalidad	Normalidad	Positiva	Mesocúrtica	Si	Normal	-	-
TC1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
TC2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TC3	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
SAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
OSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
GESAVI	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
GI	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Raíz cuadrada	Normal
MSI	Normalidad	Normalidad	Negativa	Mesocúrtica	Si	Normal	-	-
VIS123	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal

Tabla 3.13. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes radiométricas correlacionadas con ella en el clúster 1

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Elevación	No normalidad	No normalidad	Simétrica	Platicúrtica	No	No normal	-	No normal
INS_POT	Casi normalidad	Casi normalidad	Negativa	Leptocúrtica	No	No normal	Cuadrado	Casi normal
PRI_POT	Casi normalidad	Casi normalidad	Negativa	Leptocúrtica	No	No normal	Cuadrado	Normal
VER_POT_HORAS	No normalidad	No normalidad	Negativa	Mesocúrtica	No	No normal	-	No normal
OTO_POT	Casi normalidad	Casi normalidad	Negativa	Leptocúrtica	No	No normal	Cuadrado	Normal
INV_POT	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-

Tabla 3.14. Pruebas de normalidad aplicadas a las variables independientes topográficas

- Modelos de regresión múltiple del primer clúster

Las Tablas 3.13 y 3.14 recogen los resultados de las distintas pruebas individuales con un nivel de significación $p < 0,05$ aplicadas sobre la variable biomasa y sobre las variables que presentan correlaciones significativas con ella para ver si cumplen el supuesto subyacente de normalidad. En este sentido, las últimas columnas de la tabla indican si la variable cumple o no este supuesto, la transformación más adecuada para corregir este incumplimiento y si, finalmente, esta transformación permite solucionarlo.

Tal y como se observa en estas tablas, un total de 7 variables radiométricas (CP3, TC3, NDVI, SAVI, MSAVI, OSAVI y MSI) y una topográfica (INV_POT) cumplen el supuesto de normalidad, por lo que pueden ser incorporadas directamente en el modelo de regresión lineal múltiple. Junto a éstas, también se pueden agregar al modelo las transformaciones de las variables originales que dan lugar a variables normalmente distribuidas, incluyéndose dentro de este grupo el cuadrado de INS_POT y, sobre todo, la raíz cuadrada de la variable biomasa residual, ya que, a pesar de no superar el test K-S, ambas tienen una distribución muy cercana a la de una curva normal (Figura 3.16).

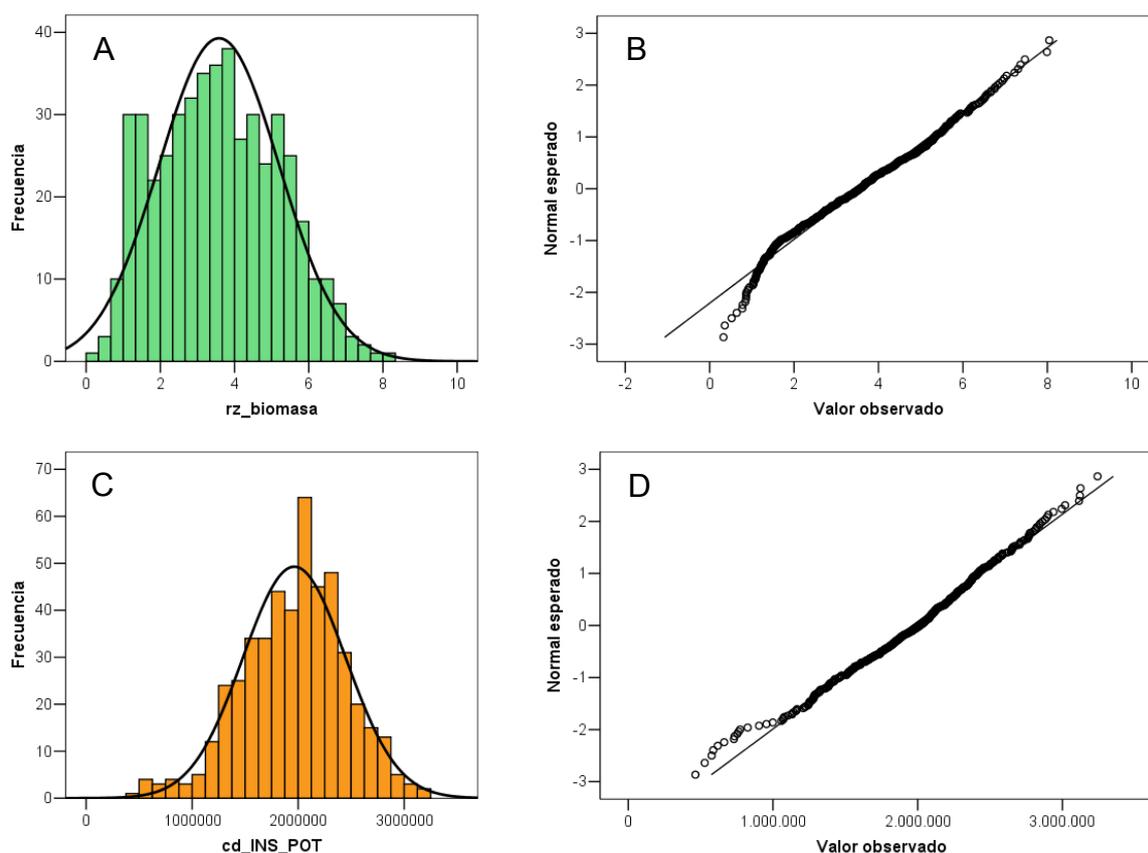


Figura 3.16. Histogramas y gráficos de distribución normal de las variables transformadas de la biomasa residual forestal (rz_biomasa) (A y B) y de la insolación potencial (cd_INS_POT) (C y D)

Por último, reseñar que las variables Elevación y VER_POT_HORAS quedan fuera del modelo, ya que ninguna de las operaciones aplicadas consigue una distribución semejante a la normal.

Para comprobar el cumplimiento de los supuestos de homocedasticidad y linealidad se generaron gráficos de dispersión individuales entre la variable transformada de la biomasa residual (*rz_biomasa*) y las variables independientes originales o transformadas que habían superado el análisis previo de la normalidad individual. Estos gráficos mostraron que ninguno de los pares examinados incumplía estos dos supuestos, por lo que todas las variables independientes pueden ser tenidas en cuenta a la hora de ajustar el modelo de regresión. Sin embargo, estos gráficos sí que dejaron claro que las variables topográficas que han pasado el corte del supuesto de normalidad no iban a ser seleccionadas en los modelos de regresión, ya que en sus gráficos no se observa ninguna relación clara.

Como se ha indicado anteriormente, para calcular los modelos de las cinco muestras del 80% de las parcelas reservadas a tal efecto se utilizó el método de pasos sucesivos. Este método dio lugar a 2 modelos univariantes y a 3 bivariantes o múltiples, siendo todos ellos significativos ($p < 0,05$). Los modelos univariantes seleccionaron las variables transformadas de MID57 (*ln_MID57*) y de TM7 (*ln_TM7*), mientras que los múltiples quedaron conformados por la combinación de la variable *ln_MID57* (seleccionada en el primer paso) con la variable original MSI y con las transformadas de TM1 (*rz_TM1*) y de GESAVI (*ln_GESAVI*) (seleccionadas en el segundo paso), respectivamente.

Sin embargo, los estadísticos de diagnosis de colinealidad en los modelos múltiples indicaron que todos ellos incumplían este supuesto, por lo que no eran robustos desde el punto de vista estadístico. Así, aunque los valores de tolerancia y de *FIV* se situaban en umbrales aceptables, el valor obtenido en sus respectivos índices de condición en alguna de sus dimensiones (superior a 30) delataba un serio problema de colinealidad (Pardo y Ruiz, 2005). Este extremo fue confirmado mediante el análisis de correlación entre *ln_MID57* y la variable seleccionada junto a ésta en cada modelo, obteniéndose valores superiores a 0,730 en todos los casos. Así pues, aunque estos tres modelos eran significativos, fueron descartados por no incumplir el supuesto básico de no-colinealidad. De esta manera, en estas 3 muestras, el mejor modelo resultó ser el univariante definido a partir de la variable *ln_MID57* (la seleccionada en primer lugar), por lo que 4 de los 5 modelos finalmente obtenidos utilizan esta variable como la mejor para

predecir la cantidad de biomasa residual del área de estudio (Tabla 3.15).

Modelo-Muestra	Variable	R^2_a	S_e	β_0	β_1
N ₁	ln_MID57	0,250	1,423	12,684	-2,691
N ₂	ln_MID57	0,242	1,423	12,882	-2,763
N ₃	ln_MID57	0,258	1,335	12,539	-2,665
N ₄	ln_MID57	0,253	1,392	12,764	-2,737
N ₅	ln_TM7	0,261	1,405	9,027	-2,268

Tabla 3.15. Modelos de regresión múltiple calculados para el clúster 1: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

Dos hechos sobresalen de la lectura de los modelos recogidos en la Tabla 3.15: (i) la estabilidad de los coeficientes de regresión de los modelos ajustados con la variable ln_MID57, lo que indica la robustez de estos modelos para estimar la biomasa residual, y (ii) la baja capacidad predictiva de todos los modelos ajustados, que supera ligeramente la alcanzada en los modelos curvilineales univariantes obtenidos con estas mismas variables en el anterior apartado, que, recordemos, eran las mejores para estimar biomasa residual.

Debido a este escaso poder de predicción, no se utilizó la muestra de validación para calcular el error de estimación de cada uno de ellos, ya que los errores que se iban a obtener iban a ser altos. Del mismo modo, al igual que en anteriores apartados, donde se han obtenido resultados similares, tampoco se elaboró ninguna cartografía de estimación de la biomasa residual de la provincia de Teruel.

Así pues, este último análisis de regresión hecho con todas las parcelas que componen la muestra confirma que las variables relacionadas con el contenido de humedad de la vegetación son las más útiles para estimar biomasa residual forestal, dando lugar a modelos de estimación altamente significativos ($p < 0,01$). Sin embargo, los coeficientes de determinación obtenidos indican que no es posible la edición de modelos operativos de estimación, ya que solamente el 25-26% de la varianza de la variable biomasa residual queda explicada mediante el concurso de estos modelos.

Por último, señalar que la alta auto-correlación existente entre las variables independientes que presentan correlación con la biomasa residual (hecho ya observado cuando este grupo de parcelas fue utilizado para ajustar un modelo de regresión logística), impide el ajuste de modelos de regresión compuestos por varias variables, lo que sin duda aumentaría la capacidad predictiva de los mismos.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Casi normal
TM1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TM4	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal
TM5	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
CP3	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TC1	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Casi normal
TC2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TC3	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
SAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
OSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
GESAVI	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Casi normal
GI	Casi normalidad	Normalidad	Positiva	Mesocúrtica	Si	Normal	-	-
MSI	Casi normalidad	Casi normalidad	Negativa	Mesocúrtica	No	No normal	Cuadrado	Normal
VIS123	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal

Tabla 3.16. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en el clúster 2

- Modelos de regresión múltiple del segundo clúster

Como se observa en la Tabla 3.16, nuevamente es necesario transformar la variable biomasa residual y un gran número de las variables correlacionadas con ella para conseguir respetar el supuesto de normalidad univariante. Las transformaciones aplicadas en cada variable en este segundo clúster son prácticamente las mismas que en el primero. Este hecho indica la objetividad del método utilizado para delimitar grupos de parcelas en función de su homogeneidad radiométrica, ya que no afecta a la forma de la distribución estadística de las variables independientes y, sobre todo, de la dependiente.

Las transformaciones aplicadas permiten cumplir los supuestos de homocedasticidad y linealidad en las relaciones individuales entre biomasa residual y cada una de las variables dependientes consideradas. De esta forma, todas las variables recogidas en la Tabla 3.16 son introducidas en los modelos de regresión por pasos que se llevan a cabo con las cinco muestras del 80% de las parcelas seleccionadas al azar.

La utilización de estas cinco muestras da lugar a modelos compuestos por dos variables en los que todas ellas, incluida la constante, son significativas a nivel de 0,05. En todos ellos se selecciona en primer lugar una variable relacionada con el contenido de humedad de la vegetación, que es la que explica la mayor parte de la variación de la variable dependiente, aumentando la segunda ligeramente la proporción de varianza explicada (Tabla 3.17).

Modelo-Muestra	R^2_a	S_e	Índice de condición superior	Variables	β	Sig.
N ₁	0,446	1,241	21,205	cd_MSI	-1,507	0,000
				inv_CP1	74,121	0,000
				Constante	2,199	0,027
N ₂	0,529	1,128	22,817	cd_MSI	-1,948	0,000
				inv_CP1	63,217	0,000
				Constante	3,133	0,002
N ₃	0,513	1,145	43,658	ln_MID57	-2,306	0,000
				rz_TM1	-1,496	0,005
				Constante	14,368	0,000
N ₄	0,465	1,183	29,362	ln_TM7	-2,083	0,000
				rz_TM1	-1,159	0,033
				Constante	10,825	0,000
N ₅	0,479	1,158	43,798	ln_MID57	-2,068	0,000
				cd_MSI	-1,396	0,004
				Constante	11,696	0,000

Tabla 3.17. Modelos de regresión múltiple calculados para el clúster 2: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables

Sin embargo, al igual que ocurría en el anterior clúster, todos estos modelos se encuentran afectados, en mayor o menor grado, por problemas de colinealidad, tal y como indican sus respectivos índices de condición recogidos en la Tabla 3.17, ya que en todos ellos se supera el valor de 15. En este sentido, los modelos de la muestra N₃ y N₅ no pueden ser considerados como válidos, dado que se sobrepasa con creces el límite establecido por este índice a partir del cual se considera que los problemas de colinealidad son graves (valor 30) (Pardo y Ruiz, 2005). De esta manera, los modelos ajustados con las muestras N₃ y N₅ quedan reducidos a una sola variable dependiente, la variable ln_MID57 (Tabla 3.18).

Modelo-Muestra	Variable	R^2_a	S_e	β_0	β_1
N ₃	ln_MID57	0,492	1,170	15,769	-3,657
N ₅	ln_MID57	0,455	1,184	14,855	-3,401

Tabla 3.18. Modelos de regresión calculados para las muestras N₃ y N₅ del clúster 2 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

Los análisis efectuados sobre los residuos de los modelos admitidos de la Tabla 3.17 y de la Tabla 3.18 mostraron la validez de los mismos, ya que la distribución de éstos se adecuaba a la esperada en caso de cumplimiento de los supuestos básicos del análisis de regresión múltiple. No obstante, en los modelos ajustados con las muestras N₁, N₂ y N₄ el análisis de sus residuos dejó entrever rasgos relacionados con el incumplimiento del supuesto de no-colinealidad, aunque no son suficientes para invalidar estos modelos.

Así pues, los resultados obtenidos en este clúster indican una vez más que las variables radiométricas relacionadas con el contenido de humedad vuelven a ser las más útiles para predecir la cantidad de biomasa residual forestal del área de estudio. Por otro lado, destaca el hecho de que la alta auto-correlación existente entre las variables radiométricas utilizadas como variables explicativas impide el ajuste de modelos de regresión múltiple de más de dos términos, pudiendo estar estos últimos afectados por problemas de colinealidad que, en algunos casos, los invalidan en términos estadísticos. Por último, destacar que los modelos bivariantes ajustados sin problemas graves de colinealidad apenas superan la capacidad predictiva de los modelos univariantes obtenidos, lo que indica la poca importancia que tiene para los modelos la variable seleccionada en el segundo paso del método de regresión. Esto se debe, una vez más, a la alta auto-correlación existente entre las dos variables seleccionadas en cada uno de

estos modelos que, aunque se sitúa en un nivel aceptable en términos de colinealidad, hace que ambas expliquen básicamente la misma parte de la variable dependiente, con lo que gran parte de la varianza que no había sido explicada por la primera de las variables seleccionadas vuelve a quedar otra vez sin ser explicada por la segunda variable (Hair *et al.*, 1999).

A pesar de ello, los coeficientes de determinación alcanzados por los modelos de regresión lineal ajustados en este apartado, tanto los de los modelos simples como los de los múltiples, superan a los obtenidos anteriormente para este segundo clúster de homogeneidad en el apartado 3.1.1.3.2 mediante modelos univariantes. Este hecho cabe atribuirlo a dos factores: en primer lugar, a la aplicación de transformaciones, lo que ha hecho que mejoren las relaciones entre la variable dependiente y las independientes al lograr que la varianza de estas últimas se acomode mejor a lo largo del rango de la variable dependiente, y, en segundo lugar, a que las tres parcelas detectadas anteriormente con comportamiento atípico, no han formado parte de la muestra de calibración de los modelos.

Aun así, los modelos obtenidos no se consideran satisfactorios en términos operativos, ya que solamente uno de ellos, el ajustado con la muestra N₂, logra explicar algo más del 50% de la varianza de la biomasa residual del área de estudio. Otro hecho negativo es que el modelo que logra alcanzar este porcentaje de explicación puede estar afectado por problemas de colinealidad y que sólo se repite una vez más en el resto de las 4 muestras empleadas, siendo su capacidad de predicción en este caso sensiblemente inferior (6% menos). Así pues, este modelo conformado por las variables MSI y CP1 puede considerarse como no robusto, ya que es muy dependiente de las parcelas que han sido consideradas para la calibración.

Dado que ninguno de estos modelos es utilizado para la elaboración de cartografía de la biomasa del área de estudio, no fue necesario calcular los errores de estimación de los mismos mediante las muestras de parcelas reservadas para ello.

- Modelos de regresión múltiple del tercer clúster

La Tabla 3.19 recoge los resultados de las pruebas de normalidad aplicadas a cada una de las variables que pueden formar parte de los modelos de regresión lineal múltiple que se van a ajustar para el grupo de parcelas que componen el tercer clúster de homogeneidad (65), así como las transformaciones que permiten el cumplimiento de este supuesto fundamental del análisis multivariante en caso de violación.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TM1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM5	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
CP3	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
TC1	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Casi normal
TC2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TC3	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
SAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
OSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
GESAVI	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
GI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
VIS123	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal

Tabla 3.19. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en el clúster 3

Un hecho a destacar es que, en esta ocasión, a diferencia de lo ocurrido en los dos anteriores clústeres, la aplicación de la transformación raíz cuadrada sí consigue la normalidad de la variable dependiente biomasa residual, lo que en principio redundará en la mejora de la capacidad predictiva de los modelos de regresión. Por otro lado, señalar que las variables que cumplen el supuesto de normalidad sin necesidad de ser transformadas son prácticamente las mismas que en los casos anteriores, repitiéndose también, casi de forma idéntica, el tipo de transformación aplicada en las variables que no cumplen este supuesto.

La edición de gráficos de dispersión individuales entre la variable transformada de la biomasa ($rz_biomasa$) y cada una de las variables dependientes normales o normalizadas para evaluar el respeto de los supuestos de heterocedasticidad y linealidad permitió detectar el incumplimiento de este último supuesto en el caso de la variable inv_TC1 , por lo que fue la única que no tenida en cuenta en los cinco modelos de regresión por pasos que se calculan en este clúster.

La Tabla 3.20 recoge los modelos obtenidos en cada una de las cinco muestras del 80% de las parcelas en los que las variables que los componen resultaron significativas ($p < 0,05$). Como se observa en la tabla, dos de los modelos quedan compuestos por una sola variable, mientras que tres quedan conformados por la participación de dos variables. Sin embargo, dos de estos últimos incumplen el supuesto de no-colinealidad de forma clara (N_1 y N_5), quedando el tercero (N_4) situado justo en el umbral definido para ser considerado como válido o no teniendo en cuenta este supuesto, por lo que fácilmente este modelo también aparecerá afectado por este problema.

La presencia de colinealidad en estos tres modelos es lógica. En los modelos N_1 y N_5 la violación del supuesto de no-colinealidad viene dada porque la banda TM5 está contenida en los dos términos que componen la ecuación de estos dos modelos (recordemos que los índices MID57 y MSI son el resultado de la combinación lineal de TM5 con TM7 y TM4, respectivamente). Por su parte, el problema de colinealidad del modelo N_4 viene dado porque los dos índices utilizados están relacionados de forma indirecta con el mismo tipo de información: el contenido de humedad de la vegetación. De esta manera, ambos están explicando la misma parte de la varianza de la variable dependiente, por lo que están altamente correlacionadas.

Modelo-Muestra	R^2_a	S_e	Índice de condición superior	Variables	β	Sig.
N ₁	0,730	0,853	49,153	ln_MID57	-3,133	0,000
				MSI	-2,665	0,038
				Constante	16,414	0,000
N ₂	0,713	0,853	21,229	ln_TM5	-5,073	0,000
				Constante	17,933	0,000
N ₃	0,750	,837	19,722	ln_TM5	-5,053	0,000
				Constante	17,900	0,000
N ₄	0,760	0,829	29,724	ln_TM7	-2,452	0,001
				MSI	-3,281	0,023
				Constante	12,365	0,000
N ₅	0,767	0,837	43,796	ln_TM5	-3,629	0,000
				MSI	-2,504	0,037
				Constante	16,203	0,000

Tabla 3.20. Modelos de regresión múltiple calculados para el clúster 3: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables

En consecuencia, los modelos afectados por este problema quedan reducidos a una sola variable dependiente, la seleccionada en primer lugar en el método de pasos sucesivos (Tabla 3.21). El análisis de los residuos de estos modelos garantizó el cumplimiento de todos los supuestos del análisis multivariante.

Modelo-Muestra	Variable	R^2_a	S_e	β_0	β_1
N ₁	ln_MID57	0,711	0,883	18,879	-4,663
N ₄	ln_TM7	0,735	0,870	12,603	-3,906
N ₅	ln_TM5	0,750	0,866	18,253	-5,204

Tabla 3.21. Modelos de regresión calculados para las muestras N₁, N₄ y N₅ del clúster 3 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

A la vista de los resultados obtenidos, dos circunstancias vuelven a repetirse con respecto a lo observado en los dos anteriores clústeres en este mismo apartado dedicado al ajuste de modelos de regresión múltiple: (i) las variables radiométricas relacionadas con el contenido de humedad son las más útiles para predecir la cantidad de biomasa residual del área de estudio y (ii) la alta correlación existente entre estas variables y el resto de variables independientes impide el ajuste de modelos múltiples para la estimación de esta variable biofísica.

Centrándonos en la capacidad predictiva de los modelos obtenidos, los coeficientes de determinación alcanzados, todos ellos por encima de 0,710, indican su

utilidad para estimar la biomasa residual del área de estudio desde un punto de vista operativo. Dado que la banda TM5 es la que ha sido seleccionada en un mayor número de modelos (3 de los 5) y a que éstos son los que mayor R^2_a alcanzan, todo parece indicar que los modelos que utilizan esta banda son los más adecuados para estimar la biomasa residual. Aun así, se calcularon los $RMSE$ y los $RMSE_r$ de todos los modelos (expresados en tons/ha y en porcentajes, respectivamente) para corroborar esta afirmación (Tabla 3.22).

Modelo-Muestra	Variable	R^2_a	$RMSE$	$RMSE_r$
N ₁	ln_MID57	0,711	4,843	26,67
N ₂	ln_TM5	0,713	4,591	43,38
N ₃	ln_TM5	0,750	4,767	51,91
N ₄	ln_TM7	0,735	6,144	42,92
N ₅	ln_TM5	0,750	4,792	34,93

Tabla 3.22. $RMSE$ y $RMSE_r$ de los modelos de regresión lineal múltiple calculados para el clúster 3

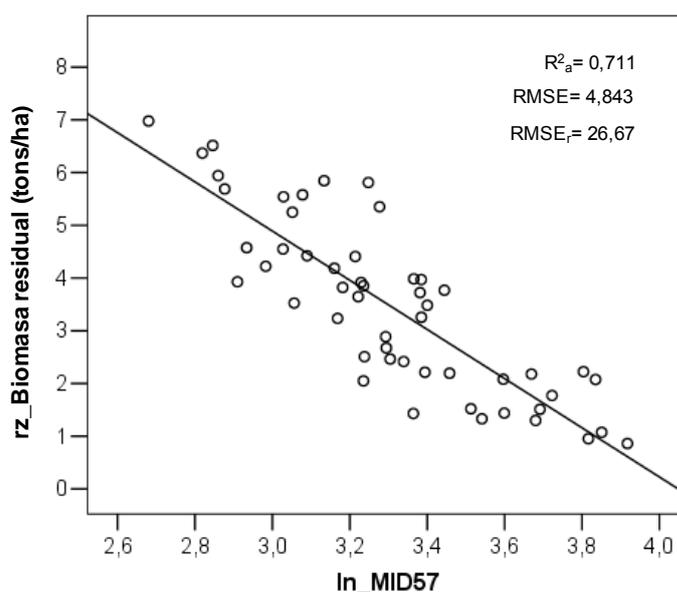


Figura 3.17. Gráfico de dispersión del modelo N₁ de la Tabla 3.22

Los resultados obtenidos en el $RMSE_r$ muestran cómo, en contra de lo esperado, el modelo ajustado con la variable MID57 se erige en el más adecuado para la estimación de la biomasa residual de la provincia de Teruel, ya que solamente presenta un error del 26,67%. Los modelos que utilizan TM5 presentan un error relativo mucho más variable (entre 34,93% y 51,91%), siendo intermedio el obtenido con el modelo que emplea la variable TM7.

En definitiva, el modelo obtenido con la variable MID57 es el que mejor relación presenta entre el coeficiente de determinación alcanzado y el error de estimación obtenido, por lo que es el utilizado para la edición de la cartografía de la biomasa residual que cierra este apartado (Figura 3.18).

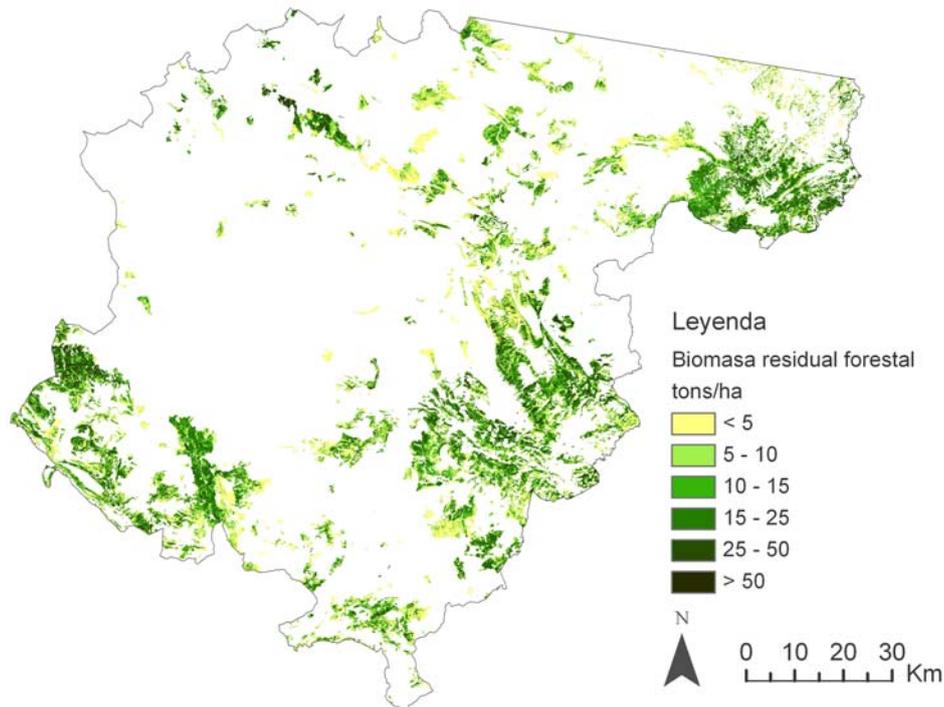


Figura 3.18. Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del tercer clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

- Modelos de regresión múltiple del cuarto clúster

La Tabla 3.23 muestra las conclusiones extraídas de las distintas pruebas gráficas y estadísticas de normalidad aplicadas sobre los valores de las variables dependiente e independientes de las 35 parcelas que componen el clúster que representa la máxima heterogeneidad radiométrica del total de parcelas disponibles. Este escaso número de parcelas favoreció el hecho de que algunas variables superaran ligeramente el test de normalidad de S-W sin que las pruebas gráficas del histograma y del gráfico de normalidad se ajustaran a la situación típica de normalidad. En estos casos, las variables fueron transformadas para lograr mejores valores en los test estadísticos y gráficos, asegurándose así el cumplimiento del supuesto. Estas situaciones se han señalado en la tabla mediante la adición de un asterisco (*) en la columna Test S-W.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test S-W	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TM1	Casi normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
TM2	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
TM5	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
CP3	Casi normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
TC1	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
TC2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TC3	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
SAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
MSAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
OSAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
GESAVI	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal
GI	Casi normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSI	Casi normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
VIS123	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal

Tabla 3.23. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en el clúster 4

Al igual que en los anteriores subapartados, el cumplimiento de los supuestos de heterocedasticidad y linealidad de las relaciones entre la variable dependiente (*rz_biomasa*) y cada una de las independientes que superaron la primera fase de análisis fue verificado mediante el uso de gráficos de dispersión individuales que combinaban estos dos tipos de variables, no detectándose en ningún caso situaciones de incumplimiento.

Solamente uno de los modelos ajustados por el método de selección por pasos sucesivos con las cinco muestras del 70% de las parcelas seleccionadas al azar dio lugar a una ecuación compuesta por dos variables independientes en la que ambas eran significativas a nivel de 0,05. Sin embargo, tanto los índices de tolerancia y *FIV* como los de condición señalaron que este modelo incumplía de una manera muy clara el supuesto de no-colinealidad, por lo que fue directamente desechado y remplazado por el calculado con esa muestra en el primer paso. De esta manera, tal y como se observa en la Tabla 3.24, los cinco modelos ajustados en este cuarto clúster quedaron nuevamente caracterizados por la utilización de una única variable relacionada con el contenido de humedad de la vegetación, siendo la variable transformada de TM7 (*ln_TM7*) la más recurrente en esta ocasión (aparece en tres de los cinco modelos).

Tal y como se esperaba, a tenor de los resultados obtenidos previamente con este grupo de parcelas mediante la utilización de regresiones logísticas y simples, la capacidad predictiva de los modelos obtenidos en este apartado es muy alta, explicando 4 de ellos más del 82% de la varianza de la variable dependiente. Este hecho es particularmente satisfactorio teniendo en cuenta la influencia que en un grupo tan pequeño de parcelas puede introducir la división aleatoria de la muestra.

Modelo-Muestra	Variable	R^2_a	S_e	β_0	β_1
N ₁	ln_TM7	0,823	0,839	13,360	-4,188
N ₂	ln_TM7	0,781	0,827	12,814	-3,927
N ₃	ln_TM5	0,842	0,726	18,803	-5,369
N ₄	ln_TM7	0,832	0,782	13,516	-4,260
N ₅	ln_MID57	0,860	0,705	20,340	-5,033

Tabla 3.24. Modelos de regresión múltiple calculados para el clúster 4: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

Respecto a la validez de estos modelos, el estudio de los residuales de cada uno de ellos permite afirmar que todos cumplen los supuestos del análisis de regresión sin problemas, ya que globalmente se ajustan a los patrones esperados.

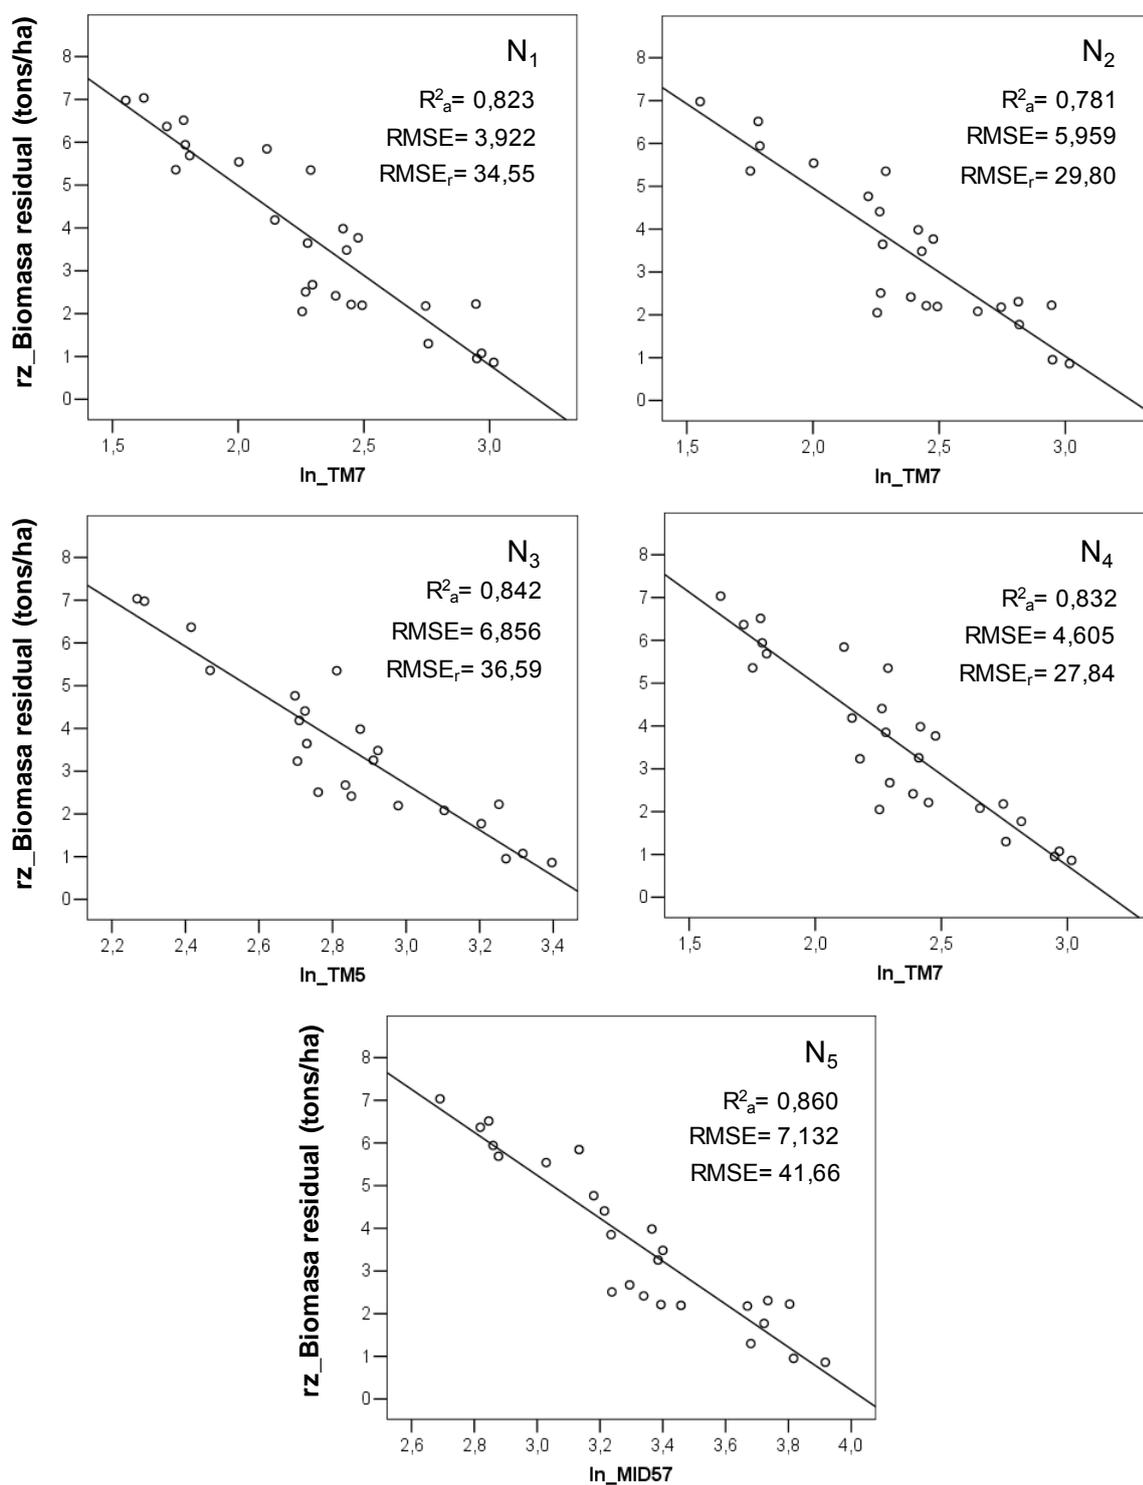


Figura 3.19. Gráficos de dispersión de los cinco modelos de la Tabla 3.24

Por último, en la Figura 3.19, que recoge los gráficos de dispersión a partir de los cuales se ajustan los modelos de la anterior tabla, se muestra el error de predicción

obtenido en cada uno de estos modelos utilizando sus respectivas muestras de validación (30% de las parcelas). Como se observa en la figura, las diferencias obtenidas en términos de error son más notables que las obtenidas teniendo en cuenta el coeficiente de determinación ajustado. Así, el modelo con mayor error (N_5) presenta un $RMSE$, 14 puntos superior al de menor error (N_4). Este hecho pone de manifiesto que la influencia que el pequeño tamaño de la muestra tiene en la robustez de los modelos es mayor de lo que se pensaba observando tan sólo el coeficiente de determinación, ya que la presencia de determinados puntos en la muestra de validación, los de mayor valor, determina que los modelos obtengan un mayor o menor error en la estimación de la biomasa residual.

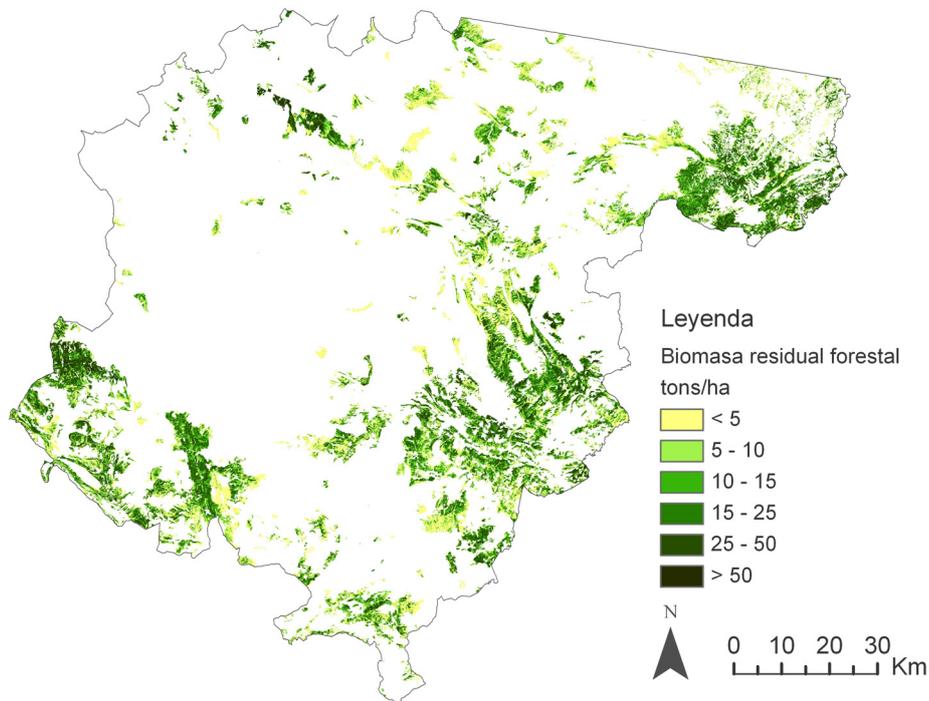


Figura 3.20. Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del cuarto clúster derivadas de la utilización del método de extracción de ventanas 3x3 y el CV

A pesar de esta circunstancia, es de destacar el hecho positivo de que estos cinco modelos se basen en la utilización de las bandas que, a lo largo de este apartado, se han mostrado como las más útiles para estimar la biomasa residual del área de estudio, independientemente del grado de heterogeneidad de la muestra utilizada, lo que avala la utilidad de las mismas. Así pues, a pesar de que estos modelos puedan estar sobreajustados a la muestra, no cabe duda de que responden a la existencia de una relación biofísica estable entre la variable estudiada y la respuesta espectral registrada por el sensor.

Para crear la cartografía de la biomasa residual del área de estudio, los modelos que utilizan la banda TM7 parecen los más adecuados, ya que son los que más se repiten y los que mejor relación presentan entre el coeficiente de determinación alcanzado y el error obtenido. Dentro de estos, se selecciona el ajustado a partir de la muestra N_4 dado que es el que presenta un $RMSE_r$ menor.

3.1.1.4. Conclusiones

La utilización de ventanas fijas de tamaño 3x3 píxeles y del CV de *Pearson* se han mostrado como técnicas útiles para conocer la influencia que la heterogeneidad espacial de los bosques mediterráneos tiene en el ajuste de modelos de estimación de biomasa residual forestal mediante el uso de imágenes ópticas de resolución media y otras variables auxiliares.

La información obtenida mediante estos dos métodos ha dado la oportunidad de considerar distintos grupos de parcelas del IFN-2 sobre las que se tiene información de biomasa residual en función de su heterogeneidad espacial-radiométrica. Los resultados obtenidos en estos grupos mediante la utilización de los diferentes métodos de regresión aquí considerados permiten llegar a las siguientes conclusiones parciales que dirigen los siguientes apartados del trabajo:

I. La heterogeneidad de los bosques mediterráneos es un factor de primera magnitud a la hora de obtener modelos estimativos precisos y operativos.

Los coeficientes de correlación obtenidos al relacionar la biomasa residual con las variables radiométricas en cada uno de los 10 grupos de parcelas delimitados en función de su heterogeneidad espacial-radiométrica han mostrado cómo las correlaciones entre ambas variables son más altas a medida que la homogeneidad es mayor.

Esta situación tiene su reflejo en los resultados obtenidos en los distintos métodos de regresión ajustados en los cuatro grupos seleccionados como representantes de distintos niveles de heterogeneidad, los denominados a lo largo de este trabajo como clúster 1 (exponente de la máxima heterogeneidad, ya que incluye toda la muestra disponible), clúster 2 (heterogeneidad intermedia resultante de la eliminación de las parcelas más problemáticas), clúster 3 (parcelas con un alto grado de homogeneidad) y clúster 4 (máximo exponente de homogeneidad de la muestra).

De esta manera, se ha mostrado la imposibilidad de ajustar modelos de regresión que permitan conocer de una forma precisa la cantidad exacta de biomasa residual en los dos primeros clústeres, dada la insuficiente relación entre la variable dependiente y las independientes y la alta correlación existente entre estas últimas. Sin embargo, el análisis de regresión logística sí se ha mostrado como una técnica estadística adecuada para cartografiar zonas con alta y baja probabilidad de biomasa residual forestal a pesar de la alta heterogeneidad radiométrica de la muestra. Aunque en estos clústeres (1 y 2) los resultados obtenidos con la regresión logística son satisfactorios, los ajustes son mejores en el clúster dos, cuando se eliminan las parcelas que más claramente presentan problemas de localización o que pueden incluir otros elementos paisajísticos. Así pues, la regresión logística se erige en una herramienta útil para obtener una primera valoración acerca de la existencia de este recurso forestal en ambientes forestales de carácter heterogéneo a partir de la consideración de variables continuas y categóricas sencillas de obtener a partir del uso de técnicas de teledetección y SIG.

Por su parte, la utilización de los clústeres 3 y 4 ha mostrado que es posible establecer modelos estimativos precisos en ambientes forestales caracterizados por una alta homogeneidad espacial. Sin embargo, como se discutirá más adelante, el hecho de que estos dos grupos estén compuestos por un escaso número de parcelas en comparación con la muestra total de la que se dispone (65 y 35 parcelas, después de la eliminación de las atípicas detectadas) puede hacer que estos modelos estén sobreajustados y que no sean representativos para todo el territorio considerado en este trabajo.

II. Entre las variables independientes consideradas, las radiométricas derivadas de la imagen Landsat son las más útiles para estimar la biomasa residual forestal del área de estudio.

La aportación de variables topográficas derivadas del MDE para estimar biomasa residual forestal es nula, ya que únicamente unas pocas variables (principalmente Elevación, VER_POT_HORAS e INV_POT) presentan correlaciones significativas en los tres grupos con mayor número de parcelas, desapareciendo la significación cuando sólo se consideran las parcelas más homogéneas. Estas correlaciones significativas son muy débiles, no logrando explicar ni el 0,5% de la varianza de la variable dependiente, por lo que esta relación puede ser achacada al factor azar. Así, a pesar de su escasa correlación con las radiométricas, ninguna de las variables topográficas consideradas fue incluida en los modelos multivariantes ajustados por el método de pasos sucesivos en el

anterior apartado, ni siquiera en los modelos de regresión logística ajustados para el clúster 1, en donde las relaciones eran más significativas.

Por el contrario, una de las dos variables forestales derivadas del *Mapa Forestal de Aragón*, COD_MADUREZ, sí que se muestra útil para estimar la biomasa residual del área de estudio. Esta información, reclasificada como variable binaria, forma parte de los modelos multivariantes de regresión logística obtenidos para los clústeres 1 y 2, teniendo un peso importante en ambos, tal y como indican los respectivos $Exp(\beta)$ de cada modelo. Como se ha señalado con anterioridad, esta variable indica en los modelos que la cantidad de biomasa residual es mayor en las masas de pináceas que se sitúan en los dos niveles de madurez superiores en el área de estudio (6 y 7) que en las que pertenecen a niveles inferiores. Así pues, aunque la utilidad de esta información en la obtención de modelos es limitada, por cuanto su naturaleza categórica sólo le permite formar parte de los modelos de regresión logística, su papel es importante, ya que estos modelos se han revelado como los únicos factibles para obtener una aproximación a la cantidad de biomasa existente en bosques caracterizados por una gran heterogeneidad.

Así, en consonancia con la hipótesis de partida de este trabajo, los resultados obtenidos han mostrado como las variables radiométricas derivadas de la imagen Landsat son las más útiles, entre todas las consideradas, para estimar la biomasa residual forestal del área de estudio, ya que todos los modelos a partir de los cuales se ha podido obtener cartografía emplean una de estas variables como principal o como única. Dentro de estas variables, los análisis realizados permiten afirmar que las relacionadas con el contenido de la humedad de la vegetación son las más útiles para cumplir con el objetivo de esta tesis.

En efecto, tal y como se observa en los resultados obtenidos en el análisis de correlaciones, las variables consideradas relacionadas directa o indirectamente con el contenido de agua de la vegetación son las que mayores coeficiente de correlación presentan, independientemente del grado de heterogeneidad de la muestra. Este hecho se ve confirmado en todos los análisis de regresión llevados a cabo en los cuatro clústeres, los cuales siempre dan como mejor resultado modelos basados en el uso de alguna de estas variables. A este respecto, señalar que la identificación de una variable radiométrica relacionada con la humedad como una de las mejores predictoras coincide con las aportaciones de algunos trabajos que han abordado la estimación de biomasa (Steininger, 2000; Foody *et al.*, 2001; Lu *et al.*, 2004; Lu, 2005; Lu y Batistella, 2005) y

otros parámetros forestales continuos como el LAI (Eklundh *et al.*, 2001; Eklundh *et al.*, 2003).

El diferente rango dinámico de las bandas originales proporcionadas por el sensor TM a las variaciones de biomasa residual forestal puede explicar porqué las variables espectrales relacionadas con la humedad son más adecuadas que el resto de las variables radiométricas consideradas en este trabajo. En relación con esto, las dos bandas originales que registran información en el infrarrojo medio (TM5 y TM7) presentan un mayor rango dinámico que las tres bandas que registran información en la región del visible (TM1, TM2 y TM3). Consecuentemente, TM5 y TM7 han resultado más útiles para describir y explicar la variabilidad de la variable dependiente. Con respecto a TM4, independientemente de su rango dinámico, se ha mostrado cómo esta banda es la que presenta menor grado de correlación con la biomasa, pudiéndose explicar esta circunstancia por los motivos anteriormente señalados que modifican la relación directa de esta banda con la biomasa esperada en un principio.

En este sentido, los resultados obtenidos con los neocanales considerados en esta investigación están también relacionados con este rango dinámico de las bandas originales TM con las variaciones de biomasa residual forestal. Por lo tanto, los neocanales que tienen mayores cargas en su formación de las bandas TM5 y TM7 son también los mejor correlacionados con la biomasa. Por otra parte, diferentes trabajos han mostrado que los índices de vegetación como el NDVI tienden a saturarse tempranamente a altas densidades de vegetación (Gitelson, 2004; Mutanga y Skidmore, 2004). Como resultado, TC3, MSI y MID57 son las tres transformaciones correlacionadas con la biomasa residual.

Como ejemplo de la solidez de estas variables relacionadas con la humedad como las más adecuadas para la estimación de la biomasa, basta recordar lo ocurrido cuando se abordó la formulación de modelos de regresión simple en el clúster 4, donde el escaso número de parcelas invitaba a que cualquier variable radiométrica pudiera ajustar de forma correcta un modelo mejor. En este clúster, los modelos ajustados con las variables VIS123, TM2 y TM3 presentaron unos coeficientes de determinación algo mejores que los que utilizaban las variables TM5 y MID57. Sin embargo, a pesar de esto, la utilización de las muestras de validación mostró cómo los modelos obtenidos con TM5 y MID57 daban lugar a errores en la estimación notablemente inferiores a los proporcionados por

los tres primeros, siendo más precisos y más coherentes con los resultados obtenidos hasta entonces.

Dentro de las variables relacionadas con la humedad, señalar que en los modelos de regresión logística la variable MSI es la más útil, mientras que en los modelos de regresión cuantitativos tradicionales curvilíneos o lineales, las variables originales de la imagen Landsat, TM5 y TM7, y el neocanal resultante de la suma de éstas, MID57, se erigen como las más adecuadas. A este respecto señalar que el carácter curvilíneo de las relaciones entre la biomasa residual y TM5, TM7 y MID57 es el responsable de que alguna de estas variables no haya sido seleccionada en los modelos de regresión logística en lugar de MSI. Recordemos que, para el ajuste de estos modelos, dada la alta auto-correlación existente entre las variables independientes, se decidió utilizar la más correlacionada con la biomasa residual que menos lo estuviera con el resto de variables predictoras, utilizándose para ello el índice de correlación de *Pearson*. Este índice, tal y como indica Hair (1982), no es el más adecuado para medir una relación de dependencia cuando ésta no es de carácter lineal, lo que hizo que MSI fuera la seleccionada, ya que, como se vio con posterioridad mediante los gráficos de dispersión creados para los modelos de regresión simple, esta variable sí estaba relacionada linealmente con la biomasa, mientras que TM5, TM7 y MID57 lo estaban de forma no lineal. Aun así, basándonos en las altas correlaciones observadas entre estos cuatro índices, podemos afirmar que los modelos de regresión logística ajustados en este trabajo son totalmente válidos y que no se diferencian mucho de los que se habrían obtenido utilizando cualquiera de las otras tres variables, más aun cuando estos modelos constituyen una primera aproximación a la cantidad de biomasa residual del área de estudio, que simplemente señalan los lugares donde existe mayor probabilidad de encontrar una determinada cantidad.

Por último, resaltar que aunque criterios basados en un mayor coeficiente de determinación, un menor error de la estimación y una mayor amplitud del rango efectivo de la variable independiente han determinado la elección entre TM5, TM7 y MID57 en los modelos univariantes ajustados en los clústeres 3 y 4, cualquiera de los otros dos índices no seleccionados hubiera dado lugar a un modelo similar e igualmente válido para obtener cartografía de biomasa residual del área de estudio. Esta afirmación se ve confirmada en los análisis de regresión multivariante posteriores llevados a cabo en estos clústeres, ya que la división aleatoria de la muestra en 5 grupos diferentes indica cómo,

aunque siempre una de las tres bandas es al final más veces seleccionada, las otras son también validas en otras subdivisiones, alcanzando similares resultados.

III. La relación entre la biomasa residual forestal y las variables radiométricas derivadas de la imagen Landsat es predominantemente de carácter curvilíneo.

A lo largo del apartado dedicado al análisis de regresión simple, los gráficos de dispersión ajustados en los diferentes clústeres entre la variable biomasa residual y las variables radiométricas han mostrado cómo las relaciones entre estos dos tipos de variables son mayoritariamente no lineales, constituyéndose como excepción los índices de vegetación NDVI, los de la familia SAVI, el MSI y el GI.

Esta circunstancia indica que la mayoría de variables radiométricas consideradas presenta un punto de saturación a partir del cual son incapaces de predecir cantidades de biomasa residual mayores, situación ya observada en otros trabajos que intentan estimar *AGB* a nivel regional mediante el concurso de satélites ópticos, sobre todo en ambientes complejos (Lu, 2006; Anaya *et al.*, 2008). La excepción la constituyen las variables que presentan una relación lineal, si bien es necesario señalar que éstas también podrían tener un comportamiento curvilíneo si se utilizaran cantidades mayores de biomasa residual que las aquí consideradas. Así pues, con respecto a estas últimas variables, solamente podemos afirmar que su rango es efectivo sin saturación para la variación de biomasa presente en la muestra, pero que lo desconocemos para variaciones superiores.

A los efectos prácticos de este trabajo, los mejores modelos de regresión ajustados en el apartado de regresión simple corresponden a los clústeres 3 y 4, que han dado lugar a cartografías de estimación válidas para el área de estudio, ya que la saturación de ambos se sitúa en un nivel ligeramente superior a la cantidad máxima de biomasa de la muestra utilizada de 482 parcelas (64,720 tons/ha).

Por otra parte, como se ha visto en el apartado centrado en el ajuste de modelos de regresión lineal múltiple, la presencia de estas relaciones curvilíneas hace que sea necesario aplicar transformaciones que garanticen los supuestos básicos de este tipo análisis de dependencia multivariante. Es necesario señalar que la linearización de las relaciones no supone la desaparición del problema de saturación en el caso de que ésta exista, ya que tal situación provoca la acumulación de puntos en el tramo superior de la relación lineal, no la dispersión de éstos a lo largo del mismo.

La aplicación de estas transformaciones es costosa en tiempo y, en el caso de que no sirvan para la el ajuste de modelos multivariantes, tal y como ocurre en este

trabajo, no sirven para lograr mejores modelos predictivos que los curvilineales, sino para ofrecer otra versión parecida de estos tanto en términos de capacidad de predicción como en términos de error de estimación.

IV. Las altas correlaciones existentes entre las variables radiométricas impiden el ajuste de modelos de estimación multivariantes.

El objetivo que se perseguía mediante la utilización de un gran número de variables radiométricas era encontrar una principal que pudiera explicar una gran proporción de esta variable biofísica, pudiendo ser el resto de varianza explicada mediante el uso de otra u otras variables.

Sin embargo, los análisis llevados a cabo en el apartado dedicado a la regresión logística mostraron que las auto-correlaciones entre las variables radiométricas que más relacionadas estaban con la biomasa residual eran muy altas, incrementándose a medida que la homogeneidad radiométrica de las parcelas era mayor. Así pues, en aras de asegurar la robustez de los modelos, esta situación desaconsejaba la consideración de todas las variables radiométricas para su ajuste, ya que éste se podía basar en una u otra dependiendo de la muestra de 80% de las parcelas utilizada para la calibración. Este hecho fue solucionado seleccionando la variable más correlacionada con la biomasa residual junto a aquellas otras radiométricas que, estando relacionadas con la biomasa, menos lo estuvieran con la introducida en primer lugar, aunque esto solo fue efectivo en el primero de los clústeres. Lo que sí se consiguió con esta estrategia fue garantizar la coherencia de los modelos de regresión logística, independientemente del grado de heterogeneidad y de las parcelas seleccionadas al azar en las 5 subdivisiones, ya que siempre se utilizaba la variable mejor correlacionada considerando todo el conjunto de parcelas.

Esta situación de alta auto-correlación también se manifestó de una forma clara en los intentos efectuados para ajustar modelos de regresión lineal múltiple. Este factor es el causante de que, dependiendo de la subdivisión utilizada, la variable radiométrica seleccionada en el método por pasos sucesivos sea una u otra, aunque siempre relacionada con el contenido de humedad de la vegetación, lo que hace que el modelo tenga una similar capacidad de predicción. Otro indicador de la alta correlación entre las independientes es que, cuando se logra ajustar una ecuación lineal compuesta por dos variables, alguno de los estadísticos utilizados para diagnosticar la colinealidad del modelo supera los umbrales máximos permitidos, por lo que son desechados. Además,

otro hecho significativo de estos modelos, que indica que las dos independientes seleccionadas están altamente relacionadas, es que el coeficiente de determinación apenas incrementa su valor con el añadido de la segunda variable, ya que ésta explica casi la misma porción de la varianza de la dependiente que la seleccionada en primer lugar.

Así pues, a pesar de haber considerado variables de diferentes partes del espectro electromagnético (las bandas originales de Landsat TM) y un amplio número de índices relacionados con variables biofísicas de la vegetación (contenido de humedad, vigor vegetal...), no resulta posible integrar dos de ellas en el mismo modelo, bien sea porque a pesar de explicar distinta información están igualmente relacionadas con la biomasa residual, bien porque no lo están suficientemente para ser integradas en un modelo explicativo.

En conclusión, la utilización de ventanas fijas de 3x3 se ha mostrado como una técnica de extracción de la información radiométrica útil para la obtención de modelos exploratorios que permiten conocer la probabilidad de existencia de una determinada cantidad de biomasa residual en boques mediterráneos caracterizados por una alta heterogeneidad espacial-radiométrica, mientras que modelos cuantitativos más precisos son sólo posibles si la muestra utilizada queda reducida a las parcelas más homogéneas. Estos resultados coinciden con lo apuntado por Salvador y Pons (1998a), que señalan cómo trabajos que utilizan un gran número de parcelas (a pesar de centrarse en ambientes boreales más homogéneos) obtienen un bajo coeficiente de determinación, mientras que investigaciones que utilizan un número mucho menor de puntos dan lugar a ajustes mejores.

A este respecto, cabe señalar que la escasez de la muestra empleada para el ajuste de estos últimos (65 y 35 parcelas) puede hacer que estos modelos estén sobreajustados, siendo sólo válidos para ser utilizados en el área en el cual han sido calculados (Salvador y Pons, 1998a,b); es decir, que estos modelos sólo sean representativos para los bosques de pináceas de la provincia de Teruel y no extrapolables a otras áreas distintas. Desde un punto de vista mucho más estricto, el escaso número de parcelas empleado teniendo en cuenta el número inicial (13,49% y 7,26%, respectivamente) puede incluso poner en duda que estos modelos sean representativos de todos los bosques turolenses, ya que pueden no ser suficientes para caracterizar todos los ambientes en los que las especies consideradas se encuentran.

Así pues, resulta necesario indagar si otros métodos de extracción radiométrica empleados en la literatura científica para estimar parámetros forestales mediante imágenes de satélite resultan más adecuados y dan lugar a ajustes de regresión similares a los obtenidos en los dos clústeres representantes del máximo grado de homogeneidad, pero a partir de un mayor número de parcelas. La consideración de un mayor número de parcelas evitará la posibilidad de que los modelos obtenidos estén sobre-ajustados, aumentándose así la probabilidad de que sean más representativos de todos los bosques de pináceas de la provincia de Teruel y extrapolables a otras áreas de similares características.

La aplicación de los nuevos métodos de extracción en los siguientes apartados se hace teniendo en cuenta los resultados obtenidos en éste relativos a la influencia que la heterogeneidad espacial-radiométrica tiene en el ajuste de modelos estimativos precisos, la nula aportación que las variables topográficas o forestales tienen en éstos, el carácter no lineal de las relaciones entre la biomasa y las variables radiométricas que mejor explican esta relación y, por último, la alta correlación existente entre estas variables radiométricas.

3.1.2. Estimación de la biomasa residual forestal a partir de la información de las variables independientes obtenida mediante la utilización de áreas homogéneas

Aunque, como se ha indicado anteriormente, la utilización de ventanas fijas es la forma más sencilla y común de extracción de información radiométrica para la estimación de parámetros forestales, diversos autores señalan que esta forma de proceder puede dar lugar a imprecisiones en los resultados, que pueden ser evitadas mediante el uso de otras metodologías de extracción (Mäkelä y Pekkarinen, 2001; Pekkarinen, 2002; Mäkelä y Pekkarinen, 2004; Muukkonen y Heiskanen, 2005; Tuominen y Pekkarinen, 2005; Hall *et al.*, 2006).

La principal crítica vertida por estos autores es que, aunque la metodología empleada anteriormente de extracción del valor medio de la ventana 3x3 situada sobre la parcelas del IFN-2 reduce la posibilidad de introducir errores relacionados con la localización de los puntos en el campo y la georreferenciación de la imagen de satélite, al tiempo que también disminuye la influencia que la resolución espacial del sensor tiene en la estimación, ninguna de estas fuentes de error desaparece completamente con este método. Esta posibilidad de conservar errores en la localización aumenta cuando, tal y

como curre en nuestro caso, el tamaño de la parcela es pequeño (Muukkonen y Heiskanen, 2005).

Además de este inconveniente, Mäkelä y Pekkarinen (2001) también señalan que esta forma de proceder hace que tras la información de la media se pierdan detalles específicos de algunas parcelas, con lo que los valores radiométricos extremos que las caracterizan no se incluyen en la relación parámetro forestal-información radiométrica. Junto a esto, Pekkarinen (2002) también apunta otro aspecto negativo de la utilización de ventanas fijas para la extracción de parámetros forestales: la posibilidad de que el *kernel* usado intersekte otras unidades con características radiométricas y forestales diferentes, lo que hace que los valores radiométricos extraídos no representen correctamente las características de la parcela. Esta última circunstancia se ha reducido al máximo en el anterior apartado utilizando la ventana fija de menor tamaño posible y, sobre todo, con el empleo del CV, que permitía la selección de parcelas con entornos radiométricos homogéneos, lo que garantizaba la no inclusión en los datos de otras realidades físicas y radiométricas. Sin embargo, como se ha mostrado con anterioridad, la combinación de estos dos métodos hacía que sólo un reducido número de parcelas cumpliera con el criterio de homogeneidad, lo que indica que, en la gran mayoría de las ocasiones, la ventana de 3x3 era representante de la mezcla de varias cubiertas, circunstancia ésta que impedía lograr buenos ajustes en las ecuaciones de estimación cuando eran consideradas. Por último, señalar que la utilización de información a nivel de parcela puede no ser representativa como unidad de análisis para toda la imagen, ya que no representan unidades homogéneas desde el punto de vista espectral (Mäkelä y Pekkarinen, 2004).

Una posible solución a estos problemas es utilizar como método de extracción unidades de mayor tamaño que las parcelas para las cuales se tienen datos de biomasa residual forestal. Estas unidades deben ser homogéneas desde el punto de vista de sus características forestales (Mäkelä y Pekkarinen, 2004; Muukkonen y Heiskanen, 2005) o espectrales (Mäkelä y Pekkarinen, 2001; Pekkarinen, 2002; Hall *et al.*, 2006).

Con respecto a la primera posibilidad, no existe para el área de estudio otra información de biomasa residual forestal distinta a la calculada en este trabajo, por lo que la creación de áreas homogéneas forestales de mayor tamaño que las parcelas circulares del IFN-2 tiene que ser a partir de éstas y de información auxiliar. En este sentido, la interpretación de fotografía aérea de alta resolución espacial se ha mostrado útil en

tareas de inventario forestal tales como la individualización de distintos estratos, la estimación de volúmenes y la medición de distintas características forestales (Lu, 2006). En este contexto, las ortofotografías aéreas de resolución espacial de 1 metro, utilizadas para la georreferenciación de las imágenes Landsat y para la eliminación de las parcelas con un comportamiento atípico, pueden ser usadas para crear áreas homogéneas forestales de igual composición y estructura que las parcelas del inventario, pero de mayor tamaño.

La segunda posibilidad se basa en el hecho de que, en un escenario ideal, las técnicas de segmentación de las imágenes de satélite son adecuadas para la individualización de unidades forestales homogéneas desde un punto de vista espectral y, por lo tanto, homogéneas también en cuanto a sus características forestales. De esta forma, las características espectrales de esa unidad forestal pueden ser extraídas directamente usando como referencia los límites que han sido definidos en el proceso de segmentación de la imagen, siendo utilizados estos datos para estimar la variable estudiada. Sin embargo, la variación interna de algunas de las características forestales dentro de las unidades delimitadas puede ser mayor a lo descrito por el método de la segmentación utilizado. Junto a esto, otro factor posible de error es que la información recogida en la parcela no tiene por qué ser representativa de toda la unidad delimitada (Pekkarinen, 2002). Debido a estas dos últimas circunstancias, cuando los datos de campo de la variable forestal han sido obtenidos a escala de parcela, además de con la información espectral ofrecida por el área producto de la segmentación, es necesario contar también con la del interior de esta parcela y de su vecindad más inmediata (Mäkelä y Pekkarinen, 2001; Pekkarinen, 2002).

En los dos siguientes apartados (3.1.2.1 y 3.1.2.2) se ensaya si estas dos formas de extraer la información radiométrica mejoran los resultados de los modelos de regresión simple y lineal multivariante ajustados anteriormente en los dos clústeres que contenían las parcelas más homogéneas.

3.1.2.1. Estimación mediante la utilización de áreas forestales homogéneas delimitadas a partir de fotografía aérea de alta resolución

3.1.2.1.1. Procedimiento de delimitación de las áreas forestales homogéneas y extracción de la información de las variables independientes continuas

Desde finales de la década de los 40, la interpretación de fotografías aéreas ha sido una técnica muy utilizada para la realización de tareas relacionadas con inventarios

forestales. En este sentido, la fotointerpretación se ha mostrado como recurso adecuado para la medición de características forestales individuales, tales como la altura y el diámetro de la copa de un árbol, o de un bosque, como por ejemplo el espesor de copas o la delimitación de áreas homogéneas (Lu, 2006).

Un ejemplo de la utilidad de la fotografía aérea en la delimitación de áreas forestales homogéneas se da en Finlandia. En este país nórdico, la delimitación de las áreas forestales que sirven como unidad básica para la recolección de datos, el planeamiento de la gestión y la realización de operaciones forestales es efectuada mediante la interpretación visual de fotografías color-infrarrojo en soporte analógico o digital a escala 1:10.000-1:30.000 (Mäkelä y Pekkarinen, 2004). Las áreas forestales así delimitadas tienen que cumplir tres criterios: (i) ser homogéneas, (ii) ser adecuadas como unidad de práctica forestal y (iii) ser adecuadas para actualizar la información forestal de inventario (Muukkonen y Heiskanen, 2005). Los límites de estas unidades, trazados con el apoyo de la fotografía, son comprobados mediante trabajo de campo durante las tareas del inventario forestal y son corregidos sólo cuando se detectan errores. Los parámetros forestales dentro de estas áreas son evaluados mediante un inventario ocular a partir de características medias medidas en algunos puntos situados en su interior, utilizando como referencia las medidas sistemáticas tomadas en parcelas de inventario más pequeñas (Mäkelä y Pekkarinen, 2004). Estos datos de campo son los utilizados como variable dependiente en la estimación de biomasa y volúmenes de madera mediante la utilización de imágenes Landsat (Ardö, 1992; Mäkelä y Pekkarinen, 2004) y ASTER (Muukkonen y Heiskanen, 2005).

Una de las ventajas del análisis visual de imágenes sobre el tratamiento digital es que el primero permite incorporar a la interpretación de la imagen criterios complejos (Chuvienco, 1996). Entre las pautas visuales manejadas en la interpretación de fotografía aérea (forma, tamaño, estructura, tono, textura, sombras, contexto, asociación y resolución, Lillesand y Kiefer, 2000), Tuominen y Pekkarinen (2005) destacan las características de estructura y textura como las más importantes. Estos autores indican la dificultad de encontrar un procedimiento automático que sea capaz de reconocer objetos basados en estas dos propiedades, por lo que el análisis visual resulta más adecuado para la interpretación de las características forestales y de su estructura.

Teniendo en cuenta lo recogido en estos párrafos, las ortofotografías aéreas de resolución espacial de 1 m del *SIG Oleícola Español* empleadas en anteriores tareas son

susceptibles de ser utilizadas para extender las parcelas del IFN-2 a áreas homogéneas de mayor tamaño con similar composición y estructura forestal a partir de la interpretación visual. Se reduce así la posibilidad de cometer los errores anteriormente asociados a la utilización de ventanas fijas, a la vez que se utiliza una escala de extracción de información más acorde con el concepto de unidad forestal.

La creación de estas áreas homogéneas forestales se hizo a partir de herramientas de digitalización en pantalla incluidas en el *software* ArcGIS-ArcINFO, procediéndose de la siguiente manera:

- En primer lugar, la importación del mosaico de la provincia de Teruel creado con estas ortofotografías para la georreferenciación de las imágenes Landsat.
- Sobre este mosaico, se superpuso la cartografía de puntos que representa el centroide de las 482 parcelas del IFN-2 para las que se dispone de información de biomasa residual. A partir de estos puntos, teniendo en cuenta la información sobre el radio de cada una de las parcelas (5, 10, 15 ó 25 m), se editaron los *buffers* que representaban el área muestreada en las tareas de inventario.
- Se superpusieron las hojas del MFA de la provincia de Teruel. Esto se hizo para garantizar que la composición forestal de las nuevas áreas fuera idéntica a la del interior de las parcelas del Inventario.
- Con toda esta información se procedió a la creación de las nuevas áreas en función de lo observado dentro de las parcelas y atendiendo a las pautas visuales de interpretación de fotografía aérea anteriormente apuntadas, generándose un nuevo fichero de tipo vectorial. Cada una de las nuevas áreas de este fichero fue definida en una tabla alfanumérica asociada con los siguientes atributos: número de parcela, cantidad de biomasa forestal (tons/ha) y aptitud. Este último atributo, que varía entre 1 y 3, hace referencia a la calidad del área delimitada en términos de grado de similitud con lo observado dentro de la parcela: 1 indica baja calidad (muchas dudas en el establecimiento de los límites de la nueva área), 2 expresa calidad media (algunas dudas en el establecimiento de los límites) y 3 denota calidad alta (la digitalización de los nuevos límites resulta sencilla y, por lo tanto, no entraña dudas).

- Finalmente, una vez delimitadas todas las nuevas áreas, se realizaron dos procesos de revisión sobre las mismas. Cuando se descubrieron errores en los límites, éstos fueron modificados, cambiándose también el valor del atributo de aptitud.

Como resultado de este proceso se obtuvieron un total de 436 áreas forestales homogéneas, ya que en 46 casos fue imposible digitalizar un entorno homogéneo mayor al de las parcelas del inventario. Un total de 83 de estas nuevas áreas fueron clasificadas como de aptitud 1, 222 fueron catalogadas como de aptitud 2 y, finalmente, 131 como de aptitud 3. Teniendo en cuenta la gran heterogeneidad espacial que caracteriza a los bosques turolenses considerados en este trabajo, la valoración final de este método para la delimitación de unidades homogéneas forestales fue positiva. La Figura 3.21 recoge un ejemplo de área homogénea de aptitud 1 y de aptitud 3.

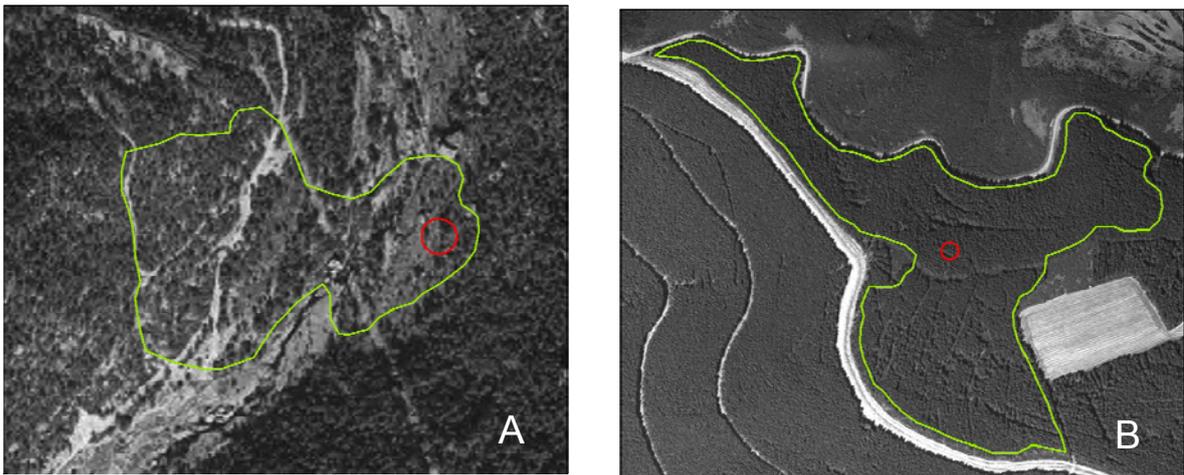


Figura 3.21. Áreas forestales homogéneas a partir de la fotointerpretación de las ortoimágenes de resolución de 1 m del SIG Oleícola Español: (A) área homogénea de aptitud 1; (B) área homogénea de aptitud 3

Para la extracción de la información radiométrica y topográfica continua contenida en estas áreas homogéneas⁴² se utilizó el mismo archivo multibanda que integraba todas estas variables, que había sido utilizado anteriormente en el método de la ventana fija de 3x3. Con objeto de evitar la influencia de los píxeles situados en los límites de estas nuevas áreas, cuya respuesta reflectiva puede estar determinada por realidades situadas justamente fuera, solamente los píxeles contenidos totalmente dentro de las fronteras delimitadas deben ser considerados (Mäkelä y Pekkarinen, 2004; Muukkonen y

⁴² Dado que en este apartado 3.1.2 sólo se van a ajustar modelos de regresión simples y lineales múltiples, no es necesario considerar las variables categóricas forestales TCE y nivel de madurez.

Heiskanen, 2005). Esto se hizo mediante la creación de AOI's en ERDAS Imagine (Figura 3.22).

Es pues, finalmente, a partir de la utilización de estos AOI's como se obtiene el valor medio de cada una de las variables consideradas, que es relacionado en el siguiente subapartado con la cantidad de biomasa residual de las parcelas que contiene.



Figura 3.22. AOI's de las áreas forestales homogéneas delimitadas mediante análisis visual utilizadas para la extracción del valor medio de las variables radiométricas y forestales sin considerar los píxeles situados en la frontera

3.1.2.1.2 Estudio de las correlaciones entre biomasa residual forestal y las variables espectrales y topográficas continuas considerando el grado de aptitud de las áreas homogéneas

La Tabla 3.25 recoge los coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual con las variables radiométricas, considerando diferentes grupos de áreas homogéneas según la calidad alcanzada en su proceso de delimitación. Así, el grupo 1 engloba todas las áreas homogéneas (aptitud 1, 2 ó 3), el grupo 2 está compuesto por las que han quedado clasificadas como aptitud 2 ó 3 y, finalmente, el grupo 3 está integrado por las parcelas con un valor de aptitud 3, es decir, para las que no existen dudas acerca de la correcta digitalización de sus límites.

Todas las variables presentan correlaciones significativas a nivel de $p < 0,01$ en los tres grupos delimitados, a excepción de CP2, que sólo presenta relaciones significativas en el grupo 3 y a nivel de 0,05. En cuanto a la magnitud de las correlaciones, ésta aumenta en todas las variables a medida que la calidad de delimitación de las áreas homogéneas es mayor. La existencia de esta relación directa entre calidad de la delimitación del área homogénea y grado de correlación con la biomasa residual avala la clasificación que de estas nuevas áreas se ha hecho mediante la utilización del atributo aptitud.

	Grupo 1 (aptitud 1, 2 y 3)	Grupo 2 (aptitud 2 y 3)	Grupo 3 (aptitud 3)
Nº de parcelas	436	353	131
TM1	-0,504**	-0,550**	-0,633**
TM2	-0,512**	-0,555**	-0,628**
TM3	-0,523**	-0,567**	-0,638**
TM4	-0,266**	-0,285**	-0,330**
TM5	-0,575**	-0,622**	-0,693**
TM7	-0,569**	-0,613**	-0,688**
CP1	-0,548**	-0,594**	-0,665**
CP2	-0,069	-0,076	-0,174*
CP3	0,527**	0,577**	0,678**
TC1	-0,531**	-0,577**	-0,648**
TC2	0,387**	0,424**	0,537**
TC3	0,581**	0,627**	0,708**
NDVI	0,529**	0,572**	0,652**
SAVI	0,527**	0,570**	0,651**
MSAVI	0,520**	0,566**	0,651**
OSAVI	0,529**	0,571**	0,652**
GESAVI	0,430**	0,469**	0,573**
GI	0,384**	0,401**	0,527**
MSI	-0,562**	-0,611**	-0,708**
VIS123	-0,518**	-0,563**	-0,637**
MID57	-0,574**	-0,620**	-0,692**
ABD	-0,545**	-0,591**	-0,662**

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 3.25. Coeficientes de correlación de Pearson obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes radiométricas en cada uno de los 3 grupos delimitados en función de la aptitud de las áreas homogéneas creadas con fotografía aérea

Al igual que en el análisis de correlación llevado a cabo con la información extraída usando la ventana fija de 3x3 píxeles, las variables espectrales relacionadas de forma directa o inversa con el contenido de agua de la vegetación (TM5, TM7, TC3, MSI y MID57) vuelven a ser las que mayores coeficientes de correlación alcanzan en los tres grupos delimitados (>0,560 en el grupo 1, >0,610 en el grupo 2 y > 0,688 en el grupo 3). Los índices de vegetación tradicionales considerados presentan correlaciones intermedias, destacando dentro de este grupo el NDVI, el OSAVI y el SAVI. En un nivel intermedio entre estos dos tipos de índices aparecen los neocanales CP1 y ABD, acompañados por TC1 en los dos primeros grupos y por CP3 en los dos últimos. Finalmente, destacar que TC2, TM4 y CP2 son de nuevo las variables que presentan menor correlación con la biomasa residual forestal, siendo la novedad que, en este caso, el índice GI también se puede añadir a este grupo de las variables menos explicativas. En

relación al signo que presenta cada una de estas correlaciones, éste vuelve a ser el mismo que el obtenido cuando considerábamos el método de la ventana de 3x3. De esta forma, la explicación física de cómo es la relación entre la biomasa residual y las variables radiométricas consideradas es idéntica a la realizada con anterioridad.

Comparando estos resultados con los obtenidos previamente a partir de la utilización del *kernel* de tamaño fijo, dos hechos parecen validar el método empleado para delimitar las áreas forestales homogéneas que aquí se utilizan para la extracción de la información: (i) en ambos métodos las variables con mejores y peores correlaciones son las mismas, situándose el resto de variables en niveles semejantes; y (ii) el signo que describe cómo son las relaciones entre la biomasa residual y cada una de las variables radiométricas utilizadas es idéntico.

Un último aspecto a destacar en la comparación directa de los resultados obtenidos en las variables radiométricas mediante la utilización de estos dos métodos de extracción es el hecho de que el nivel de las correlaciones obtenido por las variables relacionadas con el contenido de humedad de la vegetación en el grupo 3 de las áreas homogéneas es similar al alcanzado por estas variables en el percentil 4 de la ventana 3x3. Sin embargo, el número de parcelas contenido en este grupo 3 (131) es casi el doble que el de las contenidas en el percentil 4 (68).

	Grupo 1 (aptitud 1, 2 y 3)	Grupo 2 (aptitud 2 y 3)	Grupo 3 (aptitud 3)
Nº de parcelas	436	353	131
Elevación	0,137**	0,129*	0,157
Pendiente	-0,057	-0,043	0,038
INS_POT_HORAS	0,002	-0,012	-0,110
INS_POT	-0,227**	-0,246**	-0,307**
PRI_POT_HORAS	0,040	0,021	-0,037
PRI_POT	-0,233**	-0,252**	-0,310**
VER_POT_HORAS	0,166**	0,147**	0,136
VER_POT	0,007	0,003	-0,068
OTO_POT_HORAS	0,040	0,021	-0,037
OTO_POT	-0,233**	-0,252**	-0,310**
INV_POT_HORAS	-0,118*	-0,126*	-0,203*
INV_POT	-0,244**	-0,267**	-0,334**
CURVA	-0,172**	-0,166**	-0,254**

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 3.26. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes topográficas continuas en cada uno de los 3 grupos delimitados en función de la aptitud de las áreas homogéneas creadas con fotografía aérea

Las seis variables topográficas que resultan significativas en todos los grupos, a excepción de CURVA, incrementan su coeficiente conforme la calidad de la digitalización de las áreas homogéneas aumenta, manteniéndose el nivel de significación. Esta situación avala que existe una relación sólida entre estas variables y la biomasa residual forestal. En cambio, esta misma afirmación no puede ser hecha sobre las variables Elevación y VER_POT_HORAS, ya que, además de perder su significación cuando sólo se considera el mejor grupo de parcelas desde el punto de vista de la calidad de su delimitación, el coeficiente de correlación disminuye entre el grupo 1 y el grupo 2.

El signo negativo de las relaciones consideradas como válidas indica que la biomasa residual está correlacionada de forma inversa con la cantidad de iluminación recibida a lo largo del año y con la captada en las estaciones de primavera, otoño e invierno. Así pues, a mayor cantidad de insolación recibida, menor cantidad de biomasa residual. Este hecho, que en principio resulta paradójico ya que la radiación solar es la fuente primaria de energía a partir de la cual se sintetiza la biomasa vegetal, puede estar relacionado con que, generalmente, los bosques situados en umbría alcanzan mayor densidad y porte y, por lo tanto, concentran mayores cantidades de biomasa por unidad de superficie. Por su parte, el signo negativo que rige la relación con la variable CURVA indica que las masas de pináceas situadas en áreas cóncavas presentan mayores concentraciones de biomasa que las de superficies convexas. Esta situación resulta lógica, ya que las primeras zonas son *a priori* más ricas en acumulaciones de agua y nutrientes, recursos primarios para el desarrollo vegetal.

Los resultados aquí obtenidos con la información topográfica son claramente mejores que los alcanzados previamente, cuando se utilizaba la ventana de 3x3 para la extracción de la información de estas variables, ya que aparecen un mayor número de variables significativas, manteniéndose esta significación en los distintos grupos de parcelas y alcanzándose mayores coeficientes de correlación. De esta manera, la utilización de unidades homogéneas se revela como una escala de extracción más útil para considerar las relaciones existentes entre las variables topográficas y la biomasa residual forestal.

3.1.2.1.3. Ajuste de modelos de regresión

Como se ha indicado con anterioridad, el objetivo de emplear nuevos métodos de extracción de la información radiométrica y topográfica era lograr ajustar modelos de estimación de la biomasa residual con niveles predictivos similares a los calculados con el método de ventanas fijas en los dos grupos de parcelas más homogéneos, pero

utilizando para ello un número superior de parcelas para garantizar la validez de los mismos en todo el área de estudio.

Los resultados obtenidos en el análisis de correlaciones indican que el método de extracción de unidades forestales homogéneas delimitadas a partir de fotografía aérea puede ser válido para esta tarea, dado que en el grupo 3 se consigue alcanzar niveles de correlación con las variables radiométricas similares a los obtenidos con el *kernel* 3x3 en el grupo del percentil 4 con el doble de parcelas. Junto a esto, este método se ha mostrado más adecuado que el anterior para analizar la información topográfica, ya que las correlaciones entre estas variables y la biomasa residual son más altas y más consistentes.

Así, en las siguientes páginas se calculan modelos de regresión simple y lineal multivariante a partir de las áreas homogéneas incluidas en el grupo 3, ya que las correlaciones alcanzadas en los otros dos grupos no alcanzan niveles de correlación suficientes para superar los modelos de este tipo ajustados previamente para obtener cartografía.

- Modelos de regresión simple

Dado que los mejores modelos de regresión simple utilizando la ventana 3x3 se obtuvieron a partir de las variables radiométricas relacionadas con el contenido de agua de la vegetación y que éstas son nuevamente las mejor correlacionadas con la biomasa residual, sólo se calcularon modelos individuales para estas variables. Al igual que antes, para cada una de estas variables se calculan cinco modelos, utilizando para ello cinco muestras aleatorias del 80% de las 131 parcelas que componen el grupo 3⁴³.

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM5	Exponencial	0,666	0,737	299,066	-0,193
TM7	Exponencial	0,677	0,724	124,425	-0,229
TC3	Exponencial	0,657	0,733	116,835	0,289
MSI	Exponencial	0,569	0,822	523,684	-4,392
MID57	Exponencial	0,673	0,729	202,084	-0,105

Tabla 3.27. Modelos de regresión simple calculados con las áreas homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

La Tabla 3.27 recoge el mejor modelo calculado en cada una de ellas, aunque es de destacar que todos los obtenidos (25) fueron significativos a nivel de modelo y a nivel de los coeficientes de regresión ($p < 0,05$), utilizándose para todos ellos una ecuación de ajuste exponencial. Además, los R^2 de los cinco modelos calculados en cada variable

⁴³ En estas 131 parcelas no se incluye ninguna de las 3 eliminadas por su comportamiento atípico.

variaron muy poco, lo que indica la gran estabilidad de los mismos desde el punto de vista estadístico y biofísico. Por su parte, la Figura 3.23 recoge los gráficos de dispersión de estos modelos; en ellos se recoge, además del R^2 , los $RMSE$ y $RMSE_r$, obtenidos con sus respectivas muestras de validación.

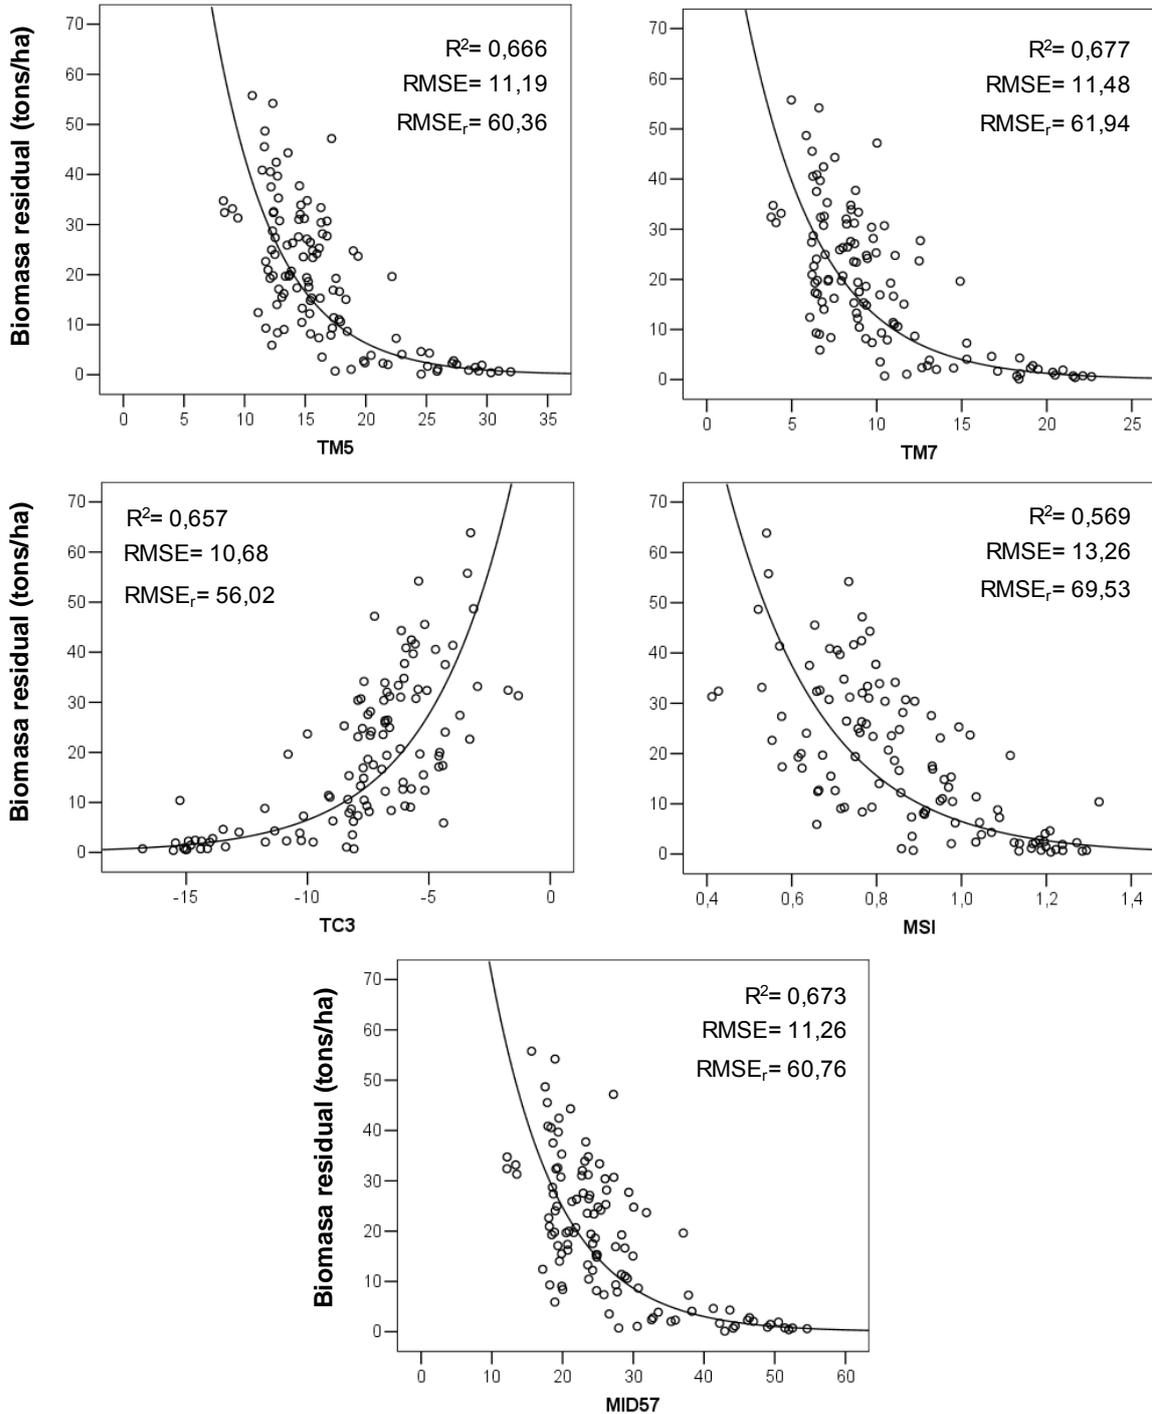


Figura 3.23. Gráficos de dispersión de los modelos de la Tabla 3.27

Los coeficientes de determinación más altos se alcanzan con los modelos ajustados con las variables TM5, TM7 y MID57 ($R^2 > 0,64$ en todos los casos), situándose en último lugar los modelos ajustados con la variable MSI ($R^2 < 0,57$). Dentro del primer grupo destacan, sobre todo, los coeficientes de determinación alcanzados con TM7 y MID57, ya que en tres de los cinco modelos calculados para cada una de ellas se supera el umbral de 0,67.

En cuanto a los errores en la estimación, todos los modelos calculados presentan un *RMSE* superior a las 10 tons/ha, destacando, una vez más en sentido negativo, los modelos que utilizan la variable MSI, que llegan a sobrepasar la cantidad de 13 tons/ha. El *RMSE*, más bajo aparece con la variable TC3 (56%), aunque son escasas las diferencias con respecto a los obtenidos con las dos bandas originales del infrarrojo medio de Landsat TM y con los que emplean la suma de éstas.

Por último, señalar que, tal y como se observa en los gráficos de dispersión, todos los modelos presentan problemas de saturación a altas cantidades de biomasa residual, situándose ésta en torno a las 40 tons/ha en los ajustados con TM5, TM7 y TC3 y cerca de las 50 tons/ha en los que emplean TC3 y MSI.

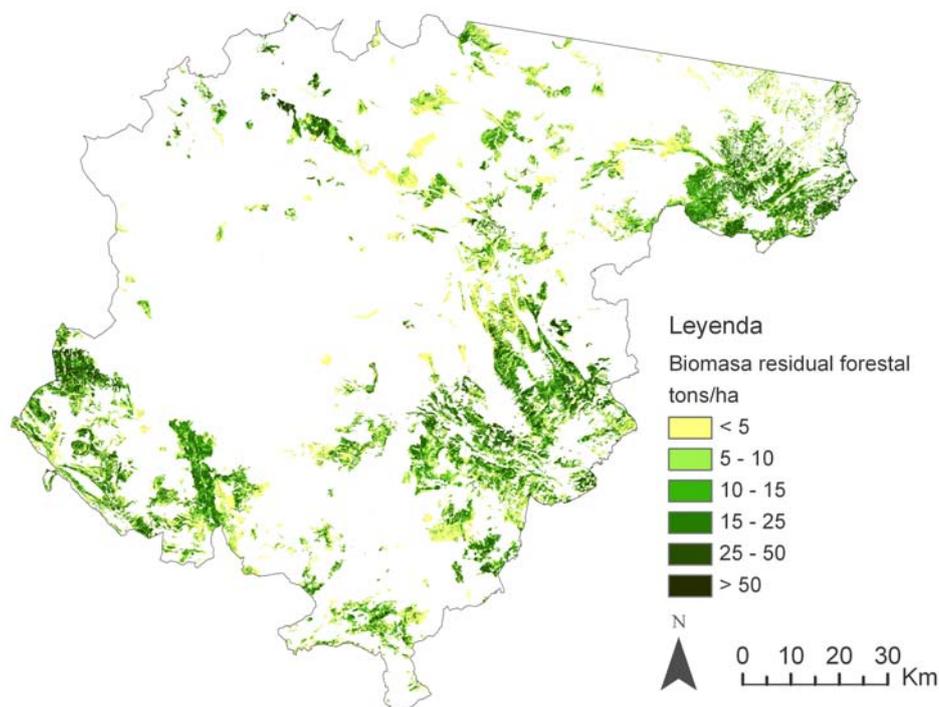


Figura 3.24. Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas incluidas en el grupo de calidad 3 derivadas de la utilización del método de extracción de áreas homogéneas creadas con fotografía aérea

En definitiva, el análisis de estos estadísticos y de los gráficos permite concluir que, de las cinco variables analizadas, MSI es la menos adecuada para la estimación de la biomasa residual del área de estudio, no existiendo grandes diferencias entre las otras cuatro. Entre los modelos presentados con estas cuatro variables en la Tabla 3.27, se eligió finalmente el calculado con la variable MID57 para cartografiar la biomasa residual del área de estudio (Figura 3.24), ya que este modelo es el que presenta un mayor equilibrio entre la capacidad de predicción y el error obtenido y, sobre todo, porque es la variable que se ha utilizado anteriormente para estimar la biomasa residual con la información obtenida con las ventanas 3x3 a partir de un mayor número de parcelas (clúster 3). De esta manera se podrá hacer una comparación directa entre los dos métodos de extracción de la información cuando validemos a escala de píxel las cartografías de estimación obtenidas mediante esta variable.

- Modelos de regresión lineal múltiple

Al igual que en el anterior apartado en el que se ha estudiado la posibilidad de establecer ecuaciones de regresión lineal múltiple, el primer paso para ajustar esta clase de modelos con la nueva información obtenida con el uso de las áreas homogéneas debe ser la comprobación de los cuatro supuestos básicos de este tipo de regresión, empezando por el de normalidad de las variables consideradas. En este sentido, las Tablas 3.28 y 3.29 recogen los resultados de las distintas pruebas de normalidad individuales con un nivel de significación $<0,05$ aplicadas sobre la variable biomasa residual y sobre las independientes que presentan relaciones significativas con ella, así como la transformación más adecuada para corregir situaciones de incumplimiento.

Sólo cuatro de las variables consideradas pueden ser incluidas directamente para formar parte del modelo de regresión múltiple respetando el supuesto de normalidad univariante. El resto de variables necesitan de transformaciones para respetar este principio y poder ser integradas en este modelo. Al igual que en anteriores casos en los que se ha hecho uso de esta herramienta estadística, las variables que no logran superar el test de normalidad de *K-S* pero tienen una distribución muy parecida a la típica de una distribución normal también son incluidas en el modelo. Así pues, la única variable que es eliminada por este criterio es INV_POT_HORAS, dado que ni la variable original ni ninguna de sus transformadas se acerca a una distribución semejante a la normal.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Casi normal
TM1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM3	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM4	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	Si	No normal	Inversa	Normal
TM5	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
CP2	Casi normalidad	Casi normalidad	Negativa	Leptocúrtica	No	No normal	Inversa	Normal
CP3	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
TC1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Casi normal
TC2	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Raíz cuadrada	Casi normal
TC3	Casi normalidad	Casi normalidad	Negativa	Mesocúrtica	No	No normal	-	Casi normal
NDVI	Casi normalidad	Casi normalidad	Simétrica	Platicúrtica	No	No normal	Cuadrado	Normal
SAVI	Casi normalidad	Casi normalidad	Simétrica	Platicúrtica	No	No normal	Cuadrado	Normal
MSAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Cuadrado	Casi normal
OSAVI	Casi normalidad	Casi normalidad	Simétrica	Platicúrtica	No	No normal	Cuadrado	Normal
GESAVI	Casi normalidad	Casi normalidad	Positiva	Platicúrtica	No	No normal	Logaritmo	Casi normal
GI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
VIS123	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal

Tabla 3.28. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes radiométricas correlacionadas con ella utilizando las áreas forestales homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
INS_POT	Casi normalidad	Casi normalidad	Negativa	Mesocúrtica	No	No normal	Cuadrado	Normal
PRI_POT	Casi normalidad	Casi normalidad	Negativa	Mesocúrtica	No	No normal	Cuadrado	Normal
OTO_POT	Casi normalidad	Casi normalidad	Negativa	Mesocúrtica	No	No normal	Cuadrado	Normal
INV_POT_HORAS	No normalidad	No normalidad	Negativa	Leptocúrtica	No	No normal	-	No normal
INV_POT	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
CURVA	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	-	Casi normalidad

Tabla 3.29. Pruebas de normalidad aplicadas a las variables independientes topográficas correlacionadas con la biomasa residual forestal utilizando las áreas forestales homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3

Los gráficos de dispersión individuales, llevados a cabo entre la variable transformada de la biomasa ($rz_biomasa$) y las variables independientes originales o transformadas que superan el análisis de normalidad, permitieron identificar seis relaciones en las que no se cumplían los supuestos de heterocedasticidad y/o linealidad. En concreto, la variable $rz_biomasa$ no presenta relaciones lineales con la variable radiométrica TC3, ni con las variables topográficas INS_POT, PRI_POT, OTO_POT, INV_POT, mientras que la relación con CURVA es, además, heterocedástica (Figura 3.25). De esta manera, ninguna de estas variables puede ser incluida en el modelo de regresión lineal múltiple, por lo que son directamente eliminadas. Esto hace que, a pesar de que con este método de extracción las variables topográficas están más correlacionadas con la biomasa residual forestal, éstas no van a ser útiles para su predicción, ya que ni siquiera pueden ser consideradas para la edición del modelo de regresión.

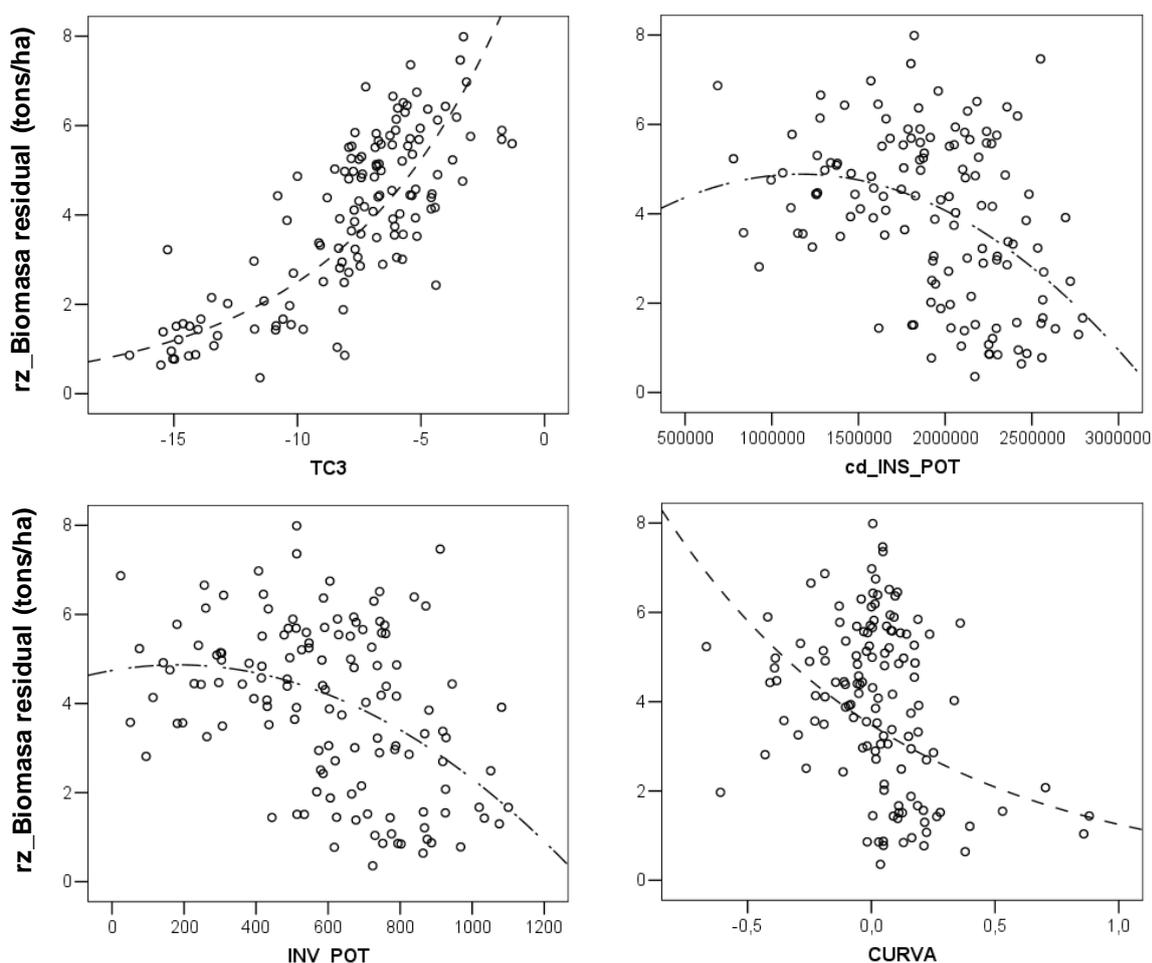


Figura 3.25. Gráficos de dispersión de la variable transformada de la biomasa residual forestal ($rz_biomasa$ residual) con las variables dependientes TC3, la transformada de INS_POT (cd_INS_POT), INV_POT y CURVA

La Tabla 3.30 muestra los modelos obtenidos con cada una de las cinco muestras aleatorias del 80% de las 131 parcelas. Como se observa, cuatro de los modelos utilizan dos variables (N_1 , N_2 , N_4 y N_5), mientras que uno quedó compuesto por una (N_3). La característica común entre todos ellos es que la variable independiente principal para explicar la varianza de la biomasa residual es nuevamente una variable relacionada con el contenido de humedad de la vegetación (TM5, MSI y MID57), siendo complementada en los modelos multivariantes por otra variable que se añade en el segundo paso del método de pasos *hacia delante* (la transformación inversa de ABD en N_1 , la transformación inversa de TM4 en N_2 y la transformación inversa de CP1 en N_2 y N_5). A este respecto, es necesario señalar que esta segunda variable no incrementa mucho el R^2 de estos cuatro modelos con respecto al obtenido en el primer paso, lo que indica de forma clara que las variables introducidas posteriormente apenas logran explicar una pequeña parte de la varianza de la biomasa residual forestal que no ha sido explicada previamente por la primera variable seleccionada.

Modelo-Muestra	R^2_a	S_e	Índice de condición superior	Variables	β	Sig.
N_1	0,628	1,094	140,236	ln_MID57	-7,550	0,000
				inv_ABD	-300,972	0,020
				Constante	33,585	0,000
N_2	0,580	1,213	161,651	ln_TM5	-9,665	0,000
				inv_CP1	-168,360	0,022
				Constante	37,384	0,000
N_3	0,595	1,194	18,805	ln_MID57	-4,191	0,000
				Constante	17,675	0,000
N_4	0,579	1,146	21,895	MSI	-5,909	0,000
				inv_TM4	45,999	0,009
				Constante	6,649	0,000
N_5	0,574	1,166	167,715	ln_TM5	-9,542	0,000
				inv_CP1	-153,574	0,033
				Constante	36,506	0,000

Tabla 3.30. Modelos de regresión múltiple calculados con las áreas homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables

Sin embargo, el análisis de los estadísticos de diagnóstico de colinealidad de los modelos multivariantes indicó que tres de ellos incumplían este supuesto estadístico de forma muy grave, superior a anteriores ocasiones. Así, tanto los valores de tolerancia como los de FIV se sitúan en los modelos N_1 , N_2 y N_5 muy por encima de los umbrales

permitidos, siendo también éste el caso de sus respectivos índices de condición (valores por encima de 100 cuando, como se ha indicado, el umbral máximo aceptable es 30). Para confirmar esta situación se analizaron las correlaciones entre las variables que componían estos tres modelos, obteniéndose $R > 0,975$ en todos los casos. En consecuencia, estos tres modelos carecen de la solidez estadística necesaria para ser considerados como válidos para estimar la biomasa residual, por lo que fueron eliminados. De esta manera, el mejor modelo posible para estas tres muestras es el univariante definido por la primera de las variables seleccionadas en el método de pasos *hacia adelante*, es decir, el ajustado con la transformación de MID57 en N_1 y los obtenidos con la variable transformada de TM5 en N_2 y en N_5 (Tabla 3.31).

Modelo-Muestra	Variable(s)	R^2_a	S_e	β_0	β_1
N_1	ln_MID57	0,610	1,120	16,822	-3,960
N_2	ln_TM5	0,562	1,240	16,625	-4,541
N_5	ln_TM5	0,558	1,186	17,492	-4,838

Tabla 3.31. Modelos de regresión calculados para las muestras N_1 , N_2 y N_5 de las áreas homogéneas creadas con fotografía aérea incluidas en el grupo de calidad 3 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

Así, cuatro de los cinco modelos finalmente obtenidos son univariantes, utilizando dos de ellos la variable MID57 (N_1 y N_3) y los otros dos la variable TM5 (N_2 y N_5) (Tablas 3.30 y 3.31). El análisis de los residuos de estos modelos y del multivariante de N_4 mostró que todos ellos cumplían los supuestos básicos de este tipo de regresión, por lo que fueron dados por válidos.

En referencia a los coeficientes de determinación alcanzados, sólo uno de ellos supera el valor de 0,6 (N_1), situándose el resto entre este valor y 0,55. En definitiva, según este estadístico, los modelos de regresión lineal múltiple ajustados poseen una capacidad predictiva sensiblemente inferior a los modelos de regresión simple exponenciales ajustados en el anterior subapartado.

En cuanto al error de predicción de estos modelos, la Figura 3.26 recoge los gráficos de dispersión de los modelos univariantes, mostrándose el $RMSE$ y el $RMSE_r$ obtenidos en cada uno de ellos con sus respectivas muestras de validación. Como se observa, en la mitad de estos modelos el error total se sitúa por debajo de las 9 tons/ha, mientras que en tres el error relativo no sobrepasa el umbral del 60%. Los peores resultados se dan con el modelo ajustado con la muestra N_1 (12,20 tons/ha de $RMSE$ y

64,95% de $RMSE_r$), que era el que mayor R^2_a alcanzaba. En cuanto a los errores obtenidos en el único modelo múltiple obtenido, éstos se sitúan en el orden de los mejores univariantes, con un $RMSE$ de 8,07 tons/ha y un $RMSE_r$ de 54,32%.

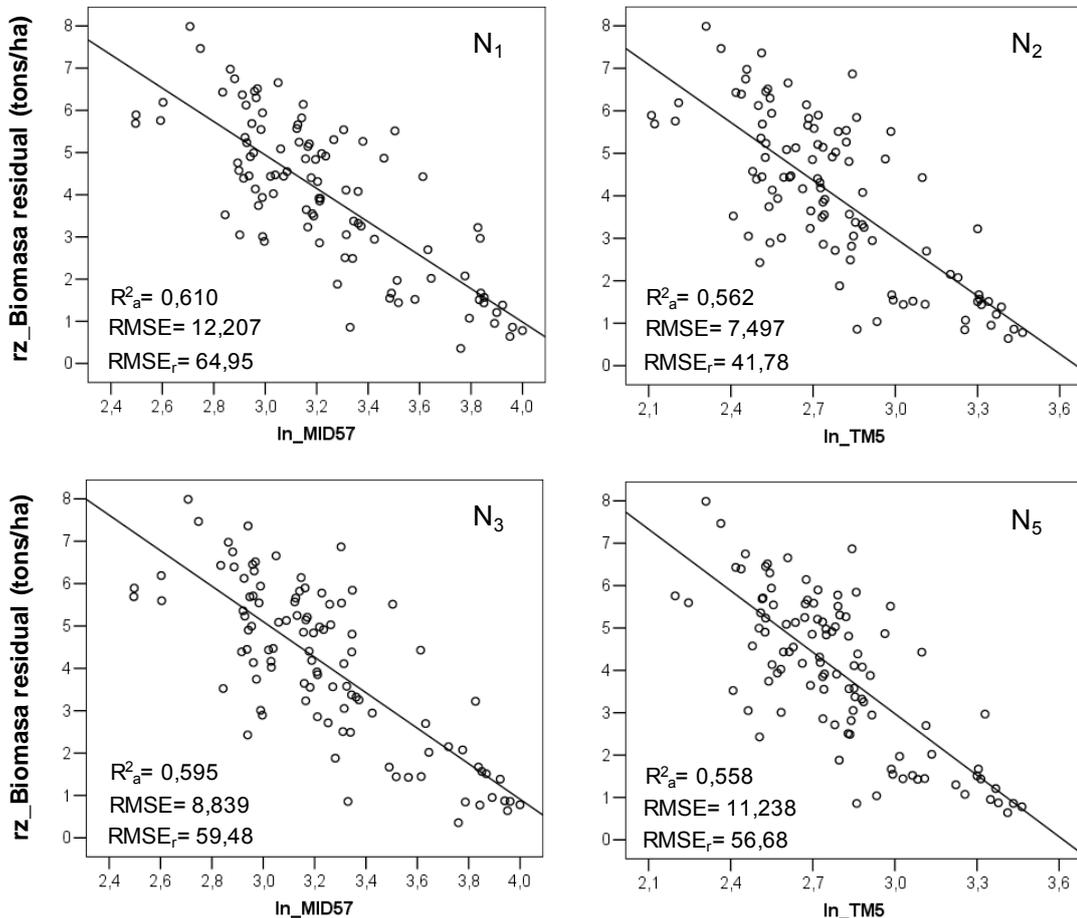


Figura 3.26. Gráficos de dispersión de los modelos de regresión lineal univariantes de las Tablas 3.30 y 3.31

A la hora de seleccionar uno de estos modelos para elaborar la cartografía de estimación de la biomasa residual del área de estudio, se atendió una vez más al criterio de elegir entre los que mejor equilibrio muestran entre su capacidad de predicción y el error de estimación. El modelo ajustado con la muestra N₃ a partir de la utilización de la variable transformada de MID57 se sitúa dentro de este grupo, pudiendo ser la cartografía obtenida con él (Figura 3.27) utilizada para hacer una comparación directa con la generada en el anterior apartado, en el que esta misma variable era empleada con un modelo de regresión exponencial, y con las obtenidas también a partir de esta variable con la información extraída mediante las ventanas fijas en el grupo homogéneo que más parcelas consideraba (clúster 3). De esta manera, los resultados que se obtengan al

validar estas cartografías a nivel de píxel servirán para comparar no sólo qué método de extracción de la información funciona mejor, sino también qué método de regresión da lugar a mejores estimaciones: los modelos simples curvilíneos que utilizan la variable sin transformar o los modelos simples lineales que utilizan valores transformados.

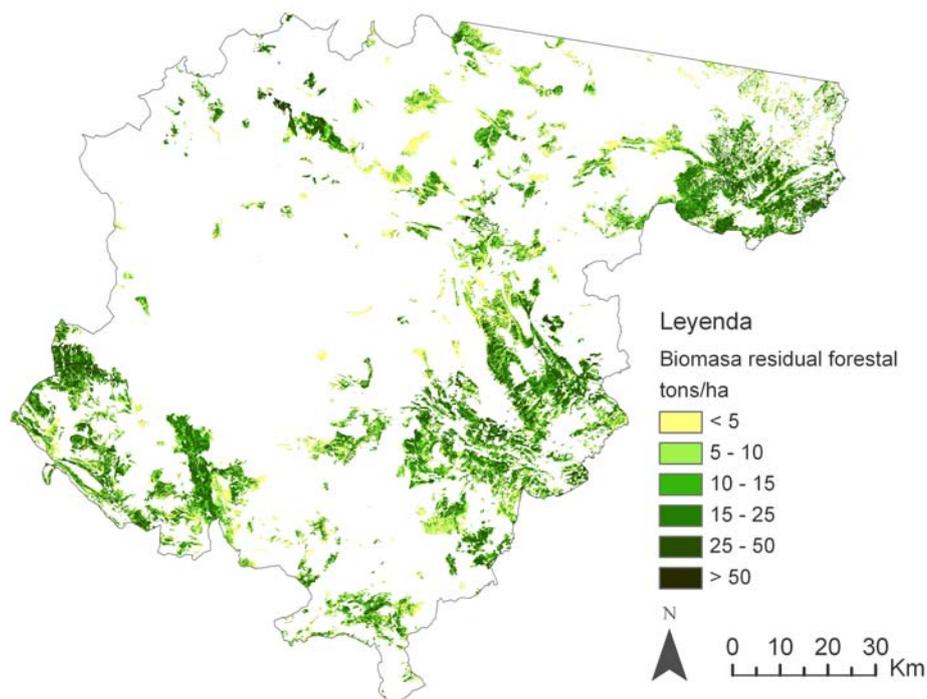


Figura 3.27. Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas incluidas en el grupo de calidad 3 derivadas de la utilización del método de extracción de áreas homogéneas creadas con fotografía aérea

3.1.2.1.4. Conclusiones

Los resultados obtenidos en el apartado de análisis de correlación y en el de ajuste de modelos de regresión a partir de la información radiométrica y topográfica obtenida mediante la utilización de áreas homogéneas forestales delimitadas a partir de fotografía aérea de alta resolución nos permiten inferir las siguientes conclusiones:

- I. La fotointerpretación se ha mostrado como una técnica útil para la delimitación de áreas homogéneas forestales susceptibles de ser utilizadas para ajustar modelos de estimación de biomasa residual forestal mediante el uso de trabajo de campo e imágenes ópticas de resolución media.**

La comparación de los resultados obtenidos anteriormente utilizando las ventanas fijas de 3x3 píxeles con los generados mediante el uso de áreas homogéneas delimitadas visualmente a partir de fotografía aérea permite observar una serie de similitudes que

hacen posible afirmar que este segundo método de extracción es útil para alcanzar el objetivo de esta tesis. Estas similitudes, como se ha constatado, refieren al hecho de que en ambos casos el sentido de las relaciones entre la biomasa residual y las variables independientes consideradas es el mismo y, lo que es más definitivo, al hecho de que las variables radiométricas y topográficas más y menos correlacionadas con este parámetro forestal son las mismas en los dos métodos, alcanzando además similares coeficientes cuando son empleadas las muestras más homogéneas de ambos.

Así, confrontando los coeficientes de correlación de la Tabla 3.3 con los de la Tabla 3.25, se observa que en ambos métodos de extracción las variables radiométricas relacionadas con el contenido de humedad de la vegetación (TM5, TM7, TC3, MID57, MSI) son las que presentan valores más altos, independientemente de los distintos grupos de parcelas delimitados en cada uno de ellos. Desde la perspectiva contraria, las variables radiométricas GI, TC2 y, especialmente, las variables TM4 y CP2 son las que peores correlaciones presentan, independientemente del método y de las parcelas consideradas dentro del método. Además, otro hecho a destacar es que en ambos casos el carácter no lineal de estas relaciones es el predominante, siendo en muchos casos el mismo tipo de relación (por ejemplo, exponencial en el caso de TM5, TM7, TC3...). En cuanto a las variables topográficas, esta circunstancia no está tan clara, dada la escasa significación de estas variables en su relación con la biomasa residual en el método de las ventanas fijas; aun así, señalar que las variables Elevación, INS_POT, PRI_POT, VER_POT_HORAS, OTO_POT e INV_POT son detectadas en ambos casos como las más significativas, al menos cuando son consideradas todas las parcelas.

Por último, dejando a un lado la comparación y centrándonos exclusivamente en los resultados obtenidos con las áreas homogéneas delimitadas visualmente, otro hecho que indica la validez de este procedimiento es que el grado de correlación entre la biomasa residual y las variables independientes radiométricas (las más útiles y significativas) aumenta conforme lo hace la calidad de delimitación de las áreas. Este hecho, además, opera en favor del procedimiento de fotointerpretación seguido para la delimitación de las parcelas y de su rigurosidad, ya que, de lo contrario, este patrón de aumento de la correlación conforme lo hace la aptitud-calidad no hubiera sido tan claro.

De esta manera, solamente es factible ajustar modelos de regresión precisos considerando las áreas más homogéneas, es decir, las de mayor calidad en su delimitación dada la escasa fragmentación del bosque y la baja complejidad de su

estructura, con lo que se confirma una de las conclusiones parciales anteriormente señalada: la influencia de la heterogeneidad de los bosques mediterráneos a la hora de obtener modelos estimativos precisos y operativos.

II. El método de extracción de áreas homogéneas forestales permite obtener modelos menos sobre-ajustados y más representativos de los bosques de la provincia de Teruel que el de ventanas fijas.

El nivel de las correlaciones obtenido por las variables relacionadas con el contenido de humedad de la vegetación en el grupo de calidad 3 en el método de las áreas homogéneas es similar al alcanzado por estas variables en el percentil 4 de la ventana 3x3. Sin embargo, el número de parcelas contenido en este grupo 3 (131) es casi el doble que las contenidas en el percentil 4 (68), con lo que disminuyen las posibilidades de obtener modelos sobre-ajustados, que era uno de los principales inconvenientes subrayados en el anterior apartado de conclusiones parciales.

Este grupo de 131 parcelas parece más que suficiente para garantizar que todos los tipos de pinares del área de estudio están representados, no sólo por su número, sino también por su distribución espacial, por el rango de la variable dependiente incluido en esta muestra (de 0,128 tons/ha a 63,846 tons/ha) y por la presencia de un número proporcional de parcelas para cada especie con respecto a la muestra total original de 482 parcelas del IFN-2 (25,95% de parcelas de *P. sylvestris*, 33,58% de *P. halepensis*, 30,53% de *P. nigra* y 9,92% de *P. pinaster*).

En consecuencia, los modelos derivados de este segundo método de extracción tendrán más posibilidades de recoger la variabilidad asociada a los diferentes factores ecogeográficos (fisiográficos, lito-geológicos, climáticos, edáficos y biogeográficos) que condicionan la existencia, las características y el desarrollo de los bosques de pináceas de la provincia de Teruel. Esto hace a estos modelos más representativos para nuestra área de estudio y más fácilmente extrapolables a otras áreas de similares características.

III. Las variables radiométricas derivadas de la imagen Landsat vuelven a ser las más útiles para estimar la biomasa residual.

Aunque las correlaciones entre las variables topográficas y la biomasa residual forestal son más altas y más estables que en el método de extracción de las ventanas de 3x3 píxeles (se mantiene la significación de 6 de ellas en los 3 grupos delimitados en función de la calidad de la digitalización), este grado de correlación no es suficiente para generar modelos de regresión univariantes con un coeficiente de determinación suficiente

para ser considerados como operativos para la estimación de biomasa residual forestal, ni para aumentar este coeficiente en los modelos de regresión lineal múltiple. Con respecto a esto último, destacar el hecho de que éstas variables no pudieron ser consideradas en este tipo de modelos porque, a pesar de las transformaciones aplicadas, no se consiguió que tuvieran una relación lineal con la biomasa residual.

En definitiva, al igual que en método de ventanas fijas, las variables radiométricas son las únicas susceptibles de ser utilizadas en el ajuste de modelos de regresión univariantes y múltiples para cartografiar las existencias de este recurso energético en el área de estudio. En este sentido, como ya hemos apuntado en la primera conclusión parcial de este apartado, las variables radiométricas relacionadas de forma positiva o negativa con el contenido de agua de la vegetación vuelven a erigirse como las más útiles en estos dos tipos de modelos predictivos, lo que concuerda con los resultados obtenidos con la otra escala empleada para extraer la información radiométrica y, por lo tanto, con los trabajos citados con anterioridad, que también llegaban a esta conclusión. En concreto, las bandas originales TM5 y TM7 y la suma de estas dos (MID57) se muestran otra vez como las más adecuadas para derivar la cartografía de estimación del área de estudio.

IV. Los modelos de regresión ajustados generan peores resultados en términos de capacidad de predicción y error de estimación que los alcanzados con el método de ventanas fijas de 3x3 y CV.

Si nos centramos, en primer lugar, en la comparación de los modelos ajustados mediante la regresión simple, los finalmente seleccionados con las ventanas fijas usando las variables relacionadas con la humedad en el grupo de parcelas del clúster 3 (Figura 3.12) presentan unos R^2 entre un 11,73% y un 23,41% más altos que los obtenidos a partir de la información radiométrica extraída con las áreas homogéneas de calidad 3 (Figura 3.23). De esta manera, la capacidad de los modelos propuestos en el presente apartado no sólo no mejora con respecto a los anteriores, sino que los empeora, si bien se mantiene en unos umbrales aceptables para la estimación ($R^2 > 0,66$ con TM5, TM7 y MID57). En cuanto a los errores de predicción obtenidos con las muestras reservadas a tal efecto, éstos son mayores en los modelos que utilizan la información obtenida mediante las áreas homogéneas ($RMSE_r$ superiores entre 20 y 23,5 puntos). Aun así, los $RMSE_r$ conseguidos se sitúan en umbrales aceptables teniendo en consideración otros trabajos de estimación de parámetros forestales en ambientes más homogéneos que el nuestro que emplean una metodología de extracción de la información radiométrica

similar a la aquí utilizada. Así, por ejemplo, el mejor resultado obtenido en la estimación de volumen de madera por Mäkela y Pekkarinen (2004) es del 48%, señalándose la existencia de otras investigaciones, como las de Trotter *et al.* (1997), Kilpeläinen y Tokola (1999) y Hyyppä *et al.* (2000), en las que el error se sitúa entre el 56% y más del 100%. Un trabajo que mejora ligeramente los resultados de Mäkela y Pekkarinen (2004) es el de Muukkonen y Heiskanen (2005), que obtiene un $RMSE_r$ del 44,6% en la estimación de biomasa total en un área forestal localizada en el sur de Finlandia, aunque con la utilización de imágenes ASTER, que tienen una resolución espacial mayor que las Landsat en las bandas del visible y del infrarrojo cercano.

Además, otro aspecto negativo de los modelos obtenidos mediante las áreas homogéneas es el hecho previamente señalado de que éstos, a diferencia de los ajustados con los datos de las ventanas fijas, sí que presentan un cierto grado de saturación, lo que hace que aumente el error en la estimación de las cantidades más altas, con lo que las zonas más ricas de este recurso pueden aparecer infra-estimadas.

Con respecto a los modelos de regresión múltiple, la alta correlación existente entre las variables radiométricas mejor correlacionadas con la biomasa residual vuelve a convertirse en una barrera insalvable para obtener modelos significativos compuestos por más de una variable, al menos en 4 de los 5 intentos efectuados. Al igual que en el caso de los univariantes curvilineales, los estadísticos relativos a la capacidad explicativa y al error de estimación de estos modelos univariantes lineales ajustados con los datos de las áreas homogéneas a partir de transformaciones de las variables originales son peores que los anteriormente ajustados con el método de ventanas fijas con las parcelas del clúster 3. En concreto se obtienen R^2 entre un 18,7% y un 21,5% más bajos y $RMSE_r$ entre 13 y 15 puntos más altos.

En resumen, la interpretación visual de fotografías aéreas de alta resolución espacial se ha mostrado como una técnica útil para obtener unidades de mayor tamaño que las parcelas del IFN-2, que pueden ser utilizadas para la estimación de la variable biomasa residual forestal. La principal ventaja de utilizar estas nuevas áreas radica en el hecho de que se consiguen coeficientes de correlación, con las variables radiométricas, similares a los obtenidos con el método de extracción de ventanas fijas analizado en el anterior apartado, pero con una población muestral cercana al doble. Este hecho hace que los modelos obtenidos sean más representativos de los distintos bosques de pináceas del área de estudio, disminuyendo las posibilidades de que estén sobre-

ajustados. Por el contrario, el efecto negativo de este aumento de parcelas para la construcción de los modelos de regresión es que los obtenidos presentan R^2 , $RMSE$ y $RMSE_r$ peores que los ajustados en los dos clústeres representantes del máximo grado de homogeneidad en el método de extracción de las ventanas fijas. Este hecho puede estar relacionado con dos causas:

- En primer lugar, al hecho lógico de que, al aumentar el número de parcelas, aumenta la varianza de la variable dependiente a estimar. Como consecuencia, es más difícil que las variables independientes expliquen la totalidad esa varianza, por lo que se reduce el valor de los estadísticos que evalúan la ecuación de regresión.
- En segundo lugar, al propio método utilizado para la extracción de la información radiométrica; en concreto, el método utilizado puede introducir errores en la estimación por dos motivos:
 - o *Debido a errores en el proceso de fotointerpretación-delimitación de las áreas homogéneas forestales.* En efecto, a pesar del cuidado y el rigor adoptados en la creación de las áreas homogéneas, es posible que se hayan producido fallos al trazar los límites, fruto de la subjetividad o de la falta de precisión. Estas inexactitudes tienen reflejo directo en los modelos de regresión, ya que el valor radiométrico medio que es relacionado con la biomasa residual queda distorsionado y no es representativo de la realidad. No obstante, es necesario señalar que la eliminación de los píxeles situados en los límites de estas nuevas áreas reduce la influencia de estos errores.
 - o *Debido a que se asume un valor constante de biomasa para toda el área homogénea delimitada a partir de una localización puntual dentro de ella.* Esto hecho refiere a la situación señalada por Pekkarinen (2002), ya apuntada con anterioridad, de que la información recogida a escala de parcela no tiene por qué ser representativa de una unidad forestal superior. Aunque, en principio, este autor se refiere a unidades forestales homogéneas individualizadas a partir de técnicas de segmentación de imágenes, esta situación también puede haberse dado en nuestro método, ya que no existe certeza absoluta de que las unidades delimitadas sean exactamente iguales en contenido de

biomasa forestal que la parcela del IFN-2 que tiene inscrita, a pesar de que la estructura espacial de la masa forestal sea casi igual o idéntica.

Esto se debe a que, aunque la estructura espacial de ambas unidades sea muy similar, otros factores de primer orden, que controlan la cantidad de biomasa residual contenida en la parcela del IFN-2, como el *dbh* y la altura de los pies arbóreos que la integran, no se pueden modelizar con las ortofotografías aéreas utilizadas. De esta manera, resulta obvio que la variación de estos dos parámetros en los árboles contenidos en las nuevas áreas producirá desviaciones más o menos importantes en cuanto al contenido de biomasa residual seca por hectárea.

Sin embargo, a este respecto es necesario señalar en favor del proceso seguido que medianas y grandes diferencias de estos dos parámetros de tamaño sí son fácilmente detectables en las ortofotografías empleadas, constituyendo uno de los criterios utilizados a la hora de establecer los límites de las nuevas áreas homogéneas, con lo que esta fuente de error ha sido minimizada, aunque, desde luego, no totalmente eliminada.

3.1.2.2. Estimación mediante la utilización de áreas forestales homogéneas delimitadas a partir de técnicas de segmentación y ventanas fijas

3.1.2.2.1. Procedimiento de segmentación de la imagen Landsat y de extracción de la información radiométrica en las nuevas unidades espectrales.

La segmentación es el proceso de dividir una imagen digital en un conjunto de regiones discretas que no se superponen, cuya delimitación está basada en criterios de homogeneidad interna. Estas regiones homogéneas pueden quedar definidas por medidas simples, como el contraste de la imagen, o pueden ser el resultado de complejos análisis estadísticos. Independientemente de la metodología usada, numerosos trabajos han mostrado que la aplicación de este tratamiento digital a imágenes de satélite o fotografías aéreas es un excelente punto de inicio para subsecuentes análisis geográficos, como la obtención de cartografía de usos del suelo, de estructura del paisaje y el modelado de las características del territorio. De esta manera, no es de extrañar que numerosos investigadores relacionados con las Ciencias de la Tierra hayan centrado sus

esfuerzos en desarrollar diversos algoritmos de computación para obtener segmentaciones útiles y precisas para sus intereses (Devereux *et al.*, 2004).

Mäkelä y Pekkarinen (2001) clasifican los diferentes métodos de segmentación en tres grandes grupos:

- *Métodos basados en el píxel.* Son aquellos que utilizan los ND de todos los píxeles que forman la imagen para, a partir de un análisis estadístico, definir una serie de umbrales que dan lugar a la creación de clústeres homogéneos, considerando las diferentes dimensiones espectrales de la imagen multibanda. El resultado de este análisis estadístico se refleja en la imagen mediante la creación de regiones independientes, espacialmente continuas, en las que cada uno de los píxeles que la integran tienen un mismo valor, que actúa como etiqueta.
- *Métodos basados en ejes.* Estos métodos buscan la identificación de ejes que quedan unidos entre sí formando una red continua de contornos. De esta manera, los grupos de píxeles que quedan dentro de estos contornos son identificados como regiones homogéneas y constituyen el resultado de la clasificación.
- *Métodos basados en regiones.* Dentro de este grupo quedan incluidos los procesos de crecimiento de regiones, unión, división y combinaciones de éstos. En los procesos de crecimiento de regiones, los píxeles adyacentes que no difieren mucho entre sí con respecto a un determinado criterio son asignados al mismo segmento o región. En las aproximaciones de unión y división, las regiones previamente definidas son combinadas o divididas en función de su similitud espectral y su homogeneidad.

Aunque, como se ha señalado, la segmentación de imágenes de satélite es una técnica de procesamiento muy extendida para diferentes aplicaciones, no existen muchos ejemplos acerca de la utilidad de esta técnica como herramienta para la extracción de información espectral que más tarde sea utilizada para la estimación de parámetros forestales continuos. En este sentido, se pueden destacar los trabajos de Mäkelä y Pekkarinen (2001), Pekkarinen (2002) y Hall *et al.* (2006).

Los tres trabajos citados emplean diferentes métodos de segmentación con este fin, pero todos ellos comparten el uso de ventanas fijas para considerar únicamente la información espectral de la parcela de campo (de menor tamaño que las áreas espectrales homogéneas definidas con sus respectivas técnicas de segmentación) y de su vecindad inmediata. Concretamente, la forma común de proceder es la siguiente: (i) localización de una ventana fija o *kernel* de tamaño variable sobre el centro de la parcela de campo; (ii) segmentación de la imagen en regiones espectralmente homogéneas; (iii) extracción de los valores radiométricos de los píxeles que pertenezcan a la misma región homogénea que el píxel central (o único) de la parcela de campo (Figura 3.28). De esta manera se reduce la posibilidad de cometer errores relacionados con la localización de las parcelas en el campo y con la georreferenciación de la imagen, a la vez que se logra modelizar la estructura de las masas forestales objeto de estudio y se evita el riesgo de utilizar píxeles no representativos de los datos de campo para el ajuste de los modelos de regresión.

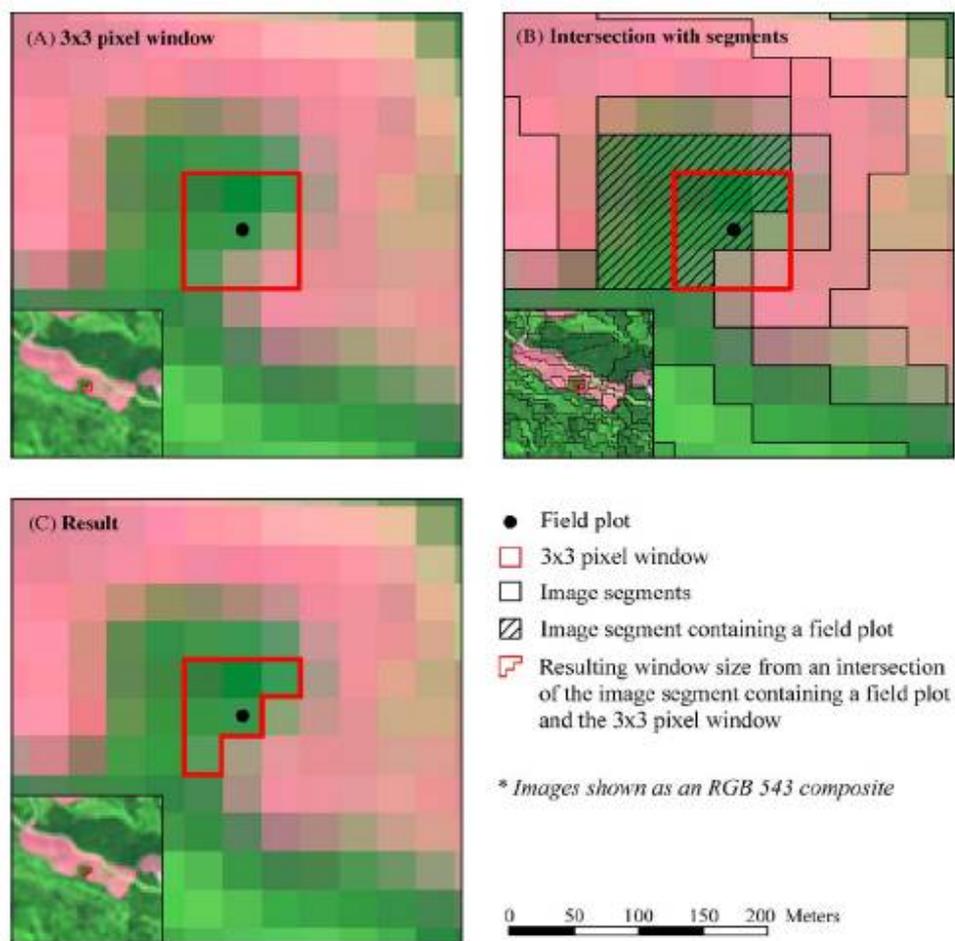


Figura 3.28. Procedimiento de extracción de la información radiométrica combinando el uso de técnicas de segmentación y ventanas fijas con restricciones. Fuente: Hall *et al.* (2006)

En concreto, siguiendo el orden cronológico de estos trabajos, Mäkelä y Pekkarinen (2001) comparan la utilidad de dos métodos de segmentación para la extracción de la información espectral de dos imágenes Landsat TM para la estimación de volumen total de madera con el método estadístico no paramétrico *k-NN*: el método ISODATA, que se sitúa dentro de los de segmentación basados en el píxel, y el método *Narendra y Goldbert* (NG), basado en la segmentación con clasificadores en árbol y que combina los procedimientos propios de los métodos basados en ejes y en regiones. Los resultados de estas segmentaciones fueron refinados, usando para ello dos algoritmos de unión de regiones para eliminar clústeres más pequeños de un determinado tamaño. Para la extracción de los valores espectrales de la parcela y de los píxeles que componen su vecindad se utilizaron diferentes tamaños de ventana fija, desde 1 hasta 11x11 píxeles, tomándose sólo los valores de los píxeles que pertenecían a la misma región que el central de la parcela de campo. Por último, con el objeto de comprobar si estos métodos mejoraban el método tradicional de ventanas fijas, los resultados de ambas se compararon con los que se obtenían utilizando esas mismas ventanas fijas sin la restricción impuesta de pertenencia de los píxeles a un determinado grupo. El resultado general fue que las mejores estimaciones se obtenían cuando se empleaba alguno de los dos métodos de segmentación, aunque esta mejora era muy pequeña (entre 0,2 y 2,8 m³/ha). De esta manera, los $RMSE_r$ de las estimaciones efectuadas con los dos métodos de segmentación y con las ventanas fijas sin restricciones permanecían por encima de los 100%, siendo la única excepción cuando todas las especies eran consideradas en la muestra de forma conjunta. En este caso, el mejor $RMSE_r$ conseguido por los métodos de segmentación se situaba en 79,3%, mientras que el de las ventanas fijas estaba en 80,4% (sólo un 1% de mejora). Así pues, como valoración final se afirma en este trabajo que el uso de estos dos métodos de segmentación no mejora significativamente la precisión de las estimaciones.

Por su parte, el trabajo de Pekkarinen (2002) usa las técnicas de segmentación como único método posible de extracción de la información en imágenes de alta resolución espacial (1,6x 1,6 m) para la estimación de volúmenes de madera, ya que en este tipo de imágenes los análisis a escala de píxel no son significativos. El método de segmentación aplicado en este trabajo consta de dos fases: en primer lugar, un clasificador en árbol es aplicado para obtener una primera segmentación, para, acto seguido, aplicar algoritmos de unión de regiones que eliminan las más pequeñas. El tamaño de la ventana para extraer el valor del píxel central y de los vecinos que pertenecen a la misma categoría es de 31x31 píxeles, siendo también esta ventana la

utilizada para extraer el valor medio de todos los píxeles contenidos sin esta restricción. Al igual que en el anterior trabajo, aunque el método de segmentación resultó exitoso para la determinación de unidades homogéneas, las diferencias en la estimación entre este método y el de ventanas fijas resultaron muy pequeñas, permaneciendo altos los errores a escala de parcela.

Finalmente, el método de segmentación usado por Hall *et al.* (2006) sobre una imagen Landsat ETM+ para estimar los parámetros estructurales forestales altura y espesor de copas (utilizados posteriormente para estimar *AGB* y volumen total a escala de unidad forestal) se aplicó utilizando el *software* eCognition. Este programa permite la utilización de criterios de forma, color y tamaño en la determinación de áreas homogéneas. En este caso, el tamaño de la ventana fija para la extracción de los valores radiométricos que pertenecen al mismo segmento que el píxel central y el de todos ellos es de 3x3 píxeles. Como resultado, a diferencia de los anteriores trabajos, éste sí que resalta que la segmentación introduce una notable mejora en la estimación de los dos parámetros forestales considerados. La comparación de los dos métodos se hace mediante la utilización del coeficiente de correlación y mediante una muestra reservada para la validación. En concreto, la mejoras más altas de *R* utilizando la información de las áreas homogéneas obtenidas en la segmentación se dan con TM5 y TC3 (aumento de 0,10 y 0,09 puntos, respectivamente) en la variable altura, mientras que en la variable espesor de copas se da con TM4 y con TC3 (aumentos de 0,07 en cada una de ellas). Estas leves mejoras (nótese que se habla de *R*, no de R^2) son confirmadas con la muestra de validación, obteniéndose diferencias medias entre los valores reales y los estimados más bajas con el método de segmentación que con el método de ventana fija sin restricción. De esta manera, para el autor, queda probado que la segmentación es capaz de ofrecer datos más adecuados para la estimación de variables forestales. Esto se produce porque el método de segmentación empleado en esta ocasión sí que logra eliminar de forma efectiva los píxeles de realidades diferentes a la de la parcela (por ejemplo, cortafuegos, caminos, otras cubiertas vegetales...) que son incluidos cuando toda la ventana fija es tomada en cuenta. Por último, señalar que quizá uno de los aspectos más controvertidos de este trabajo es que en ningún momento se justifica la selección de los parámetros de segmentación, careciendo también de una sólida discusión sobre los efectos que utilizar unos parámetros u otros tiene en el resultado de la segmentación y, por ende, en los resultados de la estimación de los parámetros forestales obtenidos de forma directa y en los obtenidos de forma indirecta (*AGB* y volumen de madera).

Así pues, teniendo en cuenta estos resultados y el objetivo de que la presente investigación debe proporcionar una metodología sencilla que pueda ser adoptada por las distintas Administraciones, se abordó la segmentación de la imagen Landsat para ver si se conseguía igualar los resultados obtenidos con el método de extracción de ventanas fijas, pero considerando un mayor número de parcelas.

De esta manera, ante la imposibilidad de contar con una licencia de eCognition, se exploraron las distintas posibilidades que ofrecía ERDAS Imagine 8.7 para realizar segmentación de imágenes. A este respecto, dos son las herramientas que destacan para obtener regiones espectrales homogéneas de forma semiautomática: el módulo *unsupervised classification* (clasificación no supervisada), que se identifica con el método ISODATA antes aludido, y el módulo *RGB clustering-Advanced RGB clustering* (agrupación RGB), que es un algoritmo rápido y simple de formación de clústeres que comprime las tres bandas que dan lugar a una composición RGB en una sola banda pseudo-color, sin clasificar necesariamente alguna característica particular (ERDAS Field Guide, 2002). Dado que el algoritmo ISODATA no se terminó de mostrar como significativamente mejor que el método de ventanas fijas en el trabajo de Mäkelä y Pekkarinen (2001) y la sencilla forma de operar de *RGB clustering*, finalmente se optó por esta última metodología, que se describe más detalladamente a continuación.

El procedimiento de segmentación en *RGB clustering* se inicia con la especificación de las tres bandas que dan lugar a la imagen RGB sobre la que se aplica el proceso (Figura 3.29(A)). El algoritmo dispone entonces todos los píxeles de la imagen en el espacio de características tridimensional definido por las bandas espectrales (Figura 3.29(B)) y luego divide este espacio en clústeres Figura 3.29(B,C). Para ello, a lo largo de cada eje del diagrama de dispersión tridimensional, cada histograma de entrada es escalado para que las particiones definidas por el usuario dividan los histogramas entre los límites especificados, pudiendo ser realizado este escalado utilizando un número determinado de desviaciones estándar por encima o por debajo de la media o entre el mínimo y el máximo ND de cada banda. En general, este número de secciones debe variar de acuerdo a los histogramas de cada banda, de tal manera que los histogramas amplios deben dividirse en más secciones y los estrechos en menos. En su versión más simple, cada una de estas particiones se convierte en una clase en la capa raster categórica de salida. Por su parte, la versión más avanzada requiere de un umbral mínimo para el tamaño de los clústeres, lo que hace que sólo aquéllos que superan el tamaño especificado por el umbral se conviertan finalmente en clases.

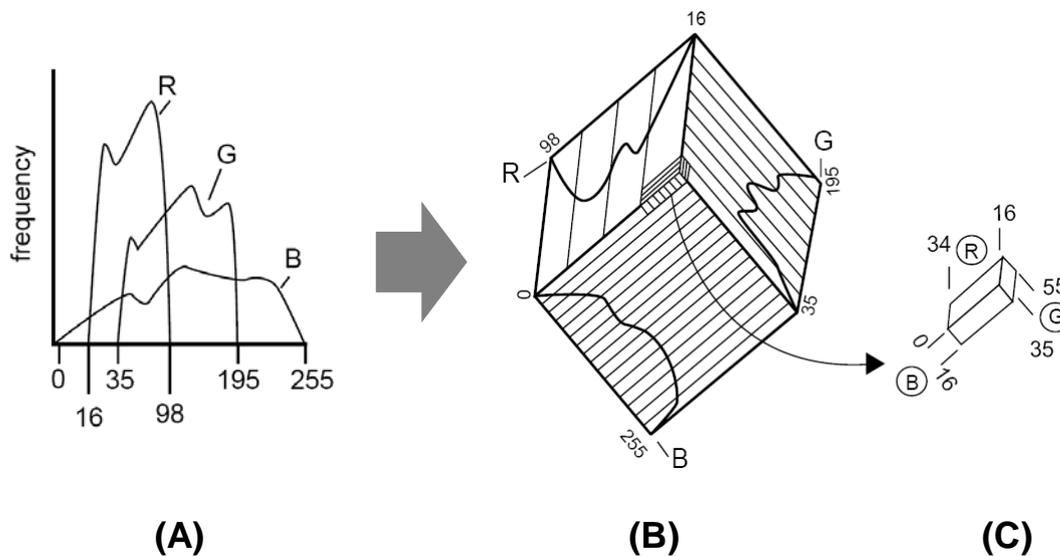


Figura 3.29. Procedimiento de segmentación *RGB clustering* en ERDAS Imagine: (A) selección de las 3 bandas; (B) disposición de los píxeles en el espacio tridimensional de las 3 bandas y seccionado por las particiones establecidas; (C) cluster resultante del seccionado tridimensional. Fuente: ERDAS Field Guide (2002)

Entre las dos versiones de este método se optó por la primera, dado que se requiere un menor número de parámetros específicos de entrada para su ejecución y, por lo tanto, es más factible argumentar la elección de los valores introducidos, siendo también más sencillo interpretar los resultados. En concreto, se tomaron decisiones a propósito de:

- **Sobre qué imagen realizar la segmentación.** La duda se presentó entre usar la imagen multibanda que recoge todo el territorio de la provincia de Teruel, obteniéndose una segmentación que afectaría a todas las cubiertas presentes en este territorio, o sobre este mismo archivo multibanda una vez aplicada la misma máscara procedente del MFA 1:50.000 utilizada para obtener las cartografías de estimación, con lo que la segmentación se reduciría solamente al espacio forestal de la provincia. Dado que nuestro objetivo es obtener áreas forestales homogéneas que describan la estructura de los bosques de pináceas de la provincia, finalmente se utilizó la segunda opción.
- **Qué composición RGB utilizar como referencia.** La elección de la composición RGB estuvo dirigida por criterios visuales y estadísticos a la hora de la estimar biomasa residual. En función de criterios visuales se determinó que la composición RGB debía tener en sí misma significación para la

visualización y el análisis de la superficie. De las 120 combinaciones posibles a partir de las 6 bandas reflectivas de Landsat TM, las más utilizadas y que cumplen estas características son: TM4-TM5-TM3, TM4-TM3-TM2, TM7-TM4-TM3 y TM3-TM2-TM1. De estas cuatro, TM4-TM5-TM3 y TM7-TM4-TM3 se erigen como las que pueden ser más útiles para nuestro objetivo, ya que contienen una de las bandas de la región del infrarrojo medio que se han mostrado como las más correlacionadas con la biomasa residual (TM5 y TM7). Además de esto, las otras dos bandas también son adecuadas, ya que TM4, como se ha visto con anterioridad, está relacionada con la estructura física forestal, condición ésta también destacada por Hall *et al.* (2006). Por su parte, destacar que TM3 es, de las bandas Landsat en la región del visible, la más correlacionada con la biomasa residual según los análisis previos.

Finalmente, ante las escasas diferencias entre estas dos composiciones desde el punto de vista de la utilidad de las bandas que las componen para estimar biomasa, fueron criterios visuales los que motivaron que la escogida fuera la composición TM7-TM4-TM3. Con esta combinación, la vegetación es visualizada en distintas tonalidades de verde, mientras que con la otra alternativa es visualizada en rojo. Esta circunstancia facilita la interpretación de la imagen a usuarios de la Administración no habituados al tratamiento de imágenes de satélite que pudieran utilizar esta metodología en el futuro.

- **Qué método usar para escalar el histograma de las 3 bandas de la composición RGB.** Para comprobar la incidencia de este parámetro de entrada se hicieron diversas pruebas, manteniendo el número de divisiones en los histogramas de cada banda. De esta manera se verificó que el método de escalamiento del mínimo-máximo era el que peores resultados ofrecía, ya que las regiones que se obtenían eran muy grandes, enmascarando la heterogeneidad espacial de los bosques mediterráneos. Un resultado similar se observó utilizando una desviación estándar, obteniéndose más manchas homogéneas y más pequeñas a medida que se aumentaba el número de desviaciones estándar. Finalmente, a la vista de los resultados, se determinó que la utilización entre 2 y 4 desviaciones estándar era un buen compromiso entre el número y el tamaño de las áreas homogéneas y la fragmentación de los bosques considerados.

- **Utilizar –o no- la opción de ignorar los valores “0” del archivo multibanda.** Esta duda se resolvió de manera inmediata al comprobar cómo la consideración de los píxeles con valor 0 hacía que el tamaño de las áreas homogéneas aumentará considerablemente y su número se redujera, con lo que se enmascaraba, de nuevo, la heterogeneidad de los bosques mediterráneos. Así, se eligió la opción de ignorar los ceros presentes en las tres bandas.
- **Qué número de secciones considerar en cada una de las bandas.** Por defecto, el programa divide la banda asignada al Rojo en 7 secciones, mientras que las bandas Verde y Azul quedan divididas en 6. Considerando la imagen y la composición RGB utilizada, estos parámetros se acomodan bien a las especificaciones de este método de segmentación, ya que dividen en más secciones que las demás la banda TM7, la que presenta un histograma más amplio. Sin embargo, dada la estrechez de los histogramas de las tres bandas consideradas, fruto de que la imagen sólo refiere a los bosques de pináceas de la provincia de Teruel, se consideró también un número de secciones menor en cada banda: 4 en la del Rojo y 3 en las asignadas a los canales Verde y Azul.

Así pues, la combinación de los parámetros de número de desviaciones estándar a considerar en las tres bandas y el número de secciones a obtener en cada una de ellas permite obtener, sobre la misma composición RGB de una imagen, distintos modelados de la heterogeneidad-homogeneidad de la estructura espacial de los bosques estudiados.

En teoría, la mejor estimación se conseguirá cuanto más coincidencia exista entre la heterogeneidad-fragmentación real de esos bosques y el modelado de estas características obtenido en la segmentación. Se impone, pues, que mediante esta herramienta se deriven varias segmentaciones que representen a diversos grados de heterogeneidad espacial para averiguar cuál de ellas representa mejor la realidad y, por lo tanto, resulta más útil para extraer la información radiométrica de las imágenes.

Con este objetivo se llevaron a cabo cuatro segmentaciones sobre la composición RGB TM7-TM4-TM3 de la imagen multibanda resultado de aplicar la máscara del MFA 1:50.000, manteniendo siempre la opción de ignorar los ceros en esa imagen. De esta manera, las diferencias entre las cuatro segmentaciones son fruto de distintas combinaciones del número de desviaciones estándar aplicados a cada banda y del

número de secciones a considerar en cada una de ellas. La Tabla 3.32 recoge la combinación usada en cada una de ellas.

Segmentación	Número de desviaciones estándar en cada banda	Número de secciones		
		Red	Green	Blue
S1	2	7	6	6
S2	4	7	6	6
S3	2	4	3	3
S4	4	4	3	3

Tabla 3.32. Parámetros de entrada de las cuatro segmentaciones aplicadas a la composición RGB TM7-TM4-TM3 tras aplicar la máscara del MFA

De esta manera, en teoría, la segmentación S1 representa una situación de alta heterogeneidad espacial (gran número de regiones de pequeño tamaño), mientras que S4 es, de las cuatro, la que menor grado de heterogeneidad espacial supone, obteniéndose un menor número de regiones y de mayor tamaño. Las segmentaciones S2 y S3 se corresponden con situaciones intermedias entre ambos extremos.

Para confirmar esta correspondencia se procedió al análisis de 21 parcelas, 3 elegidas al azar en cada uno de los 7 últimos grupos en los que se habían clasificado anteriormente estas parcelas según su CV (los más homogéneos). Este análisis consistió en comprobar, para cada una de las segmentaciones, en cuántas de estas 21 parcelas el píxel central pertenece a la misma región que el resto de píxeles vecinos contenidos en la ventana 3x3. Además, también se utilizaron estas parcelas para comparar las segmentaciones entre sí, comprobando si, dentro de la ventana fija, los píxeles eran repartidos en regiones distintas o en las mismas.

Los resultados de este análisis confirmaron lo acertado de las segmentaciones con respecto al modelado esperado de la heterogeneidad espacial que cada una de ellas opera. Así, en la segmentación S1 sólo en 3 de las 21 parcelas los 9 píxeles pertenecen al mismo segmento (14,28%), elevándose este número a 7 en S3 (33,33%), a 9 en S2 (42,85%) y, finalmente, a 16 en la segmentación S4 (76,19%). Teniendo en cuenta estos resultados, otra conclusión complementaria que se deriva es que, dentro de las segmentaciones intermedias, S3 representa una situación de heterogeneidad algo mayor que S2.

Con respecto a las comparaciones de las segmentaciones entre sí, la consideración de 2 ó 4 desviaciones estándar hace que 15 de las 21 parcelas sean

diferentes en las dos segmentaciones que consideran 7 secciones en el Rojo y 6 en el Verde y el Azul (S1 y S2). En el caso de las segmentaciones con 4 y 3 secciones (S3 y S4), las diferencias entre parcelas debidas al cambio en el número de desviaciones estándar se sitúa en 14. Por último, señalar que la incidencia de la variación del número de secciones en cada banda, manteniendo la misma desviación estándar aplicada a los histogramas, tiene una incidencia similar a la variación de este último parámetro, ya que son otra vez 15 las parcelas diferentes entre las segmentaciones S1 y S3 y también entre S2 y S4.

En conclusión, es necesario estudiar cómo son las relaciones entre la biomasa residual y la información extraída mediante estas cuatro segmentaciones y las ventanas fijas para ver cuál de ellas modela de manera más acertada la realidad y ofrece los mejores resultados. Para ello, además de las comparaciones entre sí, se utiliza como referencia la información obtenida con las ventanas fijas de 3x3 sin la restricción de las segmentaciones. Siguiendo la metodología usada en Hall *et al.* (2006), el coeficiente de correlación es el parámetro estadístico que se emplea para determinar cuál es la mejor segmentación, siendo ésta la seleccionada para el ajuste de los modelos de regresión.

3.1.2.2.2. Estudio de las correlaciones entre biomasa residual forestal y las variables espectrales considerando los distintos tipos de segmentación

Dada la escasa o nula utilidad mostrada por las variables topográficas continuas para la estimación de la biomasa residual en los anteriores apartados, estas variables son excluidas del análisis de correlaciones que se efectúa aquí para determinar qué método de segmentación es más adecuado para nuestros objetivos, así como para el posterior ajuste de regresiones estimativas. Por su parte, el conjunto de variables radiométricas a considerar en este apartado también sufre una modificación, ya que -de todos los índices de vegetación calculados- solamente permanece en la muestra el NDVI. Como se ha visto, existen escasas diferencias dentro este grupo de índices a la hora de estimar biomasa residual forestal, ya que todos ellos presentan correlaciones similares con este parámetro forestal y están altamente correlacionados entre ellos. Así pues, carece de sentido que se consideren otra vez todas estas variables relacionadas directamente con la vegetación, por lo que se elige como representativa de todas ellas el NDVI, ya que es el más utilizado de todos ellos en la bibliografía y siempre ha aparecido en los análisis previos dentro de los tres más correlacionados con la biomasa, con coeficientes casi idénticos a los índices de la familia SAVI.

Otro aspecto a señalar es que únicamente se utilizan en el análisis de correlación las parcelas que se sitúan dentro de los grupos 7 y 6 definidos a partir del CV calculado con la ventana fija de 3x3 (208 y 149 parcelas, respectivamente). Aunque quizá la consideración de las 482 parcelas hubiera permitido resaltar de forma más inmediata las diferencias entre el método combinado de extracción a partir de segmentaciones y ventanas fijas con respecto al de ventanas fijas sin restricciones, se prefirió descartar el uso de las más heterogéneas según el CV para evitar, con mayor seguridad, la influencia de los errores de localización en el campo y de la georreferenciación de imágenes, manteniéndose a su vez un número más que suficiente de parcelas para garantizar que los modelos de estimación resultantes no están sobre-ajustados y son representativos de todo el área de estudio. Además, si la diferencia entre esas dos metodologías existe, está tiene que ser igualmente detectable usando un número de parcelas más reducido, pero de mayor calidad en cuanto al grado de correlación obtenido con las variables espectrales en anteriores análisis.

Un último hecho a resaltar, antes de presentar y analizar las correlaciones obtenidas, es que la utilización de la imagen multibanda con la máscara forestal derivada del MFA hace que el número de parcelas disponible para el análisis de correlaciones en los grupos del percentil 7 y 6 disminuya con respecto al que había utilizando toda la imagen, quedando 182 en el primero y 130 en el segundo. Esto se debe a que algunas de estas parcelas se situaban en localizaciones que, según el MFA, no pertenecían a bosques de pináceas, por lo que ahora no existen datos espectrales para ella. Esta circunstancia tiene que repercutir, en teoría, en un aumento general de los índices de correlación con respecto a los obtenidos en el apartado 3.1.1.2, ya que el carácter forestal de estas parcelas viene avalado por el empleo de dos fuentes de información forestal que utilizan una metodología diferente.

Así, la Tabla 3.33 muestra las correlaciones de *Pearson* obtenidas con estas parcelas en cada una de las de las cuatro segmentaciones y con la ventana de 3x3 sin restricciones. Como se observa, a excepción de con el neocanal CP2, las correlaciones entre la biomasa residual y las variables radiométricas consideradas vuelven a ser significativas al nivel $p < 0,01$, con la única salvedad de TM4 en el grupo que contiene menos parcelas, que lo son al nivel de $p < 0,05$. En cuanto al sentido de estas relaciones, destacar que, como era esperado, no existe ninguna modificación con respecto a anteriores análisis con otras metodologías de extracción.

	Segmentación S1		Segmentación S2		Segmentación S3		Segmentación S4		Ventana fija sin restricciones	
	Percentil 7	Percentil 6	Percentil 7	Percentil 6						
Nº Parcelas	182	130	182	130	182	130	182	130	182	130
TM1	-0,595**	-0,616**	-0,600**	-0,621**	-0,599**	-0,617**	-0,606**	-0,628**	-0,598**	-0,630**
TM2	-0,585**	-0,617**	-0,580**	-0,613**	-0,573**	-0,609**	-0,579**	-0,619**	-0,585**	-0,632**
TM3	-0,594**	-0,638**	-0,591**	-0,640**	-0,588**	-0,629**	-0,597**	-0,641**	-0,602**	-0,657**
TM4	-0,224**	-0,182*	-0,243**	-0,210*	-0,220**	-0,192*	-0,224**	-0,188*	-0,240**	-0,205*
TM5	-0,622**	-0,678**	-0,642**	-0,696**	-0,635**	-0,684**	-0,638**	-0,696**	-0,650**	-0,698**
TM7	-0,605**	-0,683**	-0,625**	-0,696**	-0,621**	-0,685**	-0,632**	-0,704**	-0,641**	-0,701**
CP1	-0,592**	-0,653**	-0,608**	-0,663**	-0,601**	-0,651**	-0,606**	-0,664**	-0,615**	-0,668**
CP2	-0,059	-0,131	-0,063	-0,147	-0,084	-0,156	-0,082	-0,154	-0,082	-0,159
CP3	-0,563**	-0,621**	0,579**	0,634**	0,573**	0,621**	0,591**	0,636**	0,605**	0,649**
TC1	-0,578**	-0,629**	-0,588**	-0,637**	-0,581**	-0,624**	-0,584**	-0,636**	-0,595**	-0,643**
TC2	0,437**	0,477**	0,443**	0,484**	0,445**	0,479**	0,453**	0,484**	0,449**	0,491**
TC3	0,609**	0,670**	0,629**	0,694**	0,622**	0,678**	0,636**	0,696**	0,654**	0,700**
NDVI	0,626**	0,665**	0,627**	0,660**	0,626**	0,655**	0,634**	0,657**	0,630**	0,665**
MSI	-0,592**	-0,640**	-0,629**	-0,667**	-0,617**	-0,652**	-0,633**	-0,667**	-0,643**	-0,676**
VIS123	-0,601**	-0,635**	-0,599**	-0,636**	-0,595**	-0,628**	-0,602**	-0,640**	-0,604**	-0,651**
MID57	-0,618**	-0,684**	-0,638**	-0,699**	-0,632**	-0,687**	-0,639**	-0,702**	-0,648**	-0,701**
ABD	-0,599**	-0,649**	-0,609**	-0,662**	-0,603**	-0,650**	-0,608**	-0,664**	-0,616**	-0,668**

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 3.33. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las variables independientes radiométricas continuas en los grupos del percentil 7 y 6 según el tipo de segmentación y usando ventanas fijas sin restricciones

En referencia a la magnitud de las correlaciones, una vez más las variables relacionadas con la humedad de la vegetación alcanzan los mayores coeficientes con todas las segmentaciones y con la ventana de referencia, si bien en algunas ocasiones, la variable NDVI alcanza valores en el mismo nivel que éstas; en sentido contrario, destacan una vez más las variables TC2, TM4 y CP2. Así pues, la conclusión en cuanto a la utilidad de las variables radiométricas consideradas es el mismo que en anteriores métodos de extracción de la información.

Un aspecto más interesante es el hecho de que las correlaciones aumentan conforme lo hace la homogeneidad radiométrica de las parcelas medida mediante el CV, independientemente de la variable radiométrica (con la única excepción de TM4) y del tipo de segmentación empleado. Esta situación también se observa en los resultados obtenidos mediante el uso de la ventana fija sin restricciones. De esta manera, la lectura que se deriva es que ninguna de las segmentaciones llevadas a cabo tiene un impacto tan beneficioso para obtener una ecuación estimativa precisa de la biomasa residual como el método de reducción de la muestra de parcelas a partir de la utilización del CV calculado sobre la ventana radiométrica de 3x3 píxeles. De haberse dado la situación contraria, las diferencias entre las correlaciones obtenidas entre las parcelas de percentil 7 y 6 deberían haber sido más pequeñas, dado que las segmentaciones RGB hubieran eliminado el ya analizado efecto negativo que heterogeneidad radiométrica tiene en la estimación de esta variable.

Otro hecho que confirma el limitado éxito de las segmentaciones en eliminar la heterogeneidad de la muestra es que con ninguna de ellas se superan claramente los coeficientes de correlación alcanzados con la ventana de 3x3 sin restricciones. En este sentido, las segmentaciones que más se alejan de los valores alcanzados con la ventana de referencia son la S1 y la S3, mientras que las que más se acercan son las segmentaciones S2 y, sobre todo, S4, superando esta última, en algunas variables, los valores de referencia, tanto en el grupo de parcelas del percentil 7 como en el percentil 6. Esta circunstancia indica que de los dos parámetros conjugados a la hora de afrontar las segmentaciones RGB de la composición TM7-TM4-TM3 de la imagen con máscara forestal, el del número de desviaciones estándar a considerar en las tres bandas ha logrado modelar mejor la estructura espacial de los bosques del área de estudio que el número de secciones a obtener en cada una de ellas.

En relación con lo anterior, es necesario recordar que las segmentaciones S1 y S3 eran las que mejor se acomodaban a situaciones de alta heterogeneidad espacial de los bosques, ya que eran las que obtenían un mayor número de áreas homogéneas y de menor tamaño. A la vista de los resultados obtenidos, esta “atomización” del espacio no se corresponde con la realidad del área estudiada, que presenta menor grado de fragmentación. Esta realidad espacial, al menos para la estimación de biomasa residual, queda mejor caracterizada por la segmentación S4, la que menor número de regiones obtenía y de menor tamaño, por lo que la fragmentación del área forestal analizada es menor de lo que se esperaba *a priori*.

Aparte de que la segmentación S4 pueda ser la que mejor modele la estructura espacial de las zonas boscosas analizadas, otra circunstancia que puede incidir en que las correlaciones sean mayores en esta segmentación puede estar relacionada con el hecho -señalado por Hyyppä y Hyyppä (2001)- de que la estimación de una variable forestal continua mediante imágenes de teledetección mejora cuanto mayor sea el tamaño del área del cual se dispone de datos de campo. Así, aunque al igual que en las otras segmentaciones los datos radiométricos extraídos en S4 se restringían a los 8 píxeles vecinos del central de la parcela, el número final de píxeles considerados en cada parcela era mayor que en las otras tres, ya que en ésta existía una mayor probabilidad de que todos los píxeles de la ventana quedaran dentro de la misma región homogénea.

Centrándonos, por tanto, en la segmentación S4, el uso de ésta permite la obtención de coeficientes de correlación más altos que los de la ventana sin restricciones con las variables NDVI, TM1 y TC2, en el caso de utilizar las parcelas del percentil 7, y con TM7 y MID57, en el caso de utilizar las parcelas del percentil 6, si bien en este último grupo es donde los coeficientes alcanzados en ambos métodos de extracción son más parecidos, llegando a ser prácticamente iguales. El máximo valor de correlación se da precisamente con las variables MID57 y TM7 en grupo del percentil 6 (130 parcelas), superándose el umbral de 0,7 (0,704 y 0,702, respectivamente, utilizando la segmentación S4, y 0,701 con la ventana de referencia). Inmediatamente después de estos índices, con valores superiores a 0,69 en los dos métodos de extracción, aparecen las variables TC3 y TM5, quedando más alejada la quinta variable relacionada directamente con el contenido de humedad de la vegetación, el MSI. Estos valores de correlación son similares a los alcanzados por estas variables en el percentil 4 (clúster 3) en el apartado 3.1.1, cuando solamente se empleaba como método de extracción la ventana fija de 3x3.

De esta manera, aunque la utilización del método de segmentación no ha conseguido proporcionar correlaciones mucho más elevadas que mediante el uso de ventanas fijas de 3x3, la exploración de la utilidad de este método sí ha permitido identificar un grupo de parcelas más numeroso que el utilizado en el ajuste de los modelos de regresión obtenidos en el apartado 3.1.1 (el doble de parcelas que las contenidas en percentil 4 -clúster 3- y más del triple que las incluidas en el percentil 3-clúster 4). Además, este nuevo grupo de parcelas identificado presenta correlaciones algo superiores en las variables MID57, TM5 y TM7 que el grupo de áreas homogéneas de aptitud 3, que presentaba el mismo tamaño muestral.

Como resultado, la utilización de este grupo de parcelas permite obtener modelos de estimación más representativos del área de estudio y con menos probabilidad de estar sobre-ajustados que los generados en el apartado 3.1.1, al tiempo que ofrecen más garantías que los obtenidos en el apartado 3.1.2.1 con las áreas homogéneas delimitadas visualmente, ya que, a diferencia de lo que sucedía en este apartado, existe seguridad de que los datos radiométricos extraídos sí que se corresponden a la realidad de la variable medida en la parcela.

Dado que las correlaciones alcanzadas con la utilización de la segmentación S4 y ventanas fijas con restricción son prácticamente iguales a las que se obtienen con el uso de ventanas fijas sin restricción, la causa de que se haya encontrado este grupo de 130 parcelas con las características ya comentadas debe achacarse al hecho de que, en esta ocasión, a diferencia de lo hecho en las otras dos metodologías de extracción ensayadas, sólo se han considerado las parcelas en las que existía concordancia entre el IFN-2 y el MFA. Este hecho pone de manifiesto, una vez más, la precaución que hay que tener con la información del IFN-2 a la hora de utilizar sus datos para la estimación de parámetros forestales mediante teledetección, ya que la consideración de parcelas no clasificadas como forestales por otras fuentes de información ha podido ser motivo por el que no se han obtenido mejores resultados en anteriores modelos de estimación.

En consecuencia, estas 130 parcelas del percentil 6 son utilizadas en el siguiente subapartado para ajustar modelos de regresión univariantes y modelos de regresión lineal múltiple. Para ello, debido a la similitud de las correlaciones obtenidas a partir del uso de la segmentación S4 y de la ventana 3x3 sin restricciones, se utilizan los datos radiométricos derivados de las dos metodologías de extracción a la espera de que estos análisis permitan discriminar de manera más clara si una es mejor que la otra, ya que,

dado el carácter no lineal de las relaciones observado anteriormente y las limitaciones que el índice de correlación de *Pearson* tiene para medir este tipo de relaciones (Ebdon, 1982), este índice puede no haber sido suficiente para resaltar las diferencias entre los dos métodos.

3.1.2.2.3. Ajuste de modelos de regresión

- Modelos de regresión simple

Debido a que, una vez más, las variables relacionadas con el contenido de agua de la vegetación son las más correlacionadas con la biomasa residual, solamente se ajustaron modelos univariantes para estas variables (TM5, TM7, TC3, MSI y MID57). La Tabla 3.34 recoge, para cada una de ellas, el mejor de los modelos obtenidos con las cinco muestras aleatorias del 80% de las 130 parcelas consideradas utilizando los datos de la segmentación S4, mientras que la Tabla 3.35 muestra los obtenidos a partir de los datos de las ventanas 3x3. Todos los modelos calculados, incluidos los de las tablas, resultaron significativos tanto a nivel de modelo como a nivel de los coeficientes de regresión que los integran ($p < 0,05$). La variación del R^2 entre los modelos ajustados con una misma variable fue escasa, siendo siempre el modelo exponencial el que mejor ajusta los datos con TM5, TM7, TC3 y MID57 y el lineal con MSI. Estas dos circunstancias muestran la robustez de los modelos representados en las tablas, dado que no se deben a casualidades estadísticas.

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM5	Exponencial	0,534	0,689	194,655	-0,169
TM7	Exponencial	0,548	0,616	89,434	-0,200
TC3	Exponencial	0,524	0,632	83,115	0,238
MSI	Lineal	0,474	8,469	53,755	-40,987
MID57	Exponencial	0,543	0,683	144,856	-0,094

Tabla 3.34. Modelos de regresión simple calculados con la información de las 130 parcelas del grupo del percentil 6 obtenida mediante la utilización de la segmentación S4 y ventanas con restricciones: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM5	Exponencial	0,537	0,687	179,967	-0,164
TM7	Exponencial	0,538	0,686	88,621	-0,200
TC3	Exponencial	0,524	0,632	79,623	0,232
MSI	Lineal	0,485	8,376	54,110	-41,360
MID57	Exponencial	0,541	0,684	132,553	-0,090

Tabla 3.35. Modelos de regresión simple calculados con la información de las 130 parcelas del grupo del percentil 6 obtenida mediante la utilización de ventanas fijas sin restricciones: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

La comparación de los R^2 entre una y otra tabla confirma lo apuntado en el análisis de correlación acerca de las escasas diferencias existentes entre utilizar el método de la segmentación y el método de las ventanas fijas sin restricciones, al menos con el grupo de parcelas analizado. Así, comparando uno a uno los modelos obtenidos por variables, la segmentación ofrece R^2 ligeramente superiores en el caso de las variables TM7 y MID57, el uso de ventanas fijas ofrece resultados levemente mejores con TM5 y MSI y el resultado con TC3 es exactamente el mismo en ambos métodos. En términos absolutos, las variables TM5, TM7 y MID57 vuelven a erigirse como las más útiles, ya que alcanzan los coeficientes de correlación más altos, independientemente del método utilizado.

En cuanto a los errores de estimación alcanzados por estas variables considerando el mejor de sus dos modelos ajustados (Figura 3.30), el de la variable MID57 es el que menores $RMSE$ y $RMSE_r$ presenta (5,72 tons/ha y 36,01%, respectivamente). En segundo lugar aparecen los obtenidos con las dos variables que forman este índice, con errores relativos inferiores al 44% en ambos casos. Por último, señalar que tanto TC3 como MSI presentan errores superiores a las 10 tons/ha, lo que viene a indicar imprecisiones en la estimación algo superiores al 50%.

Con respecto al grado de saturación de estos modelos, los gráficos de dispersión de la Figura 3.30 muestran cómo el modelo obtenido con TC3 parece algo más sensible a las cantidades superiores a las 40 tons/ha que los ajustados con TM5, TM7 y MID57. En cuanto al modelo ajustado con MSI, dado que se trata de un modelo lineal, no se puede afirmar propiamente que se dé una situación de saturación, aunque tal y como se observa en la figura, sí se puede afirmar que la recta deja de ajustar correctamente los datos cuando las cantidades de biomasa residual de las parcelas se sitúan por encima de las 30 tons/ha.

De esa manera, los resultados obtenidos indican que nuevamente la variable MSI es, de las variables radiométricas probadas, la menos útil para estimar la biomasa residual forestal del área de estudio, mientras que MID57 es, una vez más, la mejor, siendo los resultados con esta variable algo superiores cuando se utilizan los datos extraídos utilizando la segmentación S4 y una ventana de 3x3 con restricciones. Es por ello por lo que se utiliza este modelo para la obtención de la cartografía de la biomasa residual que cierra este subapartado (Figura 3.31). Además, un beneficio indirecto del hecho de que la variable MID57 haya resultado ser la más útil para cartografiar la

biomasa residual es que la validación de esta cartografía permitirá la comparación de la metodología de extracción de la segmentación con las anteriormente utilizadas en este trabajo, ya que al final ésta ha sido la variable radiométrica más utilizada.

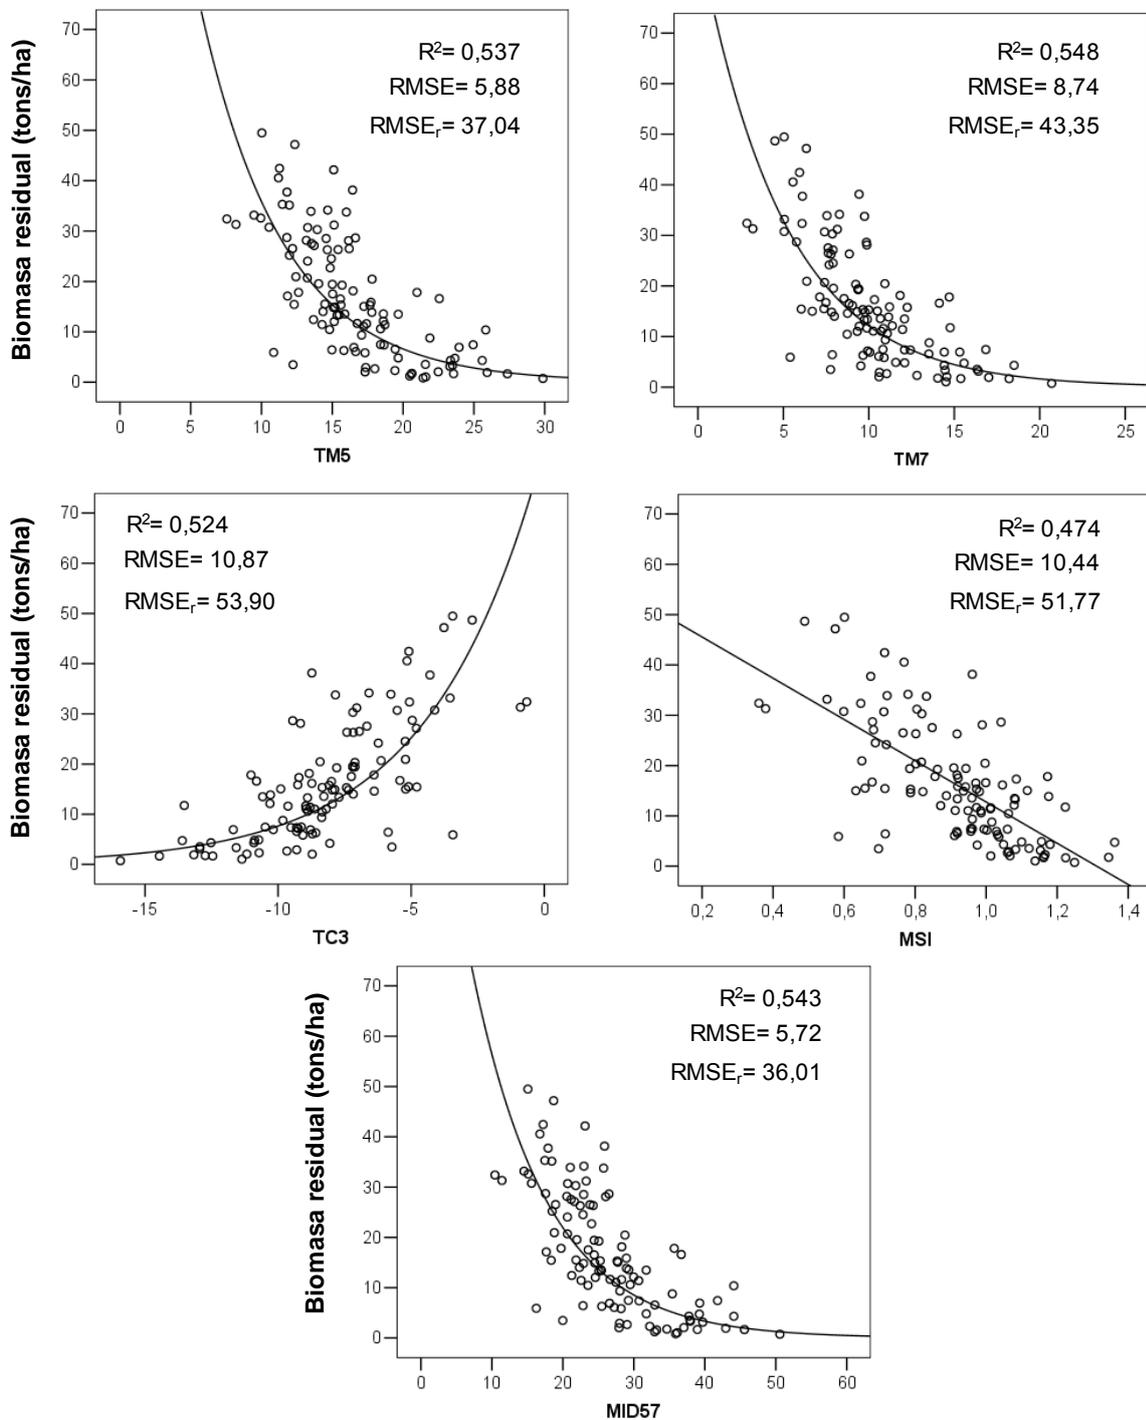


Figura 3.30. Gráficos de dispersión de los mejores modelos para cada una de las variables consideradas en las Tablas 3.34 y 3.35

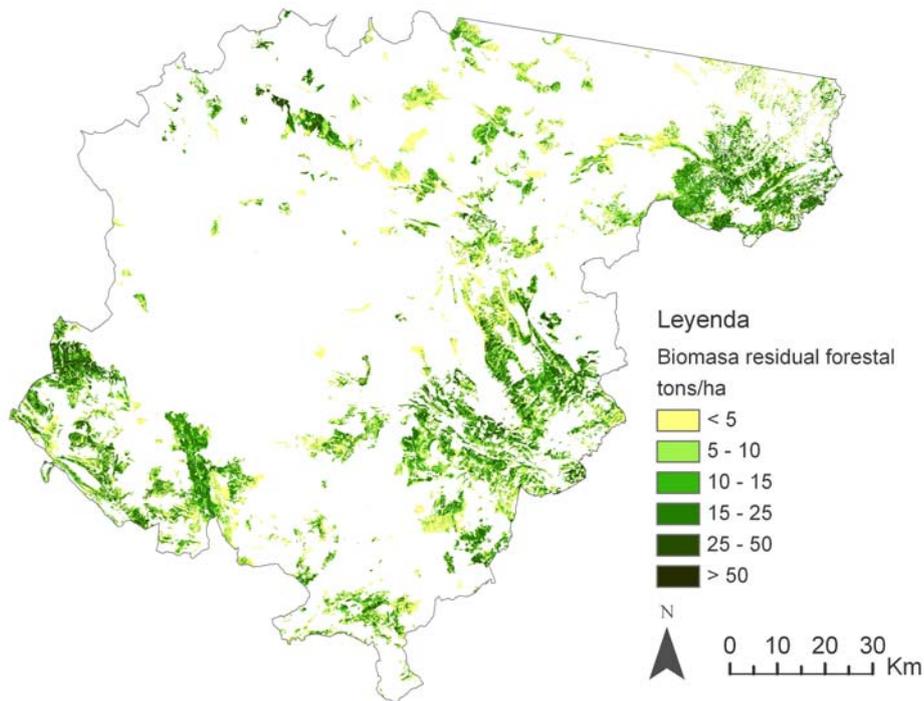


Figura 3.31. Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas incluidas en el grupo del percentil 6 derivadas de la utilización del método de extracción de segmentación (S4) y ventanas con restricciones

- Modelos de regresión lineal múltiple

Como se ha visto en el anterior apartado, existen escasas diferencias entre los modelos de estimación univariantes ajustados teniendo –o no- en cuenta los patrones espaciales obtenidos en la segmentación S4, si bien el modelo más preciso se ha obtenido considerándolos. Dada esta escasa diferencia, parece poco importante que para calcular los modelos de regresión lineal múltiple de las 130 parcelas seleccionadas se utilicen los datos de uno u otro método, ya que, casi con total certeza, los resultados volverán a ser semejantes.

Es por ello por lo que sólo los datos obtenidos a partir del método de segmentación son utilizados para calcular modelos de regresión múltiple. La justificación de esta elección reside en que, si este método de delimitación de áreas forestales no hubiera sido tenido en cuenta, no se hubiera podido delimitar el grupo de 130 parcelas homogéneas cuyo coeficiente de correlación con la biomasa es semejante al grupo de 68 obtenido a partir del uso del CV del apartado 3.1.1.2. Otro motivo igualmente importante es que se pretende comparar directamente los resultados de emplear este método de extracción con el de ventanas fijas de 3x3 y el CV y con el de áreas homogéneas forestales delimitadas visualmente. Además, está la circunstancia de que, aunque levemente, este método ofrece una mejor correlación con la variable MID57, que se ha mostrado a lo largo de estas páginas como la más adecuada para estimar la biomasa residual.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TM1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TM4	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	Si	No normal	Inversa	Normal
TM5	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal
CP3	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	-	-
TC1	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal
TC2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TC3	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSI	Normalidad	Normalidad	Simétrica	Mesocúrtica	No	Normal	-	-
VIS123	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal

Tabla 3.36. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes radiométricas correlacionadas con ella utilizando los datos obtenidos mediante la segmentación S4 y ventanas con restricciones

La Tabla 3.36 muestra los resultados de las pruebas de normalidad aplicadas sobre los datos obtenidos con el uso de la segmentación S4 y el uso de ventanas 3x3 con restricciones. Como en ella se refleja, sólo tres de las variables aquí consideradas, TC3, NDVI y MSI, son normales sin necesidad de ninguna transformación. En el otro extremo aparece CP3, ya que ninguna de las operaciones aplicadas logró revertir la situación de no normalidad de la variable original. A pesar de ello, dada la cercanía de la distribución de esta variable a la de una curva normal, fue incluida en el modelo. En cuanto al resto, señalar que, con la única excepción de TM4, las transformaciones aplicadas en cada una de ellas son coincidentes con las que se utilizaron con el grupo de parcelas del clúster 3. Otro aspecto a destacar en este último análisis sobre la distribución de las variables para el ajuste de modelos de regresión múltiple es que, un vez más, la raíz cuadrada es la mejor transformación para la variable dependiente.

Todas las variables dependientes originales o transformadas con distribución normal mostraron una relación homocedástica y lineal con la variable transformada de la biomasa residual en los gráficos de dispersión individuales, por lo que fueron consideradas a la hora de establecer los modelos de regresión. Esta situación se dio también con CP3, a pesar de no cumplir esta última variable el requisito anterior, por lo que finalmente también fue tenida en cuenta.

Modelo-Muestra	R^2_a	S_e	Índice de condición superior	Variables	β	Sig.
N ₁	0,547	0,994	14,668	TC3	0,303	0,000
				ln_TM1	-1,087	0,021
				Constante	7,746	0,000
N ₂	0,566	1,035	42,281	ln_MID57	-2,881	0,000
				ln_TM1	-1,175	0,049
				Constante	14,749	0,000
N ₃	0,560	1,051	12,975	ln_TM7	-3,411	0,000
				Constante	11,395	0,000
N ₄	0,596	0,962	21,757	ln_MID57	-3,928	0,000
				Constante	16,563	0,000
N ₅	0,533	1,047	22,198	ln_MID57	-3,846	0,000
				Constante	16,217	0,000

Tabla 3.37. Modelos de regresión múltiple calculados con los datos obtenidos mediante la segmentación S4 y ventanas con restricciones: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables

La Tabla 3.37 recoge los modelos obtenidos en cada una de las cinco muestras del 80% de las 130 parcelas que se obtuvieron utilizando una selección al azar. Como se observa en esta tabla, sólo dos de los cinco modelos, los obtenidos con las dos primeras muestras, quedaron compuestos por más de una variable (TC3 y TM1 en N_1 y MID57 y TM1 en N_2). Sin embargo, el alto índice de condición alcanzado en el modelo N_2 en su dimensión más alta (42,281) es un indicador claro de que este modelo no cumple el supuesto de no colinealidad. En efecto, este extremo quedó confirmado mediante el análisis de la correlación entre las dos variables que lo conforman, que arrojó un valor de 0,820. Dado que este modelo no cumple con uno de los supuestos básicos más críticos, fue eliminado, dejando en su lugar el univariante ajustado por la variable seleccionada en primer lugar en el método de pasos *hacia delante* (Tabla 3.38). En referencia al modelo múltiple obtenido con la muestra N_1 es preciso señalar que, aunque cumple el criterio de colinealidad, la adición de TM1 como segunda variable no incrementa mucho el R^2 con respecto al modelo obtenido en el primer paso, lo que expresa la escasa importancia de esta variable.

Variable	Tipo de modelo	R^2_a	S_e	β_0	β_1
N_2	ln_MID57	0,535	1,071	16,409	-3,888

Tabla 3.38. Modelo de regresión calculado para la muestra N_2 con los datos obtenidos mediante la segmentación S4 y ventanas con restricciones al eliminar las variables introducidas en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

Como resultado, 4 de los modelos obtenidos en este análisis son univariantes, empleando 3 de ellos la variable MID57 (N_2 de la Tabla 3.38, N_4 y N_5 de la tabla 3.37), y la TM7 el restante (N_3). El análisis gráfico de los residuos de cada uno de estos modelos y del múltiple mostró que todos ellos cumplían los supuestos de normalidad, homocedasticidad, linealidad, independencia y no colinealidad, siendo además altamente significativos, por lo que son válidos desde el punto de vista estadístico.

Centrándonos en los coeficientes de determinación obtenidos, todos ellos se sitúan en el intervalo comprendido entre 0,5 y 0,6, siendo dos de los modelos ajustados con MID57 los que marcan el valor mínimo (0,533 en N_5) y el máximo (0,596 en N_4). Así, en términos de capacidad de predicción, los resultados obtenidos mediante el análisis de regresión multivariante son algo superiores a los alcanzados previamente en la regresión univariante, ya que ninguno de estos últimos sobrepasaba el umbral de 0,55.

Sin embargo, esta ligera diferencia a favor de los modelos lineales obtenidos en este apartado no se mantiene cuando se utilizan como referencia los errores de estimación, ya que solamente uno de los ajustados en este apartado presenta un $RMSE_r < 40\%$, mientras que en el anterior se obtuvieron dos con esta característica. El error absoluto y relativo más bajo en los modelos univariantes es el alcanzado en el modelo N_2 , mientras que el más alto se da en el modelo N_4 (Figura 3.32). Por su parte, el modelo bivalente N_1 se sitúa entre ambos extremos, con un $RMSE$ de 9,064 tons/ha y un $RMSE_r$ de 44,95%.

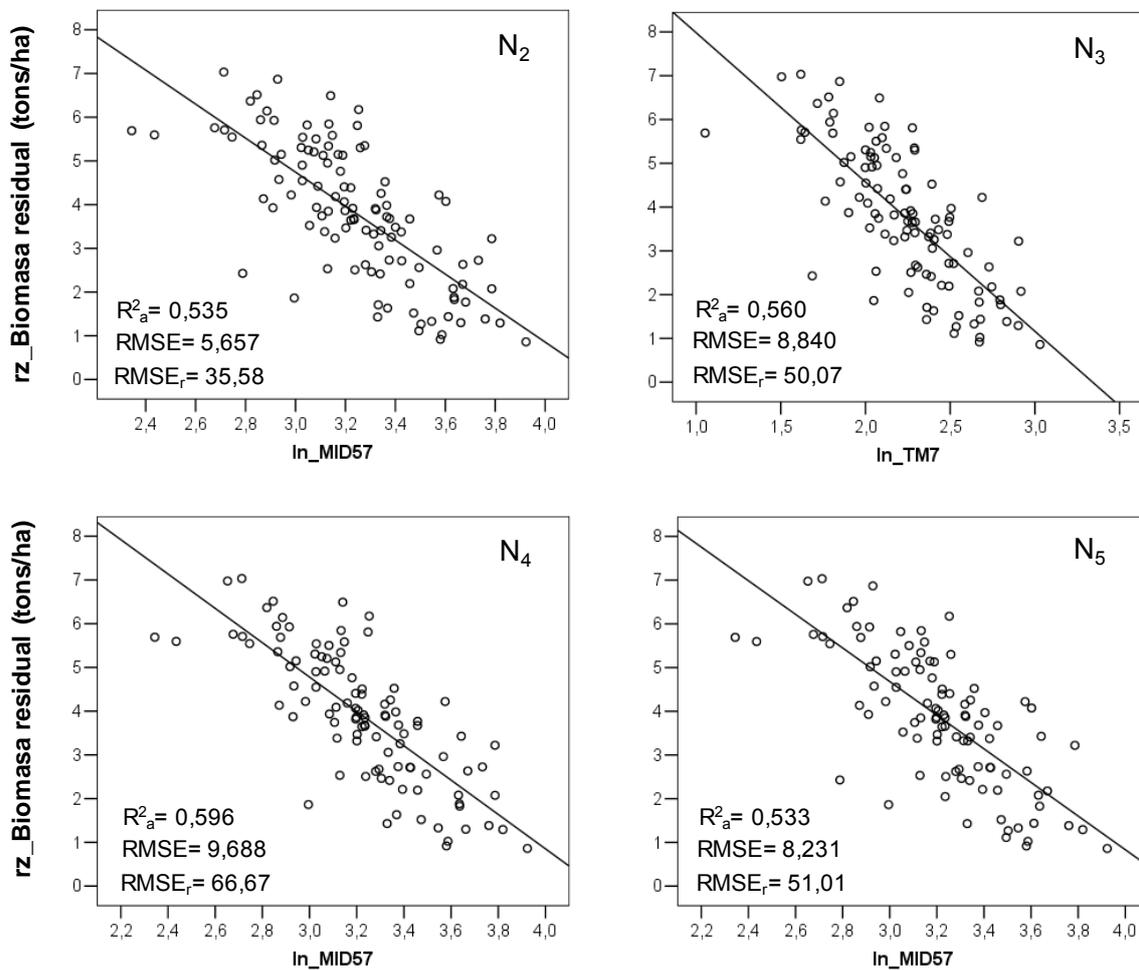


Figura 3.32. Gráficos de dispersión de modelos de regresión lineal univariantes de las Tablas 3.37 y 3.38

Dado que los modelos univariantes ajustados con la variable MID57 son los más repetidos, se elige uno de ellos para obtener la cartografía de estimación representativa de la metodología de análisis llevada a cabo en este subapartado. Para escoger entre ellos se volvió a seguir el criterio de seleccionar el que mejor equilibrio presentaba entre

su capacidad de predicción y el error de estimación obtenido con la muestra de validación. Como resultado, se seleccionó el modelo ajustado con la muestra N_2 , ya que éste, a pesar de no ser el que mejor R^2 tiene de los tres, presenta el error de estimación menor. La Figura 3.33 muestra el resultado de aplicar este modelo de regresión.

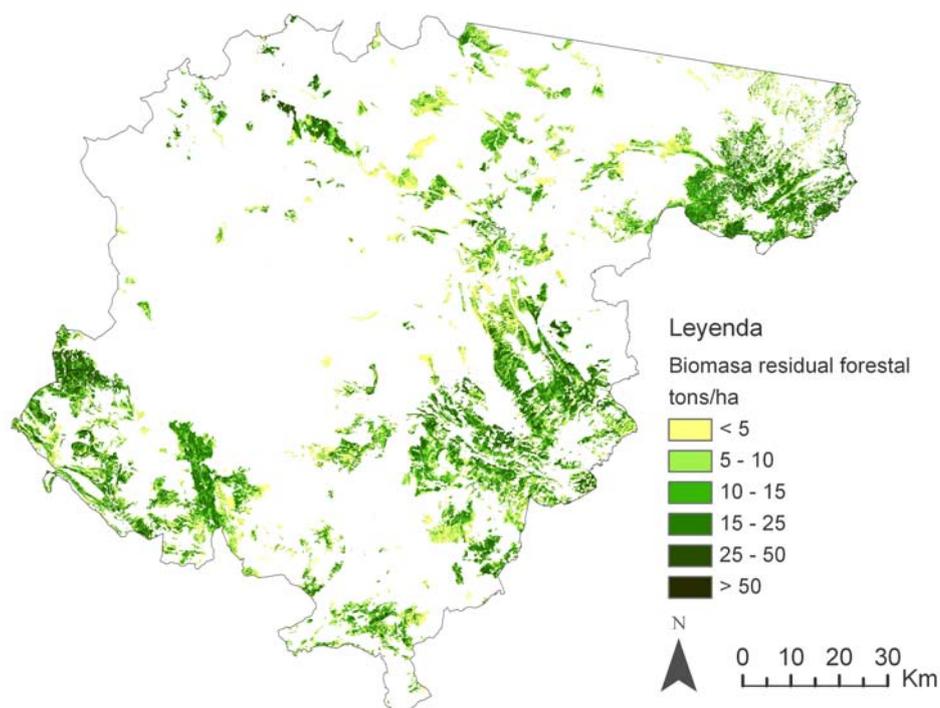


Figura 3.33. Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas incluidas en el grupo del percentil 6 derivadas de la utilización del método de extracción de segmentación (S4) y ventanas con restricciones

3.1.2.2.4. Conclusiones

Los resultados obtenidos en los apartados de análisis de correlación y de ajuste de modelos de regresión a partir de la información radiométrica obtenida mediante la utilización de áreas homogéneas forestales delimitadas a partir de técnicas de segmentación y de ventanas fijas de 3x3, con y sin restricciones, nos permiten derivar las siguientes conclusiones:

- I. **Aunque el algoritmo de aglomeración *RGB clustering* se mostró útil para segmentar la imagen en áreas radiométricas homogéneas, existen pocas diferencias entre los resultados obtenidos al utilizar -o no- esta información para restringir el número de píxeles vecinos a considerar en las ventanas fijas.**

Como se ha indicado con anterioridad, el uso de regiones espectralmente homogéneas en la extracción de la información es una forma eficiente de eliminar

algunos de los errores en el análisis de la imagen debidos a errores en su georreferenciación o en la localización de los puntos (Mäkelä y Pekkarinen, 2001). Sin embargo, al igual que en los trabajos de Mäkelä y Pekkarinen (2001) y Pekkarinen (2002), el uso de estas regiones no ha servido para mejorar significativamente las estimaciones del parámetro forestal estudiado.

Tal y como indican estos autores, uno de los motivos de esta escasa diferencia puede estar relacionado con el pequeño tamaño de las parcelas de campo, que hace que cualquier error en su localización introduzca errores que no pueden ser solventados mediante el uso de la segmentación, ya que un mínimo desplazamiento con respecto a la realidad hace que el píxel central de la ventana sea asignado a una región o a otra. Un segundo motivo puede ser que las segmentaciones acometidas no han sido exitosas a la hora de obtener áreas homogéneas en contenido de biomasa residual. Esta circunstancia puede estar relacionada con el hecho de que cuanto más pequeñas son las unidades forestales, la proporción relativa de píxeles mixtos aumenta, con lo que existe mayor probabilidad de confusión en el análisis de la imagen (Mäkelä y Pekkarinen, 2001). Por último, indicar que, posiblemente, la consideración de las 482 parcelas en lugar de únicamente las parcelas que se sitúan dentro de los grupos 7 y 6 definidos a partir del CV calculado con la ventana fija de 3x3, hubiera permitido encontrar más diferencias entre estos dos métodos de extracción, seguramente a favor del uso de regiones espectralmente homogéneas.

A pesar de lo anterior, las diferencias existentes entre los cuatro tipos de segmentaciones llevadas a cabo demuestran que existe una relación directa entre la estructura espacial de los bosques y la capacidad de estimar biomasa residual. Así, los mejores coeficientes de correlación se han obtenido cuando las áreas homogéneas delimitadas eran más grandes, lo que coincide con lo apuntado en el trabajo de Hyyppä y Hyyppä (2001) respecto de que cuanto mayor es el tamaño de la unidad de referencia, mejor es el resultado de la estimación.

Una posibilidad para mejorar los resultados hubiera sido el utilizar ventanas fijas más grandes para la extracción. Sin embargo, como se indicó al principio del apartado 3.1, la consideración de tamaños más grandes en un medio forestal mediterráneo tan heterogéneo hubiera incrementado el riesgo de asociar a la respuesta radiométrica de la parcela otras realidades espaciales distintas a las existentes en ella.

Por último, resaltar que el resultado más positivo de aplicar esta metodología de extracción es el haber identificado un grupo de parcelas con un tamaño muestral doble y coeficientes de correlación similares que el más numeroso de los delimitados con el CV en el apartado 3.1.1 sobre los que se ha obtenido cartografía de estimación (percentil 4-grupo clúster 3 y percentil 3-grupo clúster 4). De esta manera los modelos generados tienen menos probabilidad de estar sobre-ajustados y más posibilidades de ser representativos de todo el área de estudio. Al mismo tiempo, estos modelos ofrecen mayores garantías que los obtenidos a partir del uso de áreas homogéneas delimitadas visualmente, ya que los datos radiométricos pertenecen al interior de la parcela y de su vecindad más inmediata, utilizándose un número idéntico de parcelas. Este doble hecho justifica por sí solo todos los esfuerzos realizados en este subapartado.

II. Las variables radiométricas relacionadas con el contenido de humedad de la vegetación obtenidas de la imagen Landsat vuelven a confirmarse como las mejores a la hora de estimar la biomasa residual forestal.

Los análisis de correlación efectuados sobre los datos obtenidos mediante la utilización de áreas forestales homogéneas delimitadas a partir técnicas de segmentación y ventanas fijas con restricciones señalan nuevamente a las variables relacionadas de forma positiva o negativa con el contenido de agua de la vegetación como las más útiles en la estimación de la variable forestal aquí estudiada. Más concretamente, las variables TM5 y TM7 y, sobre todo, la variable MID57 se postulan como las mejores para obtener cartografía en el área de estudio, dado que muestran la mejor relación entre grado de explicación y error de predicción en los modelos de regresión.

III. Los modelos de regresión ajustados logran peores resultados que los obtenidos con el método de ventanas fijas y CV, pero mejores que los alcanzados con el método de las áreas homogéneas delimitadas visualmente.

Los modelos obtenidos con las variables relacionadas con el contenido de humedad en el análisis de regresión simple mediante la utilización de áreas forestales homogéneas delimitadas a partir técnicas de segmentación y ventanas fijas con restricciones (Figura 3.30) presentan una capacidad de predicción media aproximadamente un 30% más baja que los ajustados con esas mismas variables con el método de ventanas fijas y CV en el grupo del clúster 3 (Figura 3.12). Esta diferencia a favor de los últimos se mantiene cuando el error de predicción es el parámetro considerado, ya que, mientras en éstos la media del $RMSE_r$ se sitúa en torno al 40%, en los obtenidos usando las áreas homogéneas radiométricas esa media asciende al 44%. Sin embargo, si se comparan sólo los modelos obtenidos con la variable MID57, esta

diferencia entre los dos métodos se reduce, sobre todo en el error de estimación. Así, el $RMSE_r$ obtenido con el método de segmentación es, incluso, algo inferior al calculado con el método de ventanas fijas y CV (36,01% frente a 36,18 %).

En cuanto a la comparación con los obtenidos con el método de extracción de las áreas homogéneas visuales, los derivados de la utilización de la segmentación también presentan una peor capacidad explicativa, ya que los primeros manifiestan R^2 que oscilan, entre 0,6 y 0,7 y los segundos entre 0,5 y 0,6, a excepción de los ajustados con MSI (Figuras 3.23 y 3.30, respectivamente). Por el contrario, los $RMSE_r$ son siempre mejores en los modelos basados en la segmentación espectral independientemente de la variable relacionada con la humedad considerada, siendo esta diferencia mayor en la variable que ha servido para derivar la cartografía de estimación, MID57 (36,01% de $RMSE_r$ en el método de segmentación y 60,76% en el de áreas visuales).

Con respecto a las diferencias existentes considerando los modelos derivados del análisis de regresión lineal múltiple, apuntar en primer lugar que, al igual que en las otras dos metodologías de extracción de la información empleadas en este trabajo, tampoco se logra reducir con este método -basado en la segmentación espectral- el efecto de colinealidad entre las variables, que impide el ajuste de modelos multivariantes.

Comparando los modelos lineales obtenidos utilizando los datos extraídos a partir de la segmentación S4 con los derivados mediante el uso de las ventanas fijas y el CV en el clúster 3, estos segundos vuelven a ser mejores tanto en los coeficientes de determinación alcanzados como en los errores de predicción evaluados mediante el $RMSE$ y el $RMSE_r$. La menor diferencia se da entre los modelos empleados en cada uno de estos métodos para obtener la cartografía de estimación, ambos ajustados con la variable MID57 ($RMSE_r$ de 26,67% utilizando las ventanas fijas y el CV y de 35,58% usando la segmentación S4). En cambio, los modelos calculados en este apartado, aunque no superan los R^2 obtenidos en el apartado que utiliza las áreas homogéneas visuales, sí que presentan $RMSE_r$ inferiores a estos últimos. Así, en el caso de los modelos utilizados para derivar cartografía, la diferencia neta en este índice es de casi 24 puntos a favor del modelo finalmente utilizado en este apartado (35,58% de $RMSE_r$ frente al 59,48% en el modelo que utiliza las áreas forestales homogéneas visuales).

Por último, señalar que, a pesar de que los R^2 de los modelos derivados del análisis de regresión simple y múltiple no son muy altos, los $RMSE_r$ son netamente inferiores a los presentados en Mäkelä y Pekkarinen (2001) y Pekkarinen (2002), trabajos

que han inspirado el empleo en nuestra investigación de esta metodología basada en la segmentación. Este es un dato importante considerando que se trata de trabajos llevados a cabo en ambientes boreales donde *a priori*, como se ha señalado, la estimación de parámetros forestales mediante el uso de imágenes de satélite da mejores resultados. Además, dado que el $RMSE_r$ obtenido con este método de segmentación con la variable MID57 es mejor que el derivado del uso de áreas homogéneas con esta misma variable, es preciso resaltar que también es mejor que los obtenidos en el conjunto de trabajos citados anteriormente en las conclusiones de este método de extracción. En cuanto al tercer trabajo que ha estimulado nuestro empleo de las segmentaciones, el de Hall *et al.* (2006), debe señalarse que la comparación no es posible, ya que dicha investigación utiliza la segmentación para estimar variables dimensionales del árbol, no variables de volumen total.

En resumen, aunque el método combinado de extracción de la información basado en el uso de técnicas de segmentación sobre la imagen Landsat y de ventanas fijas con restricciones no ha logrado mejorar el grado de correlación entre la biomasa residual forestal y las variables radiométricas en comparación con el uso de ventanas fijas simples del mismo tamaño, sí ha permitido individualizar un grupo de parcelas más numeroso que con la metodología de ventanas fijas y CV del apartado 3.1.1, idéntico al basado en el uso de áreas homogéneas forestales visuales del apartado 3.1.2.1, manteniendo coeficientes de correlación similares. Esta circunstancia permite afirmar que los modelos de regresión ajustados con este método están menos sobre-ajustados a la muestra que los del apartado 3.1.1, por lo que son a su vez más representativos del área de estudio, mientras que estas características se mantienen con respecto a los ajustados en el apartado 3.1.2.1. La principal ventaja de los modelos ajustados en este apartado con respecto a los de este último es que los $RMSE_r$ obtenidos son bastante inferiores, seguramente debido al hecho de que, en esta ocasión, existe más probabilidad de que los datos radiométricos extraídos correspondan realmente a la cantidades de biomasa residual de las parcela del IFN-2, ya que solamente se han considerado los píxeles situados en su interior y los de su inmediata vecindad.

3.1.3. Validación de las cartografías de estimación de biomasa residual forestal

La validación de los modelos que han servido para obtener cartografías de estimación de la cantidad exacta de biomasa residual forestal mediante el 20% de las muestras con las que han sido calculados señala que los obtenidos mediante el método

de ventanas fijas y el CV son los más adecuados en términos de capacidad de predicción y de error, aunque, debido al escaso número de parcelas, estos resultados pueden ser engañosos y poco representativos de la realidad. Esta última cuestión queda resuelta mediante la utilización de áreas homogéneas forestales delimitadas visualmente o mediante el uso de técnicas de segmentación y ventanas fijas con restricciones, ya que con ambas metodologías de extracción se logra ajustar modelos más representativos a escala provincial, pero a costa de disminuir la capacidad de predicción y de incrementar el error de estimación. El problema de la disminución de la capacidad predictiva afecta principalmente a los modelos obtenidos a partir del uso de técnicas de segmentación, mientras que el aumento del error es más claro en los modelos ajustados a partir del uso de áreas forestales homogéneas delimitadas mediante fotointerpretación.

Todas las regresiones calculadas utilizadas para derivar cartografía se han basado en el uso de un conjunto de parcelas más o menos reducido con respecto a la muestra inicial, que, en principio, compartían la característica común de estar libres de posibles fuentes de error que dificultan el establecimiento de modelos biofísicos representativos y precisos, tales como errores de localización, consideración de otras cubiertas de vegetación, etc. Estas mismas parcelas “ideales” también han sido la fuente utilizada para medir el acierto de estos modelos y compararlos.

Sin embargo, dado que para obtener las diferentes cartografías de estimación de la variable estudiada todos estos modelos, independientemente de la técnica de extracción de la información utilizada, han sido aplicados a cada uno de los píxeles de la imagen Landsat clasificados como bosque de pináceas según el MFA, el grado de acierto de cada uno de ellos tiene que ser evaluado también a esta escala. Se trata pues de obtener una medida real del grado de precisión de cada una de las cartografías obtenidas.

El resultado de esta validación es el que permite finalmente decidir cuál de los modelos es más adecuado para la realidad del área de estudio, siendo la cartografía con menor error de estimación la seleccionada para inventariar la existencia de este recurso energético en el territorio estudiado.

Sin duda, la forma ideal de validar estas cartografías es la realización de trabajo de campo siguiendo las siguientes fases: (i) localización en las cartografías de estimación de píxeles representativos de todo el rango de biomasa residual presente en el área de estudio, proporcional a la superficie ocupada por cada una de las cuatro especies y

procurando una distribución homogénea en todo el territorio; (ii) delimitación en el campo de la superficie de esos píxeles mediante el uso de fotografías aéreas de alta resolución y sistemas GPS; (iii_a) apeo de los pies presentes en la superficie delimitada y pesado de la biomasa residual en húmedo, cogiendo muestras de acículas y ramas para su posterior secado y empleo en el cálculo de la biomasa en seco, ó (iii_b) medición del *dbh* y la altura de los pies presentes para estimar la biomasa residual mediante el uso de las regresiones de estimación por especie utilizadas en este trabajo. Sin embargo, la imposibilidad de obtener permisos por parte de la Administración forestal para llevar a cabo la tarea (iii_a) y el elevado coste en tiempo y, sobre todo, en dinero de la tarea (iii_b) hizo desistir del empleo de esta metodología para validar las cartografías.

Ante estas restricciones, una alternativa más factible e igualmente válida desde el punto de vista estadístico es la utilización de las parcelas del IFN-2 sobre las que se tiene información de biomasa residual que no han sido utilizadas para el cálculo del modelo que da lugar a la cartografía. Esta alternativa hace que se respeten los criterios de contar con una muestra de validación numerosa, representativa de la superficie ocupada por cada una de las cuatro especies consideradas y distribuida por toda el área de estudio. Así, por ejemplo, las cartografías obtenidas con la utilización del 80% de las parcelas integrantes del grupo denominado como clúster 3 en el apartado 3.1.1 pueden ser validadas potencialmente con un total de 430 parcelas⁴⁴. No obstante, el hecho de que la estimación de los modelos sólo se ha aplicado sobre los píxeles identificados como forestales en el MFA, dada la circunstancia de la no coincidencia de este documento con el IFN-2 ya mencionada, implica que el número final de parcelas útiles para la validación sea algo menor que el total de las no utilizadas en el ajuste de los modelos.

Dado el tamaño variable de las parcelas del IFN-2 (de 5 a 25 m de radio según el *dbh* de los pies situados en su interior, Tabla 2.5), existen dos posibilidades a la hora de validar las cartografías: (i) considerar sólo el valor de biomasa del píxel central de la parcela, (ii) considerar el valor resultante de la media de los píxeles contenidos total o parcialmente en esa parcela. Para dilucidar cuál de estas opciones es más adecuada no queda otra alternativa que calcular el error en cada cartografía con estos dos métodos. A este respecto, la Figura 3.34 muestra los resultados obtenidos en las 8 cartografías de estimación de la biomasa residual obtenidas a lo largo de esta investigación con la nueva

⁴⁴ Resultado de restar a las 482 parcelas que componen la muestra total las 52 que se emplean, aproximadamente, en los modelos ajustados con el grupo de parcelas del clúster 3.

denominación dada en la Tabla 3.39, utilizando para ello el máximo de parcelas disponibles para la validación en cada una de ellas.

Cartografía	Metodología de extracción de información	Tipo de modelo	Apartado	Nº de figura
Cartografía 1	Ventana 3x3 y CV (clúster 3)	Curvilínea	3.1.1.3.2	3.13
Cartografía 2	Ventana 3x3 y CV (clúster 4)	Curvilínea	3.1.1.3.2	3.15
Cartografía 3	Ventana 3x3 y CV (clúster 3)	Lineal	3.1.1.3.3	3.18
Cartografía 4	Ventana 3x3 y CV (clúster 4)	Lineal	3.1.1.3.3	3.20
Cartografía 5	Áreas homogéneas	Curvilínea	3.1.2.1.3	3.24
Cartografía 6	Áreas homogéneas	Lineal	3.1.2.1.3	3.27
Cartografía 7	Segmentación y ventana 3x3	Curvilínea	3.1.2.2.3	3.31
Cartografía 8	Segmentación y ventana 3x3	Lineal	3.1.2.2.3	3.33

Tabla 3.39. Cartografías de estimación de biomasa residual forestal obtenidas en los apartados 3.1.1 y 3.1.2. según el método de extracción de la información, el tipo de modelo utilizado, apartado donde aparecen y número de figura.

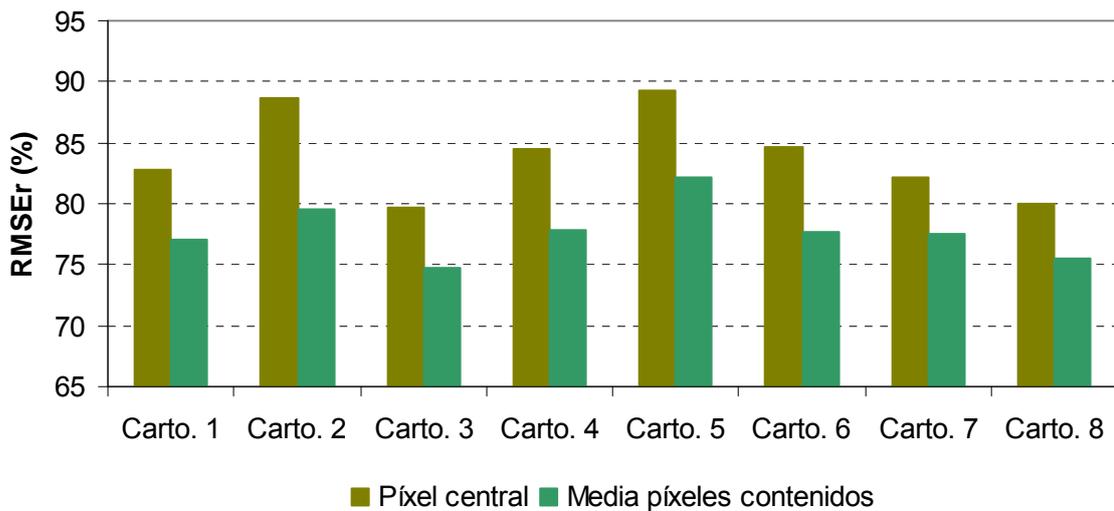


Figura 3.34. $RMSE_r$ de cada una de las cartografías de estimación obtenidas en los apartados 3.1.1 y 3.1.2 con el máximo de parcelas disponibles en cada una de ellas para la validación

Como se observa en la Figura 3.34, los $RMSE_r$ obtenidos en todas las cartografías utilizando la biomasa residual resultante de la media de los píxeles contenidos en cada parcela son netamente mejores que si solamente se considera la del píxel central, situándose el promedio de esta mejora por encima del 7,35%. El motivo de este hecho cabe achacarlo a que los modelos de regresión utilizados para la obtención de las cartografías, con independencia del método de extracción empleado, utilizan siempre datos provenientes de un promedio de píxeles constituido por el píxel central y un

conjunto de píxeles situados en su vecindad. Además, otro factor influyente puede ser que, como se ha señalado en varias ocasiones, la utilización de varios píxeles reduce la comisión de errores de localización, por lo que aumenta la probabilidad de correspondencia real entre lo predicho en la parcela del IFN-2 y lo estimado en la cartografía.

Centrándonos en esta última cuestión, dado que la utilización de los promedios de píxeles contenidos en la parcela parece más acertada, también parece conveniente examinar la incidencia que en la validación tiene el considerar todas las parcelas disponibles en cada cartografía, incluyendo aquéllas que pueden no ser óptimas para este propósito, debido a errores en la localización o por estar situadas en ambientes muy heterogéneos, o un grupo algo menor que ofrezca mayores garantías de calidad.

En efecto, como hemos visto anteriormente, algunas de las parcelas del IFN-2 consideradas se caracterizaban por estar situadas en zonas de borde entre distintos tipos de cubiertas o en ambientes altamente heterogéneos, por lo que la información radiométrica que contenían era debida no sólo a los árboles inventariados, sino que también podía estar relacionada con la presencia de otros elementos. Si se utilizan estas parcelas en la validación para calcular el promedio de biomasa residual en la parcela se considerará también el valor de estos píxeles erróneos, con lo que el error de estimación aumentará. Además, como se ha mostrado mediante el uso de fotografía aérea de alta resolución en el apartado 3.1.1 para el análisis de casos atípicos, algunas de las parcelas presentan errores de localización muy graves, no existiendo correspondencia entre lo descrito en el IFN-2 y lo observado en las ortofotografías.

Para evaluar esta circunstancia se utiliza la información de homogeneidad radiométrica proporcionada por el CV en el apartado 3.1.1. Así, se procede a validar las cartografías mediante la inclusión de todas las parcelas disponibles (entre 312 y 395, dependiendo del número utilizado para el ajuste del modelo de regresión de cada cartografía) y usando las parcelas que, considerando el CV de su entorno radiométrico, habían quedado englobadas en los grupos de los percentiles 9 y 8 (entre 225 y 308 y entre 140 y 222, respectivamente), eliminándose así las parcelas con mayor probabilidad de presentar problemas de localización o de estar situadas en zonas de borde, pero conservándose un número alto para garantizar que los resultados de la validación no están sesgados por la utilización solamente de parcelas “ideales”. Finalmente, las 5 parcelas del grupo del percentil 8 que mayor diferencia presentan entre el valor real y el

valor estimado en todas las cartografías son analizadas mediante el uso de fotografía de alta resolución para ver si se trata parcelas atípicas en las que no existe correspondencia entre las dos fuentes de información. Si esto se confirma de forma clara e inequívoca se eliminan estas parcelas y se vuelve a repetir la estimación con el resto de parcelas del percentil 8.

La Figura 3.35 muestra los resultados de este análisis. Como en ella se observa, el error de estimación es menor en todas y cada una de las cartografías obtenidas cuando las parcelas utilizadas para ello tienen menos posibilidades de presentar errores de localización o de estar situadas en zonas limítrofes de distintas cubiertas del suelo. Sin embargo, el grado de disminución del error no es constante en los distintos escenarios planteados. Así, la mayor reducción se da cuando se utilizan las parcelas del percentil 9 en lugar de todas las parcelas disponibles en cada cartografía, produciéndose una mejora promedio relativa del 8,25%. En cambio, la menor mejora se da en el paso siguiente, cuando se utilizan las parcelas clasificadas dentro del percentil 8, ya que, en este caso, la mejora promedio con respecto a la utilización de las del percentil 9 no llega al 1% (0,67%). Estos datos muestran la incidencia que en la validación tiene la utilización de parcelas afectadas por los errores comentados con anterioridad, fácilmente detectables a partir del uso del CV, dado que una vez que son eliminadas, el error de estimación permanece constante. De esta manera, es importante desechar el uso de estas parcelas, dado que lejos de ofrecer una medida acertada del error, lo que hacen es distorsionar la realidad e incrementarlo.

La segunda reducción más importante se da cuando en la muestra del percentil 8 se eliminan 3 parcelas de las 5 que mayores residuales presentan, al no coincidir los datos proporcionados por el IFN-2 con lo observado en las fotografías aéreas. Esta disintonía, que afecta concretamente a las parcelas 38, 508 y 1135, es semejante a la ya encontrada en el apartado 3.1.1.3.2 cuando las parcelas pertenecientes al grupo denominado como clúster 3 (percentil 4) fueron analizadas una por una (Figuras 3.10 y 3.11). En este caso, en la parcela 38, lo observado en la fotografía permite intuir con cierta claridad que la cantidad de biomasa residual es mayor que la obtenida en esta parcela del IFN-2 mediante el uso de las ecuaciones de estimación, mientras que en las parcelas 508 y 1135 esta cantidad es manifiestamente menor. La mejora del error promedio al retirar estas tres parcelas de la muestra de validación es del 4,58%, siendo las diferencias mínimas entre las ocho cartografías.

Un último aspecto a señalar con respecto a esta última situación de reducción significativa del error es que, casi con total certeza, el análisis individualizado mediante fotografía aérea del resto de parcelas que forman el grupo del percentil 8 hubiera hecho que más parcelas fueran eliminadas de la muestra de validación, al repetirse situaciones de no concordancia entre la fotografía y el IFN-2, semejantes a las de las parcelas retiradas en este y en el apartado 3.1.1.3.2. Sin embargo, la posición conservadora adoptada a lo largo de todo este trabajo hizo que se desistiera de este análisis pormenorizado. De esta manera, se conservan en la muestra posibles errores que, en mayor o menor grado, casi siempre están presentes en muestras empleadas para la validación en trabajos análogos a este.

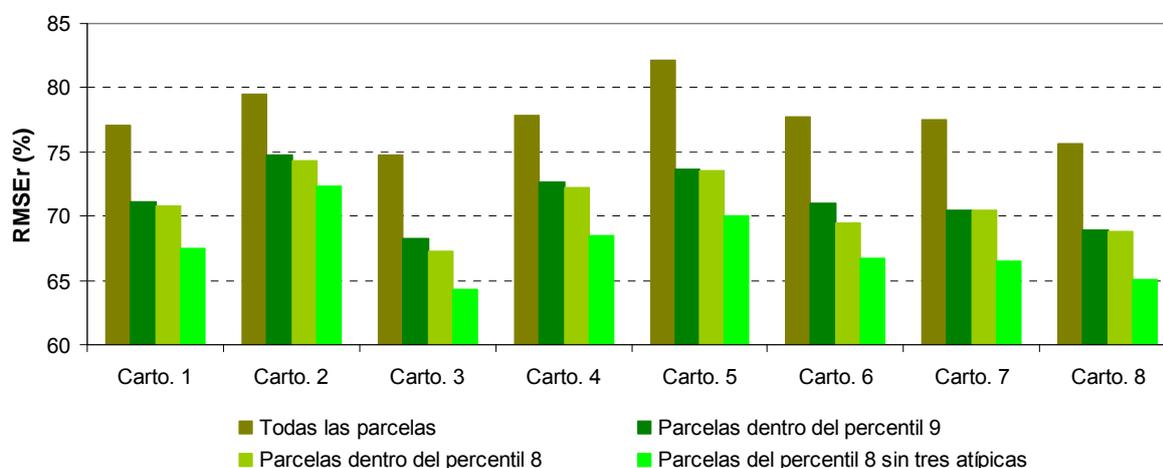


Figura 3.35. $RMSE_r$ de cada una de las cartografías de estimación obtenidas en los apartados 3.1.1 y 3.1.2 con todas las parcelas disponibles en cada una de ellas para la validación, las incluidas en el grupo del percentil 9, las incluidas en el percentil 8 y las que quedan en este grupo tras eliminar 3 parcelas con comportamiento atípico

Finalmente, para comparar el grado de precisión de las cartografías de estimación obtenidas en este trabajo mediante la utilización de tres métodos distintos de extracción de la información y dos de regresión, se utilizan los datos de error obtenidos mediante la muestra de parcelas incluidas en el percentil 8 sin las tres detectadas como atípicas. La Tabla 3.40 muestra estos datos, así como el número de parcelas empleado en cada una de las cartografías para obtenerlos.

La primera conclusión que se deriva de analizar los $RMSE_r$ obtenidos es que, independientemente del método de extracción de la información utilizado y de la variable radiométrica finalmente utilizada, los modelos de regresión lineal dan lugar a cartografías de estimación de la biomasa residual forestal ligeramente más precisas que los modelos

de regresión curvilíneos. Esta circunstancia puede estar relacionada con que este tipo de modelos, al emplear variables linealizadas mediante transformaciones, son levemente menos sensibles a la saturación de las variables radiométricas utilizadas que se observa a partir de las 40 tons/ha. Sin embargo, el análisis de los residuales obtenidos con estos dos tipos de regresión en las parcelas de validación situadas por encima de esta cantidad, que son siempre negativos debido a la saturación, no confirmó esta circunstancia, al ser levemente más bajos en términos absolutos los alcanzados con los modelos de regresión curvilínea. Así pues, el menor error relativo obtenido con los modelos lineales se debe a que éstos realizan una mejor estimación a lo largo de todo el recorrido de la variable en general.

Cartografía	Nº de parcelas⁴⁵	RMSE (tons/ha)	RMSE_r (%)
Cartografía 1	196	10,575	67,47
Cartografía 2	219	11,316	72,36
Cartografía 3	194	10,276	64,26
Cartografía 4	215	10,790	68,52
Cartografía 5	171	9,668	70,05
Cartografía 6	182	9,417	66,71
Cartografía 7	138	10,017	66,52
Cartografía 8	137	9,872	65,06

Tabla 3.40. Número de parcelas utilizado para la validación de las 8 cartografías obtenidas en los apartados 3.1.1 y 3.1.2 y error de estimación obtenido

Centrándonos en la comparación entre las metodologías de extracción utilizadas, destacar en primer lugar que los errores obtenidos son similares en todas ellas, situándose los absolutos en una horquilla entre las 9,668 y las 11,316 tons/ha y los relativos -los utilizados para comparar- entre el 64,26% y el 72,36%.

Los errores relativos más altos con los dos métodos de regresión se obtienen con el método de ventanas fijas y el CV cuando solamente se consideran las parcelas incluidas en grupo del clúster 4 (percentil 3). Recordamos aquí que este grupo estaba compuesto solamente por 35 parcelas (7,26% de la muestra total), circunstancia ésta que ha hecho que, tal y como se intuía, a pesar de los buenos coeficientes de determinación

⁴⁵ La ligera variación que se produce en el número de parcelas empleadas en la validación entre cartografías que han utilizado el mismo grupo de parcelas, pero diferente método de regresión, se debe a la metodología empleada de ajustar cinco modelos de regresión a partir de cinco muestras distintas de aproximadamente el 80% de las parcelas consideradas.

R^2 y R^2_a alcanzados por los modelos ajustados, éstos son poco representativos para todo el área de estudio.

Seguidamente, considerando de forma separada los modelos de regresión lineal y curvilínea, los $RMSE$ más altos se dan en las cartografías obtenidas a partir de los datos extraídos con las áreas homogéneas delimitadas visualmente sobre las fotografías aéreas de alta resolución. Los valores que se alcanzan con este índice son sólo ligeramente superiores a los que se obtenían cuando se utilizaba el 20% de la muestra de las 131 áreas obtenidas de esta manera, por lo que una vez más se confirma la utilidad de la fotointerpretación como técnica útil para la delimitación de áreas homogéneas forestales susceptibles de ser utilizadas para ajustar modelos de estimación de variables forestales. Sin embargo, el hecho de que las unidades delimitadas no sean exactamente iguales -en contenido de biomasa forestal- que la parcela del IFN-2 que queda en su interior puede ser el motivo por el que no se alcanzan valores más bajos.

Así, los errores relativos más bajos, tanto en los modelos lineales como en los no lineales, se dan en las cartografías obtenidas a partir del método de ventanas fijas y el CV cuando se utilizan las parcelas incluidas en grupo del clúster 3 (percentil 4) y con el método que utiliza la segmentación S4 y ventanas fijas con restricciones basadas en esa segmentación. La diferencia entre el $RMSE_r$ de la validación de las cartografías obtenidas con estos dos métodos de extracción -utilizando la variable MID57 en los dos tipos de regresión- apenas se sitúa en un 1,40% a favor del método que usa la segmentación en el caso de la regresión curvilínea y en un 1,23% a favor del que usa ventanas fijas y el CV en el caso de la regresión lineal.

Esta leve diferencia entre los dos métodos ha sido observada también en las diferentes validaciones efectuadas en este apartado considerando sólo el valor de biomasa del píxel central de la parcela o usando los píxeles contenidos total o parcialmente en esa parcela (Figura 3.34) e independientemente del número de parcelas consideradas (Figura 3.35). Semejanza que indica que las ecuaciones obtenidas en ambos representan una misma relación biofísica entre la biomasa residual forestal y la variable MID57; esta afirmación es corroborada por la similitud de los coeficientes de regresión entre las ecuaciones exponenciales y las lineales obtenidas en los dos métodos (Tabla 3.41).

Cartografía	Metodología extracción	Tipo de modelo	β_0	β_1
Cartografía 1	Ventana 3x3 y CV (clúster 3)	Curvilínea	208,014	-0,107
Cartografía 7	Segmentación y ventana 3x3	Curvilínea	144,856	-0,094
Cartografía 3	Ventana 3x3 y CV (clúster 3)	Lineal	18,879	-4,663
Cartografía 8	Segmentación y ventana 3x3	Lineal	16,409	-3,888

Tabla 3.41 Comparación de los coeficientes de regresión de las ecuaciones que han servido para obtener las cartografías de estimación 1, 3, 7 y 8

Se puede afirmar que ambos métodos parecen igual de adecuados para cartografiar la biomasa residual forestal del área de estudio si solamente se utiliza el criterio del error de estimación, presentándose las cartografías basadas en los modelos lineales como algo mejores. Por consiguiente, parece oportuno incorporar otros criterios -además del error- a la hora de seleccionar finalmente la cartografía obtenida por este método de regresión, a partir de la cual se va a inventariar este recurso energético en el territorio estudiado. Estos criterios son la capacidad de predicción y la representatividad para el área de estudio:

- Teniendo en cuenta el primero, la capacidad de predicción, la decisión a favor del método de extracción de las ventanas de 3x3 píxeles y CV es clara, ya que presenta unos coeficientes de determinación, tanto en el modelo no lineal como en el lineal, muy superiores a los alcanzados con el método que utiliza la segmentación (0,767-0,711 frente a 0,543-0,535, respectivamente).
- Atendiendo al segundo, su representatividad en el área de estudio, la similitud de los resultados obtenidos en las todas validaciones efectuadas en este apartado manifiesta que el reducido conjunto de parcelas utilizado en el método de las ventanas fijas y CV es tan representativo de la variable dependiente en el territorio estudiado como el utilizado con el método que emplea la segmentación, a pesar de que este último esté compuesto por el doble de individuos. En conclusión, los modelos que dan lugar a las cartografías 1 y 3 no están tan sobre-ajustados a la muestra como en principio se esperaba por el escaso número de parcelas empleado, ya que dan lugar a errores de precisión similares a otros métodos que utilizan muchas más.

De esta manera, demostrada la representatividad que el pequeño grupo de parcelas del clúster 3 tiene con respecto a la muestra total, se elige finalmente la metodología de extracción de las ventanas de 3x3 píxeles y CV del apartado 3.1.1 para inventariar la existencia de biomasa residual forestal en la provincia de Teruel, siempre que este método se muestre como extrapolable en el tiempo. Este último aspecto se verifica en el Capítulo 4.

3.2. Modelos de estimación a partir del coeficiente de retrodispersión de las imágenes ASAR

Concluido el proceso de generación de modelos estimativos de biomasa residual forestal a partir de las imágenes Landsat, con apoyo de informaciones auxiliares topográficas y forestales, se aborda en este apartado -con un carácter exploratorio preliminar, acorde con los objetivos de la investigación- la utilización de imágenes SAR en banda C del sensor ASAR.

Dada la accidentada topografía de la provincia de Teruel, la no aplicación del proceso de normalización topográfica –véase apartado 2.4- a las imágenes ASAR implicaba, ya de partida, la imposibilidad de obtener un modelo de estimación válido para todo el área de estudio y extrapolable a otras zonas; la ausencia de datos de campo sincrónicos a la captura de las imágenes constituía otro factor restrictivo. Aún así, conscientes de la imposibilidad de generar un modelo concluyente, se valoró -optando finalmente por hacerlo- el interés de estimar la sensibilidad del sensor ASAR con la fracción de biomasa considerada en esta investigación, dado que la gran mayoría de las experiencias previas para la estimación de biomasa llevadas a cabo con imágenes SAR en banda C se han centrado en la estimación de *AGB*, aun conociéndose que esta banda sólo es sensible al follaje y ramas de los árboles, lo que produce la temprana saturación del coeficiente de retrodispersión en comparación con el uso de otras bandas como L y P (Le Toan, 1992; Quegan et al., 2000).

Con tal fin, la estrategia diseñada de acuerdo con la Dra. Le Toan -CESBIO, Toulouse- fue la siguiente: (1) aplicación de un conjunto de medidas para paliar la no aplicación de la normalización topográfica y (2) análisis exploratorio de la relación entre el coeficiente de retrodispersión y la cantidad de biomasa residual. Dos etapas que se corresponden con los dos siguientes apartados.

3.2.1. Minimización del efecto de la topografía en las imágenes ASAR para el estudio de la relación entre el coeficiente de retrodispersión y la biomasa residual forestal

Con objeto de maximizar las posibilidades de valorar correctamente la relación entre el coeficiente de retrodispersión y la biomasa residual forestal, se procedió a la identificación del territorio abarcado por el mayor número posible de imágenes ASAR que contuviera un número de parcelas suficiente para representar adecuadamente todo el rango de la biomasa residual presente en el área de estudio. Se perseguía con ello que la

relación entre las dos variables no dependiera de la selección de parcelas que mejor se adecuara a la geometría observada en cada imagen, ya que ésta, además de por la consideración de distintos ángulos locales, también puede estar controlada por la variación del contenido de humedad de la muestra (variación de la constante dieléctrica). En este último sentido, la utilización de un único grupo de parcelas y una única imagen hubiera sido una medida suficiente, pero a costa de no tener en consideración la influencia que distintos ángulos de observación local pueden tener en esta relación. Así, la única solución es la consideración de un único grupo de parcelas próximas, de la misma especie y con características orográficas semejantes para su análisis mediante imágenes que incluyan diferentes ángulos de incidencia locales, haciendo posible, por tanto, observar si la magnitud de la relación se mantiene al hacerlo las características de observación de la imagen.

Como se observa en las Figuras 2.23 y 2.25, la zona suroeste es el único sector de la provincia de Teruel que aparece recogido en todas imágenes ASAR disponibles. Dentro de este sector, ocupado por la Sierra de Albarracín, se delimitaron tres subsectores en relación con el número de imágenes disponibles de órbita ascendente o descendente (Figuras 3.36 y 3.37). Se tomó esta condición de referencia porque la mayoría de las parcelas de esta zona se encuentran en laderas de diferente exposición, lo que hace que queden -o no- en zonas de sombra radar según sea el sentido de la pasada, situación ésta que puede invalidarlas para el análisis. El número de imágenes con el que se contaba para cada uno de estos de estos subsectores, el número de parcelas contenidas en cada uno de ellos y algunas de sus características se resume en la Tabla 3.42.

Sector	Nº escenas	Sentido de la órbita	Nº parcelas	Especies presentes	Parcelas por orientación	Pendiente (grados)	Biomasa residual (tons/ha)
1	5	Ascendente	11	<i>P.sylvestris</i>	N: 1 E: 2 S: 3 O:5 Llano: 0	5-18	2,24-48,68
2	3	Ascendente	5	<i>P.sylvestris</i> <i>P. nigra</i>	N: 3 E: 1 S: 1 O: 0 Llano: 0	5-25	23,80-44,50
3	3	Descendente	26	<i>P.sylvestris</i> <i>P. nigra</i> <i>P. pinaster</i>	N: 8 E: 5 S: 4 O:5 Llano: 4	0-29	2,78-46,46

Tabla 3.42. Características de las imágenes y las parcelas contenidas en los tres subsectores

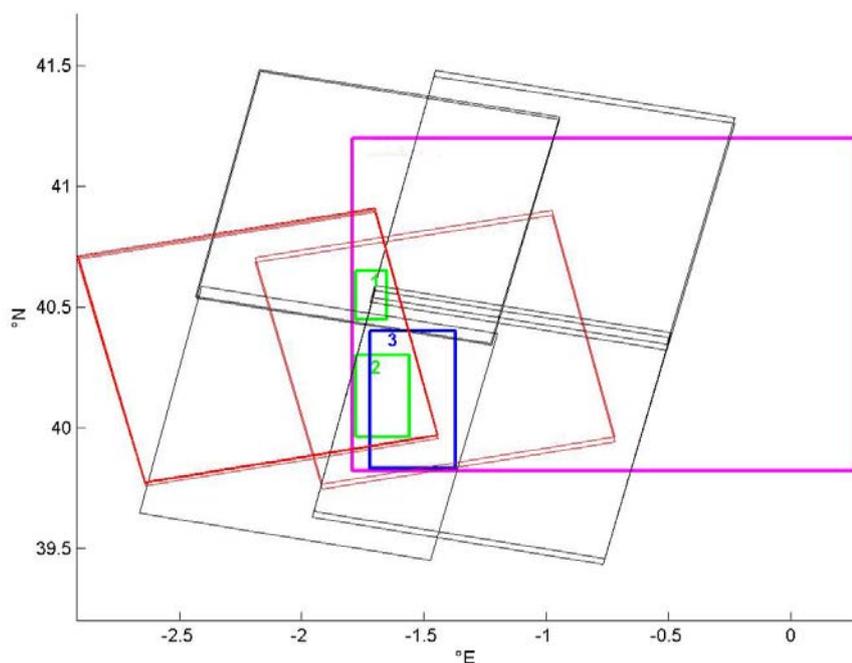


Figura 3.36. Localización de tres subsectores en el área de estudio (delimitada en rosa) que maximizan el número de imágenes ASAR de órbita ascendente (en rojo) y descendente (en negro). En verde los subsectores que tienen en cuenta las imágenes ascendentes; en azul el que considera las descendentes

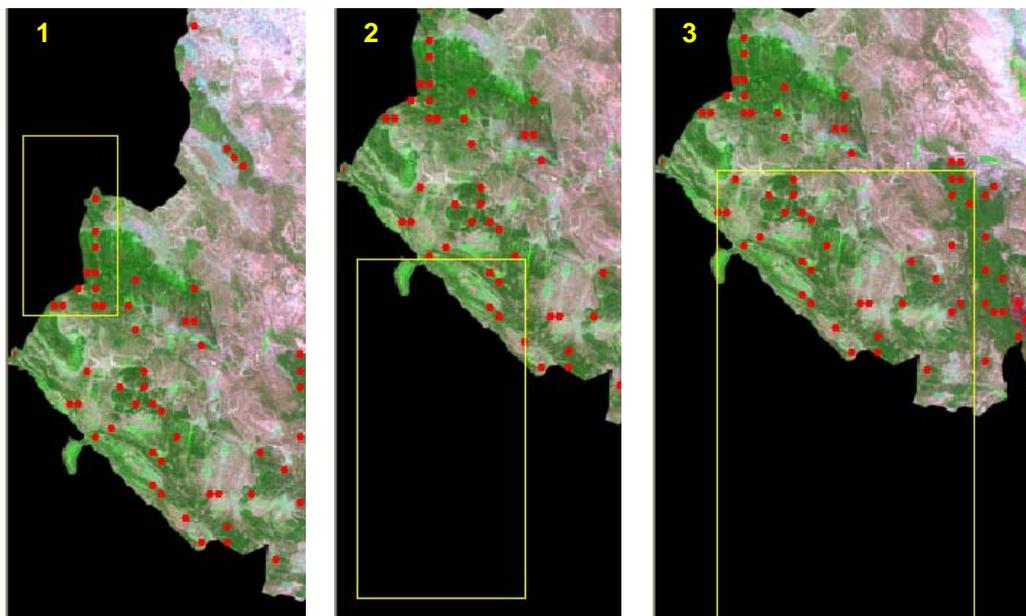


Figura 3.37. Detalle de los tres subsectores (delimitados en amarillo) sobre la imagen Landsat TM de junio de 1994 y localización de las parcelas del IFN-2 (puntos rojos)

La selección de uno u otro sector estuvo condicionada tanto por el número de escenas disponibles como por el número y las características de las parcelas. Así, el primero en descartarse fue el sector 2, ya que el sector 1 contaba con un mayor número de escenas para el mismo tipo de pasada (ascendente) y casi con el doble de parcelas

(11 frente a 5). La elección entre los sectores 1 y 3 resultó más difícil, ya el primero era el que permitía contar con un mayor número de imágenes (el doble), mientras que en el sector 3 contenía muchas más parcelas. Sin embargo, la mayor homogeneidad de las parcelas del sector 1 en términos de especie representada (sólo un tipo de pino frente a tres del sector 3) y de las características topográficas del terreno comprendido (menor rango de pendiente y mayor proporción de parcelas orientadas hacia el haz radar), hizo que este subsector fuera el finalmente seleccionado. Este sector 1 permite descartar –en mayor medida que el 3– que la relación entre biomasa residual y coeficiente de retrodispersión se deba a motivos diferentes que la variación de la cantidad, además, el rango de variación de la biomasa en el sector 1 es ligeramente mayor que en el 3, lo que permitirá indagar más adecuadamente si existe tendencia a la saturación de la señal radar con cantidades altas de biomasa residual.

Una vez determinado el conjunto de imágenes y parcelas a utilizar en los análisis de correlación y regresión, la siguiente medida para eliminar el efecto de la topografía se relaciona con el procedimiento utilizado para extraer la información radiométrica de estas parcelas. Tal y como indican Henderson y Lewis (1998), la presencia en mayor o menor grado, en todas las imágenes radar del *speckle* explica que la información de retrodispersión no pueda ser utilizada para ser relacionada con la verdad terreno de una variable a nivel de píxel. Así, la existencia de esta interferencia coherente hace que sea necesario utilizar siempre un área homogénea de la variable estudiada para extraer la información de la imagen. En este contexto, las áreas homogéneas forestales creadas en el apartado 3.1.2.1 para extraer la información radiométrica de la escena Landsat parecen también adecuadas para hacer lo propio sobre las 5 imágenes ASAR.

Sin embargo, debido a la ausencia de normalización topográfica, las áreas homogéneas delimitadas para las 11 parcelas debieron ser analizadas para ver si el área comprendida en el interior de cada una de ellas era también homogénea en términos topográficos, ya que la presencia de diferentes orientaciones y/o pendientes en una misma parcela hace que el coeficiente de retrodispersión varíe dentro de ella, independientemente de que la estructura del bosque sea la misma y de que la cantidad de biomasa permanezca constante.

Para comprobar la homogeneidad orográfica de las 11 parcelas seleccionadas se utilizaron los mapas de orientaciones y pendientes generados en el Capítulo 2 a partir del MDE. Estas capas se visualizaron en ArcGIS-ArcINFO junto a la vectorial de las áreas

forestales homogéneas y a las fotografías de alta resolución que habían servido para definir las. Con toda esta información y mediante la utilización de las herramientas de edición, se procedió a ajustar los límites de las áreas forestales para que todo el espacio quedara dentro de una misma orientación y dentro de un rango reducido de pendiente, conservándose el criterio de homogeneidad espacial con el que se habían delimitado previamente. El resultado fueron unas parcelas de menor extensión que las anteriores, pero con un mayor grado de homogeneidad. La Figura 3.38 muestra la situación anterior y posterior de este proceso de adaptación de los límites en dos de las parcelas, mientras que la Tabla 3.43 presenta las características de estas nuevas áreas homogéneas.

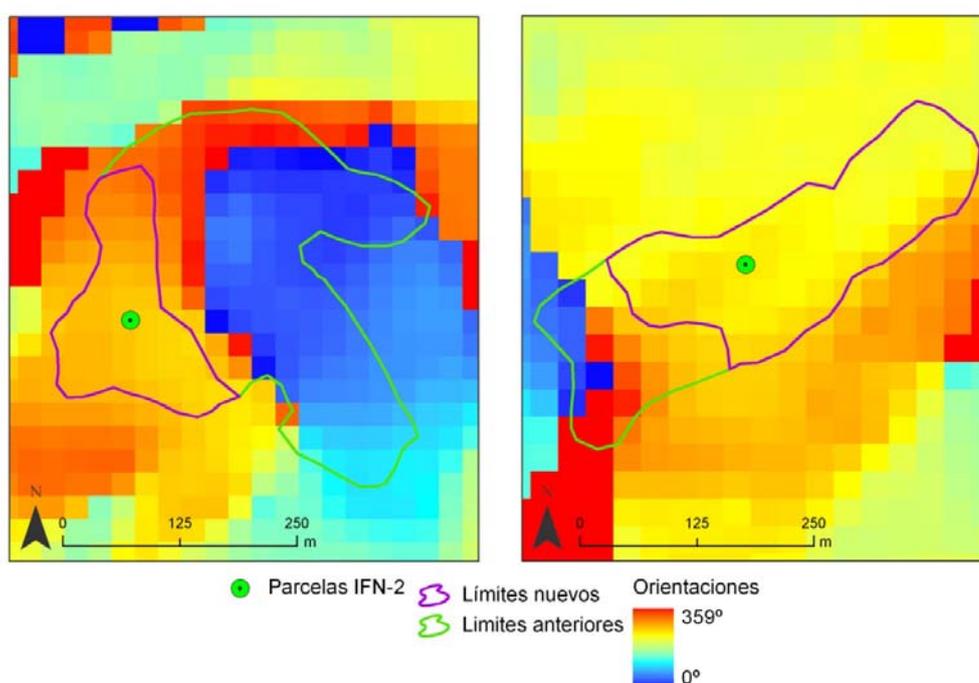


Figura 3.38. Ejemplos de modificación de los límites de las áreas forestales homogéneas con objeto de que sean también homogéneas desde el punto de vista topográfico

Parcela	Superficie (ha)	Pendiente media (grados)	Orientación	Biomasa residual (tons/ha)
830	26,64	18,01	Este	9,64
837	33,68	15,69	Oeste	48,68
843	30,12	9,91	Oeste	4,53
1034	3,41	9,09	Oeste	8,40
1035	5,32	4,29	Este	21,41
1048	2,58	15,48	Oeste	11,10
1049	2,87	5,25	Oeste	13,05
1060	4,04	5,52	Sur-Oeste	32,04
1061	2,13	12,06	Oeste	31,20
1063	16,14	13,56	Oeste	35,30
1064	5,24	7,63	Sur-Este	2,24

Tabla 3.43. Características de las áreas forestales homogéneas con los nuevos límites

La superposición de estas 11 parcelas sobre las cinco imágenes ASAR de órbita ascendente mostró que las numeradas como 830, 1035 y 1064 quedaban en zonas de sombra radar, debido a su orientación contraria con respecto al pulso emitido por el sensor. Aunque se hubiera preferido contar con todas las parcelas, es necesario señalar que la pérdida de las 3 señaladas no resulta muy relevante por dos motivos: en primer lugar, porque las 8 restantes recogen casi la misma parte del rango de la variable biomasa en el área de estudio que el conjunto de las 11 parcelas (2 de las 3 eliminadas se encontraban en posiciones intermedias de este rango); en segundo lugar, porque, desde el punto de vista estadístico, para ajustar un modelo de regresión robusto es tan poco significativa una muestra de 8 elementos como una muestra compuesta por 11. A este último respecto, recordar que el presente apartado no pretende obtener un modelo operativo para estimar la biomasa residual del área de estudio, sino que únicamente se pretende explorar si existen las relaciones entre esta variable y el coeficiente de retrodispersión obtenido con las imágenes ASAR.

3.2.2. Estudio de las relaciones entre la biomasa residual forestal y el coeficiente de retrodispersión de las imágenes ASAR de órbita ascendente

La Tabla 3.44 presenta los coeficientes de correlación de *Pearson* obtenidos al relacionar el contenido de biomasa residual de las 8 parcelas consideradas con cada una de las 5 imágenes de órbita ascendente que recogen el área donde se encuentran.

Imagen ASAR	R
5 de mayo	0,366
2 de agosto	0,532
18 de agosto	0,377
11 de octubre	0,659
15 de noviembre	0,478

Tabla 3.44. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal (variable dependiente) con las 5 imágenes ASAR consideradas

Los resultados obtenidos permiten contrastar dos hechos esperados: la no significación de las relaciones obtenidas debido al reducido tamaño de la muestra y la variación del grado de correlación en función de la órbita y la fila de observación con que ha sido tomada la imagen, parámetros que determinan el ángulo de incidencia local.

Esta segunda constatación se deduce de comparar los coeficientes obtenidos con las imágenes captadas en la órbita 373 y fila 801 (2 de agosto, 11 de octubre y 15 de

noviembre) con los derivados de utilizar las registradas en la órbita 101 del mismo *frame* (5 de mayo y 18 de agosto). Así, mientras que ninguno de los obtenidos con las imágenes de la órbita 373 presenta un valor inferior a 0,475, los resultantes de utilizar la órbita 101 arrojan correlaciones inferiores a 0,380. En definitiva, estos resultados no hacen otra cosa sino ratificar la dependencia angular del coeficiente de retrodispersión a la hora de estudiar zonas de vegetación (Ulaby y Dobson, 1989), lo que confirma la necesidad de aplicar una normalización topográfica rigurosa a la hora de utilizar imágenes ASAR para estimar cualquier parámetro relacionado con este tipo de cubiertas.

En cuanto al grado de correlación alcanzado, ninguno de los coeficientes obtenidos muestra la posibilidad de obtener con nuestros datos una ecuación de regresión precisa para poder estimar, a partir de ella, la cantidad de biomasa residual presente en un territorio en el que se den las mismas condiciones. Aun así, con el objeto de conocer con mayor profundidad el carácter de estas relaciones, en el siguiente subapartado se representan los gráficos de dispersión de cada una de las relaciones y se ajusta el mejor modelo de regresión posible para cada una de ellas, aun conscientes, *a priori*, de que ninguno va a resultar significativo.

3.2.3. Ajuste de modelos de regresión

La Figura 3.39 recoge los gráficos de dispersión obtenidos para cada una de las cinco imágenes. Sobre estos gráficos se ha trazado la línea que mejor ajusta la relación entre estas dos variables. Un aspecto a señalar, antes de comentar estos gráficos, es que en su creación se ha invertido la posición normal de las variables; es decir, la dependiente (biomasa residual) se ha representado en el eje de abscisas y la independiente (coeficiente de retrodispersión) en el eje de ordenadas; se respeta así la forma habitual de representar estos gráficos en los trabajos específicos de la bibliografía que analizan las relaciones entre *AGB* y las distintas bandas radar. Además, igual que los gráficos de dispersión ajustados con las imágenes Landsat, el eje de la variable biomasa es prolongado hasta valores mayores que los considerados en la muestra para observar mejor el carácter de la relación. La Tabla 3.45 recoge los modelos obtenidos usando el orden normal de las variables.

Imagen	Tipo de modelo	R^2	S_e	β_0	β_1
5 de mayo	Lineal	0,134	15,916	46,886	3,365
2 de agosto	Lineal	0,283	14,484	66,163	6,025
18 de agosto	Lineal	0,142	15,837	58,164	5,115
11 de octubre	Lineal	0,434	12,867	90,775	8,596
15 de noviembre	Lineal	0,228	15,026	57,671	4,765

Tabla 3.45. Modelos de regresión simple calculados con las 5 imágenes ASAR consideradas: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

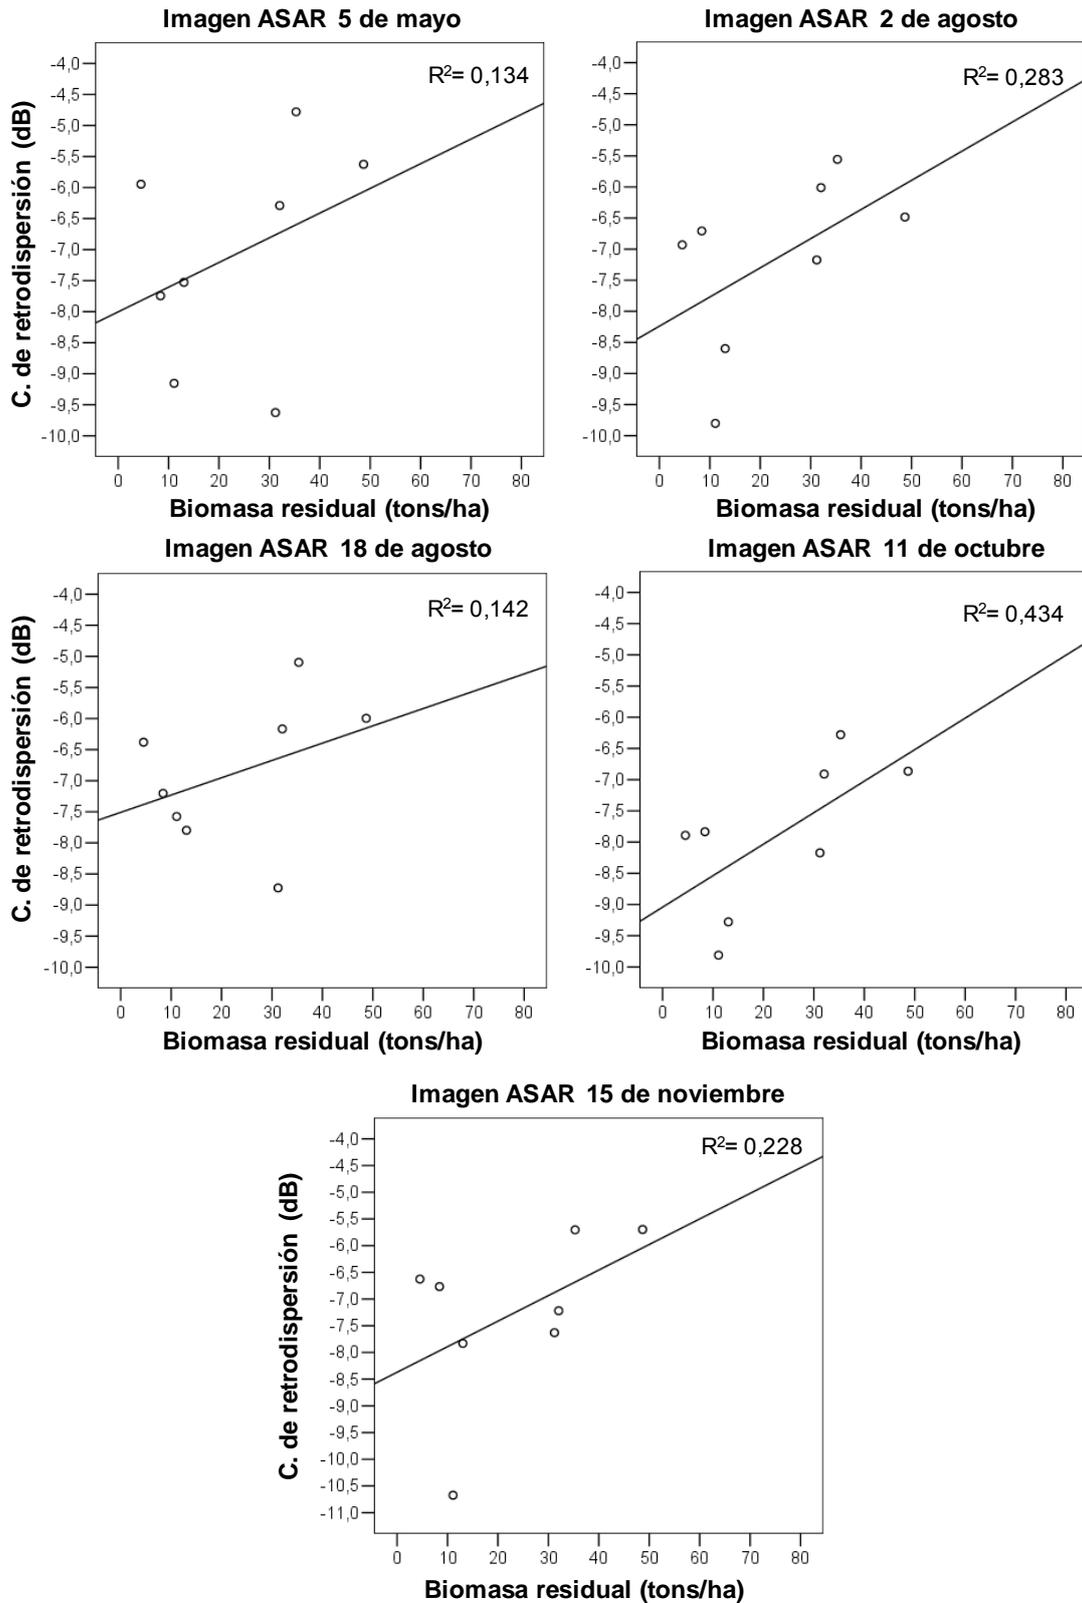


Figura 3.39. Gráficos de dispersión obtenidos con las 5 imágenes ASAR consideradas

Tal y como se puede observar, la regresión que mejor ajusta las 5 relaciones es la lineal. Este hecho es positivo, ya que indica que, al menos para la cantidad más alta de biomasa residual considerada en la muestra (48,678 tons/ha), no existe saturación de la señal radar. Considerando el hecho –ya apuntado en el Capítulo 1- de que, aproximadamente, la biomasa residual representa un 20% de la total de un árbol (60% el resto de biomasa aérea –fuste- y 20% la subterránea), ésto significa que el coeficiente de retrodispersión en banda C es sensible para cantidades de *AGB* de hasta 195 tons/ha. Esta cantidad es muy superior a las 30-50 tons/ha indicadas en otros trabajos como umbral superior a partir del cual se produce la saturación de la banda C (Le Toan y Flourey, 1998, Le Toan *et al.*, 2002). Sin embargo, esta cifra coincide con el modelo teórico de Hsu *et al.* (1994), autores que estudian la capacidad de estimación de *AGB* cuando se tienen en cuenta por separado los distintos estratos que componen un pinar: copas, troncos, matorral-maleza y superficie del suelo; en este modelo, considerando sólo la respuesta del estrato de las copas, la relación entre el coeficiente de retrodispersión de la banda C en polarización VV obtenido con un ángulo de incidencia de 26° (características análogas a las de las imágenes ASAR utilizadas) y la *AGB* ajusta, hasta las 150 tons/ha (valor máximo modelizado), una relación lineal, lo que significa que no existe saturación, al menos, para esta cantidad (Figura 3.40).

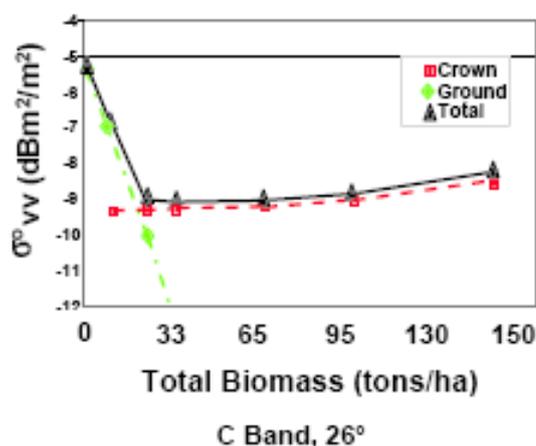


Figura 3.40. Relación según el modelo de Hsu *et al.*, (1994) entre el coeficiente de retrodispersión de la banda C con polarización VV y con un ángulo de incidencia de 26° y la biomasa en un bosque de pinos contenida en la copa (crown), la debida al sustrato (ground) y a la suma de estos dos estratos del bosque (total). Fuente: Le Toan y Flourey, (1998)

Otro factor que marca el tipo de relación entre las dos variables, aparte de la pendiente, son las características del suelo, las cuales tienen una gran influencia en el coeficiente registrado cuando la densidad de bosque es pequeña (Le Toan y Flourey,

1998). Según los modelos teóricos, la relación entre el coeficiente de retrodispersión y la cantidad de biomasa en las zonas de menor densidad forestal puede ser decreciente, si son suelos húmedos y rugosos, o creciente, si están secos y son poco rugosos o lisos (Figura 3.41). Así, de acuerdo con estos modelos y en función de lo observado en los gráficos de dispersión, los suelos de las parcelas utilizadas se caracterizan por su sequedad y por su escasa rugosidad con respecto al tamaño de la onda de la banda C en ángulo de incidencia considerado.

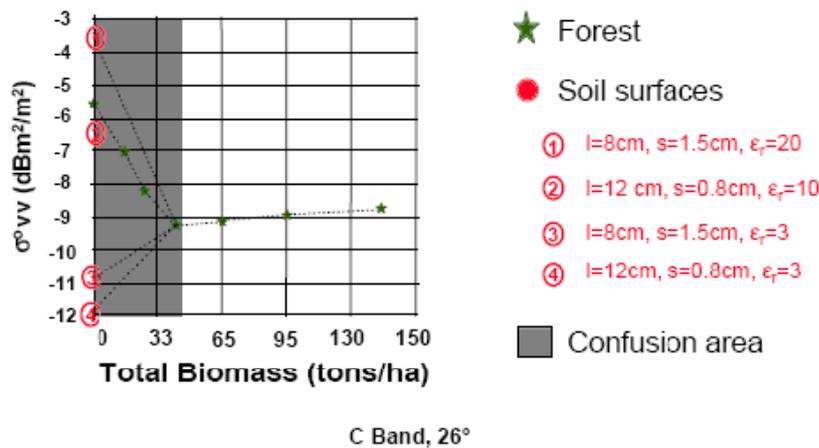


Figura 3.41. Relación entre el coeficiente de retrodispersión de la banda C -polarización VV y ángulo de incidencia de 26°- y AGB. El punto 1 simula la respuesta de un suelo húmedo y relativamente rugoso; el punto 2 un suelo con humedad media y liso; el punto 3 un suelo poco rugoso y seco; el punto 4 un suelo liso y seco. El área en gris representa los bosques de baja densidad y poca biomasa, medios en los que las características del suelo determinan la relación. Fuente: Le Toan y Floury (1998)

En cuanto al poder predictivo de las regresiones, como era esperado tras los coeficientes de correlación obtenidos, todos los modelos ajustados dejan gran parte de la varianza de la variable biomasa sin explicar. En este sentido, los coeficientes de regresión más altos se obtienen con las tres imágenes de la órbita 373 y fila 801, siendo siempre superiores a 0,225. Concretamente, el valor más alto se da con la imagen ASAR del 11 de octubre, que alcanzó un R^2 de 0,434. Así, aun a pesar del proceso de selección seguido al objeto de utilizar en los análisis ajustados las parcelas más adecuadas, este coeficiente es inferior al obtenido con las imágenes Landsat tras aplicar los procesos de selección de parcelas descritos en el anterior apartado.

Otro rasgo común a los trabajos recogidos en la bibliografía que hacen uso de imágenes SAR en banda C para estimar AGB es el reducido rango de variación del coeficiente de retrodispersión en comparación con el de la variable biomasa. Así, por ejemplo, el rango de variación del coeficiente de retrodispersión del mejor modelo

ajustado es, tan apenas, de 3,532 dB para explicar variaciones de biomasa de 44,153 tons/ha. Esta escasa sensibilidad en la variable independiente a pequeños cambios en la variable biomasa residual también es responsable de los bajos coeficientes de correlación obtenidos.

Por último, recordar que otro factor que interviene directamente en el bajo poder predictivo de los modelos ajustados son los errores que se han podido cometer en la delimitación de las áreas homogéneas, atribuyendo determinados valores de biomasa residual a zonas con mayor o menor contenido. A este respecto, debe tenerse en cuenta que los mayores errores de estimación en las cartografías obtenidas mediante la utilización de imágenes Landsat se obtuvieron, precisamente, cuando estas áreas forestales creadas a partir de fotointerpretación fueron utilizadas para extraer la información. Además, también hay que tener en cuenta el desfase temporal existente entre las ortoimágenes utilizadas para delimitar las áreas homogéneas (1999) y la fecha de captura de las imágenes ASAR (2003) y entre éstas y la fecha de estimación del contenido de biomasa residual de las parcelas del IFN-2.

3.2.4. Conclusiones

De lo anterior se desprenden las siguientes conclusiones:

- I. A pesar de la ausencia de significación estadística, por el pequeño tamaño muestral, se constata la existencia de relaciones entre el coeficiente de retrodispersión de las imágenes ASAR de banda C y la biomasa residual forestal.**

Estas relaciones son siempre de tipo directo, siendo las ecuaciones lineales las que mejor ajustan esta relación. Es de destacar la ausencia de saturación de la señal radar para la cantidad mayor contemplada en la muestra, lo que indica la posible utilidad de este sensor para estimar las cantidades más altas de esta fracción de biomasa en el área de estudio.

Se valida la hipótesis inicial de que el sensor ASAR es útil para estimar la biomasa residual forestal, circunstancia esperada teniendo en cuenta que las hojas y ramas de la copa de los árboles son los principales retrodispersores en las zonas de bosque de la energía emitida en banda C. Así pues, la novedad más importante está relacionada con la baja saturación mostrada, ya que la máxima cifra de biomasa residual considerada en la muestra equivale aproximadamente a 195 tons/ha de *AGB*, cifra muy superior a la de saturación de la señal en esta banda de algunos de los trabajos consultados, aunque en

línea con los modelos de simulación también recogidos en estos trabajos cuando es tenida en cuenta solamente la respuesta del estrato de copas del bosque para estimar la cantidad total de biomasa.

Sin embargo, es necesario volver a subrayar y recalcar que la no aplicación de la necesaria normalización topográfica para corregir el efecto de la pendiente en la señal retrodispersada y el pequeño tamaño de la muestra utilizada, invalidan totalmente cualquier extrapolación de estos resultados. Junto a esto, no se deben olvidar tampoco los bajos coeficientes de determinación obtenidos, que apenas alcanzan 0,434 en el mejor de los casos. Este bajo coeficiente puede ser debido a la suma de tres factores:

- (i) La ausencia de normalización topográfica, que hace que la pendiente modifique la señal recibida independientemente de la cantidad de biomasa.
- (ii) Errores en la delimitación de áreas homogéneas forestales, que hacen que se asignen al territorio valores diferentes de biomasa residual de los que realmente tiene.
- (iii) La utilización de datos de biomasa residual no sincrónicos con el registro de las imágenes ASAR, ya que la estructura de las áreas homogéneas delimitadas puede haber sufrido notables cambios entre la fecha de las ortoimágenes utilizadas para definir las (1999) y la fecha de adquisición de las imágenes (2003). Además, junto a esto hay que recordar que los datos de biomasa residual calculados sobre las parcelas de IFN-2 son de 1994, por lo que también puede haber cambios entre la situación de los bosques en este año y el año en el que se tomaron las ortoimágenes.

II. El ángulo de incidencia controla el grado de correlación existente entre la biomasa residual y el coeficiente de retrodispersión.

El hecho de que las imágenes utilizadas no hayan sido objeto de un proceso de normalización topográfica ha permitido constatar la importancia de este pretratamiento para cuantificar de una manera correcta el grado de correlación existente entre ambas variables. Así, mediante el uso de las imágenes tomadas en las mismas condiciones de observación (órbita y fila), que, por lo tanto, suponen el mismo ángulo de incidencia local en cada una de las parcelas de la muestra, se obtienen coeficientes de correlación y determinación análogos entre sí y significativamente diferentes con respecto a los obtenidos con las imágenes adquiridas parámetros de observación diferentes.

Este hecho vuelve a subrayar -y confirma- lo ya apuntado al principio de este apartado respecto de la necesidad del pretratamiento de la normalización topográfica cuando se trabaja con imágenes SAR que recogen información de una superficie con topografía compleja.

Teniendo en cuenta todo lo desarrollado en este apartado, la conclusión final es que, teniendo en cuenta la complejidad las imágenes SAR y los complicados tratamientos que hay que aplicar sobre ellas para garantizar la correcta relación entre los datos obtenidos en el campo y la información contenida en estas imágenes en zonas con topografía no llana, el uso de estas imágenes no se ajusta bien con el objetivo enunciado de obtener una metodología sencilla y extrapolable a otros territorios que sea fácilmente adoptada por las distintas Administraciones. Para que ésto fuera posible, sería necesario que estos organismos contaran con técnicos con un alto grado de especialización en el tratamiento de este tipo de imágenes, lo que resulta bastante difícil en la actualidad.

***CAPÍTULO 4:
EVALUACIÓN DEL EFECTO DE LA
TEMPORALIDAD EN LA ESTIMACIÓN DE
LA BIOMASA RESIDUAL FORESTAL
MEDIANTE IMÁGENES LANDSAT TM***

Los resultados obtenidos en el Capítulo 3 a partir de la imagen de junio de 1994 han mostrado que, independientemente del método de extracción de la información utilizado y del método de regresión considerado, las variables radiométricas relacionadas con el contenido de humedad de las hojas son las más adecuadas para estimar la biomasa residual de los bosques de pinos de la provincia de Teruel. Este resultado coincide con trabajos previos que señalan a estas variables como las más útiles para estimar *AGB* (Steininger, 2000; Foody *et al.*, 2001; Lu *et al.*, 2004; Lu, 2005; Lu y Batistella, 2005) y *LAI* (Eklundh *et al.*, 2001, 2003).

Por otra parte, como se ha indicado en el Capítulo 1, una de las características que debe cumplir la metodología propuesta para estimar la biomasa residual forestal perseguida en esta investigación es la de ser fácilmente actualizable a escala provincial o regional. Así, para poder concluir que tanto la metodología empleada como la relación biofísica existente entre variables radiométricas relacionadas con la humedad y la cantidad de biomasa residual son independientes de la fecha de la imagen Landsat utilizada, es necesario validar ambos aspectos con otras escenas capturadas en diferentes fechas a lo largo del año.

Aunque lo deseable para esta validación sería contar con una colección de escenas repartidas a lo largo de los doce meses de un año, ésto no fue posible debido a problemas de presupuesto, que únicamente permitieron la adquisición de las tres escenas Landsat utilizadas en esta tesis⁴⁶. De esta manera, el efecto que la temporalidad tiene en la validez de la metodología desarrollada en el Capítulo 3 sólo puede ser evaluado considerando la estación de verano, más concretamente en los meses de junio, julio y agosto. No obstante, es necesario subrayar que estas imágenes resultan óptimas para este aspecto de validación, ya que son coetáneas a las labores de campo del IFN-2. Por otro lado, conviene recordar que la época estival es la más frecuentemente seleccionada en el campo de las aplicaciones forestales de la teledetección, ya que se minimiza el efecto de las sombras en la respuesta radiométrica registrada por el sensor debido a que el ángulo de elevación solar presenta sus valores anuales máximos en esta época.

Este capítulo, que se corresponde con el objetivo parcial VI y con la fase

⁴⁶ El acceso libre y gratuito a imágenes Landsat, recientemente habilitado por el *USGS (United States Geological Survey)*, así como las posibilidades que ofrece el *Plan Nacional de Teledetección* en España, no existían en el momento de desarrollar el cuerpo fundamental de esta tesis.

metodológica VII, se divide en dos apartados, siendo el primero más extenso que el segundo:

- En el primero se aplica el método que mejor resultado ha dado con la imagen de junio de 1994 a las de julio de 1993 y agosto de 1994. Se trata de comprobar la validez del método para obtener ecuaciones de estimación de la biomasa residual de forma independiente a la fecha de verano en la cual ha sido tomada la imagen. De igual manera, los resultados parciales y finales que se obtengan en este proceso servirán para validar si las variables relacionadas con el contenido de humedad de la vegetación siguen siendo, de todas las consideradas, las más útiles para ajustar los ajustes de regresión.
- En el segundo apartado se analiza la variación del contenido de humedad en los meses de junio, julio y agosto para las especies de pino consideradas en la presente investigación, con objeto de comprobar si existen diferencias significativas en esta variable durante el periodo de verano. Se pretende con ello valorar la estabilidad temporal de los modelos de estimación de la biomasa basados en el uso de variables radiométricas relacionadas con esta variable; ya que, si la variación de humedad entre los meses de verano es alta, el modelo de estimación será menos robusto, al presentar distintos ajustes para una misma cantidad de biomasa residual.

Para realizar este segundo análisis se utilizan datos procedentes del trabajo de campo del proyecto FIRERISK, recopilados por personal investigador del Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza. La adquisición de estos datos, como se detallará más adelante, se hizo en dos áreas de muestreo de la Comunidad Autónoma de Aragón -fuera, aunque próximas, de la provincia de Teruel- y en fecha muy posterior -años 2001 y 2002- a la de las imágenes Landsat utilizadas en este trabajo. Debido a estos dos condicionantes y a la escasez de datos disponibles (sólo dos años), este análisis no podrá ser tomado como estadísticamente representativo para concluir certezas, aunque sí como exploratorio para derivar conclusiones parciales.

4.1. Validación temporal de la metodología óptima de estimación de biomasa residual forestal ajustada mediante el uso de la imagen Landsat de junio de 1994

Como se ha concluido en el Capítulo 3, el método que combina el uso de ventanas fijas 3x3 para extraer la información radiométrica con el cálculo del CV para

individualizar grupos de parcelas del IFN-2 dependiendo de su heterogeneidad radiométrica se erige como el más adecuado, tanto en términos de capacidad de predicción (R^2), como en relación al error de estimación, habiendo quedado comprobada su representatividad para todo el área de estudio.

La réplica de este método en las imágenes Landsat TM de julio de 1993 y de agosto de 1994 requiere de los siguientes pasos:

- **Determinación de qué parcelas del IFN-2 sobre las que se dispone de información de biomasa residual están dentro de cada una de estas dos nuevas escenas.** Esto se debe a que, aunque las tres imágenes utilizadas pertenecen a la órbita de observación terrestre (*track*) 199 y, dentro de ésta, a la fila (*frame*) 32, el área registrada en ellas no es exactamente igual, por lo que el número de parcelas a considerar puede ser diferente.
- **Extracción de la información de media y desviación estándar de las variables radiométricas consideradas utilizando ventanas de 3x3.** Dado que las variables topográficas y forestales son invariantes (al menos para la escala temporal contemplada en este trabajo) y que no han mostrado utilidad para obtener modelos de estimación precisos, la extracción de información se restringe exclusivamente a las variables radiométricas originales y derivadas de las imágenes Landsat.
- **Calculo del CV de cada parcela en las 6 bandas originales de cada escena y definición de 10 grupos de parcelas utilizando estos CV.** De esta manera, al igual que en el caso de la imagen de junio, aunque con los valores específicos de las imágenes de julio y agosto, pues la información radiométrica es diferente, los primeros grupos contendrán las parcelas que presentan mayor variabilidad espectral, mientras que los últimos recogerán las más homogéneas.
- **Estudio de las correlaciones entre la biomasa residual forestal y las variables espectrales en los grupos de parcelas delimitados.** Al igual que en el Capítulo 3, se utiliza el coeficiente de correlación de *Pearson* (R) para determinar la existencia -o no- de relaciones entre la biomasa residual y las variables radiométricas de las imágenes de julio y agosto, su fuerza y su dirección. Aunque en este momento de la investigación se conoce que la

mayoría de las variables radiométricas presenta relaciones no lineales con la biomasa residual, pese a ser el índice de correlación de *Spearman* (R_s) algo más adecuado para cuantificar estas relaciones que el de *Pearson* (Ebdon, 1982), se prefirió seguir utilizando este último para facilitar la comparación de resultados entre la imagen de junio y las dos escenas analizadas en este apartado. Es, por tanto, en este apartado dónde se obtendrá un primer resultado acerca de la posibilidad de establecer modelos predictivos operativos de la biomasa mediante la consideración de determinados grupos de parcelas, así como una primera aproximación sobre si las variables radiométricas relacionadas con el contenido de humedad de la vegetación se erigen otra vez como las más adecuadas para estimar la biomasa. Dentro de este paso se incluye el análisis de las auto-correlaciones entre las variables dependientes entre sí.

- **Ajuste de los modelos de regresión.** En este paso se ajustan modelos de regresión simples y lineales múltiples para obtener modelos estimativos precisos mediante el empleo de las variables independientes radiométricas de las imágenes de julio y agosto. El ajuste de estos modelos de regresión para cada una de las dos nuevas imágenes se hará sobre un grupo de parcelas identificado en el análisis de correlaciones que sea análogo al grupo que mejores resultados ha dado en el Capítulo 3, es decir, que presente un grado de correlación intermedio-alto de la biomasa residual con la mayor parte de las variables radiométricas consideradas, contando con un número suficiente de parcelas para no comprometer su representatividad en todo el área de estudio. Asimismo, al igual que en el Capítulo 3, se aplica en primer lugar la regresión simple, adquiriéndose así información sobre la forma de las relaciones entre las variables dependiente e independientes, lo que será útil para dirigir el ajuste de los modelos de regresión lineal múltiple. Cada uno de estos modelos es ajustado mediante el 80% de las parcelas consideradas, reservándose el restante 20% para la validación.

- **Validación de las cartografías de estimación derivadas de los modelos.** En este último paso se validan las cartografías de los modelos obtenidos para las dos imágenes de forma análoga a como se ha hecho en el apartado 3.1.3 para lo obtenidos con la de junio. El error obtenido en cada una de ellas será el dato final que nos permita concluir si la metodología que ha resultado más

precisa con la imagen de junio es también adecuada para las imágenes de julio y agosto.

4.1.1. Determinación del número de parcelas, extracción de la información y obtención de los 10 grupos de parcelas a partir de los CV en las imágenes de julio de 1993 y agosto de 1994

Un total de 481 parcelas del IFN-2 con información de biomasa residual pudieron ser utilizadas para la imagen de julio de 1993 (tan sólo una menos que en el caso de la imagen de junio de 1994), mientras que para la imagen de agosto de 1994 este número se vio reducido a 470 (12 menos con respecto a la imagen de junio de 1994). El motivo de la importante reducción en el caso de esta última se debe principalmente a que esta escena recoge el impacto ocasionado por el incendio acaecido en la comarca del Maestrazgo.

El “incendio del Maestrazgo”, causado por un rayo, tuvo lugar entre el 2 y el 8 de julio de 1994 y afectó a un área forestal de 16.000 ha⁴⁷, situada al noreste de la provincia de Teruel, compuesta principalmente por *P. halepensis* y, en mucho menor grado, por *Quercus ilex rotundifolia*. Dentro del área afectada se encontraban 10 puntos del IFN-2 mono-específicos de *P. halepensis* que, para esas fechas, ya habían sido inventariados, por lo que han podido ser utilizados en los análisis efectuados para la imagen de junio de 1994 (registrada un mes antes del incendio), pero no van a poder ser utilizados para los análisis sobre la imagen de agosto, al no corresponderse ya la información radiométrica de estas parcelas con la cantidad de biomasa estimada por las ecuaciones alométricas. Por otra parte, otras 2 parcelas con información de biomasa residual debieron ser también eliminadas de la muestra porque su respuesta radiométrica en la imagen de agosto estaba afectada por unas pequeñas nubes, localizadas en el sur de la Provincia.

Para la extracción de la información radiométrica de las dos nuevas escenas se siguió la metodología descrita en el apartado 3.1.1.1, con la diferencia de que en esta ocasión los multibandas de las dos escenas sólo estaban compuestos por variables radiométricas, debido a la nula aportación ya comentada de las variables topográficas continuas en los modelos estimativos precisos con la imagen de junio de 1994. Además, es necesario señalar que, para evitar cualquier tipo de imprecisión derivada de los

⁴⁷ Este incendio traspasó los límites de la provincia de Teruel y se extendió por parte de las serranías occidentales de la provincia de Castellón. En el texto sólo se recoge el área afectada en la provincia de Teruel.

procesos de corrección geométrica de las tres imágenes, se crearon nuevos AOI's de 3x3 píxeles centrados en el punto central de las parcelas del IFN-2, tanto para la imagen de julio de 1993 como para la de agosto de 1994.

Una vez que creados los dos archivos SPSS –uno para cada nueva escena considerada- con la información del IFN-2, de la biomasa residual y de la de las variables radiométricas (media y desviación estándar) de cada una de las parcelas, se calculó el CV de las parcelas en las bandas reflectivas y se calcularon los 10 percentiles de CV que permitían la separación de las parcelas en grupos en función de su heterogeneidad-homogeneidad radiométrica en su entorno 3x3. Las Tablas 4.1 y 4.2 muestran los umbrales de CV de cada una de las bandas reflectivas usados para la delimitación de los 10 grupos de parcelas en las imágenes de julio de 1993 y agosto de 1994.

Percentil	CV TM1	CV TM2	CV TM3	CV TM4	CV TM5	CV TM7
9	0,245	0,272	0,321	0,135	0,240	0,298
8	0,202	0,221	0,259	0,101	0,198	0,237
7	0,171	0,186	0,222	0,086	0,166	0,207
6	0,151	0,165	0,199	0,074	0,147	0,180
5	0,134	0,145	0,172	0,065	0,130	0,159
4	0,119	0,126	0,152	0,057	0,115	0,143
3	0,104	0,109	0,128	0,048	0,100	0,124
2	0,084	0,092	0,107	0,039	0,082	0,108
1	0,063	0,068	0,082	0,031	0,066	0,082

Tabla 4.1. Umbrales de CV de cada una de las bandas reflectivas de la imagen de julio de 1993 utilizados para la delimitación de los 10 grupos de parcelas con distinto grado de heterogeneidad espacial-radiométrica

Percentil	CV TM1	CV TM2	CV TM3	CV TM4	CV TM5	CV TM7
9	0,183	0,238	0,267	0,133	0,231	0,299
8	0,150	0,195	0,217	0,103	0,197	0,235
7	0,126	0,164	0,188	0,084	0,164	0,203
6	0,110	0,141	0,159	0,072	0,143	0,179
5	0,097	0,124	0,137	0,063	0,126	0,158
4	0,083	0,109	0,122	0,052	0,111	0,139
3	0,073	0,092	0,099	0,045	0,098	0,124
2	0,063	0,076	0,081	0,038	0,077	0,103
1	0,051	0,056	0,063	0,031	0,061	0,077

Tabla 4.2. Umbrales de CV de cada una de las bandas reflectivas de la imagen de agosto de 1994 utilizados para la delimitación de los 10 grupos de parcelas con distinto grado de heterogeneidad espacial-radiométrica

La distribución de las parcelas en estos diez grupos resultó similar a la realizada en el caso de la imagen de junio de 1994 en el Capítulo 3, quedando definidos más o menos por el mismo número de parcelas, siendo mayores las diferencias en el caso de la imagen de agosto debido al menor número de parcelas que componen la muestra en este caso (ver Tablas 4.3 y 4.4, en el siguiente apartado). Este resultado es positivo, ya que significa que se puede llevar a cabo un análisis semejante al realizado anteriormente, por lo que los resultados serán directamente comparables entre las distintas imágenes.

El análisis de correlaciones entre la biomasa residual y las variables radiométricas en cada uno de estos 10 grupos, que se efectúa en el siguiente apartado, permite observar si se cumple el patrón detectado en la imagen de junio de que a mayor homogeneidad del entorno radiométrico de la parcela, mayor correlación entre estas variables. Del mismo modo, también permite contrastar si las variables relacionadas con la humedad vuelven a obtener los mejores coeficientes y, por lo tanto, son *a priori* las más adecuadas para el establecimiento de modelos predictivos.

4.1.2. Estudio de las correlaciones entre la biomasa residual forestal y las variables espectrales en los grupos de parcelas delimitados en las imágenes de julio de 1993 y junio de 1994

Las Tablas 4.3 y 4.4 muestran los coeficientes de correlación de *Pearson* obtenidos en cada uno de los 10 grupos de parcelas delimitados usando las escenas de junio de 1993 y agosto de 1994, respectivamente. Como sucedía con la imagen de junio de 1994, en general, estas correlaciones son mayores conforme los grupos contienen parcelas con entornos radiométricos más homogéneos. Asimismo, todos los grupos presentan correlaciones significativas con la mayoría de las variables consideradas a nivel $p > 0,01$, con la única salvedad del grupo percentil 1 en el caso de la imagen de julio y de los percentiles 2 y 1 en la imagen de agosto. En ambos casos, la pérdida de la significación estadística con algunas variables se puede achacar al escaso número de parcelas que compone estos grupos; por ello, estos últimos grupos se dejan fuera del comentario sobre el grado de correlación que sigue a continuación.

Tanto en la imagen de julio como en la de agosto las mayores correlaciones en todos los grupos se obtienen con las variables que ofrecen información sobre el contenido de agua de la vegetación (TM5, TM7, TC3, MSI y MID57) y con los índices de vegetación NDVI, SAVI, OSAVI y MSAVI, replicándose así el mismo patrón que cuando se estudiaban las relaciones existentes con la información radiométrica de la imagen de junio de 1994.

	Percentil 10	Percentil 9	Percentil 8	Percentil 7	Percentil 6	Percentil 5	Percentil 4	Percentil 3	Percentil 2	Percentil 1
Nº Parcelas	481	370	282	207	148	107	69	39	18	6
TM1	-0,395**	-0,412**	-0,488**	-0,504**	-0,476**	-0,572**	-0,674**	-0,608**	-0,609**	-0,819*
TM2	-0,400**	-0,419**	-0,494**	-0,502**	-0,469**	-0,547**	-0,667**	-0,632**	-0,604**	-0,768
TM3	-0,387**	-0,404**	-0,488**	-0,491**	-0,459**	-0,549**	-0,685**	-0,638**	-0,624**	-0,802
TM4	-0,205**	-0,200**	-0,242**	-0,232**	-0,160	-0,208*	-0,312**	-0,212	-0,298	-0,180
TM5	-0,460**	-0,470**	-0,543**	-0,551**	-0,531**	-0,591**	-0,747**	-0,727**	-0,728**	-0,875*
TM7	-0,455**	-0,470**	-0,546**	-0,558**	-0,549**	-0,611**	-0,744**	-0,734**	-0,716**	-0,884*
CP1	-0,442**	-0,454**	-0,529**	-0,533**	-0,508**	-0,577**	-0,721**	-0,691**	-0,682**	-0,839*
CP2	0,040	0,020	0,038	0,035	-0,058	-0,047	-0,047	-0,119	-0,001	-0,290
CP3	-0,028	-0,045	-0,034	-0,048	-0,126	-0,155	-0,273*	-0,369*	-0,362	-0,718
TC1	-0,408**	-0,420**	-0,494**	-0,490**	-0,451**	-0,528**	-0,671**	-0,617**	-0,612**	-0,754
TC2	0,304**	0,314**	0,365**	0,400**	0,463**	0,532**	0,617**	0,670**	0,813**	0,902*
TC3	0,480**	0,488**	0,555**	0,579**	0,597**	0,630**	0,788**	0,815**	0,833**	0,964**
NDVI	0,439**	0,457**	0,533**	0,564**	0,576**	0,638**	0,759**	0,760**	0,835**	0,972**
SAVI	0,437**	0,455**	0,531**	0,562**	0,576**	0,637**	0,757**	0,759**	0,837**	0,972**
MSAVI	0,431**	0,450**	0,530**	0,557**	0,568**	0,632**	0,753**	0,753**	0,803**	0,961**
OSAVI	0,438**	0,457**	0,533**	0,563**	0,576**	0,637**	0,758**	0,760**	0,836**	0,972**
GESAVI	0,402**	0,415**	0,472**	0,515**	0,539**	0,583**	0,696**	0,700**	0,921**	0,989**
GI	0,280**	0,345**	0,427**	0,431**	0,438**	0,543**	0,693**	0,650**	0,783**	0,968**
MSI	-0,480**	-0,489**	-0,549**	-0,580**	-0,618**	-0,653**	-0,789**	-0,826**	-0,889**	-0,976**
VIS123	-0,398**	-0,416**	-0,495**	-0,502**	-0,471**	-0,559**	-0,681**	-0,634**	-0,619**	-0,796
MID57	-0,461**	-0,473**	-0,547**	-0,556**	-0,542**	-0,602**	-0,747**	-0,732**	-0,724**	-0,881*
ABD	-0,423**	-0,437**	-0,512**	-0,513**	-0,480**	-0,556**	-0,694**	-0,651**	-0,640**	-0,794

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 4.3. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal con las variables radiométricas continuas obtenidas de la imagen de julio de 1993 en cada uno de los grupos delimitados usando el CV

	Percentil 10	Percentil 9	Percentil 8	Percentil 7	Percentil 6	Percentil 5	Percentil 4	Percentil 3	Percentil 2	Percentil 1
Nº Parcelas	470	365	279	206	150	95	54	34	15	5
TM1	-0,419**	-0,472**	-0,482**	-0,484**	-0,503**	-0,543**	-0,638**	-0,635**	-0,667**	-0,940*
TM2	-0,428**	-0,471**	-0,468**	-0,465**	-0,472**	-0,516**	-0,606**	-0,588**	-0,590*	-0,908*
TM3	-0,434**	-0,477**	-0,474**	-0,480**	-0,493**	-0,527**	-0,615**	-0,592**	-0,572*	-0,932*
TM4	-0,189**	-0,216**	-0,186**	-0,137*	-0,148	-0,163	-0,309*	-0,289	-0,282	-0,705
TM5	-0,470**	-0,533**	-0,544**	-0,549**	-0,584**	-0,609**	-0,723**	-0,737**	-0,723**	-0,953*
TM7	-0,479**	-0,534**	-0,541**	-0,558**	-0,599**	-0,623**	-0,729**	-0,742**	-0,740**	-0,956*
CP1	-0,445**	-0,499**	-0,500**	-0,502**	-0,525**	-0,549**	-0,662**	-0,661**	-0,648**	-0,946*
CP2	0,460**	0,521**	0,563**	0,598**	0,674**	0,696**	0,790**	0,824**	0,861**	0,930*
CP3	-0,035	0,030	0,064	0,117	0,178*	0,106	0,143	0,305	0,450	0,846
TC1	-0,429**	-0,480**	-0,478**	-0,476**	-0,494**	-0,518**	-0,630**	-0,624**	-0,608*	-0,938*
TC2	0,371**	0,408**	0,453**	0,484**	0,527**	0,580**	0,655**	0,671**	0,807**	0,876
TC3	0,483**	0,556**	0,580**	0,597**	0,657**	0,679**	0,787**	0,826**	0,825	0,954*
NDVI	0,469**	0,515**	0,539**	0,556**	0,600**	0,646**	0,752**	0,751**	0,801**	0,925*
SAVI	0,468**	0,513**	0,538**	0,555**	0,600**	0,645**	0,751**	0,750**	0,802**	0,924*
MSAVI	0,465**	0,509**	0,533**	0,552**	0,594**	0,642**	0,741**	0,742**	0,788**	0,933*
OSAVI	0,469**	0,514**	0,538**	0,555**	0,600**	0,646**	0,752**	0,751**	0,801**	0,925*
GESAVI	0,419**	0,460**	0,493**	0,508**	0,555**	0,576**	0,686**	0,688**	0,829**	0,865
GI	0,213**	0,259**	0,286**	0,317**	0,372**	0,403**	0,425**	0,495**	0,526*	0,897*
MSI	-0,492**	-0,563**	-0,600**	-0,625**	-0,695**	-0,713**	-0,823**	-0,843**	-0,862**	-0,930*
VIS123	-0,434**	-0,480**	-0,480**	-0,483**	-0,496**	-0,534**	-0,625**	-0,606**	-0,602*	-0,932*
MID57	-0,477**	-0,536**	-0,545**	-0,555**	-0,593**	-0,617**	-0,727**	-0,741**	-0,731**	-0,956*
ABD	-0,447**	-0,500**	-0,500**	-0,503**	-0,525**	-0,550**	-0,659**	-0,655**	-0,643**	-0,945*

* Correlación significativa al nivel 0,05; ** Correlación significativa al nivel 0,01

Tabla 4.4. Coeficientes de correlación de *Pearson* obtenidos al relacionar la biomasa residual forestal con las variables radiométricas continuas obtenidas de la imagen de agosto de 1994 en cada uno de los grupos delimitados usando el CV

Al igual que con la imagen de junio de 1994, la variable MSI es la que presenta un mayor coeficiente de correlación en un mayor número de grupos, en 7 de los 8 considerados en este análisis en el caso de la imagen de julio y en los 8 considerados en el caso de la imagen de agosto. En el grupo de la imagen de julio donde el MSI no es la variable más correlacionada (percentil 8), ésta se sitúa en segundo lugar, siendo ocupado el primero por la variable TC3, es decir, por otra variable relativa al contenido de humedad.

Un análisis más detallado por grupos de parcelas sobre el comportamiento de este conjunto de variables mejor correlacionadas con la biomasa residual muestra que las referidas a la humedad de la vegetación ocupan los cinco primeros lugares en los tres grupos con más parcelas (percentiles 10, 9 y 8) en las dos imágenes. A partir del percentil 7, los índices de vegetación NDVI, SAVI, OSAVI y MSVAVI empiezan a situarse más arriba en cuanto a grado de correlación, desplazando a las variables TM5, TM7 y MID57, aunque siempre la variable más correlacionada es MSI, seguida por TC3 en la mayoría de grupos. Sin embargo, a pesar de este cambio en la importancia relativa de estas variables en cuanto a grado de correlación, las diferencias en el valor de R son reducidas, situándose en rangos pequeños en los diversos grupos, aunque aumentando ligeramente conforme lo hace la homogeneidad radiométrica de las parcelas. Así, todas estas variables presentan un coeficiente R entre 0,431 y 0,480 y entre 0,465 y 0,492 en el percentil 10, entre 0,551 y 0,580 y entre 0,549 y 0,625 en el percentil 7 y entre 0,744 y 0,789 y entre 0,723 y 0,823 en el percentil 4 de las imágenes de julio y agosto, respectivamente. Como se puede observar en los rangos citados y en las tablas, ambas imágenes presentan coeficientes similares en los distintos grupos, si bien los valores máximos de la imagen de agosto tienden a ser superiores a los de julio.

Un último aspecto a reseñar sobre el grado de correlación de este grupo de 10 variables con la biomasa residual es el impacto que el índice de correlación utilizado -el índice de *Pearson*- ha podido jugar en que unas parezcan más correlacionadas que otras. Esta afirmación se basa en lo observado en los análisis de regresión llevados a cabo con la imagen de junio de 1994. Como se pudo comprobar en aquel análisis, las variables MSI, TC3, NDVI, SAVI, MSAVI y OSAVI tendían a presentar con la biomasa residual relaciones lineales o, mejor dicho, algo más lineales que las variables TM5, TM7 y MID57. Esta situación, que puede haberse repetido en las dos nuevas imágenes si la relación biofísica entre estos pares de variables es estable (algo que se quiere comprobar en este capítulo), hace que el índice de *Pearson* ofrezca mejores resultados para el grupo

de variables que presentan relaciones más lineales que para las que presentan un comportamiento más curvilíneo. Así pues, si hubiéramos utilizado el índice de *Spearman*, más adecuado para medir las relaciones no lineales entre variables al discretizar sus rangos en grupos para compararlos entre sí, quizá la posición relativa de las variables en cuanto a grado de correlación con la biomasa residual hubiera variado ligeramente, situándose en posiciones superiores las variables TM5, TM7 y MID57.

En cuanto al resto de variables, un hecho significativo es el distinto comportamiento de CP2 y CP3 con respecto a la biomasa residual en las imágenes de julio y de agosto, siendo también este comportamiento distinto en relación a lo observado con la imagen de junio de 1994. En esta última imagen, el CP3 era el que mejor correlación presentaba con la biomasa residual, situándose el CP1 dentro de las variables con correlaciones intermedias, mientras que CP2 no mostraba relaciones significativas con la biomasa en 9 de los 10 grupos de parcelas, por lo que fue excluida de análisis posteriores. Sin embargo, en el caso de la imagen de julio de 1993, tanto el CP2 como el CP3 carecen de significación estadística en su relación con la biomasa residual (excepto CP3 en los grupos de los percentiles 4 y 3, lo que se debe a una casualidad estadística), presentando el CP1 unos niveles de correlación intermedios. Por su parte, el CP2 calculado en la imagen de agosto de 1994 sí presenta correlación significativa con la biomasa residual, situándose los valores alcanzados en los grupos de parcelas más homogéneos al nivel del grupo conformado por las variables relacionadas con el contenido de humedad y por los índices de vegetación anteriormente destacados. Mientras, el CP1 se sitúa, una vez más, en una situación intermedia y el CP3 no presenta correlación significativa con la variable independiente.

El comportamiento dispar de estos neocanales en su relación con la biomasa residual dependiendo de la imagen utilizada se debe a su propia naturaleza, es decir, al proceso por el cual se originan. Conviene recordar que los CP son una síntesis de la información contenida en todas las bandas que forman una imagen multispectral y que la información contenida en estos neocanales depende directamente de la recogida en la imagen, siendo la cantidad sintetizada en los distintos componentes calculados diferente en cada imagen, tanto desde el punto de vista cuantitativo como cualitativo⁴⁸. De esta manera, como ya se sospechaba desde un principio, se puede concluir que los CP no son útiles para elaborar modelos predictivos de biomasa residual, ya que no se pueden

⁴⁸ En la tabla 2.17 se recogía el distinto porcentaje de información original de cada uno de los componentes calculados para las tres imágenes Landsat utilizadas en este trabajo.

establecer relaciones biofísicas estables entre este parámetro forestal y los neocanales derivados de la aplicación del ACP, por cuanto dependientes de la información contenida en cada imagen. Esta misma conclusión, dada la naturaleza del problema, se puede extender al intento de modelización de cualquier otro tipo de parámetro forestal.

Junto a los CP, que carecen de significación estadística, la variable peor correlacionada -tanto en la imagen de julio como en la de agosto- vuelve a ser TM4, lo que coincide con lo observado en el análisis de correlaciones de la imagen de junio de 1994. Además de sus bajos coeficientes de R , como sucedía con la imagen de junio, la correlación con la biomasa residual deja de ser significativa a partir de un cierto grado de homogeneidad radiométrica de las parcelas; en este caso, tanto en la imagen de julio como en la de agosto, a partir del percentil 6, aunque en algunos grupos recupera una débil significación de manera anecdótica. Por tanto, se confirma lo apuntado en el anterior capítulo acerca de la no utilidad de TM4 para la estimación de biomasa residual forestal, al menos en bosques caracterizados por una estructura espacial abierta y compleja. Recordamos que, en esta situación, la reflectividad captada en esta banda está influenciada por las sombras, la vegetación subyacente e, incluso, por el sustrato edáfico, lo que hace que la relación biofísica entre radiometría y cantidad de biomasa en esta región del espectro se vuelva inconsistente.

Por último, señalar que el resto de variables consideradas no mencionadas hasta ahora (TM1, TM2, TM3, TC1, TC2, GESAVI, GI, VIS123 y ABD) presentan un grado de correlación intermedio entre los dos extremos analizados, aunque siempre significativos con valores $p < 0,01$, variando su posición relativa en el ranking en los diferentes grupos de las dos imágenes ahora analizadas, como sucedía en la imagen de junio de 1994. De estas variables, ABD y GESAVI presentan los valores de correlación más altos, aunque en ningún caso alcanzan los de las variables relacionadas con la humedad ni los de los índices de vegetación, destacados como los mejores, por lo que los modelos de regresión simple ajustados con ellas serán siempre peores. En sentido negativo, las correlaciones más bajas dentro de este grupo se dan con TC2 y GI, sobre todo en los grupos que contienen más parcelas.

Con respecto al signo de las correlaciones que presentan significación, tanto en la imagen de julio como en la de agosto se respetan los patrones observados con las variables radiométricas originales y derivadas de la imagen de junio de 1994. Así, la biomasa residual presenta una relación inversa con todas las bandas reflectivas originales, siendo éste también el sentido de la relación con los neocanales CP1, TC1, ABD (brillo de la imagen), VIS123 (absorción por los pigmentos fotosintéticos) y MSI y

MID57 (inversamente relacionadas con el contenido de agua de las hojas). La relación positiva se vuelve a dar con todos los índices de vegetación considerados (NDVI, SAVI, MSAVI, OSAVI, GESAVI, GI), con el neocanal TC2 (verdor) y con TC3 (contenido de agua en la hojas). Por último, el CP2 obtenido a partir de la imagen de agosto también tiene una relación directa con la variable biomasa residual, debido a que este neocanal ha sintetizado información de la imagen referente a la actividad vegetal como los índices de vegetación.

Un aspecto que se ha revelado como importante en la búsqueda de modelos de regresión logística y modelos de regresión lineal múltiple en el anterior capítulo es el alto grado de auto-correlación existente entre las variables que mejores relaciones tenían con la biomasa residual forestal. Esta situación impedía el ajuste de modelos de regresión compuestos por varias variables, lo que restaba potencial de predicción. Así pues, se impone aquí comprobar si también existe una alta auto-correlación entre las variables radiométricas obtenidas en las imágenes de julio de 1993 y agosto de 1994, para saber si se va a repetir esta situación.

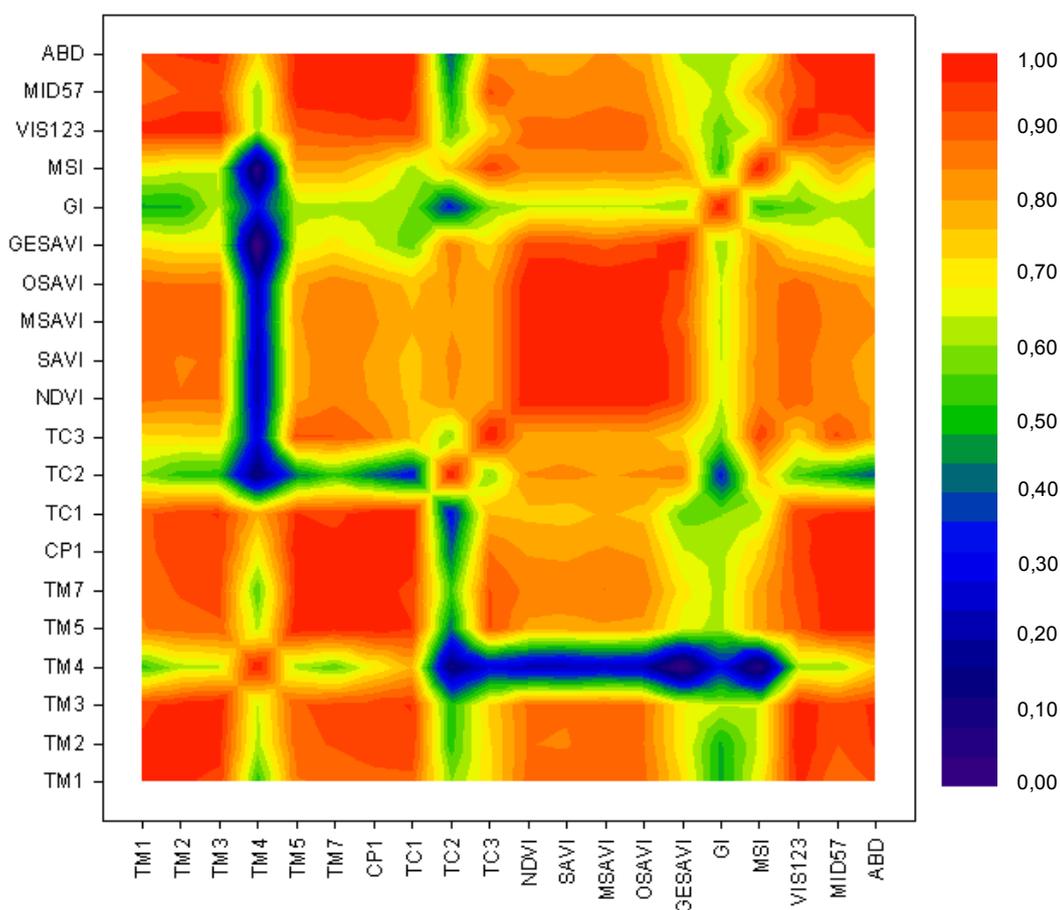


Figura 4.1. Auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual en el grupo del percentil 10 de la imagen de julio de 1993

Las Figuras 4.1 y 4.2 muestran cómo considerando todas las parcelas (grupo del percentil 10), al igual que con la imagen de junio de 1994, las variables radiométricas mejor correlacionadas con la biomasa residual -las relacionadas con la humedad y los índices de vegetación- se encuentran muy correlacionadas entre sí. Esta auto-correlación aumenta en los siguientes grupos con menos parcelas, es decir a medida que lo hace la homogeneidad radiométrica de las parcelas. En definitiva, es altamente improbable que dos de estas variables aparezcan conjuntamente en un modelo de regresión múltiple si se emplea un grupo de parcelas caracterizado por su baja heterogeneidad y, por tanto, que presenta buenas correlaciones con la biomasa residual.

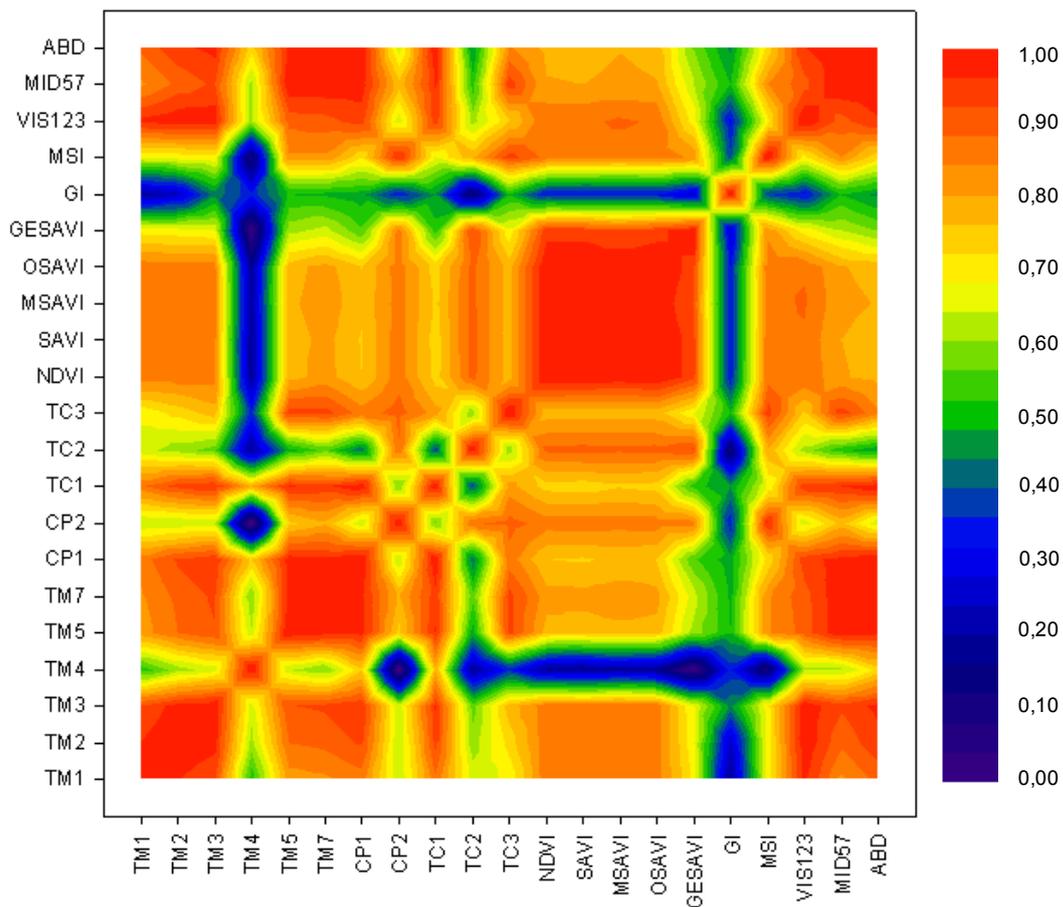


Figura 4.2. Auto-correlaciones existentes entre las variables independientes que presentan una correlación significativa con la biomasa residual en el grupo del percentil 10 de la imagen de agosto de 1994

Por otro lado, la auto-correlación entre las variables bien relacionadas con la biomasa y las que lo están menos es algo menor, aunque también aumenta con la homogeneidad radiométrica de la muestra, con lo que sí es posible que alguna de estas

variables aparezca como complementaria en modelos de regresión multivariantes, aunque su aportación a la capacidad predictiva del modelo será escasa con respecto a la participación de la primera variable. De esta manera, se puede anticipar antes de abordar el ajuste de modelos de regresión lineal múltiple que, al igual que lo acaecido con la imagen de junio de 1994, la nota predominante será la obtención de modelos de regresión univariantes, pudiéndose ajustar con alguna de las muestras aleatorias alguno compuesto por dos variables independientes sobre el que habrá que analizar si se cumple el supuesto no colinealidad, básico de este tipo de regresión.

Teniendo en cuenta todos estos resultados, como en el caso de la información radiométrica de la imagen de junio de 1994, sólo se podrán obtener modelos estimativos precisos de la biomasa residual considerando un grupo de parcelas que contenga un número suficientemente representativo para todo el área de estudio, estando estas parcelas caracterizadas por tener un entorno radiométrico homogéneo, por cuanto:

- En los grupos con parcelas de entornos heterogéneos, las correlaciones entre la biomasa residual y las variables radiométricas no parecen suficientes para conseguir ajustar una ecuación de regresión simple con un coeficiente de determinación importante. Además, debido a la alta auto-correlación existente entre las variables mejor correlacionadas y al escaso poder de predicción de las restantes, no resulta factible obtener un modelo lineal múltiple que mejore estos modelos simples. Estas circunstancias restringen el análisis de regresión a los grupos de parcelas que contienen las correlaciones más altas.
- La consideración de un escaso número de parcelas puede hacer que la ecuación de regresión quede sobre-ajustada a la muestra, no siendo representativa para todo el territorio que se quiere modelizar. Así pues, debe elegirse el grupo de parcelas, entre los que presentan las correlaciones más altas, que contenga una mayor muestra.

Esta doble premisa, como sucedía con la imagen de junio de 1994, vuelve a darse en el grupo del percentil 4, el identificado a lo largo de todo el capítulo como clúster 3. En este grupo, representante de un elevado grado de homogeneidad radiométrica de las parcelas, las variables relacionadas con la humedad y los índices de vegetación NDVI, SAVI, MSVI y OSAVI presentan correlaciones con la biomasa residual superiores a 0,744 en el caso de la imagen de julio y a 0,723 en la imagen de agosto, conservándose un número de parcelas similar al que se ha mostrado como suficientemente representativo

para todo el área de estudio y el mejor en los análisis llevados a cabo con la imagen de junio en el Capítulo 3.

En consecuencia, en el siguiente apartado se aborda el ajuste de modelos de regresión simple y lineales múltiples únicamente sobre el grupo de parcelas que conforman el grupo del percentil 4.

4.1.3. Ajuste de modelos de regresión con las imágenes de julio de 1993 y agosto de 1994

4.1.3.1. Modelos de regresión simple

A pesar de que, *a priori*, se conoce que los modelos de regresión simple que van a arrojar los mejores R^2 son los que se van a ajustar con las variables radiométricas relacionadas con la humedad y con los índices de vegetación NDVI, SAVI, MSVI y OSAVI, el contexto de validación en el cual se circunscribe este capítulo hizo que se calcularan modelos para todas las variables radiométricas con relación estadística significativa, tanto en la imagen de julio de 1993 como en la de agosto de 1994.

Al igual que en apartados anteriores donde se ha abordado el establecimiento de modelos de regresión, para cada variable se calcularon cinco de ellos utilizando cinco muestras aleatorias del 80% de las parcelas que componen el percentil 4 de las dos imágenes analizadas, reservando el restante 20% para la validación. Antes de realizar estas divisiones en las dos muestras se comprobó si estaba presente alguna de las tres parcelas de comportamiento atípico detectadas para la imagen de junio de 1994 por no corresponderse la realidad descrita en el IFN-2 con la observada en las ortofotografías aéreas de alta resolución y con la información radiométrica de la imagen (parcelas 286, 340 y 426). Así, se comprobó la presencia de la parcela 286 en la muestra de la imagen de julio y de la 340 en la de agosto, por lo que retiraron. De esta manera, la muestra de la imagen de julio quedó compuesta por un total de 68 parcelas y la de agosto por 53.

Las Tablas 4.5. y 4.6 recogen para las variables derivadas de la imagen de julio y agosto, respectivamente, el mejor de los modelos calculado en cada una. Es de destacar que casi todos los modelos obtenidos con las cinco muestras de las distintas variables resultaron significativos tanto a nivel de modelo como a nivel de sus coeficientes de regresión. La única salvedad la constituyen los ajustados con CP3, en el caso de la imagen de julio, y con TM4, en las dos imágenes. Esto se debe a que, aunque estas dos variables son estadísticamente significativas en este grupo y, por tanto, son incluidas en

este análisis de regresión, esta significación es -como se ha indicado en el anterior apartado- fruto del azar, ya que ninguna de ellas tiende a ser significativa en los grupos de parcelas más homogéneos de las dos imágenes. Dejando a un lado estas dos variables, otro hecho positivo a destacar es que el ajuste obtenido en los distintos modelos calculados varió muy poco, lo que es indicador de la estabilidad de los mismos y expresa la robustez de los recogidos en estas tablas.

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM1	Exponencial	0,642	0,741	214,208	-0,678
TM2	Exponencial	0,661	0,721	155,158	-0,480
TM3	Exponencial	0,674	0,707	96,612	-0,381
TM4	Logarítmico	0,092	12,868	90,010	-25,939
TM5	Exponencial	0,730	0,644	180,125	-0,180
TM7	Exponencial	0,730	0,644	91,410	-0,221
CP1	Exponencial	0,714	0,662	206,537	-0,122
TC1	Logarítmico	0,501	9,542	205,590	-53,499
TC2	Logarítmico	0,382	10,612	-28,985	25,854
TC3	Exponencial	0,719	0,656	91,778	0,284
NDVI	Potencia	0,665	0,716	194,984	4,313
SAVI	Potencia	0,661	0,721	37,519	4,345
MSAVI	Potencia	0,672	0,709	142,583	6,354
OSAVI	Potencia	0,664	0,718	202,243	4,324
GESAVI	Logarítmico	0,558	8,979	10,287	19,592
GI	Lineal	0,501	9,541	17,674	191,977
MSI	Lineal	0,625	8,269	57,161	-45,701
VIS123	Exponencial	0,672	0,710	142,667	-0,164
MID57	Exponencial	0,733	0,640	134,338	-0,099
ABD	Exponencial	0,689	0,690	265,395	-0,054

Tabla 4.5. Modelos de regresión simple calculados para el grupo de parcelas del percentil 4 con las variables derivadas de la imagen de julio de 1993: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

Como se observa en estas tablas, los modelos ajustados con las variables relacionadas con el contenido de humedad TM5, TM7, MID57 y TC3 son -en las dos imágenes- los que alcanzan unos coeficientes R^2 más elevados, utilizándose en todos ellos una ecuación exponencial. Además, es de destacar que el valor de estos coeficientes es muy parecido, siendo todos ellos $>0,7$, umbral sólo superado por el modelo ajustado con la variable CP1 en la imagen de julio. Ninguno de los índices de vegetación destacados como los mejores en su relación con la variable dependiente logra superar este umbral de 0,7, presentando los modelos ajustados con los neocanales CP1,

ABD y TM3 en la imagen de julio mayores R^2 que los obtenidos en los modelos de estos índices. Por último, señalar que los modelos ajustados con la variable MSI, la más correlacionada con la biomasa residual en ambas imágenes, ocupan un lugar intermedio en cuanto a capacidad de predicción en la imagen de julio y algo superior en la de agosto, utilizándose en cada caso un modelo distinto.

Variable	Tipo de modelo	R^2	S_e	β_0	β_1
TM1	Logarítmico	0,489	9,953	90,214	-42,592
TM2	Exponencial	0,587	0,791	201,616	-0,451
TM3	Exponencial	0,648	0,729	166,770	-0,370
TM4	Logarítmico	0,132	12,973	106,719	-31,708
TM5	Exponencial	0,710	0,662	210,699	-0,179
TM7	Exponencial	0,732	0,637	115,265	-0,220
CP1	Exponencial	0,667	0,710	357,529	-0,123
CP2	Exponencial	0,650	0,728	2,895	0,350
TC1	Logarítmico	0,487	9,975	217,607	-56,020
TC2	Logarítmico	0,404	10,754	-15,965	22,886
TC3	Exponencial	0,724	0,646	103,820	0,294
NDVI	Potencia	0,685	0,691	579,420	4,471
SAVI	Potencia	0,682	0,694	105,423	4,509
MSAVI	Potencia	0,691	0,684	344,799	6,197
OSAVI	Potencia	0,684	0,692	603,036	4,483
GESAVI	Logarítmico	0,512	9,730	23,000	22,858
GI	Exponencial	0,247	1,067	27,083	17,532
MSI	Logarítmico	0,680	7,876	12,422	-49,167
VIS123	Exponencial	0,622	0,756	244,374	-0,159
MID57	Exponencial	0,723	0,647	162,864	-0,099
ABD	Exponencial	0,667	0,710	353,447	-0,054

Tabla 4.6. Modelos de regresión simple calculados para el grupo de parcelas del percentil 4 con las variables derivadas de la imagen de agosto de 1994: tipo de modelo, coeficiente de determinación, error estándar y coeficientes de regresión

De esta manera, los resultados obtenidos en este análisis de regresión simple confirman los obtenidos a lo largo del Capítulo 3 con la imagen de junio de 1994 respecto de que las variables TM5, TM7, MID57 y TC3 son las más adecuadas para estimar biomasa residual forestal mediante imágenes Landsat, ya que, además de ser las que mayor R^2 alcanzan, los coeficientes son similares en las tres imágenes, utilizando las respectivas parcelas del grupo del percentil 4 (Tabla 4.7), empleando además el mismo tipo de modelo en el ajuste con coeficientes de regresión casi idénticos para la variable explicativa. Estos tres hechos indican que, al menos con los datos manejados hasta

ahora, la relación biofísica entre estas variables y el parámetro forestal estudiado es sólida e independiente del momento de adquisición de la imagen dentro del verano.

Variable	R^2 en junio de 1994	R^2 en julio de 1993	R^2 en agosto de 1994
TM5	0,764	0,730	0,710
TM7	0,766	0,730	0,732
TC3	0,743	0,719	0,724
MID57	0,767	0,733	0,723

Tabla 4.7. Comparación de los R^2 obtenidos en los modelos de regresión simple ajustados con las variables TM5, TM7, TC3 y MID57 para las parcelas incluidas en el grupo del percentil 4 de las imágenes de junio de 1994, julio de 1993 y agosto de 1994

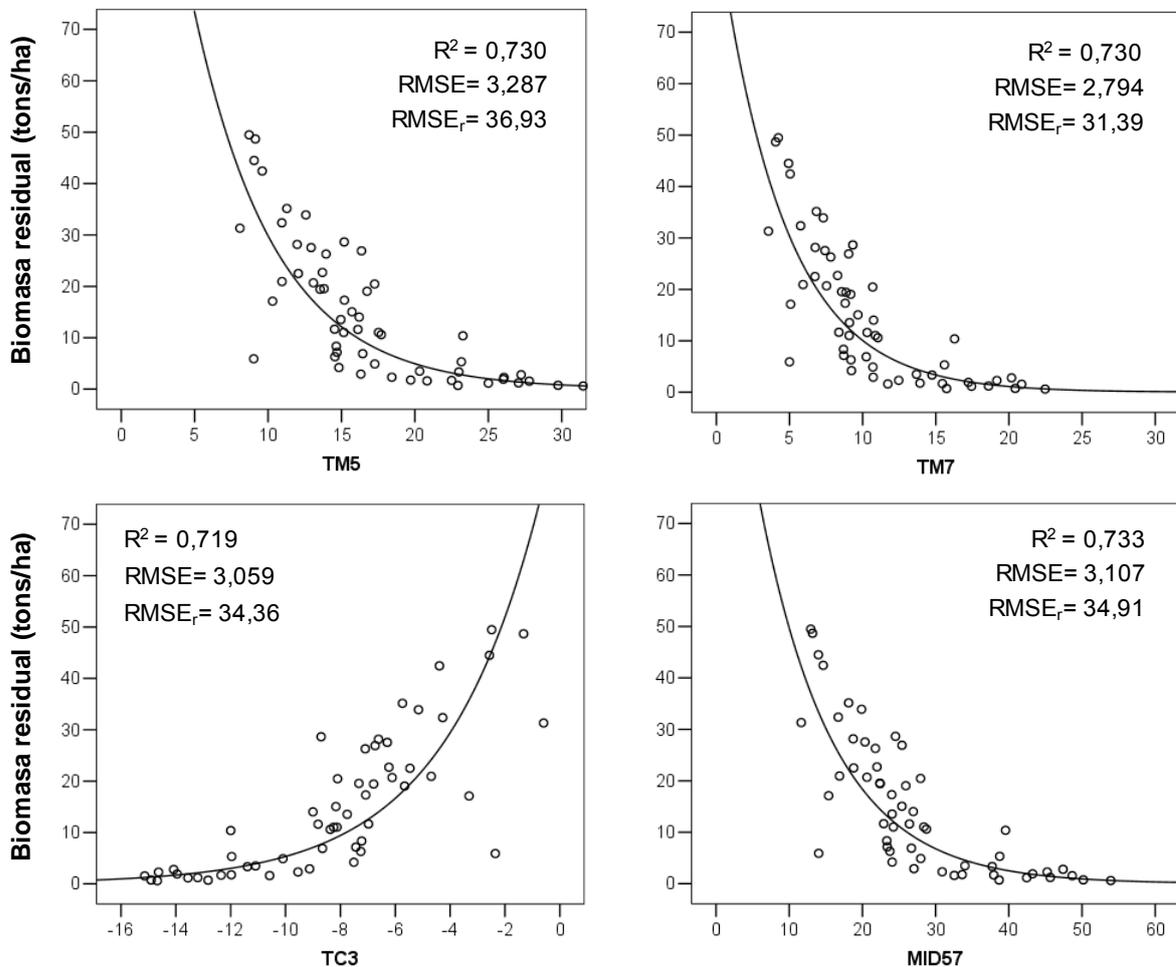


Figura 4.3. Gráficos de dispersión de los cuatro modelos con mayor capacidad predictiva de la Tabla 4.5 (imagen de julio de 1993)

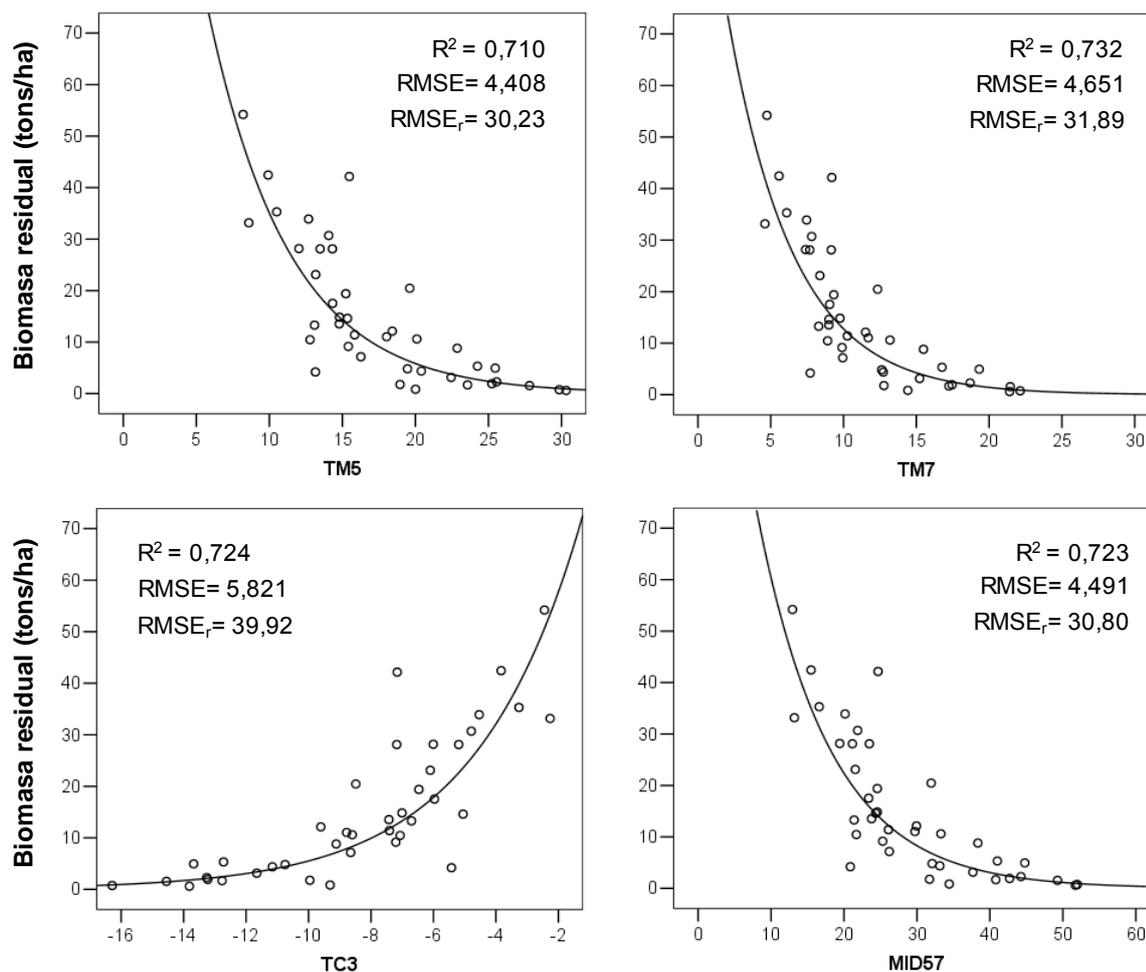


Figura 4.4. Gráficos de dispersión de los cuatro modelos con mayor capacidad predictiva de la Tabla 4.6 (imagen de agosto de 1994)

Para tener mayor certeza en la anterior afirmación, se calcularon los errores de estimación de los cuatro modelos de estas variables en cada imagen con sus respectivas muestras de validación del 20%. Tal y como se observa en los gráficos de dispersión (Figuras 4.3 y 4.4), todos los modelos presentan $RMSE$ bajos, siendo sólo >5 tons/ha el ajustado con la TC3 en la imagen de agosto. De forma análoga, los $RMSE_r$ que nos permiten comparar directamente el error de los modelos son también bajos, todos ellos entre el 30% y el 40%. También dentro de este intervalo se situaban 3 de los 4 $RMSE_r$ obtenidos con estas variables para el grupo de parcelas del percentil 4 en la imagen de junio de 1994, siendo la única excepción el alcanzado con la variable TC3, que rozaba el 46%. Este parámetro vuelve a confirmar la solidez de la relación biofísica de estas variables con la biomasa residual forestal del área de estudio sin que la fecha de captura de la imagen tenga incidencia, siempre que ésta se sitúe en uno de los meses del verano. Por último, como se observa en los gráficos de dispersión, las funciones ajustadas presentan niveles de saturación como los observados con estas variables en la imagen de junio de 1994, alrededor de las 40 tons/ha.

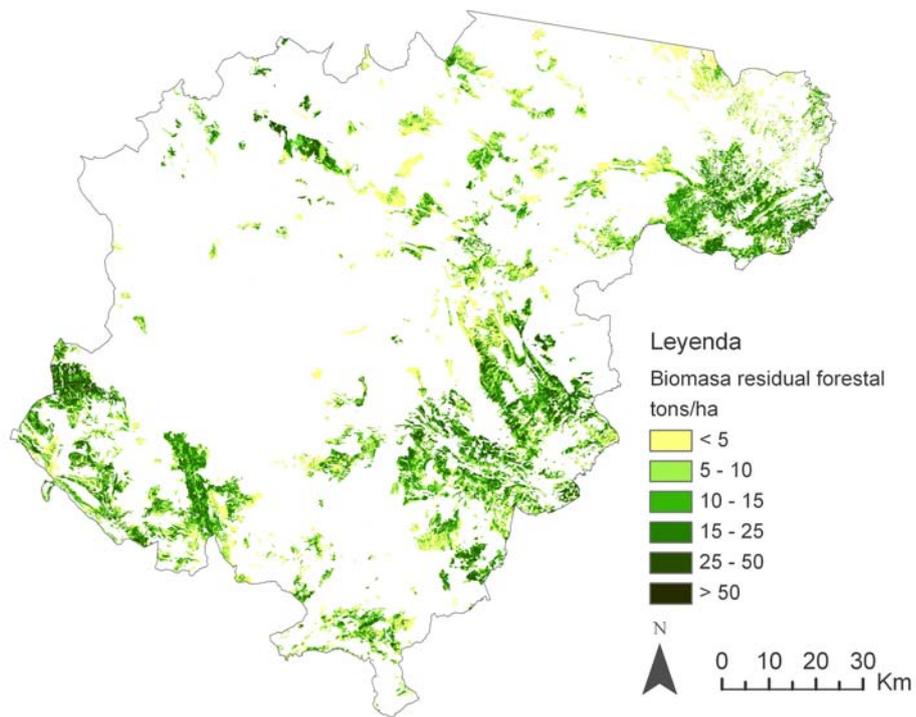


Figura 4.5. Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CV en la imagen de julio de 1993

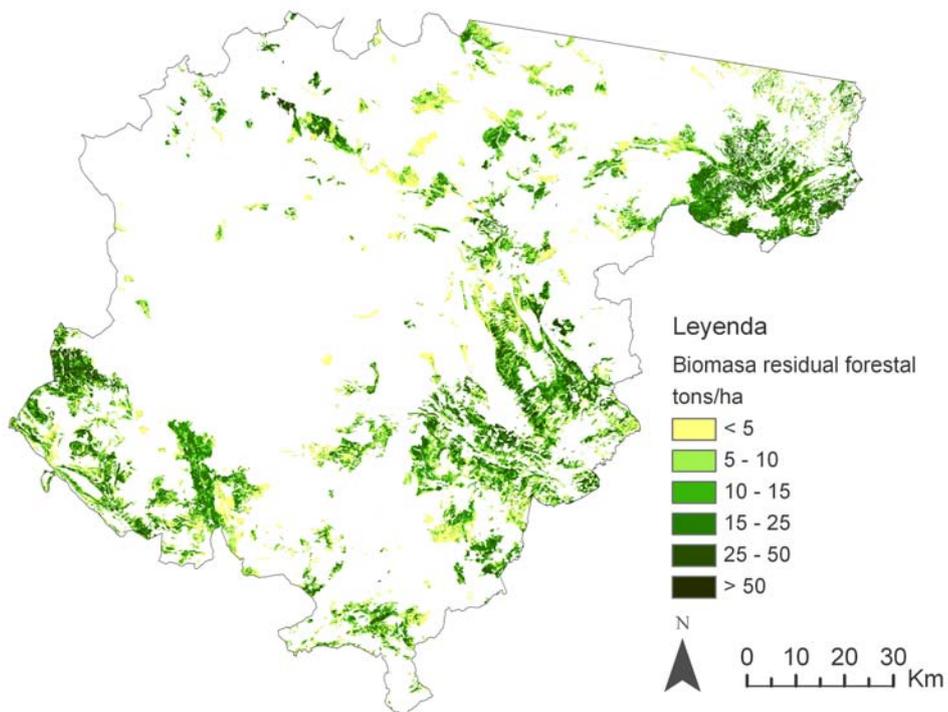


Figura 4.6. Cartografía de biomasa residual forestal obtenida mediante regresión curvilínea usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CV en la imagen de agosto de 1994

Dada la similitud existente entre los modelos de estimación obtenidos con estas cuatro variables en cada imagen, cualquiera de ellos es válido para cartografiar la biomasa residual del área de estudio. Sin embargo, dado que fue el modelo ajustado con la variable MID57 el que se utilizó para obtener la cartografía de estimación con el grupo de parcelas del percentil 4 en la imagen de junio de 1994, se utilizan también los respectivos modelos de esta variable para obtener las cartografías a partir de las imágenes de julio de 1993 y de agosto de 1994, haciendo directamente comparables los resultados que se obtengan del proceso de validación de estas cartografías (Figuras 4.5 y 4.6).

4.1.3.2. Modelos de regresión lineal múltiple

Como en el resto de apartados en los que se ha abordado el ajuste de modelos de regresión lineal múltiple, el primer paso para hacerlo con la información obtenida en las imágenes de julio de 1993 y agosto de 1994 fue la comprobación de los cuatro supuestos básicos inherentes a la aplicación de este tipo de regresión. En este contexto, las Tablas 4.8 y 4.9 muestran los resultados de las pruebas de normalidad aplicadas a cada una de las variables espectrales derivadas de estas dos imágenes y a la variable dependiente, así como las transformaciones aplicadas en caso de incumplimiento de este supuesto.

Un hecho a reseñar, que ha sido marcado en las tablas mediante la adición de un asterisco en la columna test *K-S* de estas tablas, es que en algunas ocasiones las variables superan este estadístico de normalidad sin que las pruebas gráficas se ajusten a esta situación. En estos casos se optó por transformar estas variables para asegurar el cumplimiento del supuesto tanto en las pruebas gráficas como en las estadísticas. Esta circunstancia se da, sobre todo, en los índices de vegetación mejor correlacionados con la biomasa residual en la imagen de julio.

Tal y como se observa en las tablas, las transformaciones requeridas por las distintas variables son semejantes en ambas imágenes, consiguiéndose o mejorándose la distribución normal en casi todos los casos. Así, la raíz cuadrada es, en ambos casos, la transformación más adecuada para la variable biomasa residual, consiguiéndose la normalidad en la imagen de agosto y, prácticamente, en la imagen de julio. El logaritmo es la más apropiada para las bandas originales, para los neocanales CP1, VIS123 y MID57 y la inversa para TC1 y ABD. Las discrepancias se producen simplemente en la variable GSAVI, ya que en el resto de variables no es necesario aplicar ninguna transformación en las procedentes de la imagen de agosto, dado que cumplen este supuesto y muchas de las que se aplican en las variables de julio son simplemente para mejorar la distribución calificada como normal con el estadístico *K-S*.

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Casi normal
TM1	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM4	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM5	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TC1	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Casi normal
TC2	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
TC3	Casi normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
SAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
MSAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
OSAVI	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	Si*	Normal	Logaritmo	Normal
GESAVI	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Inversa	Normal
GI	Casi normalidad	Casi normalidad	Positiva	Leptocúrtica	No	No normal	Raíz cuadrada	Normal
MSI	Casi normalidad	Casi normalidad	Negativa	Mesocúrtica	Si*	Normal	Cuadrado	Normal
VIS123	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal

Tabla 4.8. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en percentil 4 de la imagen de julio de 1993

Variable	Métodos gráficos		Métodos estadísticos			Diagnóstico		
	Histograma	G. Normalidad	Asimetría	Curtosis	Test K-S	Descripción	Transformación	Norm. posterior
Biomasa resid.	No normalidad	No normalidad	Positiva	Mesocúrtica	No	No normal	Raíz cuadrada	Normal
TM1	No normalidad	Casi normalidad	Simétrica	Mesocúrtica	No	No normal	Logaritmo	Normal
TM2	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM3	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM4	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	Si*	Normal	Logaritmo	Normal
TM5	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
TM7	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
CP2	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
TC1	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal
TC2	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
TC3	Casi normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
NDVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
SAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
OSAVI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
GESAVI	No normalidad	No normalidad	Positiva	Leptocúrtica	No	No normal	Logaritmo	Normal
GI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
MSI	Normalidad	Normalidad	Simétrica	Mesocúrtica	Si	Normal	-	-
VIS123	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
MID57	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Logaritmo	Normal
ABD	Casi normalidad	Casi normalidad	Positiva	Mesocúrtica	No	No normal	Inversa	Normal

Tabla 4.9. Pruebas de normalidad aplicadas a la variable dependiente biomasa residual forestal y a las variables independientes correlacionadas con ella en en percentil 4 de la imagen de agosto de 1994

Estos resultados del análisis de normalidad son análogos a los obtenidos en el Capítulo 3 con las parcelas del percentil 4 (clúster 3) en la imagen de junio de 1994, sobre todo los de la imagen de agosto. Así pues, este hecho apunta también en la dirección de la replicabilidad de la metodología que se está evaluando a lo largo de este capítulo.

Al igual que con la imagen de junio de 1994, los gráficos de dispersión creados para las dos imágenes ahora analizadas entre la variable transformada de la biomasa residual y las radiométricas normales o normalizadas permitieron identificar que la única variable que no cumplía, en su relación con la biomasa, los supuestos de homocedasticidad y linealidad era inv_TC1 . Así pues, ésta fue la única variable no tenida en cuenta en el ajuste de los 5 modelos de regresión por pasos que se calcularon para cada imagen.

La Tabla 4.10 muestra los modelos obtenidos con cada una de las cinco muestras del 80% de las parcelas para la imagen de julio de 1993 en los que las variables que los componen resultaron significativas. Como se puede observar, solamente uno de los modelos ajustados (N_2) utiliza más de una variable, concretamente MID57 y MSI. No obstante, como era esperado dado que estas dos variables están relacionadas con el contenido de agua de la vegetación, el índice de condición superior de este modelo está muy por encima del valor definido como umbral máximo para cumplir el supuesto de no-colinealidad.

Modelo-Muestra	R^2_a	S_e	Índice de condición superior	Variables	β	Sig.
N ₁	0,702	0,923	10,614	ln_TM7	-3,219	0,000
				Constante	10,678	0,000
N ₂	0,711	0,941	47,451	ln_MID57	-2,276	0,008
				cd_MSI	-1,628	0,041
				Constante	12,276	0,000
N ₃	0,731	0,919	10,569	ln_TM7	-3,476	0,000
				Constante	11,256	0,000
N ₄	0,696	0,927	18,497	ln_MID57	-3,928	0,000
				Constante	16,113	0,000
N ₅	0,718	0,940	17,628	ln_MID57	-4,043	0,000
				Constante	16,481	0,000

Tabla 4.10. Modelos de regresión múltiple calculados con el grupo de parcelas del percentil 4 de la imagen de julio de 1993: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables

De esta manera, como se ha hecho en anteriores ocasiones, este modelo es reducido a la variable seleccionada en primer lugar (Tabla 4.11). Como resultado, todos los modelos lineales obtenidos en la imagen de julio resultaron ser finalmente univariantes. El análisis de los residuos de estos cinco modelos mostró que todos ellos cumplían los supuestos básicos de la regresión lineal, por los que todos son válidos para obtener la cartografía de estimación.

Modelo-Muestra	Variabes	R^2_a	S_e	β_0	β_1
N ₂	ln_MID57	0,693	0,969	15,953	-3,858

Tabla 4.11. Modelo de regresión calculado para las muestra N₂ de la imagen de julio de 1993 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

En definitiva, de todas las variables radiométricas consideradas, los modelos lineales ajustados sólo hacen uso de TM7 y MID57, dos de las tres variables utilizadas en los modelos ajustados por este mismo procedimiento con la imagen de junio de 1994 (la otra fue TM5). Además, los modelos lineales obtenidos con ambas imágenes tienen una capacidad predictiva similar, ya que los coeficientes de determinación alcanzados con la imagen de julio de 1993 oscilan entre 0,693 y 0,731 y los de la imagen junio de 1994 entre 0,711 y 0,750.

La Figura 4.7 recoge, junto a los gráficos de dispersión de cada uno de los cinco modelos ajustados en este apartado, los errores de predicción calculados con sus respectivas muestras de validación. Como se observa, todos los modelos presentan errores absolutos y relativos parecidos, oscilando entre 5'8 y 8,5 tons/ha y entre el 47% y el 60%, respectivamente. La diferencia con respecto a los modelos ajustados en la imagen de junio teniendo en cuenta estos valores es algo mayor que cuando se comparaba el coeficiente de determinación de las ecuaciones. Así, los errores de los modelos de la imagen de julio presentan errores de estimación algo mayores.

Para generar la cartografía de biomasa residual del área de estudio para julio de 1993, representante de estos modelos de regresión lineal, se eligió uno de los modelos ajustados con la variable MID57, ya que son los que más se repiten y fue ésta también la variable seleccionada con la imagen de junio de 1994. Dentro de éstos se seleccionó el ajustado con la muestra N₅ (Figura 4.8).

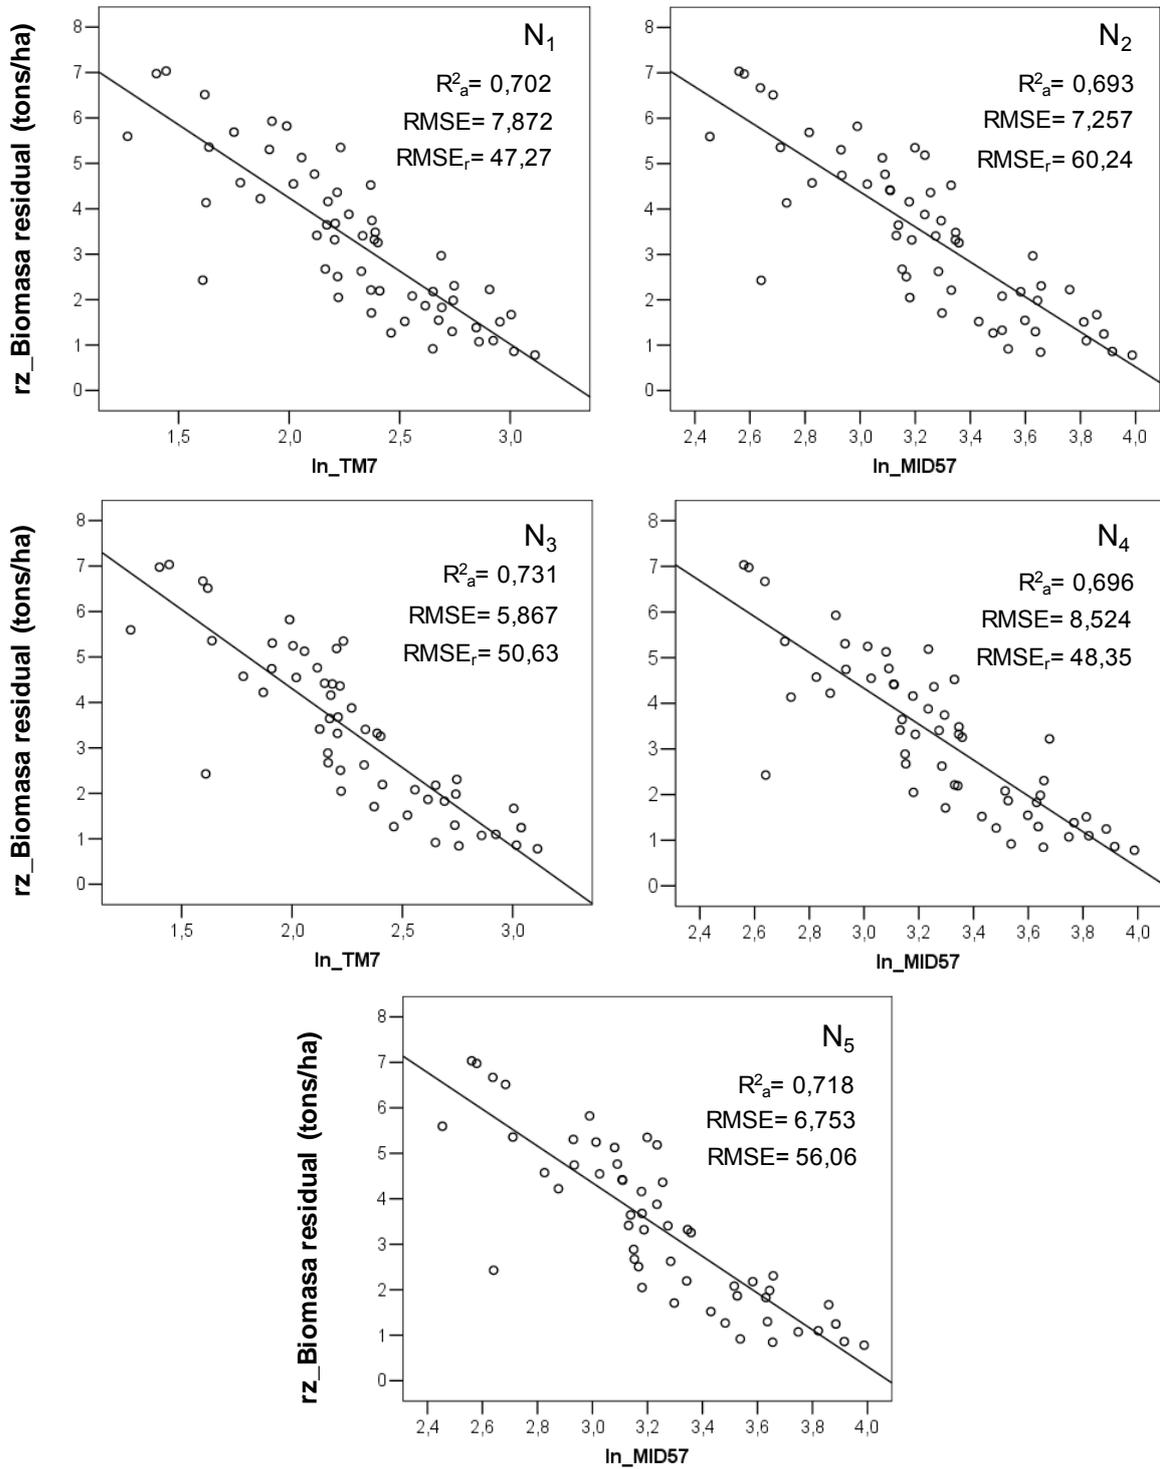


Figura 4.7. Gráficos de dispersión de los modelos de regresión lineal univariantes de las Tablas 4.10 y 4.11

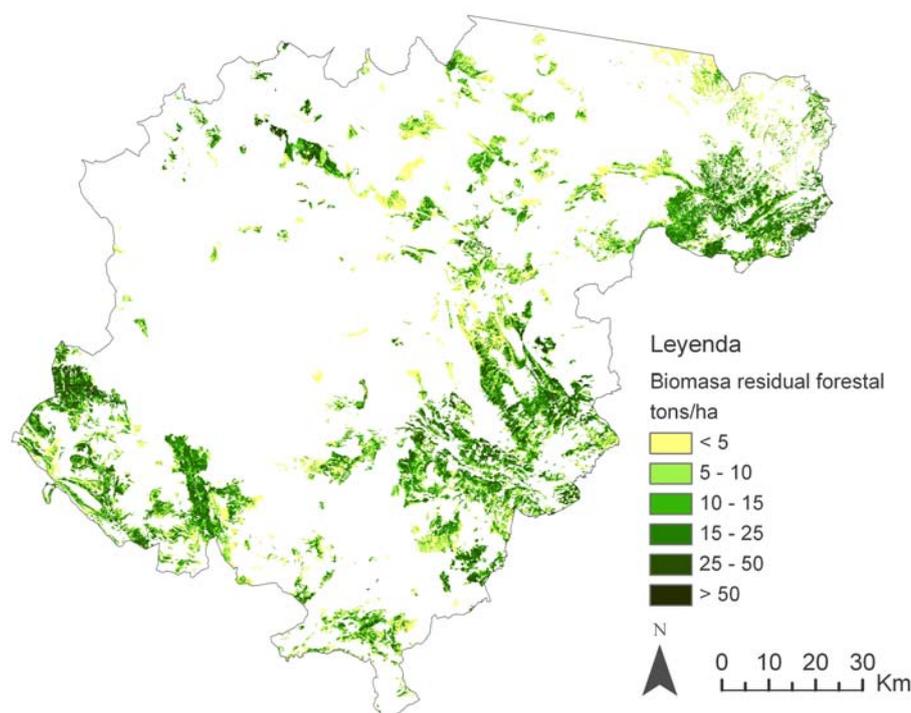


Figura 4.8. Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CV en la imagen de julio de 1993

En el caso de la imagen de agosto, los cinco modelos obtenidos quedaron compuestos por dos variables (Tabla 4.12). En todos los casos, el modelo por pasos seleccionó en primer lugar la variable TM7, siendo complementado en el segundo paso por la variable TM4 en tres de las ocasiones y por TC2 en las otras dos. Sin embargo, tal y como se observa en la Tabla 4.12, el índice de condición superior de los modelos que utilizan la variable TM4 sobrepasa el valor máximo permitido para asegurar que no existe co-linealidad en el modelo, por lo que no son válidos. Además, independientemente de que esta circunstancia anule directamente la validez de estos modelos, otro factor que desaconsejaba su consideración era la debilidad de la significación estadística de la relación entre la banda TM4 y la biomasa residual. Esta banda fue incluida como posible en los modelos de este apartado porque en el grupo de parcelas considerado, el del percentil 4, esta relación sí era significativa. Sin embargo, ésta era la única excepción en los grupos que recogen las parcelas con entornos radiométricos relativamente homogéneos o muy homogéneos. Así pues, estos tres modelos fueron eliminados, quedando el univariante ajustado por la variable seleccionada en primer lugar por el método de pasos *hacia delante* (Tabla 4.13).

Modelo-Muestra	R^2_a	S_e	Índice de condición superior	Variables	β	Sig.
N ₁	0,752	0,862	54,831	In_TM7	-4,744	0,000
				In_TM4	2,517	0,032
				Constante	7,563	0,008
N ₂	0,742	0,874	55,877	In_TM7	-4,845	0,000
				In_TM4	3,060	0,015
				Constante	6,333	0,028
N ₃	0,779	0,758	24,419	In_TM7	-2,941	0,000
				TC2	0,237	0,010
				Constante	9,520	0,000
N ₄	0,744	0,851	24,074	In_TM7	-3,015	0,000
				TC2	0,278	0,017
				Constante	9,554	0,000
N ₅	0,732	0,911	53,814	In_TM7	-4,346	0,000
				In_TM4	2,518	0,043
				Constante	6,581	0,029

Tabla 4.12. Modelos de regresión múltiple calculados con el grupo de parcelas del percentil 4 de la imagen de agosto de 1994: muestra de parcelas sobre la que se ha calculado, coeficiente de determinación ajustado, error estándar, índice de condición superior obtenido en las dimensiones en las que se descompone el modelo, variables seleccionadas y coeficientes y significación estadística de esas variables

Modelo-Muestra	Variables	R^2_a	S_e	β_0	β_1
N ₁	In_TM7	0,727	0,903	13,258	-4,105
N ₂	In_TM7	0,705	0,934	12,988	-3,963
N ₅	In_TM7	0,708	0,951	12,372	-3,741

Tabla 4.13. Modelos de regresión calculados para las muestras N₁, N₂ y N₅ de la imagen de agosto de 1994 al eliminar la variable introducida en el segundo paso: muestra de parcelas sobre la que se ha calculado, variable seleccionada, coeficiente de determinación ajustado, error estándar y coeficientes de regresión

A diferencia de lo que ocurría siguiendo esta metodología con las imágenes de junio de 1994 y de julio de 1993, con la de agosto de 1994 sí ha sido posible ajustar al menos dos modelos de regresión lineal con más de una variable que cumplen el supuesto de no-colinealidad. Esto se debe a que en estos modelos se conjugan dos variables que ofrecen información distinta: sobre el contenido de agua de la vegetación la banda original TM7 y sobre el grado de actividad vegetal el neocanal TC2. Por otra parte, el análisis de los residuos en estos dos modelos también validó el cumplimiento de todos los supuestos del análisis multivariante.

Aun así, es necesario señalar que la adición de TC2 como segunda variable apenas mejora la capacidad de predicción en ambos modelos, ya que en ninguno de los dos casos el R^2_a aumenta más de un 0,04 con respecto al obtenido en el primer paso, cuando sólo se tiene en cuenta la variable TM7. Además de esto, conviene recordar que la adición de TC2 únicamente se ha producido en dos de los cinco modelos ajustados, es decir, que el ajuste de estos modelos no es la situación predominante en la muestra considerada.

De esta manera, la variable TM7 -una de las dos y tres con las que, respectivamente, se ajustan todos los modelos de regresión lineal de imágenes de julio y junio- se erige en esta ocasión como la mejor para estimar la biomasa residual. Con respecto a la capacidad predictiva de los cinco modelos obtenidos, el R^2_a oscila entre 0,705 y 0,779, con lo que es similar al de los ajustados anteriormente, en este apartado, con la imagen de julio y también a los ajustados con la de junio de 1993, aunque ligeramente superior debido a la presencia de los dos modelos que utilizan dos variables.

Con respecto al error de predicción de estos modelos, la Figura 4.9 y la Tabla 4.14 muestran los $RMSE$ y los $RMSE_r$ obtenidos con las pruebas de validación, que oscilan entre 5,337 y 9,968 tons/ha en el primer caso y entre el 36,16% y el 52,20% en el segundo. En ambos estadísticos los máximos vienen marcados por uno de los modelos bivariante ajustados, concretamente por el N_3 . Estos umbrales de $RMSE_r$ son del mismo orden que los obtenidos en los modelos de la imagen de junio de 1994 e inferior a los de la imagen de julio de 1993.

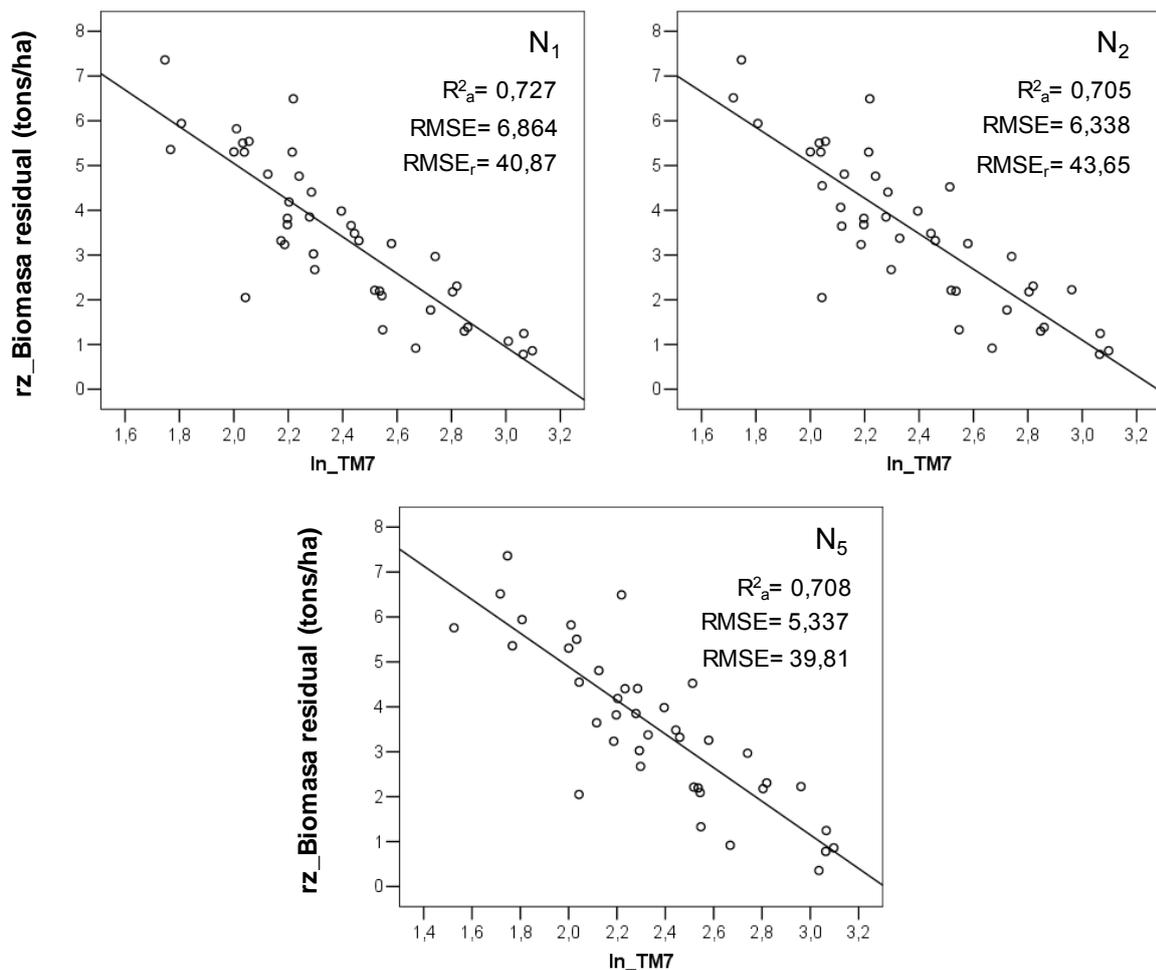


Figura 4.9. Gráficos de dispersión de los tres modelos de regresión lineal univariantes de la Tabla 4.13

Finalmente, para crear la cartografía de la biomasa residual representante de las ecuaciones de regresión lineal de la imagen de agosto, se seleccionó uno de los modelos univariantes, dado que éstos han sido los que más se han repetido en las cinco muestras. Dentro de ellos se eligió finalmente el ajustado con la muestra N_1 , por cuanto es el que presenta mejor relación entre el coeficiente de determinación y el error de predicción. La Figura 4.10 muestra el resultado de la aplicación de este modelo.

Modelo-Muestra	Variables	R^2_a	RMSE	RMSE _r
N_3	ln_TM7 y TC2	0,779	9,968	52,20
N_4	ln_TM7 y TC2	0,744	6,837	36,16

Tabla 4.14. RMSE de los modelos de regresión lineal múltiple de la Tabla 4.12

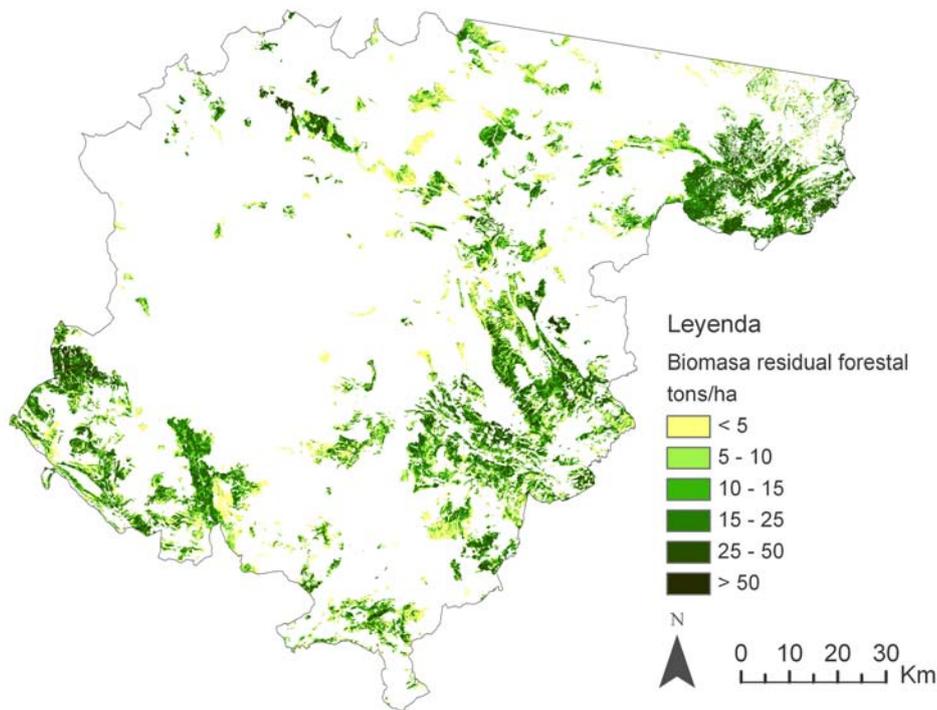


Figura 4.10. Cartografía de biomasa residual forestal obtenida mediante regresión lineal usando las parcelas del percentil 4 derivadas de la utilización del método de extracción de ventanas 3x3 y el CVU en la imagen de agosto de 1994

4.1.4. Validación de las cartografías de estimación obtenidas con las imágenes de julio de 1993 y agosto de 1994

Teniendo en cuenta los resultados obtenidos en la validación de las cartografías de estimación derivadas a partir de la imagen de junio, las 4 generadas en este capítulo son validadas considerando, para cada parcela, el valor de biomasa residual resultante de la media de los píxeles contenidos total o parcialmente en ella y utilizando como

muestra de validación las parcelas de sus respectivos grupos percentil 8, pudiéndose eliminar de este grupo las 5 que mayor diferencia presenten entre el valor real y el estimado, en caso de que se compruebe, mediante el uso de la fotografía de alta resolución, que no existe correspondencia entre este documento y el IFN-2. La siguiente tabla recoge la denominación que, en este apartado, se da a las cuatro cartografías obtenidas en el presente Capítulo 4.

Cartografía	Imagen empleada	Método de regresión utilizado	Nº de figura
Cartografía 1	Julio de 1993	Regresión simple	4.5
Cartografía 2	Agosto de 1994	Regresión simple	4.6
Cartografía 3	Julio de 1993	Regresión lineal múltiple	4.8
Cartografía 4	Agosto de 1994	Regresión lineal múltiple	4.10

Tabla 4.15. Denominación utilizada para designar las cartografías obtenidas en el Capítulo 4 dependiendo de la imagen empleada y del método de regresión utilizado

Las parcelas 508, 1135 y 1885, como en la imagen de junio de 1994, fueron eliminadas de las muestras de validación de la imagen de julio de 1993. Dado que la parcela 508 no existía en las muestras de la imagen de agosto, se suprimió la 37 junto a las 1135 y 1885. La Tabla 4.16 muestra el número final de parcelas de validación utilizado en cada cartografía y los resultados obtenidos.

Cartografía	Nº de parcelas⁴⁹	RMSE (tons/ha)	RMSE_r (%)
Cartografía 1	187	9,954	64,28
Cartografía 2	211	9,997	61,16
Cartografía 3	189	10,222	64,29
Cartografía 4	208	10,894	65,97

Tabla 4.16. Número de parcelas empleado para la validación de las cartografías de estimación de biomasa residual creadas en el Capítulo 4 y errores de estimación obtenidos

Como se observa en la tabla, el grado de precisión de las cuatro cartografías es casi idéntico. Así, la variación en el error absoluto entre estas cartografías es de <1 ton/ha, mientras que la variación de error relativo es inferior a cinco puntos. Además, hay que destacar que estas mínimas diferencias no están relacionadas con que se haya

⁴⁹ La ligera variación que se produce en el número de parcelas empleadas en la validación entre cartografías que han utilizado la misma imagen y el mismo grupo de parcelas, pero diferente método de regresión, se debe a la metodología empleada de ajustar cinco modelos de regresión a partir de cinco muestras distintas de, aproximadamente, el 80% de las parcelas consideradas. Esto hace que el número de parcelas utilizadas siempre varíe entre modelos.

utilizado una imagen u otra, ya que los dos extremos relativos se dan en las cartografías derivadas de la imagen de agosto, siendo el mínimo correspondiente a la utilización del modelo simple exponencial y el máximo al lineal univariante. Aun así, no se puede afirmar que un tipo de modelo sea mejor que otro, ya que, además de la escasa diferencia entre los ajustados con la imagen de agosto, los de la imagen de julio ofrecen resultados idénticos.

En cuanto a la comparación de los errores relativos de estas cartografías con los obtenidos con la imagen de junio de 1994 siguiendo la misma metodología de extracción de la información radiométrica, la Figura 4.11 muestra cómo apenas existen diferencias, ya que todos ellos se sitúan en el intervalo 60-68% de error. Uno de los detalles que se observa en este gráfico es que el error de las cartografías creadas a partir de modelos lineales parece más estable en el tiempo que el de las creadas con modelo curvilíneas. Así, la variación del $RMSE_r$ entre las cartografías de las tres fechas es solamente de 1,71 puntos porcentuales cuando se ha utilizado un modelo lineal, mientras que en las cartografías creadas con modelos exponenciales es de 6,31 puntos.

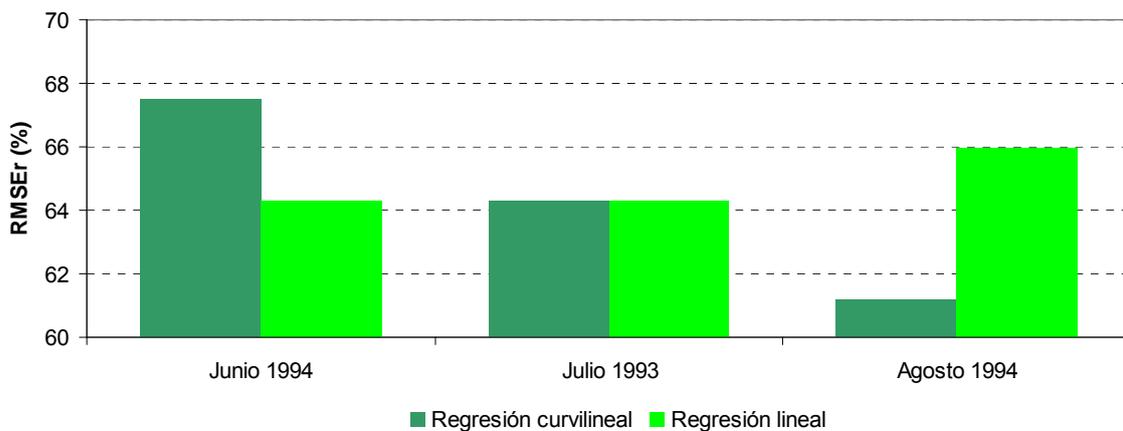


Figura 4.11. $RMSE_r$ obtenido en cada una de las cartografías de estimación derivadas de las tres imágenes disponibles con el método de extracción de las ventanas de 3x3 píxeles y CV considerando las parcelas incluidas en sus respectivos grupos del percentil 4

4.2. Análisis de la variación del contenido de humedad en los meses de junio, julio y agosto para las cuatro especies de pino consideradas

Dado que la reflectividad captada por los sensores ópticos espaciales está mucho más relacionada con el follaje que con las partes de madera de los pies arbóreos, la

estimación del contenido de humedad en los trabajos de teledetección está principalmente relacionada con las condiciones de la cubierta foliar. Además, el contenido de humedad del follaje es mucho más sensible para evaluar el contenido de agua de la planta (Chuvieco, 1999). En consecuencia, la variación en el contenido de humedad del follaje es la variable que se emplea en esta investigación para evaluar cómo es la variación del contenido de humedad de las especies consideradas a lo largo de la estación estival.

Como ya se ha indicado, el muestreo del contenido de humedad de las hojas de determinadas especies o cubiertas con objeto de ser relacionado con imágenes de satélite es una tarea costosa, tanto en tiempo como en dinero. Es por ello por lo que en la presente investigación se hace uso de datos disponibles en el Departamento de Geografía de Ordenación del Territorio. A continuación se refiere el origen de estos datos y la metodología seguida para obtenerlos.

4.2.1. Los datos de contenido de humedad

Los datos de contenido de humedad de la cubierta foliar de las cuatro pináceas consideradas fueron obtenidos en el marco del proyecto FIRERISK⁵⁰. El objetivo general de este proyecto, financiado por Plan Nacional de I+D+I (2000-2003, Ministerio de Ciencia y Tecnología), era desarrollar una metodología operativa a escala regional y local para la evaluación del riesgo de incendio forestal (en sus vertientes física y humana), así como su integración en documentos válidos para las labores de gestión forestal. Para ello, uno de los objetivos específicos era la estimación del contenido de humedad del combustible vivo a partir de imágenes de satélite, ya que esta variable es crítica para determinar tanto el riesgo de ignición como la velocidad de propagación de los incendios forestales.

Para el cumplimiento de este objetivo concreto se establecieron tres actividades: (i) muestreo periódico en el campo de la variable contenido de humedad de la vegetación (*Fuel Moisture Content, FMC*) en distintas parcelas dentro del territorio nacional; (ii) análisis radiométrico de los dominios vegetales de las áreas implicadas en el proyecto y establecimiento de modelos de reflectividad del dosel para permitir una interpretación

⁵⁰ FIRERISK: "Empleo de la Teledetección y los sistemas de información geográfica en la estimación del riesgo de incendios forestales: análisis integrado de factores naturales y socio-económicos". Proyecto de investigación liderado por el Dr. E. Chuvieco, Universidad de Alcalá (AGL2000-0842-C04-04, <http://www.geogra.uah.es/firerisk/index.html>).

más directa de las imágenes de satélite utilizadas; y (iii) estimación del *FMC* mediante la utilización de imágenes de resolución espacial baja y media. El muestreo de campo realizado desde el Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza se desarrolló –mediante un protocolo común a todo el proyecto (Chuvienco *et al.* (2003)- en la Cordillera Ibérica y en el Prepirineo durante la primavera y el verano de los años 2001 y 2002⁵¹.

Las cuatro parcelas de muestreo de la Cordillera Ibérica se ubicaron en las sierras paleozoicas del ramal zaragozano, cerca de la provincia de Teruel (Chuvienco *et al.*, 2004). De las especies de pino consideradas en esta tesis, *Pinus sylvestris*, *P. nigra* y *P. halepensis* aparecían representadas en las parcelas situadas en el Prepirineo (2 parcelas con *P. sylvestris*, 2 con *P. nigra* y 1 con *P. halepensis*), mientras que *P. pinaster* aparecía tan sólo en una de las delimitadas en la Cordillera Ibérica.

El protocolo de campo, en el caso de la vegetación arbórea, especificaba que había que recoger hojas-acículas en las diferentes partes del mismo individuo, siendo necesario coger hojas fundamentalmente de verticilos inferiores (1º y 2º), así como de los de coronación en la copa. Las muestras eran pesadas en el campo (peso húmedo) y posteriormente sometidas a secado (48 horas a 60°C) antes de su segunda pesada (peso seco). La Tabla 4.17 recoge el número de muestras finalmente disponibles por especie y mes del año.

Especie	nº muestras junio	nº muestras julio	nº muestras agosto	TOTAL
<i>P. sylvestris</i>	3	3	3	9
<i>P. halepensis</i>	2	2	2	6
<i>P. nigra</i>	3	3	3	9
<i>P. pinaster</i>	2	2	2	6
TOTAL	10	10	10	30

Tabla 4.17. Muestreo de campo realizado por el Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza en el marco del proyecto FIRERISK (Cordillera Ibérica y Prepirineo)

⁵¹ El muestreo se realizó cada 16 días desde principios de abril a finales de septiembre, coincidiendo con la periodicidad de paso del satélite Landsat. Las muestras se recogieron entre las 12 y las 16 horas, cuando la temperatura del aire es mayor y, por tanto, la vegetación está más afectada por el estrés hídrico. Este horario coincidía aproximadamente con el paso del satélite NOAA-AVHRR. No se tomaron muestras de vegetación en condiciones de lluvia o cuando las hojas aparecían mojadas.

4.2.2. Análisis de la variación del contenido de humedad

Con objeto de comprobar si existen diferencias significativas en el contenido de humedad de las especies de pino consideradas a lo largo de los meses de junio, julio y agosto, se recurrió a un modelo de análisis de la varianza (ANOVA). Este tipo de modelos permite explicar el comportamiento de una variable dependiente o respuesta de tipo continuo a partir de una o más variables independientes o predictoras categóricas (Pardo y Ruiz, 2005). En nuestro caso, la variable dependiente es el contenido de humedad y la variable predictora puede ser tanto el tipo de especie como el mes de verano o ambas a la vez.

Varios análisis de tipo ANOVA se pueden plantear como útiles para estudiar en profundidad cómo es la variación de contenido de humedad en las especies consideradas. Así, por ejemplo, resulta interesante comprobar si existen diferencias significativas de esta variable entre las especies dentro de un mismo mes o si estas especies se comportan igual a lo largo de los tres meses considerados, identificándose de esta manera si unas especies son menos estables que otras. Sin embargo, la escasez de la muestra disponible por especie y por mes impide este tipo de análisis, ya que los resultados obtenidos no serían representativos y carecerían de validez desde el punto de vista estadístico.

En consecuencia, el único análisis ANOVA que puede ser ajustado con ciertas garantías estadísticas es considerando toda la muestra de forma conjunta, independientemente de la especie, analizándose si existen diferencias significativas en el contenido humedad a lo largo de los tres meses de verano (Ecuación 35). Para efectuar este análisis, dado que existen 3 categorías en la variable predictiva, se utilizó la prueba *post-hoc* de Bonferroni para analizar las diferencias entre grupos.

$$FMC = \mu + \alpha_1(junio) + \alpha_2(julio) + \alpha_3(agosto) \quad \text{Ecuación 35}$$

donde *FMC* es el contenido de humedad, μ es el valor de la constante y α_1 , α_2 y α_3 son los coeficientes de regresión para los meses de junio, julio y agosto, respectivamente (adaptado de Pardo y Ruiz, 2005).

El resultado de este análisis es que no existen diferencias significativas en el contenido de humedad de las 4 especies consideradas a lo largo del periodo estival. Esta circunstancia se evidencia claramente en la Figura 4.12, que compara las barras de error

-dato medio $\pm 1,5$ desviaciones estándar- de la variable contenido de humedad obtenida en cada uno de los tres meses. Como se observa en este gráfico, el recorrido de la variable humedad en los tres meses presenta partes comunes, produciéndose solapamiento en todos ellos y no existiendo un rango de valores único para alguno de los meses. En este sentido, la mayor variabilidad en el contenido de humedad se da en el mes de junio, siendo mucho menor y casi idéntica en los meses de julio y agosto. Esta variabilidad del contenido de humedad en el mes de junio es responsable de que no existan diferencias a lo largo del verano, ya que la parte superior del recorrido de esta variable solapa casi por completo el recorrido total en los meses de julio y agosto.

Lo observado en el gráfico de barras se ve confirmado por los estadísticos de la prueba *post-hoc* de Bonferroni de la Tabla 4.18, que indican de una forma cuantitativa que no existen diferencias significativas en ninguna de las comparaciones posibles entre estos tres meses.

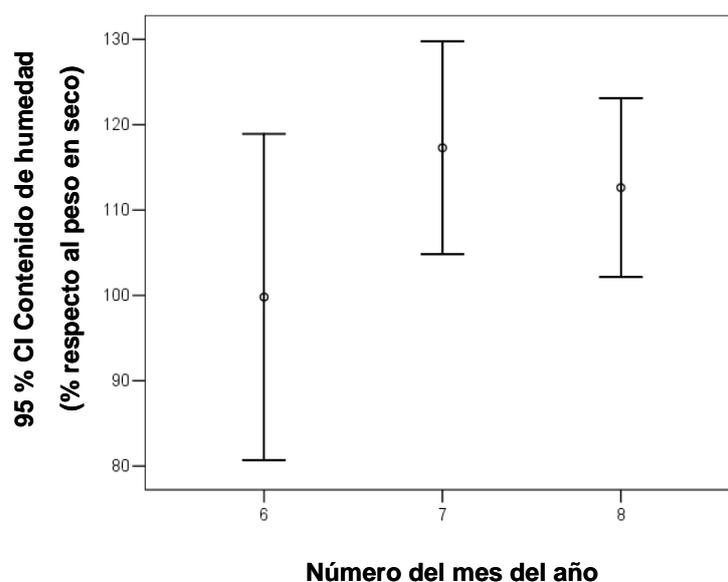


Figura 4.12. Gráfico de barras de error que compara el contenido de humedad de las muestras de las cuatro especies consideradas en los meses de junio (6), julio (7) y agosto (8)

Variable (I) mes	Variable (J) mes	Diferencia de medias (I-J)	S _e	Sig.
6	7	-17,103	7,995	0,125
	8	-13,395	7,995	0,316
7	6	17,109	7,995	0,125
	8	3,708	7,995	1,000
8	6	13,395	7,995	0,316
	7	-3,708	7,995	1,000

Tabla 4.18. Resultado del análisis ANOVA ajustado para explorar las diferencias en el contenido de humedad de las muestras de las cuatro especies consideradas en los meses de junio (6), julio (7) y agosto (8)

4.3. Conclusiones

Los resultados obtenidos en los dos subapartados de este capítulo permiten llegar a las siguientes conclusiones:

- I. El método que combina el uso de ventanas fijas 3x3 para extraer la información radiométrica, con el cálculo del CV de estas ventanas para individualizar grupos de parcelas del IFN-2 dependiendo de su heterogeneidad radiométrica, se muestra válido para estimar biomasa residual forestal, independientemente de la fecha de adquisición de la imagen Landsat dentro del periodo estival.**

Esta conclusión descansa sobre los siguientes hechos, observados al emplear las imágenes de junio de 1994 en el Capítulo 3 y de julio de 1993 y agosto de 1994 en el Capítulo 4:

- La aplicación de este método proporciona grupos de parcelas en función de su heterogeneidad-homogeneidad radiométrica semejantes en número. Esta circunstancia permite llevar a cabo análisis cuantitativos semejantes en las tres imágenes, de modo que los resultados son directamente comparables.
- Los grupos de parcelas obtenidos con esta metodología en las tres imágenes contrastan la hipótesis de que a mayor homogeneidad del entorno radiométrico de la parcela, mayor correlación entre la biomasa residual forestal y las variables radiométricas, independientemente de la imagen utilizada. En este sentido, casi todas las correlaciones obtenidas con las variables radiométricas consideradas en este trabajo presentan el mismo tipo de relación (directa o inversa) y, sobre todo, similar grado de correlación en cada uno de los 10 grupos de parcelas delimitados. La única excepción a esta norma la constituyen los neocanales obtenidos mediante el ACP, ya que, dado su carácter imagen-dependiente, no sintetizan la información radiométrica de igual manera en cada una de ellas; por ello, los componentes CP2 y CP3 presentan un grado de significación variable en su relación con la biomasa residual dependiendo de la imagen analizada.
- En las tres imágenes, el grupo de parcelas del percentil 4 se revela como el mejor para generar buenos modelos de estimación de la biomasa residual. Esto es así porque en él las correlaciones entre la biomasa residual y las variables radiométricas son suficientes para conseguir ajustar ecuaciones de regresión simple con coeficientes de determinación importantes, circunstancia

ésta indispensable al no poderse ajustar regresiones múltiples debido a la alta auto-correlación existente entre las variables radiométricas.

- Los modelos de regresión lineal y no lineal -ajustados mediante este método- que finalmente se utilizan para obtener cartografía presentan valores de R^2 , $RMSE$ y $RMSE_r$ muy parecidos, por lo que resulta indiferente cuál de ellos se aplique definitivamente para inventariar este recurso energético en el área de estudio. Además, todos estos modelos estimativos utilizados para obtener cartografía con las tres escenas se basan en un mismo tipo de variables: las relacionadas con el contenido de humedad de la vegetación. Por último, en este mismo sentido, debe añadirse que los resultados obtenidos en las pruebas de validación llevadas a cabo sobre las cartografías obtenidas con este método son también semejantes, ya que el $RMSE_r$ varía escasamente entre la cartografía más precisa y la menos (61,16% y 67,47%, respectivamente).
- Dado que este $RMSE_r$ es similar o inferior al obtenido en las cartografías derivadas con la imagen de junio con otros métodos que utilizaban más parcelas en el ajuste de las ecuaciones, se puede concluir que los modelos ajustados con la metodología empleada en este capítulo no están sobreajustados a la muestra, a pesar del reducido número de parcelas empleado. En consecuencia, este método -que utiliza ventanas 3x3 y el CV- se muestra como adecuado para seleccionar un grupo de parcelas suficientemente representativo del territorio con unas condiciones de homogeneidad que permiten ajustar buenas ecuaciones de estimación.

II. Las variables radiométricas relacionadas de forma directa o inversa con el contenido de agua de la vegetación son las más útiles para estimar la biomasa residual forestal en el área de estudio, independientemente de la fecha de adquisición de la imagen Landsat dentro del periodo estival.

Esta conclusión descansa en el hecho de que, como sucede con la imagen de junio de 1994, las variables radiométricas relacionadas con el contenido de agua de la vegetación son también las más correlacionadas con la biomasa residual con las imágenes de julio de 1993 y de agosto de 1994. Este mayor grado de correlación se da en todos los grupos de parcelas delimitados en función de su heterogeneidad-homogeneidad radiométrica. Esta circunstancia, unida a la alta auto-correlación existente entre las variables radiométricas, hace que los modelos estimativos lineales y no lineales ajustados con las tres escenas para obtener cartografía utilicen siempre una de estas variables.

Destaca, en particular, la variable MID57, ya que su uso en los modelos no lineales en las tres imágenes siempre alcanza un buen compromiso entre el grado de ajuste de la función y el error de estimación obtenido con la muestra de validación. Además, junto a TM7, es también la variable que más se repite en los modelos lineales ajustados con las escenas de junio, julio y agosto. Es por ello que la variable MID57 es utilizada para obtener 5 de las 6 cartografías derivadas mediante este método de extracción de la información. Los resultados de las validaciones de estas cartografías, que se sirven de aproximadamente el 80% de las parcelas no utilizadas previamente en el ajuste de este modelo, muestran que el error de estimación medido con el *RMSE*, es similar en todas ellas, por lo que su utilidad no depende del momento del verano en el cual se adquiere la imagen.

La razón del ajuste de mejores modelos curvilíneos con MID57, frente al resto de variables relacionadas con la humedad, puede estar relacionada con el hecho anteriormente mencionado de que esta variable siempre presenta un rango dinámico más amplio que las otras para explicar las variaciones de biomasa residual forestal. Esta circunstancia se observa claramente en la Tabla 4.19, que compara el rango de MID57 en los modelos que se han utilizado para obtener cartografía con el de los modelos desechados que se valen de otras variables relacionadas con la humedad, siempre para la misma muestra de parcelas. Sin embargo, en los modelos lineales, la transformación de la banda 7 presenta un mayor rango que la de MID57, razón por la cual la primera variable resulta elegida en más ocasiones en las distintas pruebas que se hacen con este tipo de regresión. Aun así, el mejor compromiso que existe entre la capacidad de predicción y el error de estimación hace que se seleccionen los modelos lineales que utilizan MID57, con la única excepción de los ajustados con la imagen de agosto, donde el método por pasos selecciona siempre la variable transformada de TM7.

Imagen	Tipo de modelo	Rango dinámico				MSI
		MID57	TM5	TM7	TC3	
Junio de 1994	Curvilíneo	35,68	20,19	15,84	13,40	0,90
	Lineal	1,24	1,13	1,35	-	-
Julio de 1993	Curvilíneo	42,29	23,38	18,92	14,55	0,93
	Lineal	1,54	-	1,84	-	-
Agosto de 1994	Curvilíneo	38,79	21,73	17,54	14,02	0,81
	Lineal	-	-	1,35	-	-

Tabla 4.19. Comparación del rango de MID57 en los modelos que se han utilizado para obtener cartografía con el de los modelos desechados ajustados con otras variables relacionadas con la humedad para la misma muestra de parcelas

Los resultados obtenidos en el apartado 4.2 respecto de la variación del contenido de humedad en los meses de junio, julio y agosto de las cuatro especies de pino consideradas muestran que no existen diferencias significativas de esta variable durante el periodo estival. Esta circunstancia, unida a que las variables radiométricas relacionadas con el contenido de humedad son siempre las más correlacionadas en las tres imágenes y las seleccionadas en el proceso de ajuste de los distintos modelos de regresión, lleva a concluir que, en principio, esta relación biofísica es estable e independiente del momento de adquisición de la imagen dentro del verano. Sin embargo, dada la escasez de la muestra utilizada, es necesario señalar que, para garantizar la validez estadística de esta afirmación, sería necesario contar con más datos de campo de contenido de humedad, tanto por tipo de especies como por años muestreados, siendo también deseable que la muestra, más que en territorios cercanos, se situara dentro del área de estudio.

En resumen, se concluye que la metodología que combina el uso de ventanas fijas 3x3 para extraer la información radiométrica con el cálculo del CV de estas ventanas para individualizar grupos de parcelas del IFN-2 dependiendo de su heterogeneidad radiométrica es replicable en el tiempo siempre que las imágenes Landsat que se utilicen hayan sido adquiridas en los meses de junio, julio y/o agosto. Esta afirmación descansa en el hecho de que los modelos operativos que se obtienen con las imágenes de este periodo del año siempre utilizan variables relacionadas con el contenido de humedad, destacando, dentro de éstas, MID57. Estos modelos representan una relación biofísica robusta, ya que tanto los coeficientes de regresión de estas ecuaciones, como su grado de ajuste global y los errores de estimación calculados con sus respectivas muestras de validación son muy similares. Asimismo, el grado de error de las distintas cartografías de estimación obtenidas con estos modelos es de la misma magnitud, oscilando en un intervalo inferior al 7%. El hecho de que la variabilidad del contenido de humedad medida en el campo tampoco presente diferencias significativas dentro de los meses de verano apunta también a la robustez biofísica de los modelos obtenidos, aunque para poder confirmar este extremo sería necesario disponer de una mayor muestra estadística.

La no correspondencia exacta de los modelos derivados con una u otra escena de verano y, por lo tanto, de las cartografías de estimación derivadas a partir de ellos, puede deberse principalmente a imprecisiones producidas durante los procesos de corrección geométrica y radiométrica de las tres imágenes. Cualquier ligera imprecisión en estos

pretratamientos, como resulta evidente, modifica la relación existente entre el dato tomado en el campo y la información radiométrica. Sin embargo, es preciso señalar que, a tenor de la similitud de los resultados obtenidos tanto en los modelos como en las cartografías, las imprecisiones que se han podido cometer en estos procesos han sido poco relevantes. Otro motivo de la no correspondencia estricta es que, a pesar de haberse utilizado parcelas pertenecientes al mismo percentil para la elaboración de los modelos, éstas no son exactamente las mismas en todos los casos, por lo que es lógico que los coeficientes de regresión de las ecuaciones varíen ligeramente.

***CAPÍTULO 5:
LA BIOMASA RESIDUAL FORESTAL
ACTUAL DE LA PROVINCIA DE TERUEL.
INVENTARIO DEL RECURSO Y
LOCALIZACIÓN DE ZONAS ÓPTIMAS
PARA SU APROVECHAMIENTO***

Comprobada la replicabilidad del método seleccionado en el Capítulo 3 y la utilidad y estabilidad de las variables radiométricas relacionadas con el contenido de agua de la vegetación para estimar la variable biomasa residual forestal, siendo independientes estas dos cuestiones de la fecha de la imagen Landsat utilizada dentro del periodo estival, sólo resta aplicar cualquiera de las ecuaciones así obtenidas para conocer la cantidad existente de este recurso en la provincia de Teruel en la actualidad.

Cumpliendo con la fase III recogida en el apartado de metodología y materiales, el presente capítulo se desglosa en tres bloques:

- En el primero se realizan los procesos de pretratamiento (corrección geométrica y radiométrica) sobre una imagen Landsat de características análogas a las utilizadas en los Capítulos 3 y 4, pero de fecha más cercana a la actualidad. Una vez corregida, si la ecuación de estimación finalmente seleccionada lo requiere, se obtendrá el neocanal necesario. Seguidamente, se aplicará el modelo de estimación, obteniéndose así una cartografía base, equivalente a las ya calculadas, en las que cada píxel está expresado en tons/ha.
- El segundo bloque consistirá en derivar información cartográfica y estadística de la biomasa residual forestal obtenida para los tres niveles de división administrativa operativos en el territorio turolense: provincial, comarcal y municipal, si bien sólo se producirá cartografía para los dos primeros. Para ello, la cartografía obtenida en el apartado anterior, en la que cada píxel está expresado en tons/ha, será utilizada para calcular otra nueva en la que se exprese la cantidad de biomasa contenida realmente en cada píxel, ya que cada uno de ellos representa una superficie de 0,0625 ha.
- Por último, se ensayará una metodología para localizar las zonas óptimas para el aprovechamiento de este recurso. Mediante herramientas SIG esta metodología modelará cuatro variables críticas para conocer la viabilidad económica de la extracción de la biomasa residual forestal (cantidad, extensión de la masa forestal, orografía y proximidad a pistas, caminos o carreteras que permitan su extracción y transporte), obteniéndose un valor de aptitud para cada punto del territorio.

5.1. Estimación de la biomasa residual forestal actual de Teruel

La selección de la imagen utilizada en este capítulo se hizo entre las disponibles de forma gratuita en el *Plan Nacional de Teledetección*. En concreto, se buscó entre las escenas disponibles en 2008 que correspondían a la misma órbita de observación terrestre y fila que las utilizadas para obtener los modelos de regresión (*track 199/ frame 32*) y que hubieran sido adquiridas en algún momento del verano. De las imágenes que cumplían este doble criterio, sólo la escena de 5 de julio se encontraba libre de nubes en su mayor parte, por lo que finalmente fue la seleccionada.

Comprobada la correcta radiometría de la imagen mediante su análisis visual y el de los histogramas de cada banda, se iniciaron los pretratamientos para eliminar las distorsiones geométricas y radiométricas, obteniéndose una imagen expresada en valores de reflectividad. Los procesos de corrección aplicados con el mismo rigor que para las imágenes de 1993 y 1994, utilizándose los mismos métodos. De esta manera se garantizó la correcta extrapolación temporal de los modelos de estimación obtenidos en los anteriores capítulos.

En el caso de la corrección geométrica, se volvió a emplear un modelo empírico basado en el uso de puntos de control, utilizándose nuevamente las ortofotografías del *SIG Oleícola Español* como documento auxiliar de referencia y el MDE creado en el apartado 2.2 para lograr resultados más precisos y ajustados. El polinomio de ajuste fue también de segundo grado. El total de puntos de control utilizados fue de 122, obteniéndose un error inferior al píxel, concretamente de 0,52 píxeles (15,73 m). Cumplido el nivel de tolerancia exigido en este trabajo, se procedió a la transferencia de los ND originales a la posición corregida mediante el método del vecino más próximo.

La imagen fue sometida al proceso de corrección radiométrica. La Tabla 5.1 muestra los parámetros básicos implicados: los ND mínimos que fueron restados a cada banda para eliminar el efecto de la dispersión atmosférica y los coeficientes de calibración extraídos de los ficheros de cabecera de la escena que fueron utilizados para calcular la radiancia espectral. Los valores de irradiancia solar en el techo de la atmósfera y de transmisividad del flujo incidente para el cálculo de la reflectividad sin normalización topográfica fueron los mismos que los utilizados en las imágenes de 1993 y 1994, modificándose sólo el factor corrector de la distancia Tierra-Sol y el ángulo cenital solar. Para el cálculo del modelo no-Lambertiano propuesto por Colby (1991), que conduce a la

obtención de la reflectividad normalizada topográficamente, fue necesario recalcular los siguientes parámetros: ángulo cenital solar, coseno del ángulo de incidencia y constantes K de Minnaert para cada banda, con valores específicos relacionados con el momento adquisición de la imagen.

	ND mínimos	$a_{0,k}$ (offset)	$a_{1,k}$ (gain)
Banda 1	45	-1,50	0,60235
Banda 2	15	-2,80	1,17490
Banda 3	12	-1,20	0,80588
Banda 4	8	-1,50	0,81451
Banda 5	4	-0,37	0,10808
Banda 7	1	-0,15	0,05698

Tabla 5.1. ND mínimo y coeficientes de calibración de cada banda de la imagen de julio de 2008 utilizados para la corrección de la dispersión atmosférica y el cálculo de la radiancia espectral

En concreto, para obtener la constante K de Minnaert se siguió la metodología anteriormente expuesta de utilizar información pre-existente de las cubiertas vegetales presentes en el área de estudio, calculándose una constante específica por banda para las superficies con nula o escasa cubierta vegetal ($NDVI < 0,20$), para las superficies con cubierta vegetal poco activa o en forma de matorral y/o monte abierto ($NDVI$ entre 0,20 y 0,46) y para las zonas con cubierta vegetal activa en forma de bosque ($NDVI > 0,46$); la Tabla 5.2 muestra los valores obtenidos. Finalmente, la imagen de reflectividad obtenida tras este proceso de corrección fue re-escalada de tantos por uno a tantos por cien para facilitar los análisis posteriores.

	(i)	(ii)	(iii)
Banda 1	0,890	0,633	1
Banda 2	1	0,938	1
Banda 3	1	1	1
Banda 4	0,830	0,944	0,905
Banda 5	1	0,897	1
Banda 7	1	0,959	1

Tabla 5.2. Valores calculados para la constante de Minnaert para la imagen de julio de 2008 en función de las bandas y las categorías (i) suelo con nula o escasa cubierta vegetal; (ii) cubierta vegetal poco activa o en forma de matorral y/o monte abierto; y (iii) cubierta vegetal activa en forma de bosque

Realizados los pretratamientos, fue necesario decidir cuál de los mejores modelos de estimación de la biomasa residual forestal obtenidos en los Capítulos 3 y 4, para las imágenes de junio de 1994 y julio de 1993 y agosto de 1994, iba a ser aplicado, ya que

en función de ello sería necesario –o no– aplicar la transformación preceptiva a la imagen de reflectividad de 2008 para obtener el neocanal utilizado en esa ecuación.

Dado que tanto el mejor modelo lineal y no lineal obtenido para cada una de las tres imágenes anteriores utiliza siempre una variable relacionada con el contenido de humedad, el criterio empleado para seleccionar los de una u otra imagen debe ser temporal: debe seleccionarse entre los dos de la imagen que más próxima este en el calendario con la de julio de 2008, ya que el contenido en agua de la vegetación en ambas imágenes será más similar que con otras.

De esta manera, teniendo en cuenta que la imagen de 2008 fue tomada el 5 de julio, la imagen utilizada para obtener modelos de estimación que puede presentar mayor similitud es la de junio de 1994, ya que fue registrada sólo 7 días antes (29 de junio). Por tanto, prescindiendo de las posibles fluctuaciones interanuales, el contenido de humedad de los bosques de pináceas en la imagen del 5 de julio de 2008 tiene que ser más similar con la imagen de 29 de junio de 1994 que con las imágenes de 28 de julio de 1993 y 16 de agosto de 1994, más adentradas en la época estival y, en consecuencia, con contenidos de agua en la vegetación menores, al menos desde el punto de vista teórico.

Para la elección entre el modelo no lineal o el lineal, ajustados con la imagen de junio de 1994 mediante el método de ventanas fijas y el CV considerando las parcelas del clúster 3 (percentil 4), se debe atender a dos criterios: (i) cuál de los dos alcanza con esta imagen mejores resultados en términos de capacidad predictiva y de error de estimación con la muestra y en la cartografía obtenida y (ii) qué tipo de regresión ofrece resultados más estables con las tres imágenes analizadas.

En atención al primer criterio, tanto el modelo curvilíneo como el lineal obtenidos utilizan la variable MID57 y presentan un R^2 elevado ($>0,7$), si bien el del modelo curvilíneo es algo más alto (0,767 frente a 0,711). Sin embargo, cuando se observan los resultados alcanzados en los errores de estimación con sus respectivas muestras no utilizadas en el ajuste de la ecuación, el modelo lineal presenta $RMSE_r$ más bajos en casi 10 puntos (26,67% frente a 36,18% en el curvilíneo) (Figuras 3.12d y 3.17). Esta diferencia entre modelos se debe principalmente a la división aleatoria de la muestra para ajuste y validación que se ha utilizado en ambos. En consecuencia, el error de estimación en las cartografías obtenido en el apartado 3.1.3 es un parámetro más sólido a la hora de escoger uno de los dos.

Como se observa en la Tabla 3.40, la cartografía obtenida con el modelo lineal (cartografía 3) presenta un $RMSE_r$ sensiblemente inferior al de la cartografía derivada de aplicar la curvilínea (cartografía 1) (64,26% frente a 67,47%), siendo además la que presenta el mejor resultado de las ocho cartografías obtenidas con diferentes metodologías de extracción y de regresión en el Capítulo 3. Así pues, este primer criterio señala a la ecuación lineal como la más adecuada para obtener la información de biomasa residual con la imagen de julio de 2008.

Tal y como se advierte en la Figura 4.11, el segundo criterio también señala al modelo lineal como el mejor para ser utilizado con la imagen de 2008, ya que el $RMSE_r$ obtenido con este tipo de ecuaciones presenta resultados más estables que el curvilínea en las tres imágenes. Atendiendo a los datos absolutos, la variación del $RMSE_r$ entre las cartografías de las tres fechas es solamente de 1,71 puntos porcentuales cuando se ha utilizado un modelo lineal, mientras que en las cartografías creadas con modelos exponenciales es de 6,31 puntos.

En consonancia con los anteriores resultados, se escogió para estimar la biomasa residual actual el modelo lineal⁵². Como se observa en la Ecuación 36, para su aplicación se hizo necesario el cálculo del neocanal MID57 con la imagen de julio de 2008 (Figura 5.1).

$$y = -4,663(\ln MID57) + 18,879 \quad \text{Ecuación 36}$$

5.2. Inventario del recurso energético

Como ya se ha indicado, para obtener correctamente la cantidad de biomasa residual de la provincia de Teruel a escala provincial, comarcal y municipal, es necesario transformar la cartografía obtenida en el anterior apartado –en la que cada píxel está expresado en tons/ha– en otra en el que se exprese la cantidad de biomasa contenida realmente en cada píxel. Para ello se utilizó el módulo *Spatial Analyst* de ArcGIS, concretamente la herramienta *Raster Calculator*, en la cual se multiplicó la cartografía obtenida por el valor 0,0625, siendo el resultado obtenido la cartografía de la Figura 5.2. Tal y como se observa en esta figura, el valor máximo de biomasa contenido en un píxel de 25x25 m en la provincia de Teruel no supera las 7 toneladas.

⁵² Esta ecuación se corresponde a la ajustada con la muestra de parcelas N₁ de la Tabla 3.21

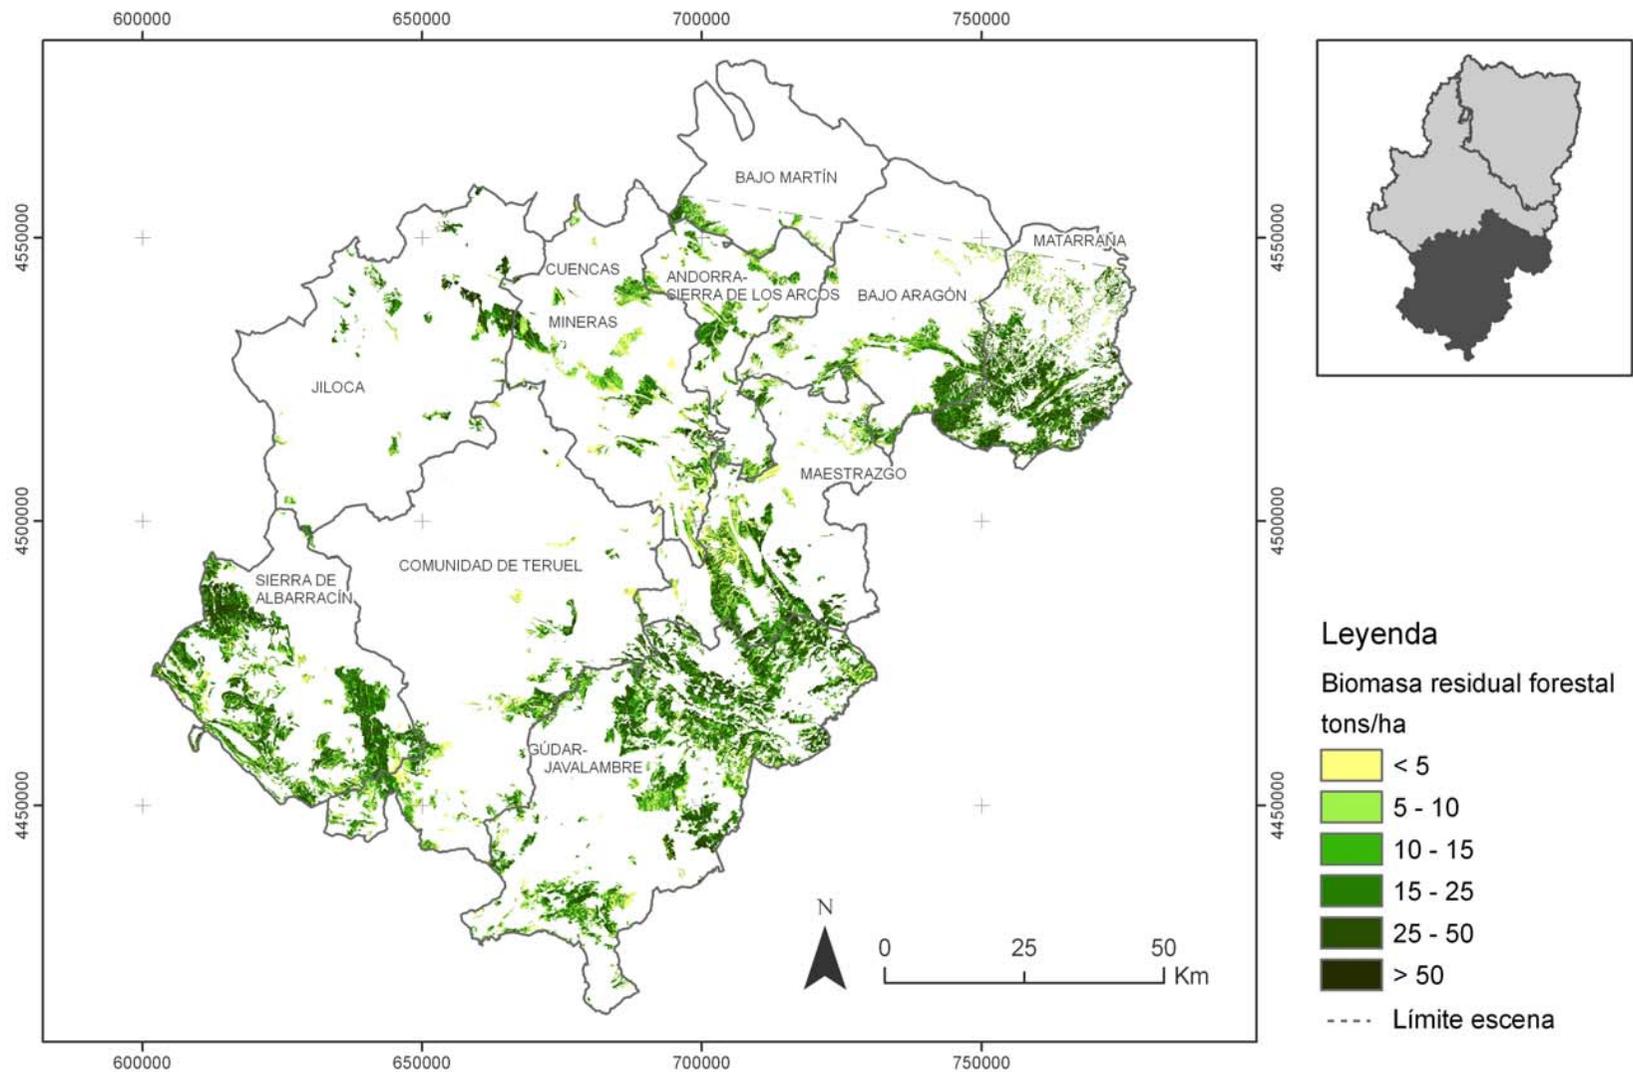


Figura 5.1. Cartografía de la biomasa residual forestal en la provincia de Teruel obtenida a partir de la aplicación de la Ecuación 36 sobre la imagen de julio de 2008

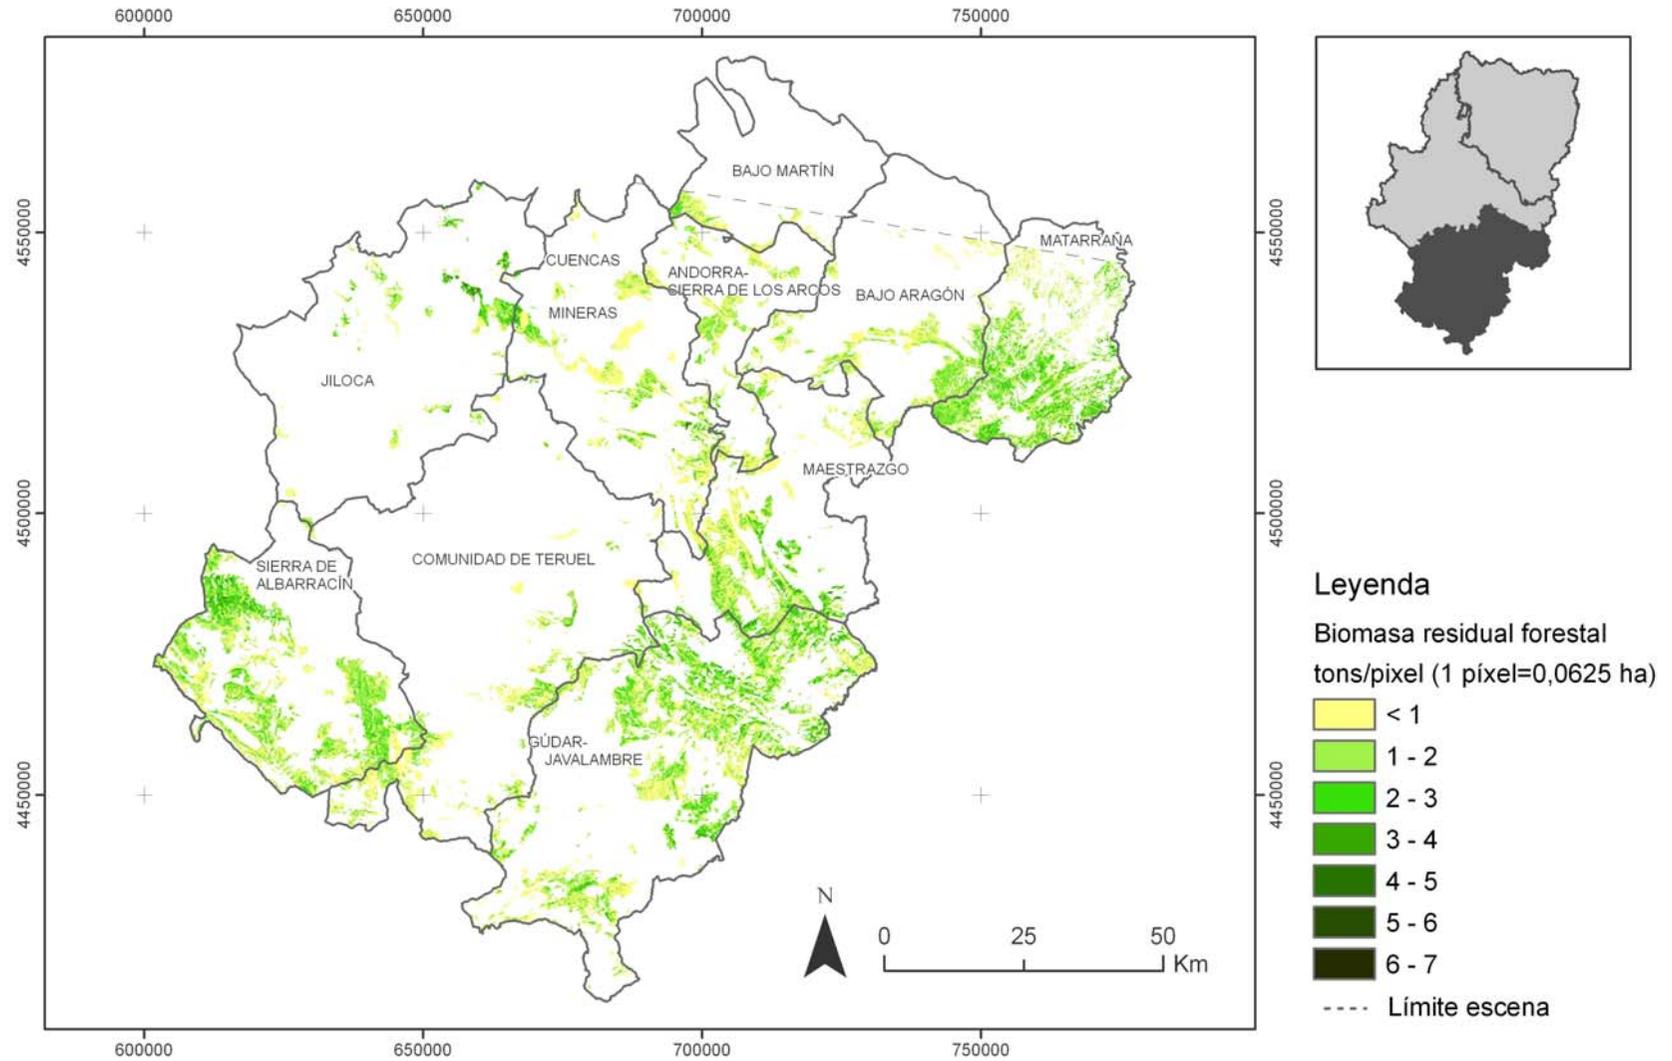


Figura 5.2. Cartografía de biomasa residual forestal en la provincia de Teruel en julio de 2008 expresada tons/píxel (1 píxel=0,0625 ha)

Para el inventariado del recurso existente en los tres niveles administrativos considerados, esta capa raster se cruzó mediante la herramienta *Zonal Statistics* de *Spatial Analyst* con las capas vectoriales de comarcas y municipios de la provincia de Teruel. En los siguientes subapartados se recogen los resultados obtenidos.

5.2.1. Inventario a escala provincial

El total de biomasa residual forestal aprovechable potencialmente como recurso energético en la provincia de Teruel en julio de 2008, omitiendo el sector más septentrional que queda fuera de la escena Landsat utilizada (Figura 5.3)⁵³, asciende a 5.449.252 tons.

Como se observa en la Figura 5.2, la distribución de esta biomasa no es homogénea por todo el territorio, sino que se concentra, como era esperado, en las zonas de sierra de la mitad meridional (Sierras de Gúdar, Javalambre y Albarracín), que es donde se localizan los bosques más extensos y mejor conservados de toda la provincia, compuestos principalmente de *P. sylvestris* en las zonas más altas y *P. nigra* conforme se descende en altitud, muchas veces introducido por repoblación. Dentro de esta zona, un importante sector de acumulación de recurso aparece en los llamados “pinos de rodeno”, compuestos fundamentalmente por *P. pinaster*.

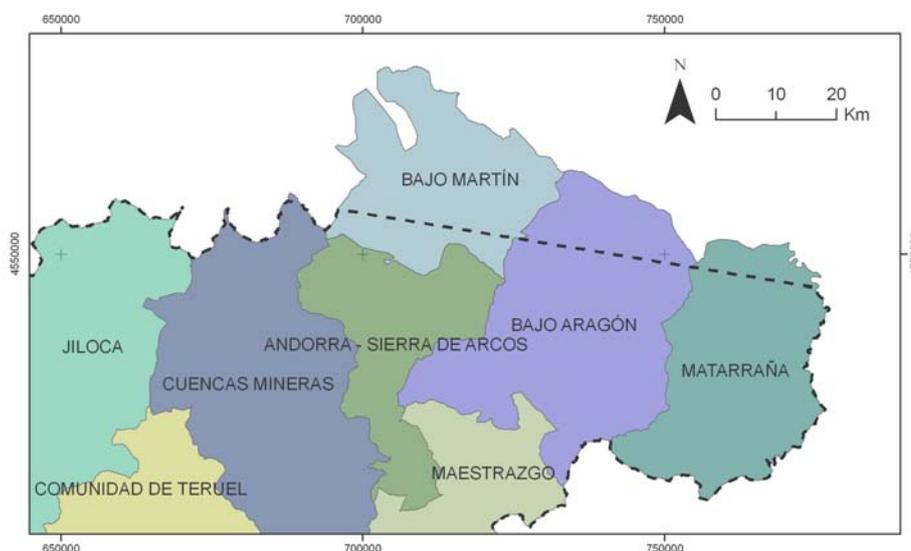


Figura 5.3. Detalle de la superficie provincial –sector septentrional de las comarcas de Bajo Martín, Bajo Aragón y Matarraña- no inventariada

⁵³ Esta circunstancia afecta, en orden de importancia, a las comarcas del Bajo Martín (79,30% de su territorio), Bajo Aragón (18,92%) y Matarraña (9,97%).

Destaca en segundo lugar el sector nororiental (Puertos de Beceite), donde se combina, en un gradiente altitudinal, la presencia de *P. sylvestris*, *P. nigra* y *Pinus halepensis*. En el sector central de la provincia, las zonas con mayores acumulaciones de biomasa residual se corresponden con las masas de pinar situadas en las laderas de las Sierras Menera, Cucalón, Palomera y San Just, destacando sobre todo la segunda, fruto de la existencia en esta zona de repoblaciones densas de *P. nigra*. Por último, señalar la existencia, en la zona más septentrional de la provincia, de teselas –de menor continuidad espacial que las anteriores y con menor contenido de recurso– que se identifican con masas de *P. halepensis* de estructura abierta, características de este sector de la provincia.

5.2.2. Inventario a escala comarcal

La Tabla 5.3 y la Figura 5.4 muestran, respectivamente, cómo se distribuye en cantidades absolutas y en porcentajes la biomasa residual forestal en las 10 comarcas turolenses. Como puede observarse, en la comarca de Gúdar-Javalambre es donde se concentra la mayor cantidad de recurso, seguida por la comarca de la Sierra de Albarracín y por la del Matarraña, a pesar del territorio de esta última que ha quedado sin inventariar; en cuarto lugar, con un porcentaje algo inferior debido sobre todo a su menor superficie, se encuentra la comarca del Maestrazgo. Estas cuatro comarcas contienen conjuntamente casi las tres cuartas partes del total de la biomasa residual forestal de la provincia de Teruel (74,32%).

Comarca	Toneladas
Andorra – Sierra los Arcos	178.051
Bajo Aragón*	299.612
Bajo Martín*	61.030
Comunidad de Teruel	312.907
Cuencas Mineras	317.533
Gúdar - Javalambre	1.570.650
Jiloca	230.206
Maestrazgo	544.989
Matarraña*	892.904
Sierra de Albarracín	1.041.370

* Comarca no inventariada totalmente

Tabla 5.3. Biomasa residual forestal en cada una de las comarcas turolenses

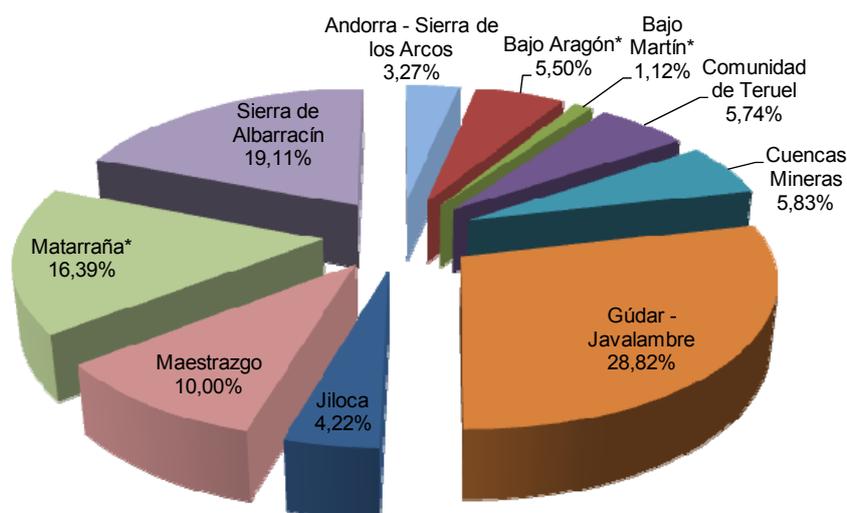


Figura 5.4. Distribución porcentual por comarcas de la biomasa residual forestal (* comarca no inventariada totalmente)

Las seis comarcas restantes presentan siempre proporciones de recurso inferiores al 6% del total provincial, destacando entre ellas las de Cuencas Mineras, Comunidad de Teruel y Bajo Aragón (>5%). El contenido total de las tres comarcas con menor cantidad de biomasa residual forestal –Jiloca, Andorra-Sierra los Arcos y Bajo Martín– asciende a un total de 469.287 toneladas, lo que equivale a sólo el 8,61% del total provincial.

Comarca	tons/ha
Andorra – Sierra los Arcos	2,64
Bajo Aragón*	2,30
Bajo Martín*	0,77
Comunidad de Teruel	1,12
Cuencas Mineras	2,26
Gúdar - Javalambre	6,68
Jiloca	1,19
Maestrazgo	4,52
Matarraña*	9,56
Sierra de Albarracín	7,37

* Comarca no inventariada totalmente

Tabla 5.4. Densidad media de biomasa residual forestal por comarca

Un dato complementario de este inventario por comarcas, útil a la hora de matizar estos datos, es conocer la densidad de recurso en cada una de ellas. Como se observa en la Tabla 5.4, la mayor concentración de biomasa residual por hectárea se da en la comarca de Matarraña, con una densidad media que casi alcanza las 10 tons/ha. En segundo y tercer lugar, aunque muy próximas entre sí, aparecen las comarcas de Sierra

de Albarracín y Gudar-Javalambre, con valores de 7,37 tons/ha y 6,68 tons/ha, respectivamente. La cuarta comarca con mayor contenido –Maestrazgo– es también la cuarta que mayor densidad media presenta (4,52 tons/ha). El resto presenta concentraciones por hectárea sensiblemente inferiores a las cuatro anteriores, con valores siempre <2,7 tons/ha, siendo el dato medio más bajo, sin contar el Bajo Martín, el de la comarca de la Comunidad de Teruel (1,12 tons/ha).

Por último, para cerrar este apartado, se recogen las cartografías de todas las comarcas de Teruel, lo que permite observar de manera detallada la distribución espacial de la biomasa residual forestal en cada una de ellas (Figuras 5.5 a 5.14).

5.2.3. Inventario a escala municipal

En este subapartado se recoge simplemente el contenido de biomasa residual forestal de cada uno de los municipios de Teruel para los que se han obtenido datos por estar total o parcialmente contenidos en la imagen Landsat utilizada. Para facilitar la consulta de estos datos se ha optado por agrupar los municipios en función de la comarca a la que pertenecen (Tablas 5.5 a 5.14).

Andorra – Sierra de los Arcos			
Municipio	Toneladas	Municipio	Toneladas
Alacón	2645,11	Ejulve	37591,60
Alloza	18518,09	Estercuel	42548,89
Andorra	21130,30	Gargallo	11178,70
Ariño	17838,80	Oliete	11818,90
Crivillén	14781,09		

Tabla 5.5. Biomasa residual forestal por municipios de la comarca de Andorra–Sierra de los Arcos

Bajo Aragón*			
Municipio	Toneladas	Municipio	Toneladas
Aguaviva	5939,33	La Codoñera	2899,85
Alcañiz*	12081,09	La Ginebrosa	25536,09
Alcorisa	21587,09	La Mata de los Olmos	8136,00
Belmonte de San José	37314,60	Las Parras de Castellote	24370,90
Berge	14696,70	Los Olmos	16339,20
Calanda	15147,90	Mas de las Matas	2420,73
Castelserás	191,97	Seno	323,59
Foz-Calanda	15137,20	Torrecilla de Alcañiz	980,82
La Cañada de Verich	16390,19	Torrevelilla	16972,80
La Cerollera	61380,10	Valdealforga	1765,72

* Comarca y/o municipio no inventariados totalmente

Tabla 5.6. Biomasa residual forestal por municipios de la comarca del Bajo Aragón

Bajo Martín*	
Municipio	Toneladas
Albalate del Arzobispo*	53.221,10
Híjar *	7.808,99

* Comarca y/o municipio no inventariados totalmente

Tabla 5.7. Biomasa residual forestal por municipios de la comarca del Bajo Martín

Comunidad de Teruel			
Municipio	Toneladas	Municipio	Toneladas
Ababuj	843,49	Galve	0,00
Aguatón	0,00	Jorcas	3,17
Aguilar del Alfambra	3783,67	Libros	5486,20
Alba	0,00	Lidón	0,00
Alfambra	936,49	Monteagudo del Castillo	14909,29
Almohaja	2321,88	Orrios	27,37
Alobras	11525,20	Pancrudo	2566,12
Alpeñés	939,09	Peralejos	11887,29
Argente	33,19	Perales del Alfambra	822,85
Camañas	0,00	Rillo	1744,65
Camarillas	1608,01	Riodeva	1183,69
Cañada Vellida	468,46	Santa Eulalia	0,00
Cascante del Río	1186,93	Teruel	68103,20
Cedrillas	23932,00	Tormón	34125,69
Celadas	0,00	Torrelacarcel	0,00
Cella	0,00	Torremocha de Jiloca	0,00
Corbalán	22356,90	Tramacastiel	23516,69
Cubla	10827,20	Valacloche	5269,70
Cuevas Labradas	6114,16	Veguillas de la Sierra	7562,29
El Cuervo	5530,97	Villarquemado	0,00
El Pobo	6016,20	Villastar	7794,75
Escorihuela	4590,66	Villel	24886,00
Fuentes-Calientes	3,37	Visiedo	0,00

Tabla 5.8. Biomasa residual forestal por municipios de la comarca de la Comunidad de Teruel

Cuencas Mineras			
Municipio	Toneladas	Municipio	Toneladas
Alcaine	6369,71	La Zoma	12843,40
Aliaga	79910,70	Maicas	809,78
Anadón	4119,89	Martín del Río	5583,91
Blesa	3804,18	Mezquita de Jarque	1982,97
Cañizar del Olivar	12510,59	Montalbán	52061,69
Castel de Cabra	3498,40	Muniesa	12571,20
Comunal Segura de Baños -	22,36	Obón	3914,37
Cortes de Aragón	5491,43	Palomar de Arroyos	10400,79
Cuevas de Almudén	11393,00	Plou	0,00
Escucha	338,68	Salcedillo	20970,09
Fuenferrada	3635,00	Segura de los Baños	31575,90
Hinojosa de Jarque	174,29	Torre de las Arcas	11460,70
Huesa del Común	6236,49	Utrillas	1276,36
Jarque de la Val	3677,63	Villanueva del Rebollar de la	1427,5
Josa	5258,31	Vivel del Río Martín	2775,37
La Hoz de la Vieja	1438,26		

Tabla 5.9. Biomasa residual forestal por municipios de la comarca de Cuencas Mineras

Gúdar - Javalambre			
Municipio	Toneladas	Municipio	Toneladas
Abejuela	12676,90	Manzanera	94965,79
Albentosa	19407,09	Mora de Rubielos	140938,00
Alcalá de la Selva	139302,00	Mosqueruela	326061,10
Arcos de las Salinas	24275,19	Nogueruelas	99438,89
Cabra de Mora	57097,30	Olba	39097,00
Camarena de la Sierra	41067,19	Puertomingalvo	82153,79
El Castellar	39851,00	Rubielos de Mora	54238,10
Formiche Alto	22638,50	San Agustín	4884,66
Fuentes de Rubielos	28716,40	Sarrión	2942,04
Gúdar	65125,00	Torrijas	43187,39
La Puebla de Valverde	12894,20	Valbona	13620,40
Linares de Mora	160233,00	Valdelinares	45839,60

Tabla 5.10. Biomasa residual forestal por municipios de la comarca de Gúdar-Javalambre

Jiloca			
Municipio	Toneladas	Municipio	Toneladas
Allueva	19.723,30	Loscos	4267,47
Badenas	5142,20	Monforte de Moyuela	14804,90
Báguena	1752,18	Monreal del Campo	5992,83
Bañón	9089,16	Nogueras	4865,27
Barrachina	24,41	Odón	0,00
Bea	3357,85	Ojos Negros	55,81
Bello	0,00	Peracense	4446,41
Blancas	125,65	Pozuel del Campo	1605,53
Bueña	3,52	Rubielos de la Cérda	48,90
Burbáguena	13217,40	San Martín del Río	966,23
Calamocha	49642,10	Santa Cruz de Nogueras	0,00
Caminreal	0,00	Singra	0,00
Castejón de Tornos	2774,32	Tornos	8680,44
Cosa	6411,74	Torralba de los Sisonos	5,91
Cucalón	5879,08	Torre los Negros	1580,75
Ferreruela de Huerva	29,76	Torrecilla del Rebollar	45139,69
Fonfría	13430,29	Torrijo del Campo	23,46
Fuentes-Claras	0,00	Villafranca del Campo	0,00
Laqueruela	1658,57	Villahermosa del Campo	11,71
Lanzuela	3413,59	Villar del Salz	2035,89

Tabla 5.11. Biomasa residual forestal por municipios de la comarca del Jiloca

Maestrazgo			
Municipio	Toneladas	Municipio	Toneladas
Allepuz	20722,50	Mirambel	875,19
Bordón	0,00	Miravete de la Sierra	1086,35
Cantavieja	76694,70	Molinos	24016,80
Cañada de Benatanduz	25012,09	Pitarque	29548,40
Castellote	33307,69	Tronchón	4519,02
Fortanete	221297,00	Villarluengo	56083,60
La Cuba	0,00	Villarroya de los Pinares	36862,10
La Iglesuela del Cid	14964,29		

Tabla 5.12. Biomasa residual forestal por municipios de la comarca de Maestrazgo

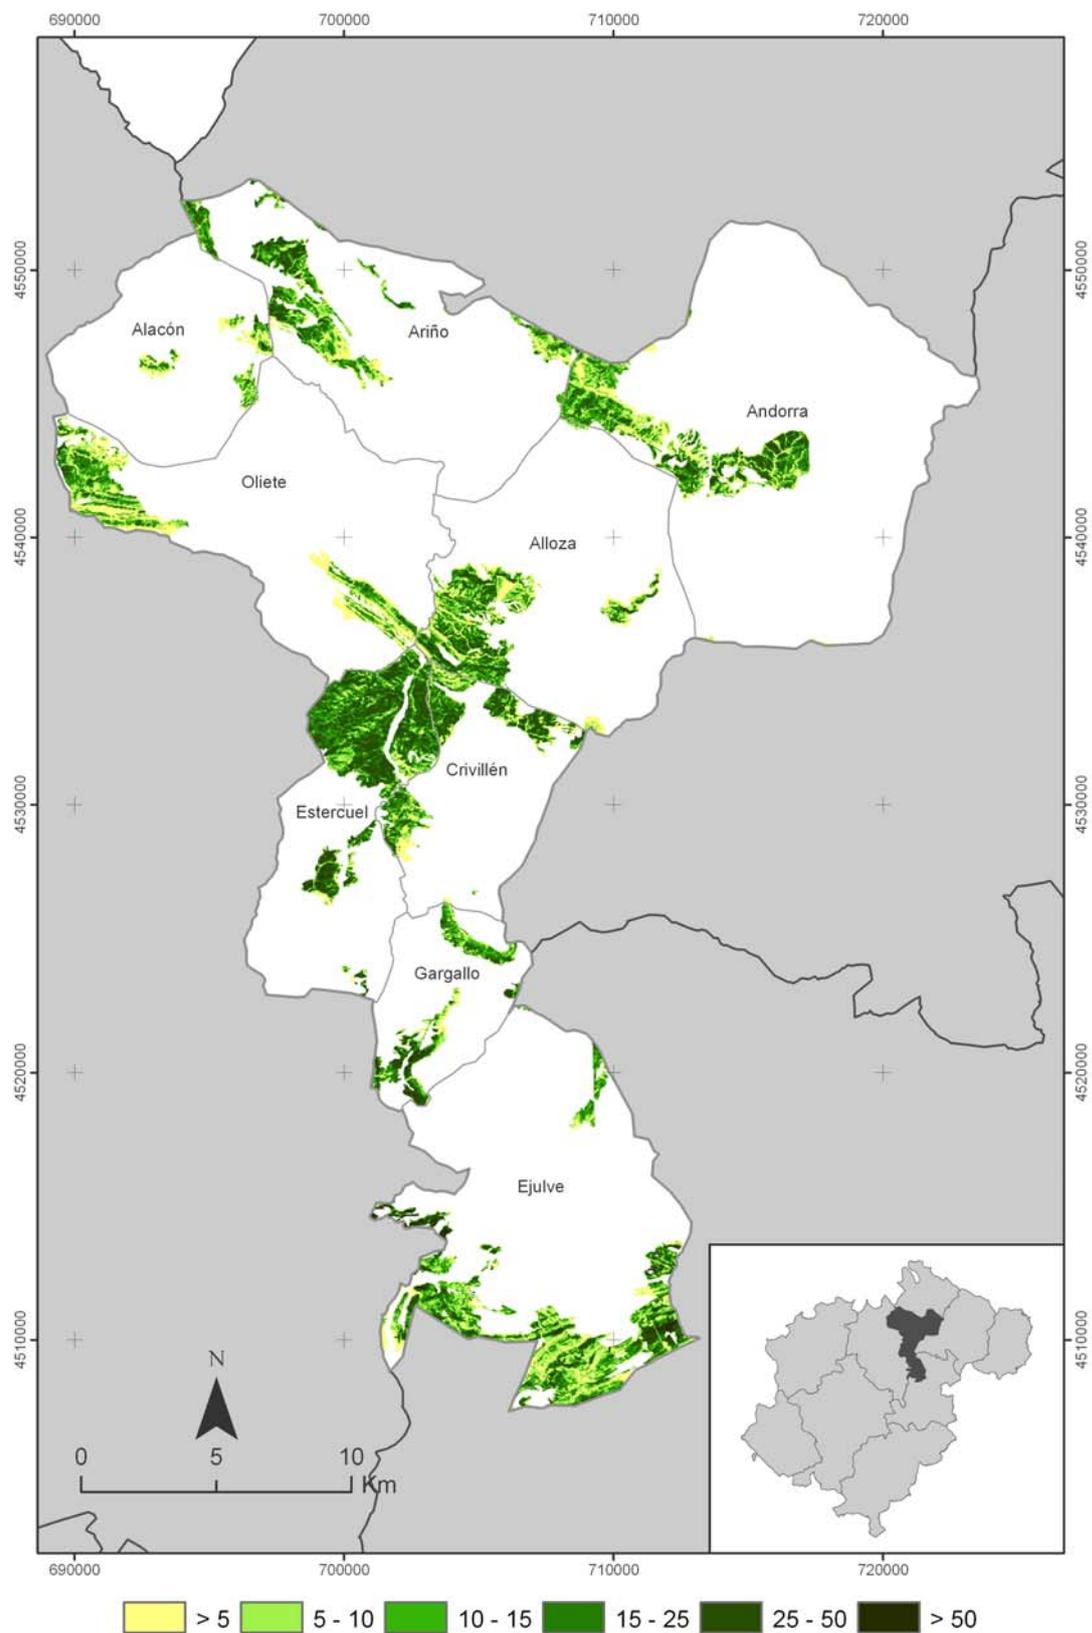


Figura 5.5. Biomasa residual forestal en la comarca de Andorra-Sierra de los Arcos (tons/ha, julio 2008)

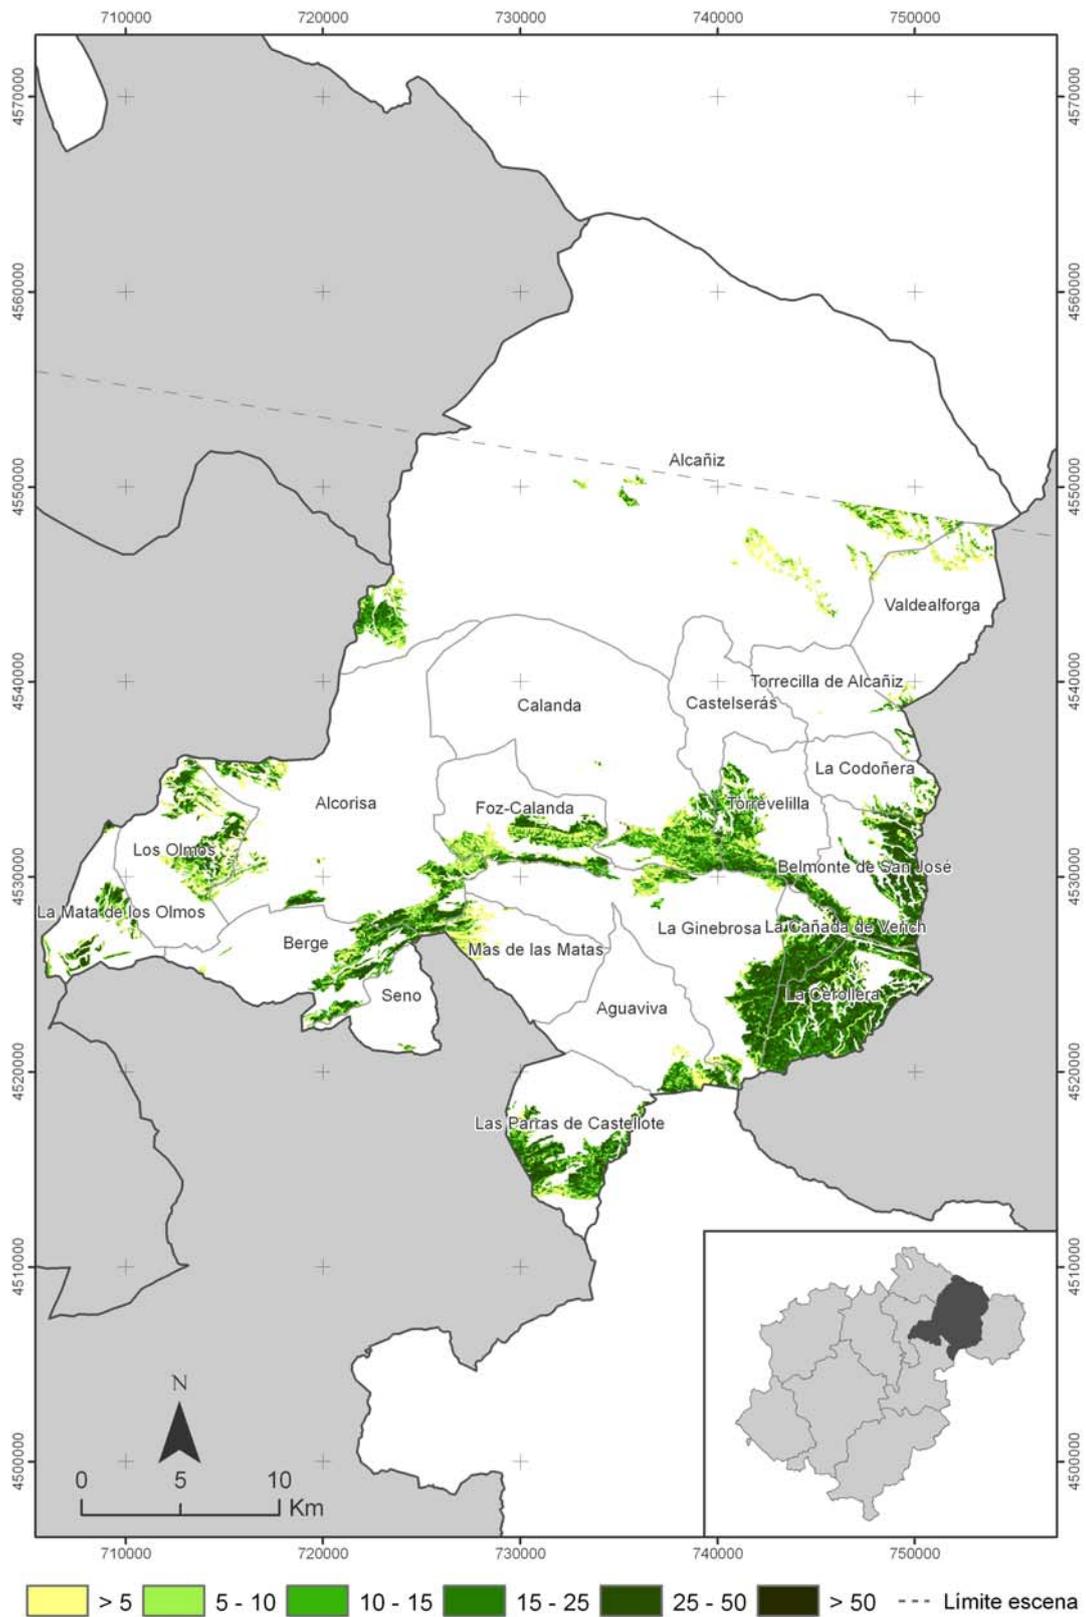


Figura 5.6. Biomasa residual forestal en la comarca del Bajo Aragón (tons/ha, julio 2008)

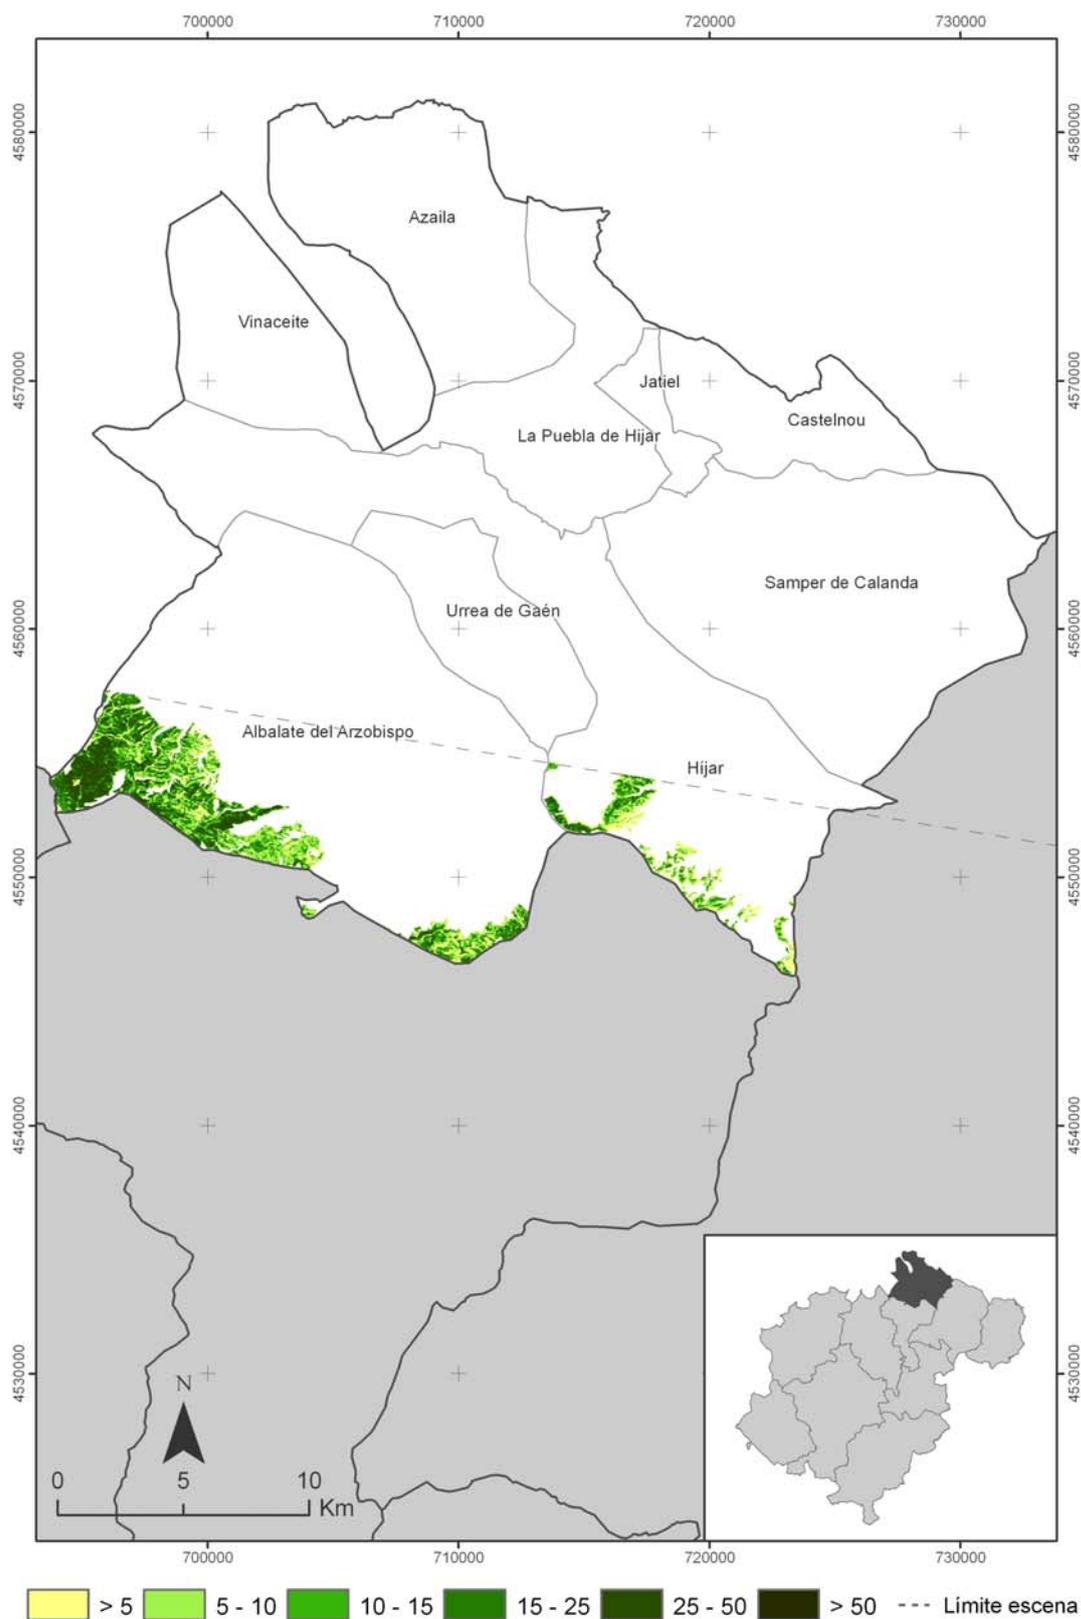


Figura 5.7. Biomasa residual forestal en la comarca del Bajo Martín (tons/ha, julio 2008)

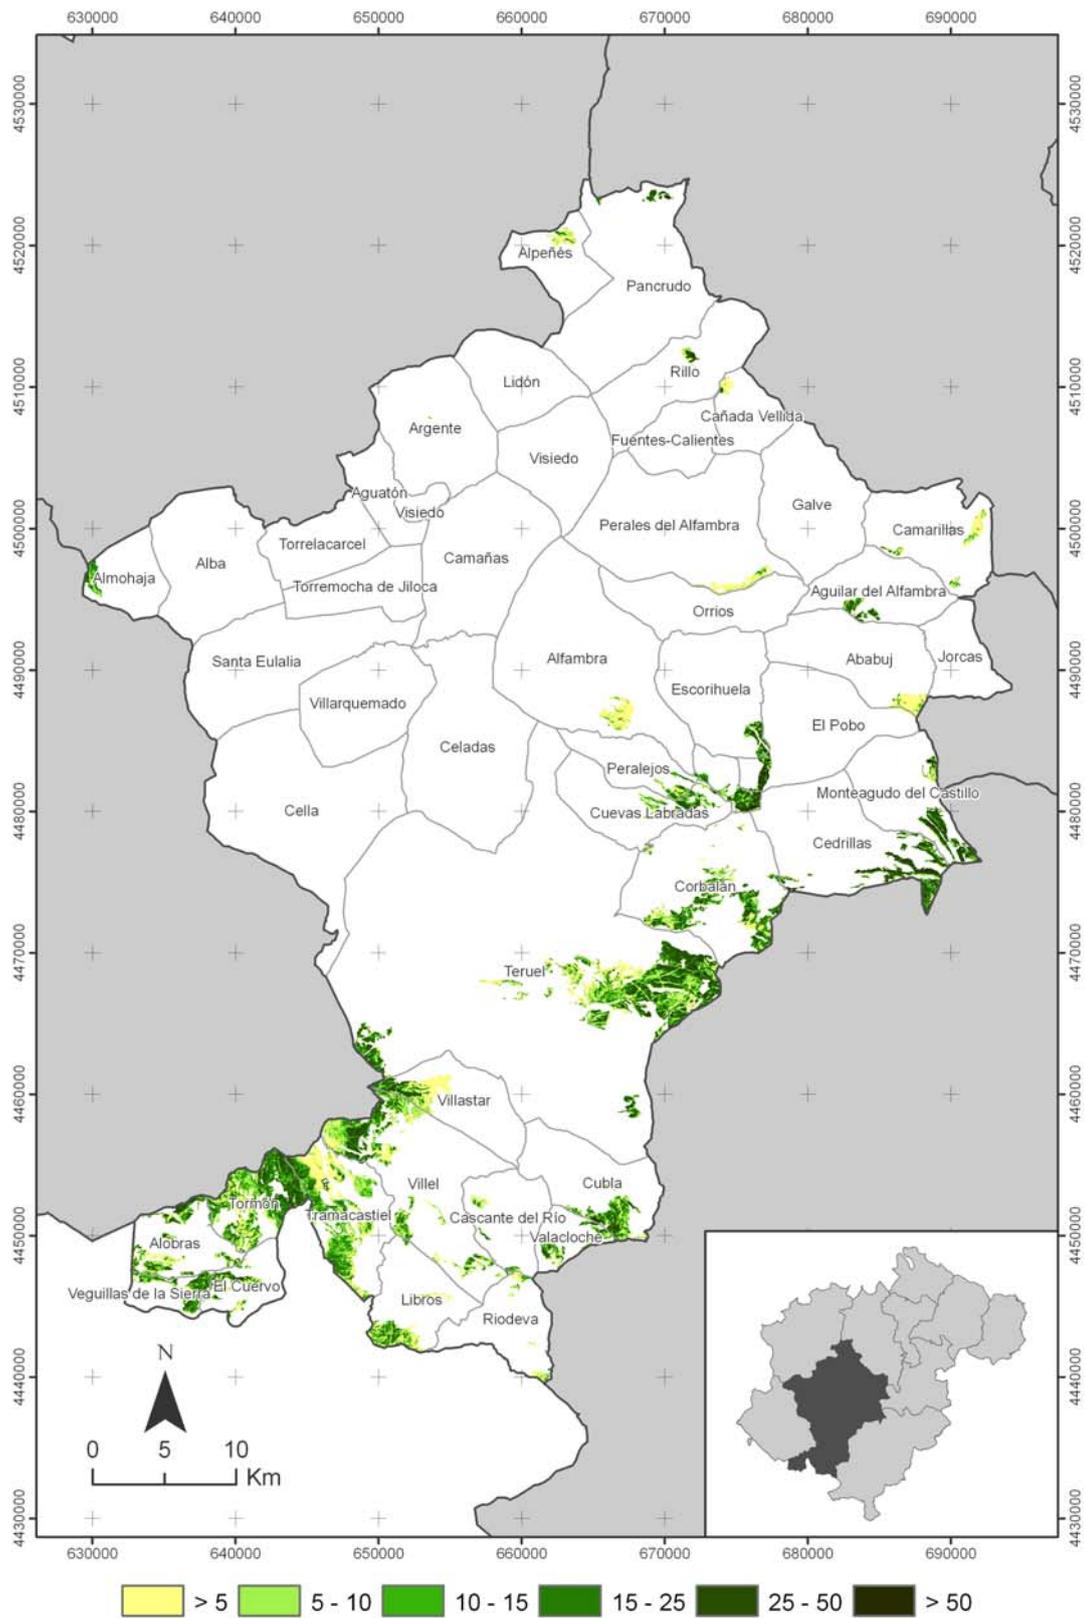


Figura 5.8. Biomasa residual forestal en la comarca de la Comunidad de Teruel (tons/ha, julio 2008)

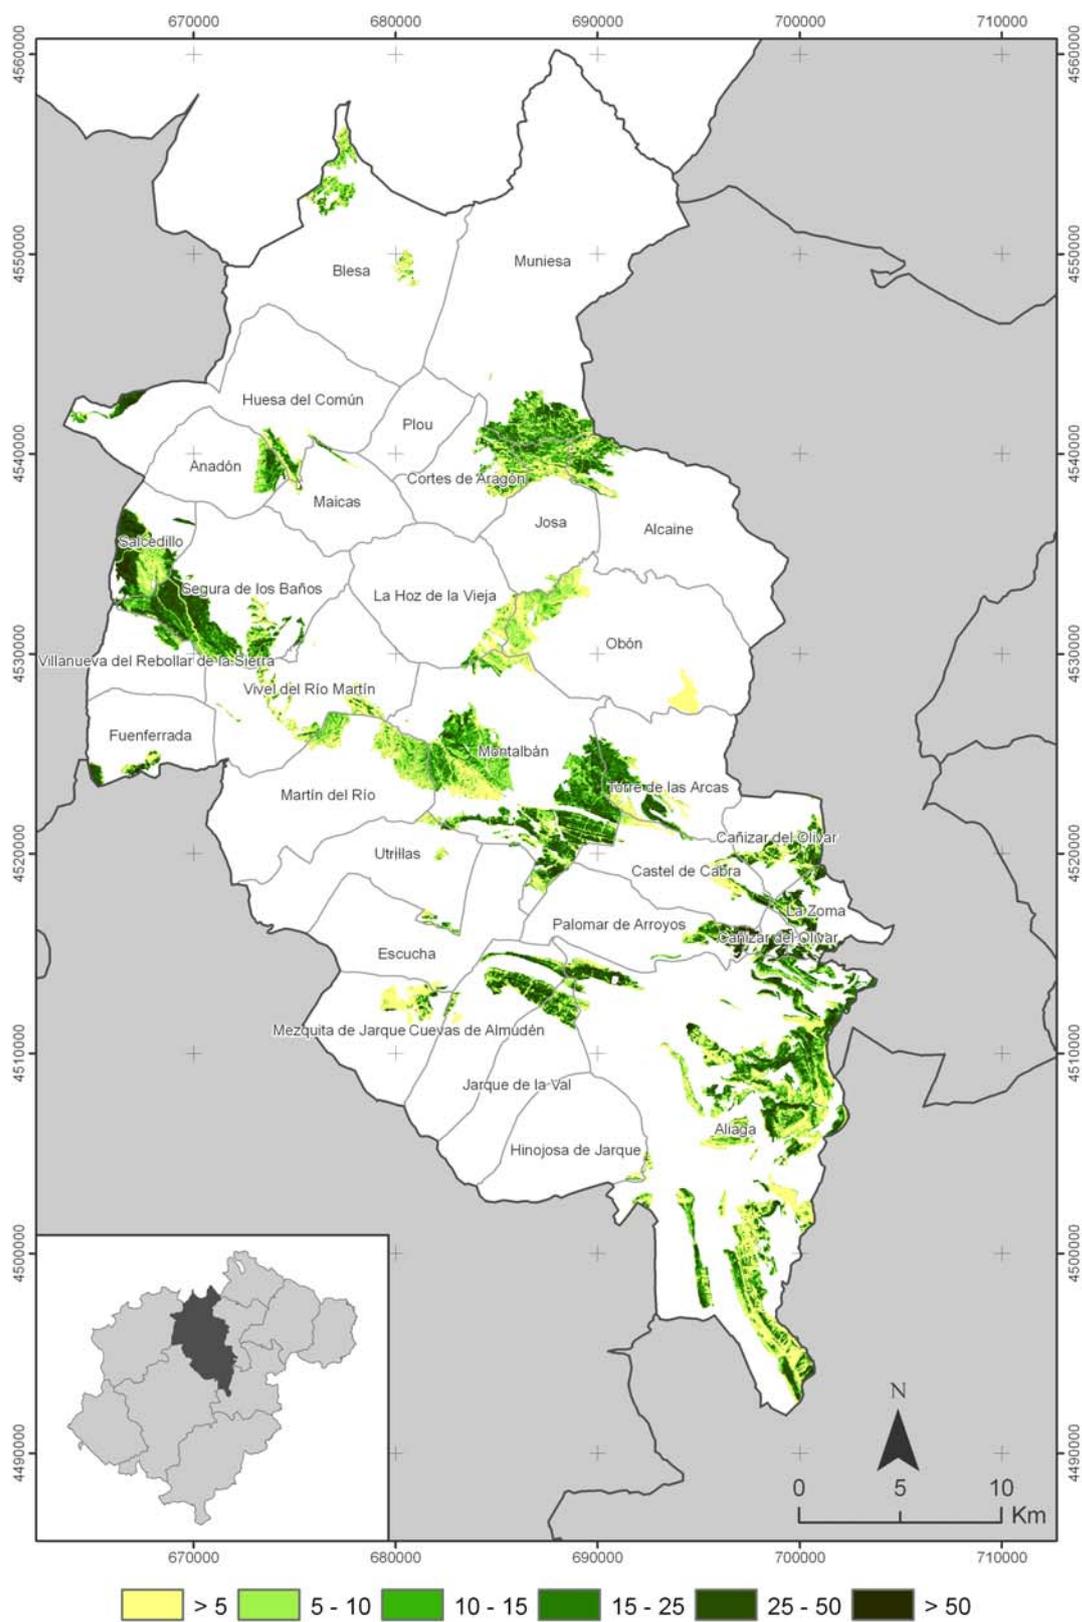


Figura 5.9. Biomasa residual forestal en la comarca de Cuencas Mineras (tons/ha, julio 2008)

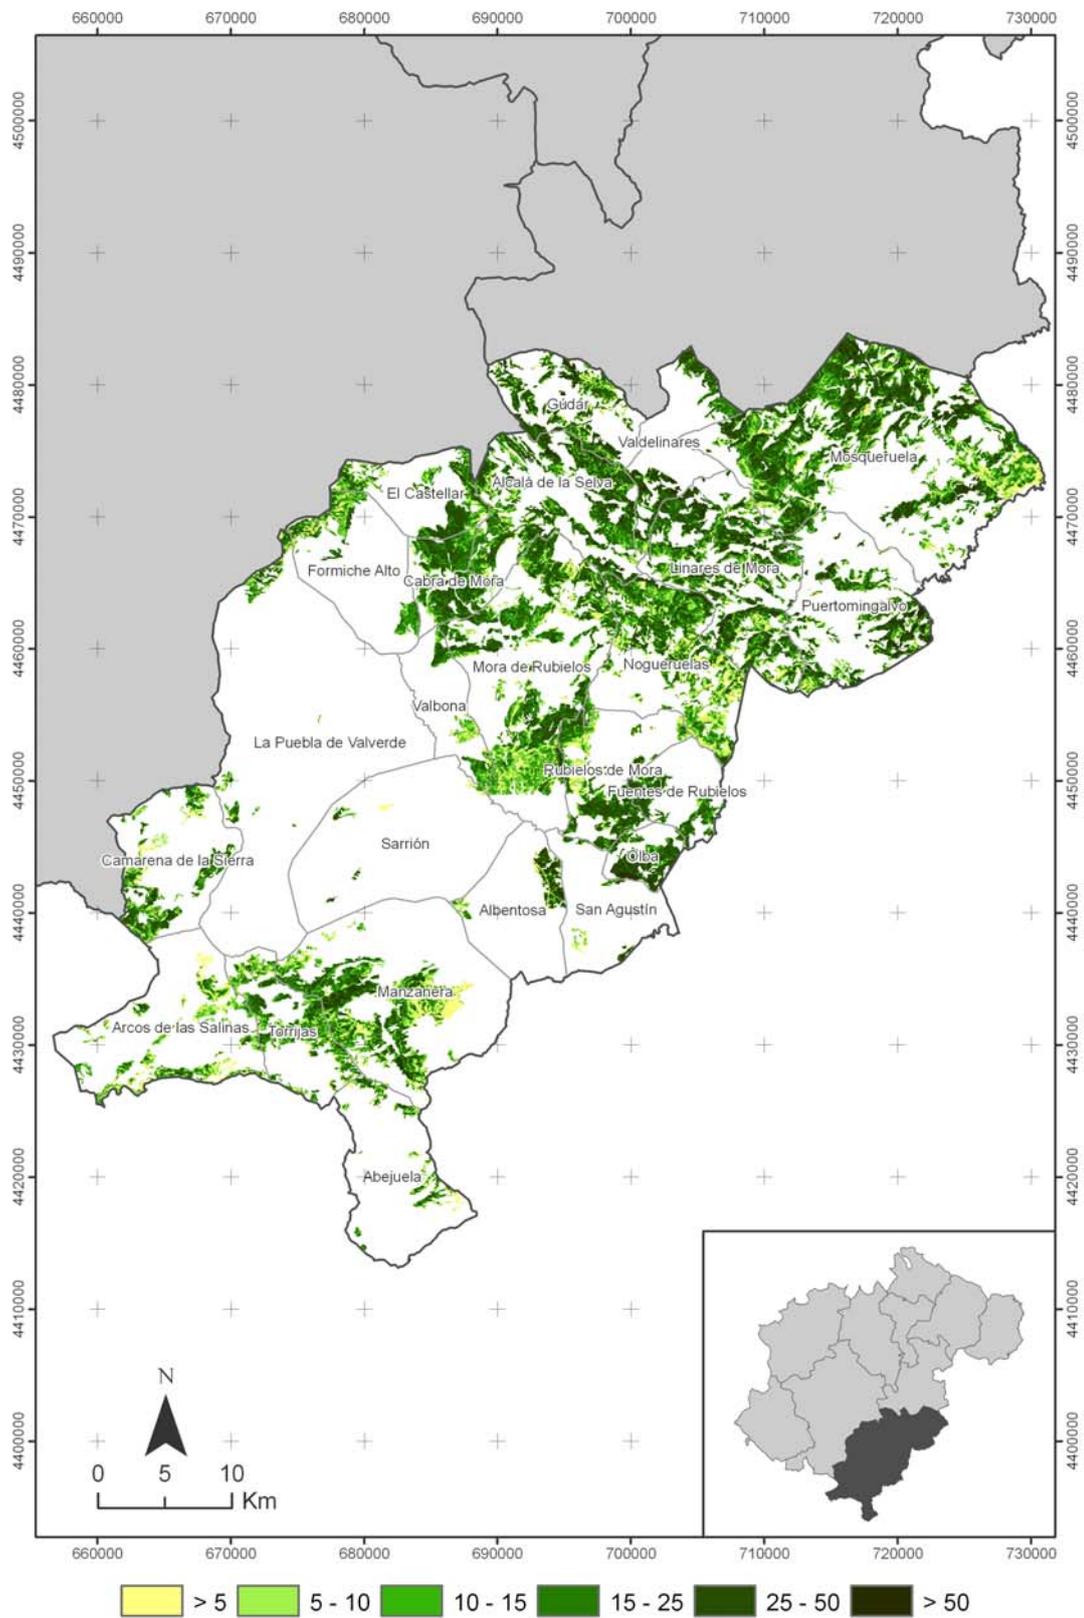


Figura 5.10. Biomasa residual forestal en la comarca de Gúdar-Javalambre (tons/ha, julio 2008)

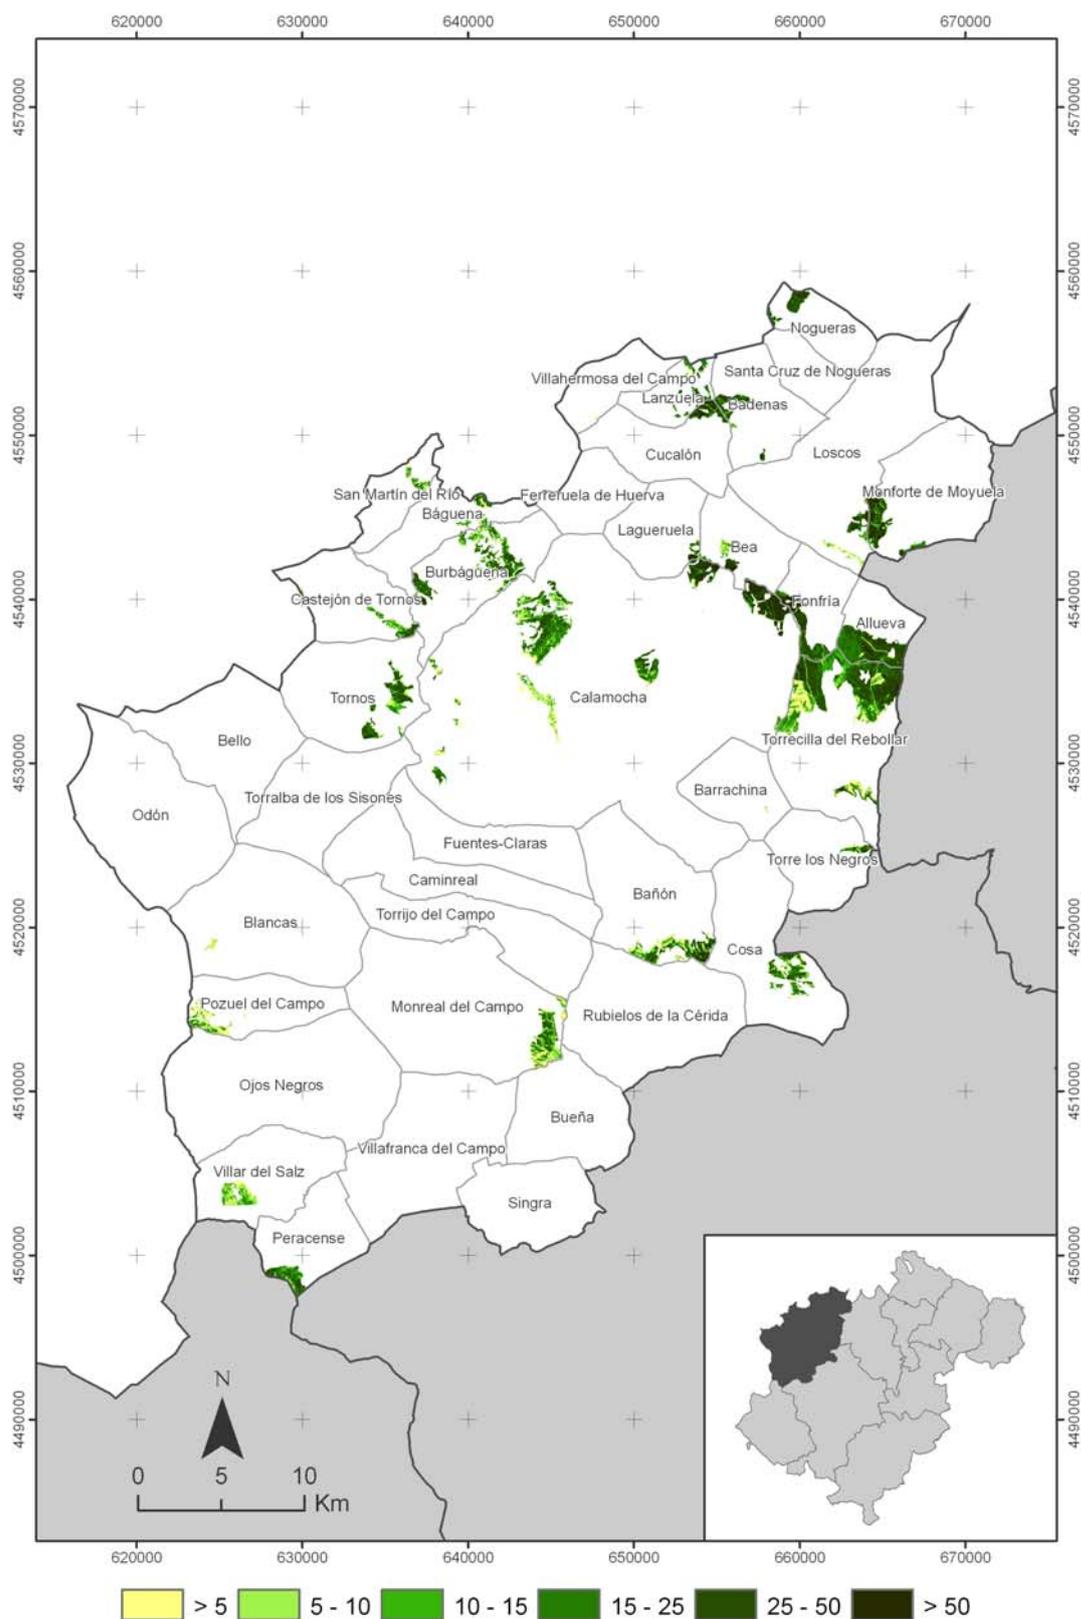


Figura 5.11. Biomasa residual forestal en la comarca del Jiloca (tons/ha, julio 2008)

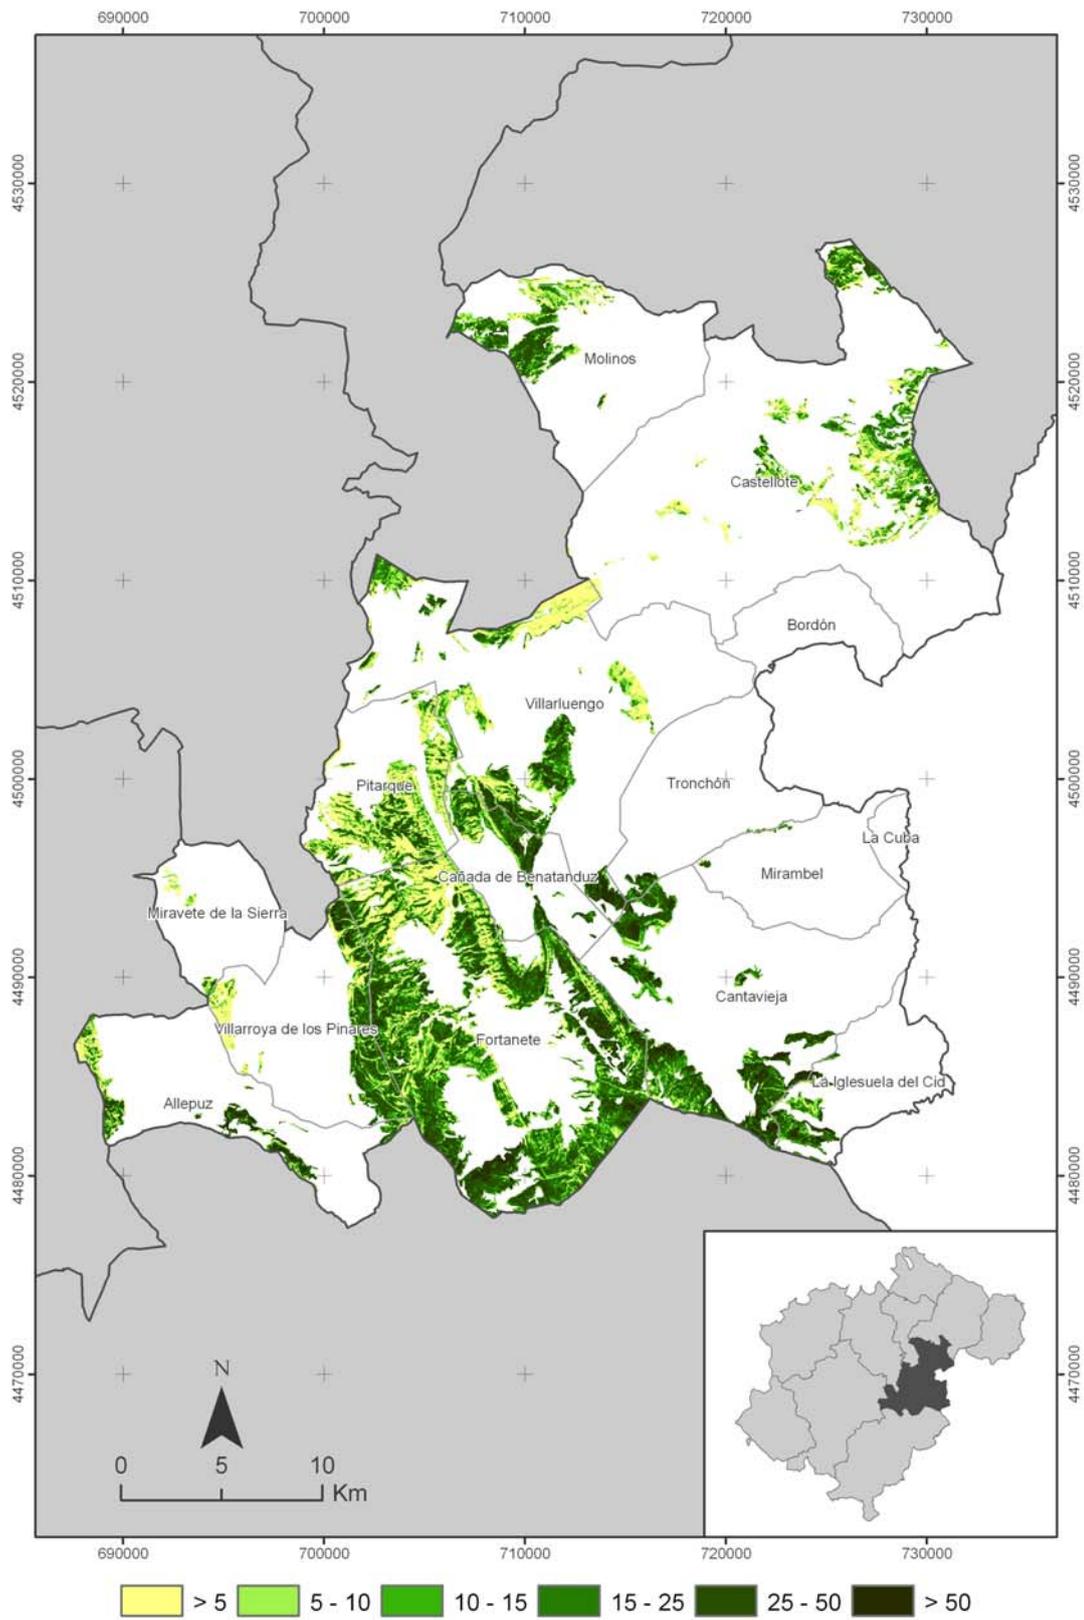


Figura 5.12. Biomasa residual forestal en la comarca del Maestrazgo (tons/ha, julio 2008)

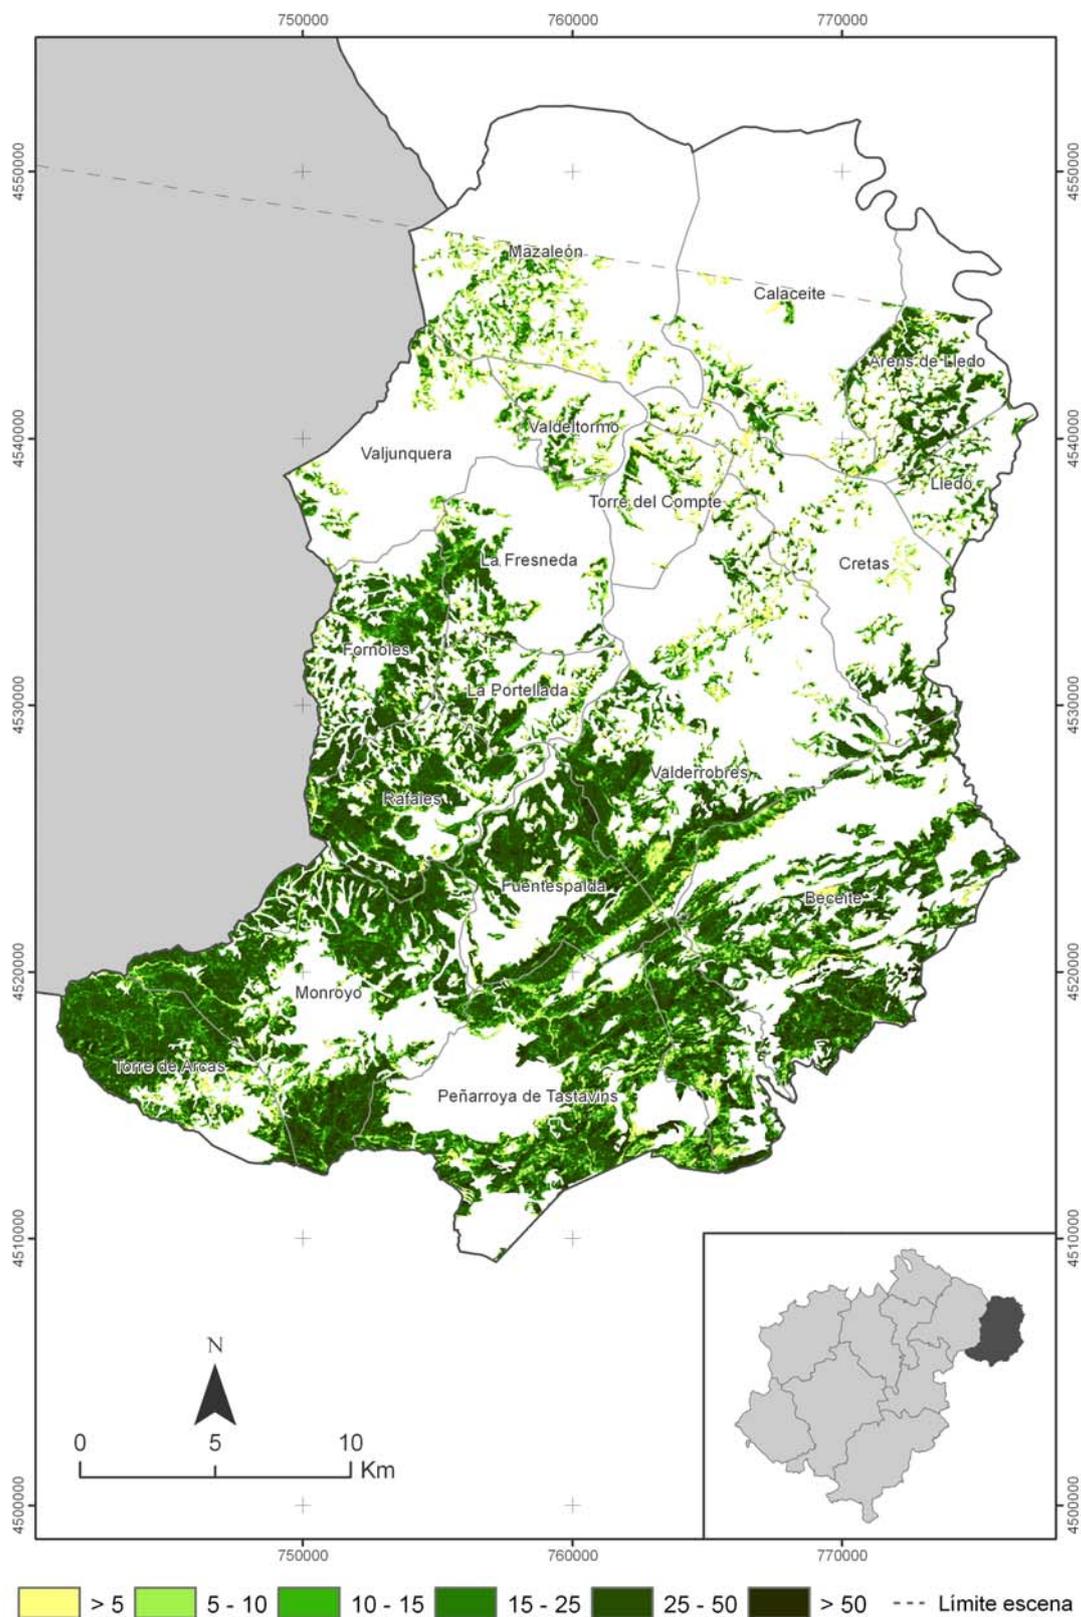


Figura 5.13. Biomasa residual forestal en la comarca del Matarranya (tons/ha, julio 2008)

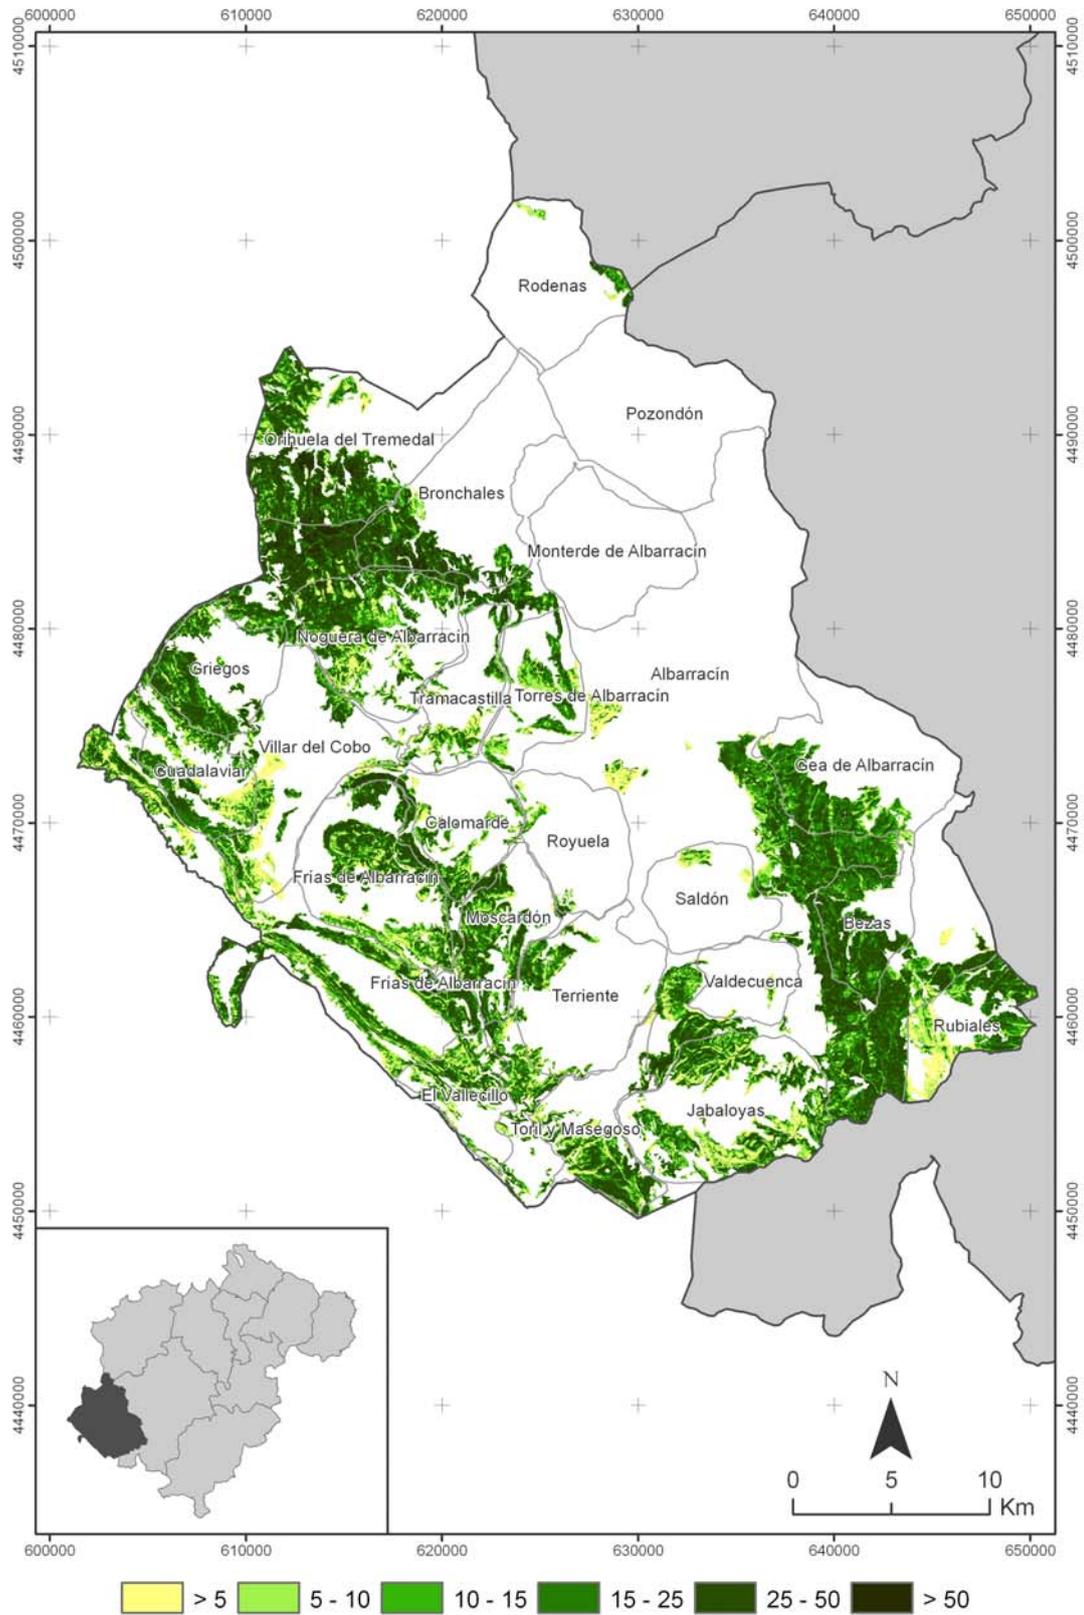


Figura 5.14. Biomasa residual forestal en la comarca de la Sierra de Albarracín (tons/ha, julio 2008)

Matarraña*			
Municipio	Toneladas	Municipio	Toneladas
Arens de Lledo*	27372,40	Mazaleón*	11597,70
Beceite	134217,00	Monroyo	141310,10
Calaceite*	7398,70	Peñarroya de Tastavins	121100,00
Cretas	15728,90	Ráfales	65118,39
Fornoles	44587,00	Torre de Arcas	68398,60
Fuentespalda	71728,50	Torre del Compte	5047,12
La Fresneda	18031,69	Valdeltormo	5962,16
La Portellada	19143,30	Valderrobres	123053,11
Lledo	6811,18	Valjunquera	6297,97

* Comarca y/o municipio no inventariados totalmente

Tabla 5.13. Biomasa residual forestal por municipios de la comarca del Matarraña

Sierra de Albarracín			
Municipio	Toneladas	Municipio	Toneladas
Albarracín	385315,01	Orihuela del Tremedal	94918,00
Bezas	48320,69	Pozondón	0,00
Bronchales	48136,89	Rodenas	3705,79
Calomarde	13958,90	Royuela	2469,08
El Vallecillo	18098,50	Rubiales	28667,90
Frías de Albarracín	53985,80	Saldón	2039,18
Gea de Albarracín	35036,69	Terriente	13429,40
Griegos	35926,39	Toril y Masegoso	32069,19
Guadalaviar	30618,90	Torres de Albarracín	16615,09
Jabaloyas	51704,89	Tramacastilla	12255,20
Monterde de Albarracín	1,62	Valdecuenca	935,92
Moscardón	33132,19	Villar del Cobo	20785,40
Noguera de Albarracín	59244,89		

Tabla 5.14. Biomasa residual forestal por municipios de la comarca de la Sierra de Albarracín

5.3. Determinación de las zonas de aprovechamiento óptimas mediante la utilización de un índice espacial

Como se ha señalado en el Capítulo 1, el desconocimiento de la cantidad de biomasa residual presente en un territorio es una de las mayores barreras que limita su utilización como fuente de energía. Una vez resuelta esta incógnita, es necesario modelizar otros factores de índole espacial que también inciden de forma decisiva en su aprovechamiento, por cuanto determinan el coste de la extracción del recurso. Estos factores son la extensión del área forestal, la pendiente del terreno y la distancia a pistas, caminos y carreteras que puedan ser utilizados para su evacuación y transporte desde la zona de extracción (Álvarez, 2004).

Estos tres factores son fácilmente modelizables en un SIG, adoptando para cada punto del territorio valores de aptitud recogidos en la bibliografía específica en relación con la viabilidad económica y técnica de la extracción de la biomasa residual. Una vez modelizados, estos tres factores se pueden integrar junto al factor cantidad de biomasa residual para desarrollar un único índice que los integre, determinando así las zonas de aprovechamiento óptimas, las que presentan mayor viabilidad desde el punto de vista económico y técnico.

En consecuencia, en las siguientes páginas se desarrolla una metodología para determinar mediante SIG las zonas de la provincia de Teruel que presentan una mayor aptitud para el aprovechamiento de su biomasa residual forestal, teniendo en cuenta las características de las masas forestales (cantidad de biomasa residual y superficie de la masa), las características orográficas del terreno (pendiente) y la existencia de las infraestructuras necesarias en términos de cercanía a pistas y caminos. Esta metodología consiste, en primer lugar, en desarrollar un índice parcial para cada uno de los cuatro factores señalados para después, en un segundo paso, crear un índice de aptitud espacial que sintetice la viabilidad técnico-económica de extraer la biomasa residual forestal presente en una zona. Este índice tiene que ofrecer además la posibilidad de ponderar cada factor de forma diferente en función de las características del territorio o de la experiencia de técnicos y gestores. Esta metodología fue diseñada conjuntamente con personal de CIRCE (ver Pascual *et al.*, 2006; 2007)

5.3.1. Obtención y modelización de los índices parciales

5.3.1.1. Índice parcial en función de la cantidad de biomasa residual forestal (I_{BRF})

La cantidad de biomasa residual potencialmente aprovechable existente presenta una relación directa con la aptitud de la masa forestal para su extracción ya que, siempre que el resto de los factores contemplados se mantengan constantes, a mayor cantidad el coste de extracción es menor y, por tanto, mayor es la rentabilidad.

No es fácil encontrar en la bibliografía un valor determinado de cantidad de biomasa residual forestal a partir del cual determinar si la extracción del recurso en una determinada área es rentable. Así, por ejemplo, Esteban *et al.* (2004) aplican una función para corregir el coste de la extracción en relación con la biomasa existente, considerando como valor óptimo 7 tons/ha. Richardson *et al.* (2002), al analizar las condiciones del monte como factores de coste, citan como factor normalizador una cantidad de metros cúbicos de residuo por cada 100 metros de calle de tractor de arrastre (*skidder*) que

equivale a unas 6-10 tons/ha. Por último, Álvarez (2004) establece que el menor coste para cada tipo de tratamiento necesario para el uso energético de la biomasa se da cuando la cantidad de biomasa verde es mayor de 35 tons/ha, lo que, suponiendo un contenido de agua del 50%, equivale a 17,5 tons/ha de biomasa seca. En definitiva, a la vista de las referencias consultadas, no existe consenso a la hora de determinar el valor óptimo mínimo a partir del cual es rentable la extracción de biomasa, estando éste comprendido en un amplio rango que oscila de las 6 tons/ha hasta las 17,5 tons/ha.

Por otro lado, es necesario señalar que la gestión forestal sostenible de las masas forestales requiere que se mantengan determinados umbrales de fertilidad que se relacionan con el contenido de materia orgánica y el nivel de pH de los suelos, estando estas dos cuestiones ligadas a la fracción de biomasa de los árboles que se desprende de éstos y pasa a formar parte de humus y, más tarde, del horizonte orgánico del suelo. Por ello, no toda la biomasa residual existente en la masa forestal puede ser extraída, siendo necesario mantener determinados aportes al suelo para garantizar la sostenibilidad de los bosques intervenidos. En la búsqueda bibliográfica efectuada, sólo se encontró un trabajo sobre evaluación del recurso de la biomasa forestal en el cual se citaba una cifra precisa sobre la cantidad de biomasa residual que debía permanecer en el bosque para evitar estos problemas, situándose esta cifra en las 11 tons/ha (McNeil Technologies, 2003).

Un último factor que se debe tener en cuenta a la hora de establecer el índice parcial relacionado con la cantidad de biomasa óptima para garantizar la rentabilidad económica y ecológica de su extracción es la eficiencia de la maquinaria empleada. De acuerdo con los trabajos de Hakkila (2003) y Ranta (2005), los sistemas de recogida tienen siempre una eficiencia inferior al 100%, incluso en las condiciones más favorables, llegando a alcanzar en estas situaciones una eficacia del 70%.

En función de los tres factores señalados se decidió considerar como óptimas aquellas masas forestales con un contenido en biomasa ≥ 37 tons/ha, dado que, aun suponiendo el máximo de eficiencia de recogida de la maquinaria (70%), queda siempre garantizada la cantidad mínima de residuo necesario para asegurar el aporte de nutrientes del suelo (11,1 tons/ha), siendo la cantidad neta de residuos obtenida de 25,9 tons/ha, cifra ésta muy superior al valor óptimo mínimo contemplado en los trabajos de Richarson *et al.* (2002), Esteban *et al.* (2004) y Álvarez (2004), a partir del cual es rentable la extracción de biomasa: entre 6 y 17,5 tons/ha.

Establecido el valor óptimo mínimo y teniendo en cuenta que a menor cantidad de este valor debe disminuir el índice parcial en función de la cantidad de biomasa (I_{BRF}), solamente resta establecer la función que controle este índice. Esta función tiene que cumplir la siguiente condición: un valor constante y máximo para cantidades ≥ 37 tons/ha y decreciente para valores menores. En este contexto se optó por asignar el valor 100 a cantidades ≥ 37 tons/ha, mientras que para cantidades inferiores se utiliza una función decreciente directamente proporcional. Para facilitar la apreciación visual y la interpretación de la cartografía resultante, se clasifica la función en intervalos regulares, asignando como valor de I_{BRF} el promedio de cada intervalo (Tabla 5.15).

Toneladas de biomasa	I_{BRF}
≥ 37	100
30 - 37	91
25 - 30	74
20 - 25	61
15 - 20	47
10 - 15	34
5 - 10	20
0 - 5	7

Tabla 5.15. Valores de I_{BRF} en función de la cantidad de biomasa residual forestal calculada en tons/ha

Dado que la cartografía de biomasa residual forestal utilizada para inventariar este recurso en la provincia de Teruel en 2008 no está expresada en tons/ha sino en toneladas por cada 0,0625 ha (el área de cada píxel), es necesario transformar este índice para poder aplicarlo a nuestra cartografía. Esto se hace multiplicando el valor de tons/ha por 0,0625 (Tabla 5.16).

Toneladas de biomasa	I_{BRF}
$\geq 2,31$	100
1,87 - 2,31	91
1,56 - 1,87	74
1,25 - 1,56	61
0,93 - 1,25	47
0,62 - 0,93	34
0,31 - 0,62	20
0,01 - 0,31	7
0,00 - 0,01	0

Tabla 5.16. Valores de I_{BRF} en función de la cantidad de biomasa residual forestal calculada en tons/píxel (1 píxel=0,0625 ha)

La cartografía de este índice se elabora reclasificando la de biomasa residual forestal que ha servido para inventariar este recurso de acuerdo con los intervalos de la

anterior Tabla 5.16, obteniéndose así una nueva capa raster en la que cada píxel de 25x25 m representa el valor de idoneidad en función de la cantidad de biomasa residual contenida (Figura 5.15).

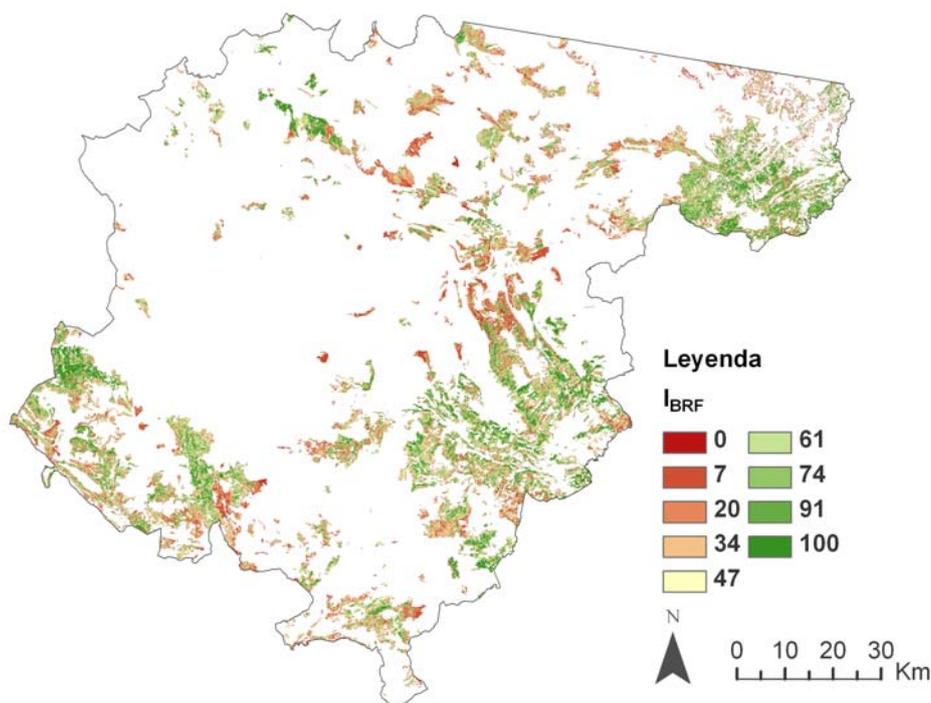


Figura 5.15. Cartografía obtenida tras reclasificar la cantidad de biomasa residual estimada en 2008 con los valores del índice I_{BRF}

5.3.1.2. Índice parcial en función de la superficie de la masa forestal (I_{sup})

El segundo factor espacial que incide a la hora de determinar la viabilidad económica de extraer la biomasa residual forestal con fines energéticos es la extensión de la masa forestal objeto de tratamiento. Según Richarson *et al.* (2002), los costes de operación son menores cuando los trabajos forestales necesarios se centran en una zona extensa, ya que se reducen los tiempos de desplazamiento de un cuartel a otro; sin embargo, no se ha encontrado en la bibliografía consultada un tamaño mínimo óptimo estándar. De esta manera, al igual que con el anterior índice, hay que determinar un valor óptimo mínimo que se identificará con el máximo del índice propuesto (I_{sup}). A partir de ese máximo, el índice irá disminuyendo proporcionalmente para superficies menores que la establecida.

Para determinar la superficie mínima se utilizó el criterio de minimizar el tiempo consumido en los desplazamientos de la maquinaria pesada y del personal de un monte

a otro. Así pues, para reducir estos tiempos de trabajo improductivos debido a los traslados, se buscó determinar un área mínima suficientemente extensa para trabajar en ella a tiempo completo durante una semana. Teniendo en cuenta lo recogido en los trabajos de Sanz y Piñeiro (2003) y Álvarez (2004) se obtiene que el rendimiento medio de la maquinaria limitante en la extracción de la biomasa residual (de la astilladora móvil o de la compactadora) es de aproximadamente 6 tons/hora. Teniendo en cuenta este dato, una jornada de 8 horas de trabajo en 5 días laborables y suponiendo que el contenido en biomasa residual de la masa forestal sea aproximadamente un tercio de la cantidad óptima neta establecida, unas 13 tons/ha, la superficie mínima que se obtiene para no mover la maquinaria durante una semana es de 18,5 ha.

En consecuencia, se adopta la superficie de 18,5 ha como valor mínimo óptimo de la extensión de la masa forestal, asignándose a ésta o mayores extensiones un valor de 100 en el I_{sup} . Para calcular el valor del índice para teselas de menor área se utiliza nuevamente una función decreciente directamente proporcional. Además, al igual que en índice de cantidad I_{BRF} , para facilitar la interpretación y la discriminación visual de la cartografía que se obtiene, se clasifica la función en intervalos regulares, asignando como valor de I_{sup} el valor promedio de cada intervalo (Tabla 5.17).

Superficie de la masa	I_{sup}
$\geq 18,5$	100
16 - 18,5	94
14 - 16	81
12 - 14	70
10 - 12	59
8 - 10	49
6 - 8	38
4 - 6	27
2 - 4	16
0 - 2	5

Tabla 5.17. Valores de I_{sup} en función de la superficie (ha) de la masa forestal

Para obtener este índice se utilizó la cartografía vectorial procedente del MFA 1:50.000 utilizada para crear la máscara usada en las cartografías de estimación. En esta cartografía vectorial se creó un nuevo campo con la superficie en hectáreas de cada tesela, siendo posteriormente esta capa convertida a raster, tomando el valor de cada píxel el de la superficie de la parcela que lo contiene. Finalmente, este raster es reclasificado, asignando a cada píxel el valor del índice I_{sup} de acuerdo con las equivalencias recogidas en la Tabla 5.17; la Figura 5.16 muestra el resultado obtenido.

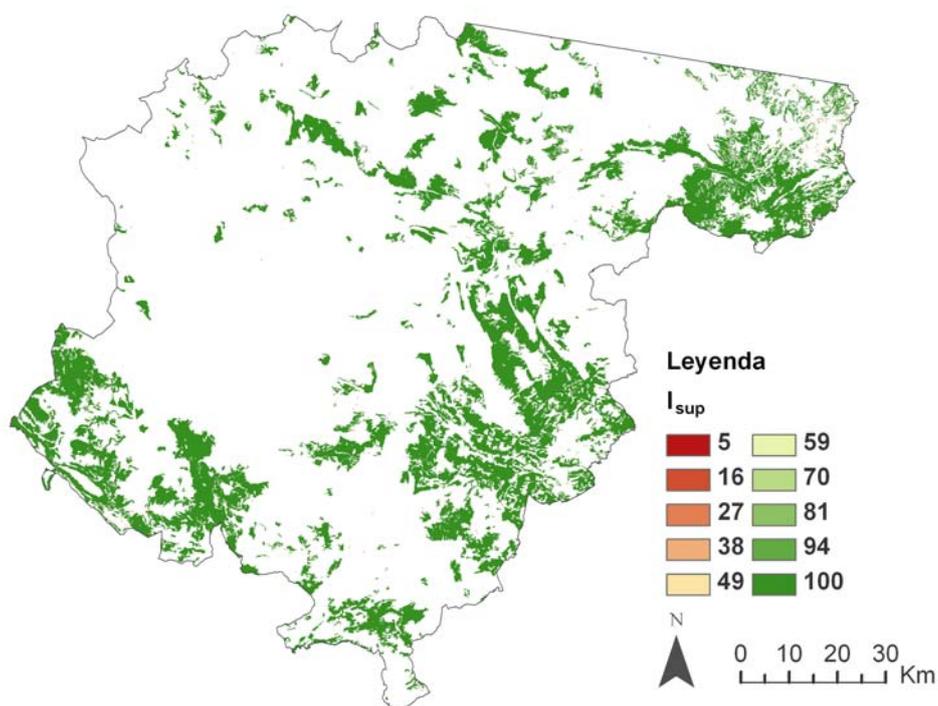


Figura 5.16. Cartografía obtenida tras reclasificar la superficie de cada tesela forestal con los valores del índice I_{sup}

5.3.1.3. Índice parcial en función de la pendiente (I_{pend})

El factor pendiente juega un papel importante a la hora de determinar la viabilidad de extraer la biomasa residual de una zona, ya que incide directamente en la maquinaria necesaria y, por lo tanto, en los costes. La maquinaria utilizada en estos trabajos forestales puede operar hasta determinados valores máximos de trabajo, de manera que el terreno susceptible de ser explotado puede clasificarse de acuerdo a estos valores.

Los trabajos consultados difieren a la hora de establecer estos umbrales. Así, en el documento elaborado por McNeil Technologies (2003) se considera que no se debe contabilizar la biomasa residual situada en zonas con pendientes $> 30\%$, mientras que en Álvarez (2004) las zonas no contempladas son aquellas que se presentan pendientes $>50\%$. Garrañeda y Bengoa (2005) precisan más a cerca de la incidencia de la pendiente en la extracción de la biomasa, estableciendo unos intervalos de eficiencia de recogida: eficiencia del 80% en zonas con pendientes $<10\%$, del 70% en zonas con pendientes comprendidas entre el 10 y el 30%, del 20% para pendientes del 30 al 50% y nula para zonas con pendientes $>50\%$.

Para establecer los valores del índice I_{pend} se tuvieron en cuenta estos intervalos de pendiente del terreno-eficiencia de extracción de recurso estimados por Garrañeda y

Bengoa (2005) para Castilla y León, pero con un carácter más restrictivo. Para zonas con pendientes <10% se considera que la eficiencia máxima es del 70%, respetándose así el máximo de eficiencia de la maquinaria establecido en los trabajos de Hakkila (2003) y Ranta (2005); dado que ésta es la situación óptima, siguiendo con el procedimiento seguido en los otros dos índices parciales establecidos, el valor para el índice I_{pend} que le corresponde es 100. A partir del anterior valor se asignan de forma proporcional decreciente los restantes de este índice a intervalos de pendiente más pequeños que los de Garrañeda y Bengoa (2005), considerándose nula la cantidad de biomasa residual que se puede extraer en zonas con pendientes >35%, no sólo por la pérdida de eficiencia en la recogida de la maquinaria, sino también por criterios medioambientales, ya que se considera que por encima de esta inclinación el riesgo de generar erosión durante los trabajos es muy alto (Tabla 5.18).

Pendiente (%)	Eficiencia	I_{pend}
0 - 10	70	100
10 - 20	60	86
20 - 35	45	64
>35	0	0

Tabla 5.18. Valores de I_{pend} en función de la pendiente (%) del terreno

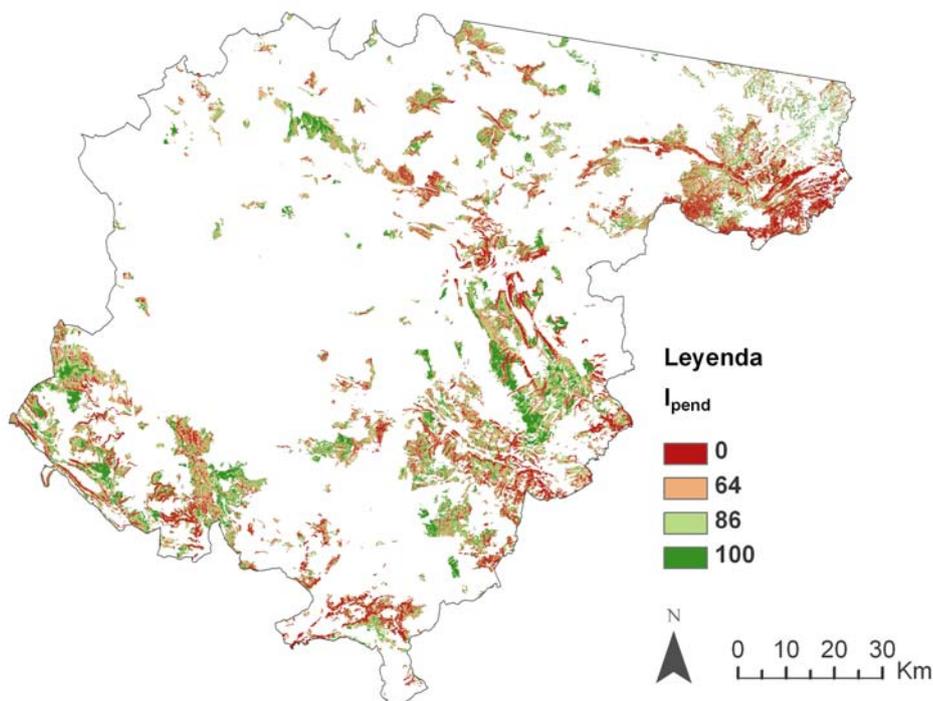


Figura 5.17. Cartografía obtenida tras reclassificar la pendiente de las zonas forestales con los valores del índice I_{pend}

Para obtener la cartografía de este índice se utilizó el MDE generado en esta tesis a partir de la información de pendiente en porcentajes y se aplicó la máscara forestal usada en las cartografías de estimación. El raster resultante fue reclasificado, asignando a cada píxel el valor del índice I_{pend} de acuerdo con las equivalencias recogidas en la Tabla 5.18; la Figura 5.17 muestra el resultado obtenido.

5.3.1.4. Índice parcial en función de la distancia a desembosque (I_{dist})

El coste de extracción de la biomasa es dependiente tanto de la naturaleza del terreno como de la distancia de saca o desembosque (Richardson *et al.*, 2002). Por ello, en el presente subapartado se pretende crear un índice parcial que modele el efecto que tiene en la aptitud de una zona para el aprovechamiento de la biomasa residual la distancia entre la zona de corta de la biomasa y las pistas, caminos o carreteras donde habitualmente se sitúan las zonas de acopio del recurso.

Distancia a desembosque	I_{dist}
0 - 100	100
100 - 200	97
200 - 300	93
300 - 400	90
400 - 500	86
500 - 600	83
600 - 700	79
700 - 800	76
800 - 900	72
900 - 1000	69
1000 - 1500	60
1500 - 2000	43
2000 - 2500	26
2500 - 3000	7
≥3000	0

Tabla 5.19. Valores de I_{dist} en función de la superficie (ha) de la masa forestal

Los datos de la relación productividad-distancia de desembosque se obtuvieron a partir de los resultados mostrados en los trabajos de Richardson *et al.* (2002) y Sanz y Piñeiro (2003). El primero de ellos representa la variación de la productividad en función de la capacidad de carga de la maquinaria y de la distancia de desembosque, mientras que el segundo considera, junto a la distancia de desembosque, la productividad en función de la especie (pino o eucalipto) y la forma de preparación del residuo. Los datos de productividad obtenidos se transformaron a porcentaje, utilizando para normalizar la muestra el máximo valor. Del estudio de estos datos se concluyó que la rentabilidad era

máxima cuando las distancias de desembosque eran <100 m, disminuyéndose de una forma proporcional hasta llegar a distancias >3000 m, en las que el beneficio es nulo. De esta forma, al igual que en los anteriores factores, este óptimo de distancias <100 m fue igualado a un valor máximo de 100 en el índice I_{dist} ; a partir de ahí el valor del índice va disminuyendo de forma proporcional hasta un valor nulo para distancias ≥ 3000 m. La Tabla 5.19 muestra el valor de este índice I_{dist} para diferentes intervalos.

Para la obtención de este índice se utilizó como información base una capa vectorial proporcionada por la Dirección General de Gestión Forestal del Gobierno de Aragón con la red de pistas forestales, caminos y carreteras de la provincia de Teruel. A partir de esta capa se calcularon *buffers* que consideraban la distancia ortogonal en metros a estas infraestructuras según los intervalos establecidos. Posteriormente, estos *buffers* fueron convertidos individualmente a capas raster donde cada pixel tenía como valor la distancia a las pistas, caminos y carreteras. Estos raster fueron integrados en una única capa, que fue reclasificada en función de los valores del índice I_{dist} establecidos; por último, sobre esta capa se aplicó la máscara forestal procedente del MFA 1:50.000. La Figura 5.18 recoge el resultado final.

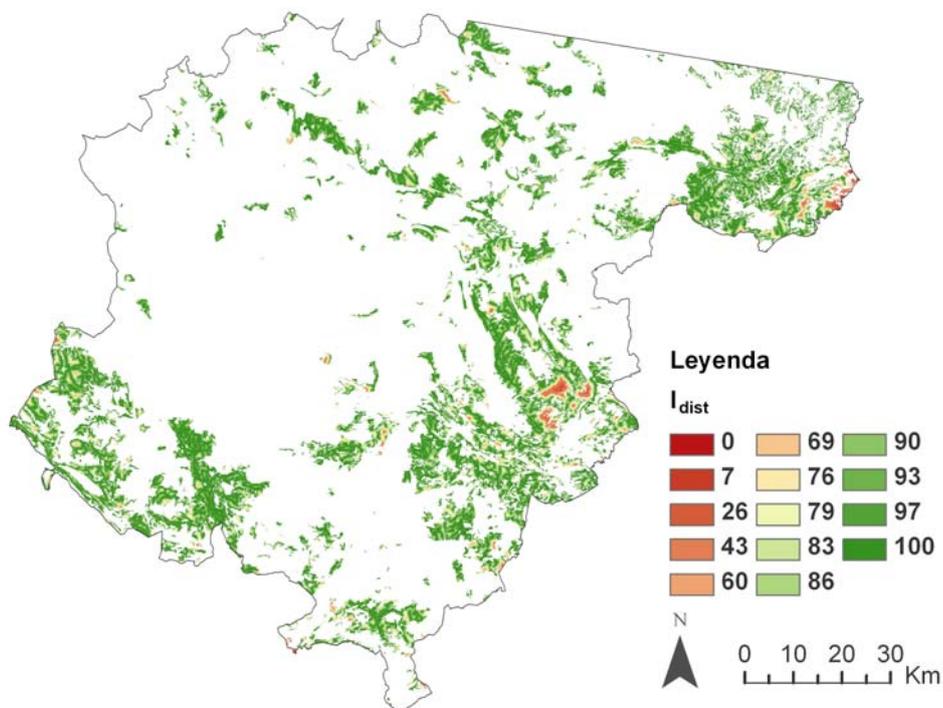


Figura 5.18. Cartografía obtenida tras reclasificar la distancia a pistas, caminos y carreteras con los valores del índice I_{dist}

5.3.2. Combinación de los índices de aptitud parcial

Para asignar a cada punto del territorio un valor de aptitud para el aprovechamiento de la biomasa residual como recurso energético se formularon dos índices de aptitud. Ambos combinan los cuatro parciales previamente calculados, pero lo hacen de forma diferente; los dos índices fueron pensados para que variaran de 0 (zonas de nula aptitud) a 100 (zonas de máxima aptitud para el aprovechamiento de la biomasa).

El primer índice, denominado índice de aptitud multiplicativo (I_{aptM}), es calculado como el producto de los cuatro parciales, multiplicándose el resultado obtenido por 10^{-6} para que el valor final esté comprendido en el rango 0-100 (Ecuación 37).

$$I_{aptM} = I_{BRF} \cdot I_{sup} \cdot I_{pend} \cdot I_{dist} \cdot 10^{-6} \quad \text{Ecuación 37}$$

donde I_{BRF} es el índice parcial en función de la cantidad de biomasa residual forestal; I_{sup} es el índice en función de la superficie de la masa forestal; I_{pend} es el índice en función de la pendiente; e I_{dist} es el índice en función de la distancia a desembosque.

El segundo índice, denominado índice de aptitud ponderado (I_{aptP}), es el resultado del sumatorio de los cuatro parciales considerados, pudiéndose asignar diferentes pesos entre 0 y 100 a cada uno de ellos para modelar su importancia en la aptitud global (Ecuación 38).

$$I_{aptP} = (w_{BRF} \cdot I_{BRF}) + (w_{sup} \cdot I_{sup}) + (w_{pend} \cdot I_{pend}) + (w_{dist} \cdot I_{dist}) \quad \text{Ecuación 38}$$

donde w_{BRF} , w_{sup} , w_{pend} y w_{dist} son los pesos que se asignan, respectivamente, a los índices parciales I_{BRF} , I_{sup} , I_{pend} e I_{dist} .

5.3.3. Resultados de los índices parciales y de los índices de aptitud global

5.3.3.1. Resultados de los índices parciales

- Resultados del índice I_{BRF}

A pesar del alto valor propuesto como indicador de las masas óptimas para ser explotadas en función de la cantidad en comparación con el más alto de los trabajos consultados (37 tons/ha frente a 17,5 tons/ha), un 13,62% de los bosques de pináceas de Teruel presentan un I_{BRF} de 100, lo que supone 37.167 ha. Además, tal y como se observa en la Figura 5.19, el porcentaje de estos bosques que queda con índices de I_{BRF}

>60 puntos es muy elevado, abarcando casi la mitad de la superficie boscosa total (44,29%, 120.838 ha).

El porcentaje de superficie con valores de I_{BRF} intermedios, entre 20 y 47 puntos, se sitúa en torno al 40%. La rentabilidad –o no– de explotar estos bosques dependerá en gran medida de los valores que se obtengan en los otros índices parciales. Por último, reseñar que, desde el punto de vista de este índice, un 15% de las masas de pinos sobre las que se ha obtenido la cantidad de biomasa residual forestal no son óptimas para la explotación, ya que obtienen una valoración igual o inferior a 7. Estas masas serán, además, *a priori* las menos rentables según los índices de aptitud que combinan los índices parciales, ya que aunque presenten valores muy altos en los otros tres índices parciales, el bajo valor en I_{BRF} explicará una baja puntuación global.

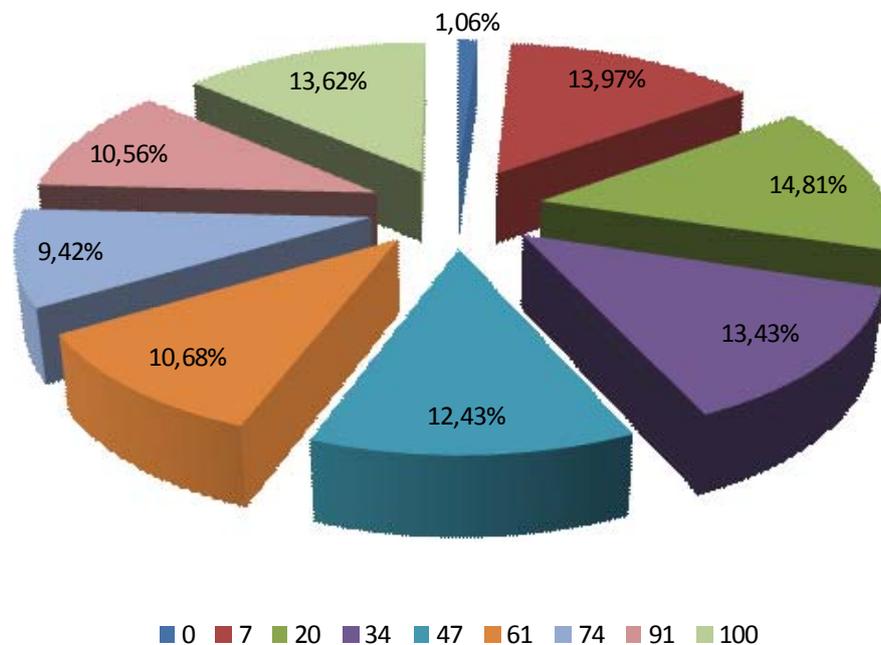


Figura 5.19. Distribución de la superficie forestal de pináceas respecto al índice I_{BRF}

- Resultados del índice I_{sup}

El 98,09% de las teselas forestales sobre los que se ha estimado la biomasa residual tienen una extensión >18,5 ha. De esta manera, casi la totalidad de la superficie inventariada queda con un valor 100 en el índice I_{sup} , no incluyéndose en ninguno de los intervalos restantes contemplados en este índice superficies >0,5% de la total. Este resultado es producto, en primer lugar, de la escala de trabajo utilizada en la elaboración del MFA (1:50.000) y, en segundo, de que se ha aplicado una reclasificación del mismo

hecha con el objetivo de sintetizar la leyenda original en categorías más simples, agrupando las teselas por especies. Este doble hecho hace que el tamaño de la tesela final utilizada sea bastante grosero, tal y como evidencia el índice I_{sup} .

Por tanto, los resultados obtenidos sugieren que el índice I_{dist} es superfluo, ya que no aporta nada a la hora de determinar la aptitud de las masas para la explotación del recurso; casi todas ellas resultan igualmente idóneas desde el punto de vista de su extensión, al menos en función de la cartografía de referencia empleada. Sin embargo, dado el carácter restrictivo que tiene el índice de aptitud multiplicativo I_{aptM} –ya que al multiplicarse todos los factores por igual sólo las mejores zonas en todos ellos resultarán óptimas- se decidió mantener el I_{dist} en su cálculo. En cambio, es eliminado del índice I_{aptP} , por haberse constatado que su peso relativo con respecto a los demás índices parciales es mínimo o prácticamente nulo.

- Resultados del índice I_{pend}

De acuerdo con lo esperado, el índice I_{pend} tiene un carácter mucho más restrictivo que el anterior (Figura 5.20). Así, en casi un 25% de la superficie forestal considerada resulta inviable retirar la biomasa presente, ya que se encuentra en zonas con pendientes >35%, que impiden el uso de determinada maquinaria, encareciéndose en demasía su extracción. Aun así, la cantidad de bosque que se considera óptima desde el punto de vista de este parámetro puede calificarse como elevada, ya que algo más del 46% presenta un I_{pend} superior a 86 puntos, lo que supone un total de 125.800 ha.

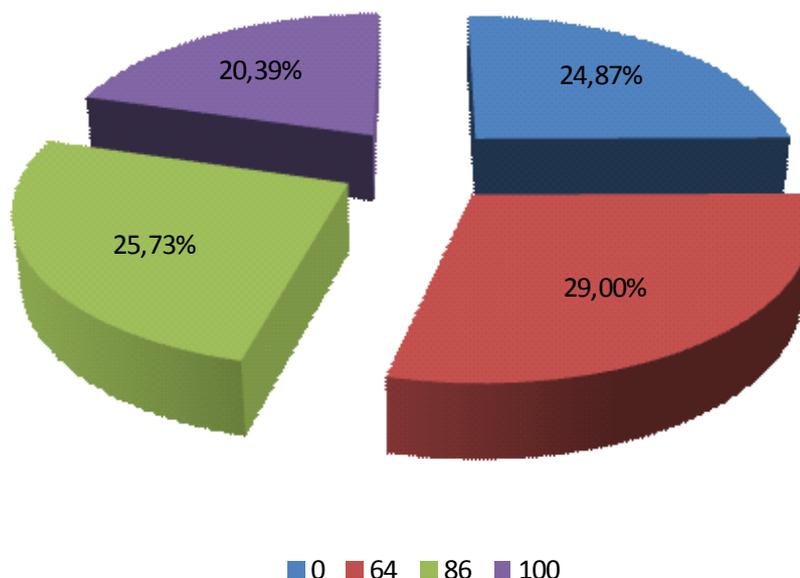


Figura 5.20. Distribución de la superficie forestal de pináceas respecto al índice I_{pend}

La rentabilidad-viabilidad de explotar el restante 29% dependerá, al igual que en el caso de la superficie clasificada con valores intermedios de I_{BRF} , de lo obtenido para los otros tres factores considerados en esas áreas con pendientes entre el 20-35%. Si en ellas existe una gran cantidad de recurso y la distancia de desembosque es pequeña serán óptimas, mientras que si se dan cantidades y distancias a pistas y caminos intermedias su aptitud para la obtención de recurso será escasa o nula.

- Resultados del índice I_{dist}

Tal y como se observa en la Figura 5.21, la mayor parte de las masas forestales presenta unos valores I_{dist} elevados. En concreto, el 81,26% de la superficie inventariada presenta un valor ≥ 90 , lo que significa que está situada a <400 m de una pista, camino o carretera desde donde realizar el desembosque del recurso. Dentro de este grupo, las áreas clasificadas con un I_{dist} de 100 son las más abundantes, representando casi un 31,5% de la superficie total. Un último dato a destacar, que refuerza la viabilidad de explotación de los bosques de pináceas de Teruel teniendo en cuenta únicamente este factor, es que tan sólo 3.990 ha tienen un I_{dist} <60, apenas el 1,5% del total.

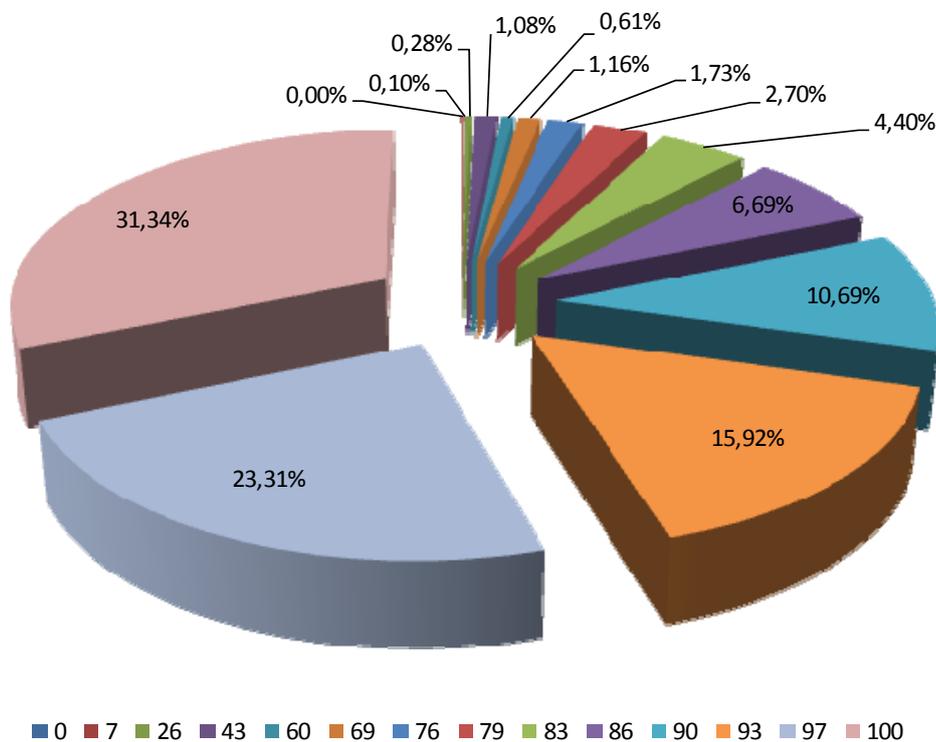


Figura 5.21. Distribución de la superficie forestal de pináceas respecto al índice I_{dist}

Este resultado, fruto de la existencia de una buena infraestructura forestal y de un exhaustivo inventario de la misma por parte de la Administración autonómica, indica que la distancia de desembosque no va a ser un factor limitante a la hora de determinar si una zona resulta óptima o no a la hora de extraer su biomasa residual.

5.3.3.2. Resultados del índice de aptitud multiplicativo (I_{aptM})

La cartografía obtenida mediante la aplicación del índice de aptitud multiplicativo I_{aptM} (Figura 5.22) permite visualizar y seleccionar de forma precisa aquellas zonas en las que es, o puede ser, viable económicamente el aprovechamiento de la biomasa residual forestal con fines energéticos manteniendo criterios de sostenibilidad de los bosques. Aquellas masas con un valor >50 serán zonas con un moderado interés, mientras que valores por encima de 70-75 identificarán zonas muy apropiadas. Sin embargo, es necesario volver a subrayar, antes de interpretar los resultados obtenidos, el carácter restrictivo de este índice multiplicativo, dado que sólo es posible obtener para él valores altos cuando todos y cada uno de los 4 factores considerados presentan sus valores máximos. Así, por ejemplo, si una zona presenta un valor de 90 en los 4 índices parciales considerados, el resultado del I_{aptM} será de 65,61 puntos.

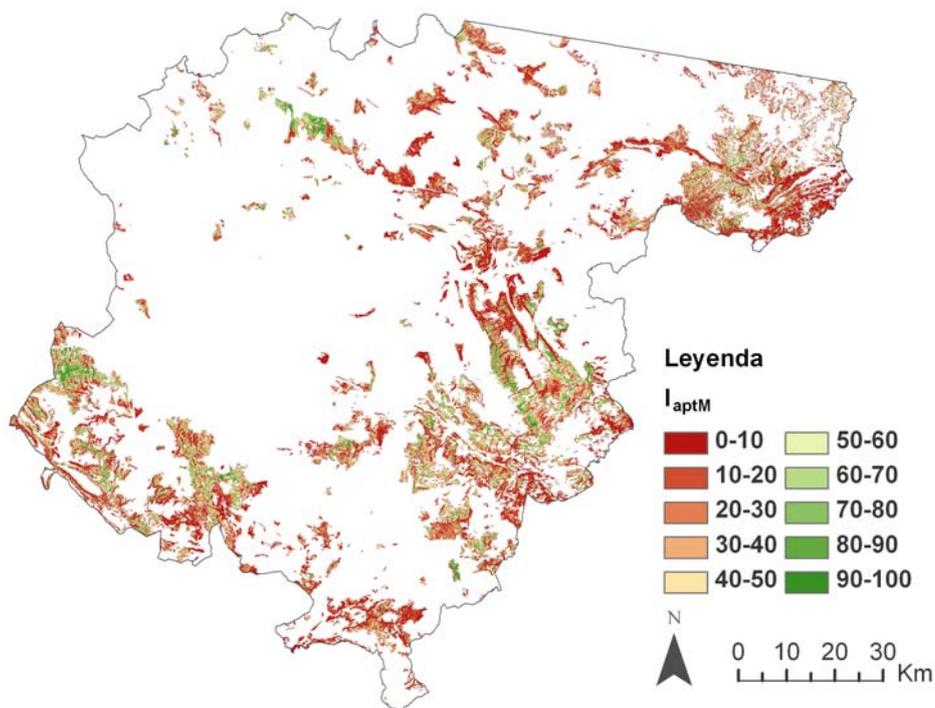


Figura 5.22. Cartografía obtenida tras aplicar el índice I_{aptM}

Teniendo en cuenta la anterior premisa, no es extraño que, tal y como se observa en la Figura 5.23, sólo el 25% de la superficie forestal inventariada es considerada como de moderado interés para la explotación de biomasa, mientras que las zonas consideradas como muy apropiadas ($I_{aptM} \geq 70$) se reducen apenas al 10,80%. Por último reseñar que un total de 7.251 ha se identifican como zonas excepcionalmente apropiadas, dado que presentan valores de I_{aptM} superiores a 90. Estas zonas corresponden a masas forestales de >37 tons/ha, con una superficie >18,5 ha, situadas sobre un terreno con pendientes entre el 0 y el 10% y con una distancia de desembosque <200 m.

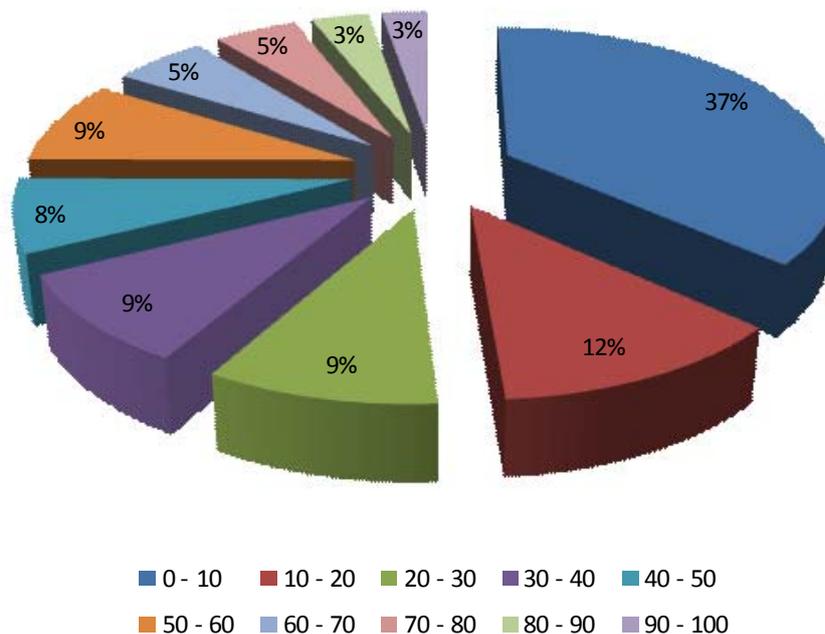


Figura 5.23. Distribución de la superficie forestal de pináceas respecto al índice I_{aptM}

Como se observa en la cartografía, tres zonas son las que concentran la mayor parte de las masas forestales que han quedado clasificadas como de un interés medio-alto para su explotación: la Sierra de Albarracín (Sierra del Tremedal y Pinares de Ródeno), la Sierra de Cucalón y el sector nororiental de la Sierra de Gúdar. Dado que los dos factores más restrictivos, de los cuatro considerados, son la cantidad de recurso y la pendiente, es fácil concluir que estas tres zonas estarán caracterizadas por una alta cantidad de biomasa residual y por unas pendientes bajas; la visualización de las cartografías de los índices parciales I_{BRF} e I_{pend} así lo confirma.

5.3.3.3. Resultados del índice de aptitud ponderado (I_{aptP})

Como ya se ha adelantado, el índice parcial I_{sup} no es utilizado en el cálculo del índice de aptitud ponderado (I_{aptP}) dada su escasa significación (98% de la superficie con

I_{aptP} 100). Para conocer cómo influyen las ponderaciones asignadas en este índice a las tres variables restantes se llevaron a cabo un total de 3 pruebas, asignando un peso mayor en cada una de ellas a cada índice parcial sobre los otros dos (Tabla 5.20).

Pruebas con I_{aptP}	Peso asignado a I_{BRF}	Peso asignado a I_{pend}	Peso asignado a I_{dist}
A	0,6	0,2	0,2
B	0,2	0,6	0,2
C	0,2	0,2	0,6

Tabla 5.20. Pesos asignados a cada uno de los índices parciales considerados en las tres pruebas con el índice I_{aptP}

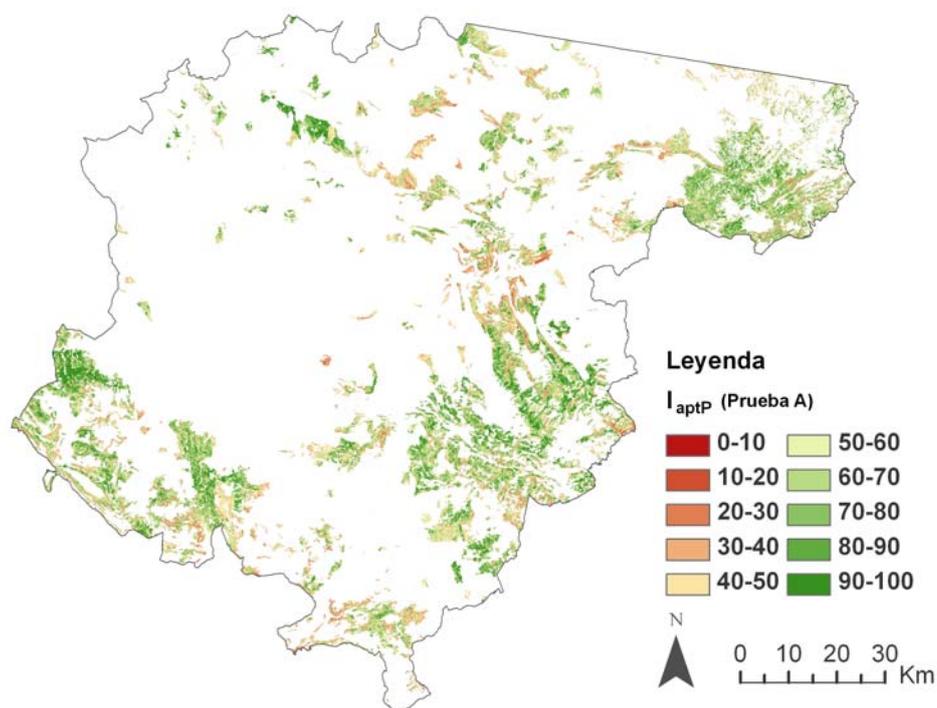


Figura 5.24. Cartografía obtenida tras aplicar el índice I_{aptP} con los pesos de la prueba A

Las tres pruebas realizadas con el índice I_{aptP} (Figuras 5.24, 5.25 y 5.26) presentan una mayor cantidad de superficie forestal con aptitudes medias y altas para la extracción de biomasa residual que con el índice I_{aptM} . Así, en la cartografía resultado de asignar un peso de 0,6 al índice I_{BRF} y 0,2 a I_{pend} e I_{dist} (prueba A), un 65,40% de la superficie queda clasificada con un valor por encima de los 50 puntos y un 35,35% tiene un índice superior a 70. De esta manera, a pesar de la alta cantidad de biomasa establecida como valor óptimo en el índice I_{BRF} (37 tons/ha) –aquél con mayor peso en esta prueba–, un total de 96.451 ha quedan clasificadas como masas muy apropiadas

para la explotación del recurso. La masas excepcionalmente apropiadas, por encima de los 90 puntos ascienden a 36.429 ha, es decir, a un 13,35% del total.

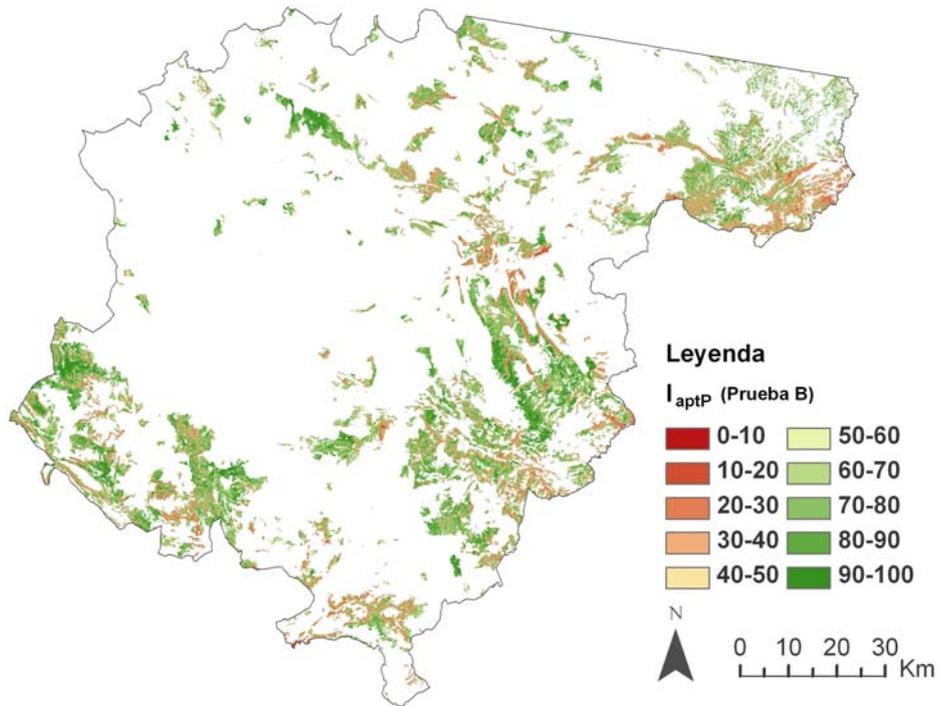


Figura 5.25. Cartografía obtenida tras aplicar el índice I_{aptP} con los pesos de la prueba B

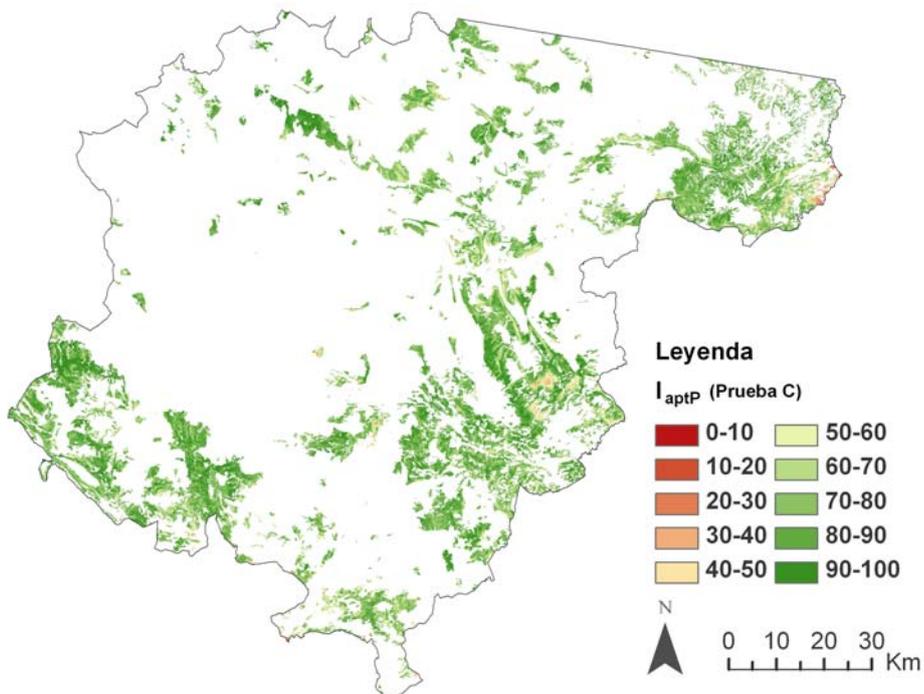


Figura 5.26. Cartografía obtenida tras aplicar el índice I_{aptP} con los pesos de la prueba C

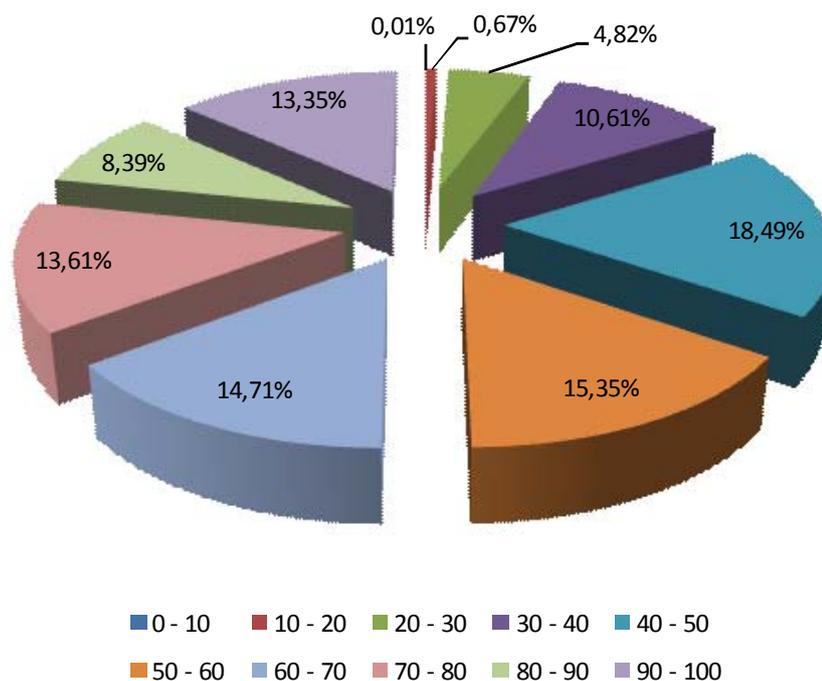


Figura 5.27. Distribución de la superficie forestal de pináceas respecto a la prueba A del índice I_{aptP}

El análisis visual de la cartografía de esta prueba A permite confirmar las conclusiones obtenidas con el índice I_{aptM} en relación con la distribución de las zonas óptimas para el aprovechamiento del recurso. Así, la Sierra de Albarracín (principalmente en los sectores de Sierra del Tremedal y Pinares de Rodeno), la Sierra de Cucalón y el sector nororiental de la Sierra de Gúdar se confirman como las mejores zonas, si bien hay que destacar que la superficie considerada como excepcionalmente o muy adecuada es mucho mayor. Esta situación se observa, sobre todo, en la Sierra de Gúdar, ya que la mayor parte del entramado de sierras que la componen presenta estos elevados valores, no sólo las sierras nororientales que resultaban destacadas con I_{aptM} . Por último, señalar la presencia de una nueva e importante zona con valores altos de aptitud según esta prueba A del índice I_{aptP} ; se trata del sector nororiental, en la comarca del Matarraña, donde se localizan los Puertos de Beceite. Asimismo destacar que, además de en estas zonas, aparecen numerosas teselas de menor tamaño con altos valores de este índice por todo el territorio provincial.

A pesar de que la cartografía obtenida en la prueba B es fruto de otorgar más peso a uno de los factores más restrictivos –la pendiente– frente a los otros dos considerados (0,6 a I_{pend} y 0,20 a I_{BRF} e I_{dist}), los resultados son más semejantes a los de la prueba A que a los obtenidos con el índice I_{aptM} . Así, tres cuartas partes de la superficie

inventariada queda clasificada con valores de aptitud iguales o superiores a 50, elevándose el porcentaje de masas forestales muy apropiadas para la explotación –las que presentan valores por encima de 70 puntos– al 56%, es decir, más de la mitad de la superficie inventariada. El porcentaje de masas con valores superiores a 90 puntos se sitúa en esta ocasión alrededor del 10%.

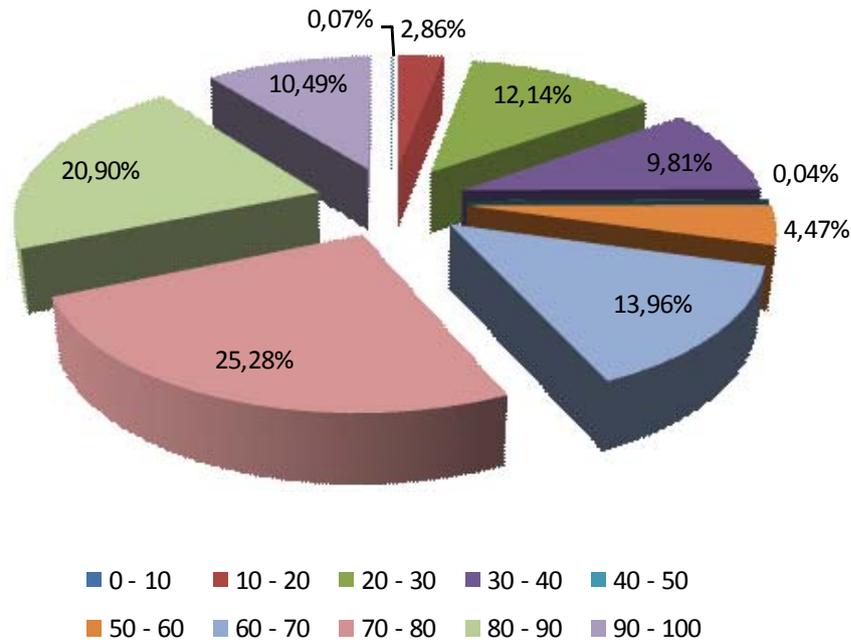


Figura 5.28. Distribución de la superficie forestal de pináceas respecto a la prueba B del índice I_{aptP}

Por tanto, los resultados de esta prueba B reflejan una situación de rentabilidad-viabilidad de explotación algo más optimista que la de la prueba A. Esta conclusión también se desprende del análisis comparado de las cartografías obtenidas. Así, las zonas consideradas como óptimas son, a grandes rasgos, las mismas en una y otra, existiendo dos matices: (i) las superficies situadas en la orla de las zonas más rentables en la prueba A han pasado a pertenecer también a este intervalo en la cartografía de la prueba B; (ii) la superficie óptima del sector nororiental de los Puertos de Beceite se ha visto reducida, debido a los altos porcentajes de pendiente que caracterizan estas zonas; en cambio, las zonas llanas de este sector, situadas al norte, presentan altos índices de aptitud, compensándose el dato medio.

Por último, la prueba C del índice I_{aptP} es la que ofrece unos resultados más posibilistas en cuanto a la aptitud de las masas forestales inventariadas de cara a su

explotación. Según los resultados obtenidos, la práctica totalidad de la superficie inventariada es de un interés moderado (el 98,28% tiene un valor por encima de los 50 puntos), aunque lo que quizás es más llamativo es que algo más del 77% queda clasificado como muy apropiado. La obtención de valores tan elevados se debe a la distribución de pesos efectuada, que ha sobreestimado el protagonismo de la variable I_{dist} , la menos restrictiva de las tres dado que el 81,26% de las masas tenían una pista o camino a <400 m, lo que le otorgaba un valor de 90. Así, en la cartografía sólo se identifican como zonas menos óptimas aquellas con una menor densidad de infraestructuras viarias, dependiendo la mayor o menor aptitud del resto de la combinación por igual de los factores cantidad y pendiente.

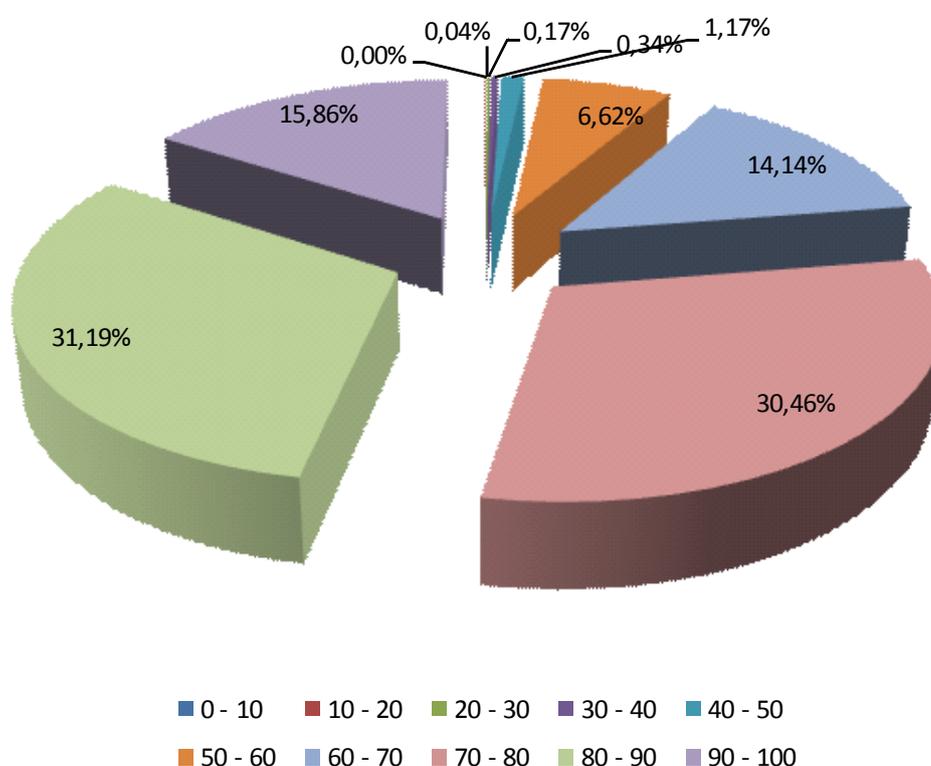


Figura 5.29. Distribución de la superficie forestal de pináceas respecto a la prueba C del índice I_{aptP}

5.3.4. Conclusiones

En el presente apartado se ha desarrollado una metodología útil para valorar y espacializar la viabilidad de explotar la biomasa residual forestal presente en un territorio desde el punto de vista técnico y económico sin perder de vista la sostenibilidad de ecológica de los bosques. Ello es así por cuanto los índices de aptitud propuestos

integran cuatro factores críticos a la hora de establecer la adecuación de las masas forestales para hacer rentable la extracción: (i) la cantidad potencial de recurso que se puede obtener; (ii) la existencia de masas de superficie suficiente para minimizar los tiempos improductivos de trabajo debido a los desplazamientos; (iii) la pendiente, que controla la posibilidad de utilizar o no una maquinaria u otra para hacer más eficiente el trabajo; y (iv) la distancia de desembosque, que, al igual que la variable superficie, controla la cantidad de recurso que se puede extraer en cada jornada de trabajo. El resultado de integrar estos cuatro factores parciales con los modelos de síntesis propuestos mediante las funciones implementadas en un SIG permite la obtención de una cartografía de alta resolución espacial (25 m de píxel), facilitándose así la localización y delimitación precisa de las zonas más factibles de explotación de este recurso.

Las características de la provincia de Teruel y los criterios utilizados a la hora de valorar estos cuatro factores hacen que la cantidad de biomasa y la pendiente sean los factores más restrictivos para considerar la explotación de una zona óptima. Sin embargo, es necesario señalar que hay diferencias entre estas dos variables, ya que mientras que los intervalos propuestos para modelar la incidencia de la pendiente son bastante rígidos (la eficiencia de la maquinaria es menor conforme aumenta la pendiente hasta un umbral en el que ya no se puede utilizar), los propuestos para modelar el papel de la cantidad son bastante más arbitrarios, pudiéndose modificar dependiendo de las necesidades de la planta de generación eléctrica y/o de las experiencias de futuros trabajos encaminados a dilucidar esta cuestión. A este respecto recordar que en este trabajo, debido a que se ha adoptado una perspectiva conservadora, se ha utilizado un valor óptimo para definir los intervalos de este índice parcial muy elevado –más del doble– en comparación con el de otros trabajos. En concreto, con el motivo de preservar 11 tons/ha de residuo forestal que garanticen la sostenibilidad de los bosques, se ha aplicado un valor que supera en 19,5 tons/ha el valor más alto propuesto en los trabajos consultados, que era de 17,5 tons/ha. La utilización de un valor más bajo que también garantizara un elevado número de nutrientes al suelo, que podrían ser complementados con la necromasa procedente de arbustos, matorrales y herbáceas anuales, hubiera hecho que la valoración de la aptitud de los bosques turolenses fuera mucho más alta que la finalmente obtenida con los dos índices utilizados⁵⁴.

⁵⁴ Por ejemplo, si el valor mínimo óptimo de cantidad de biomasa se hubiera establecido en 26 tons/ha, manteniendo el 70% de eficiencia de recogida contemplado en este trabajo, se hubiera

El carácter menos limitante de los índices parciales relacionados con la superficie de la masa boscosa (I_{sup}) y con la distancia de desembosque (I_{dist}) también se debe a diferentes motivos. En el caso del índice I_{sup} , la escasa incidencia en la valoración final de la aptitud de las masas forestales se debe a la cartografía utilizada para delimitar la superficie forestal, que tiene un tamaño de tesela demasiado grosero. Así, esta variable sólo tendrá incidencia en la evaluación final si se utiliza como referencia para delimitar la superficie forestal una cartografía de más detalle, que proporcione teselas más precisas. Por su lado, el escaso poder restrictivo del índice I_{dist} no guarda relación con la metodología seguida, debiéndose, exclusivamente, a la existencia de una buena infraestructura de pistas forestales y caminos en el territorio estudiado.

Los dos índices creados para combinar los índices parciales y ofrecer una valoración integrada de la aptitud de las masas forestales para la obtención de la biomasa forestal también presentan grandes diferencias. Así, el índice I_{aptM} , al estar formulado como una simple multiplicación de factores, presenta una complicada lectura, teniendo además un carácter restrictivo muy importante, ya que solamente da un valor alto a aquellas zonas en las que los cuatro factores tienen valores máximos. Por su parte, el índice de ponderado I_{aptP} , además de presentar un carácter menos restrictivo, permitiendo presentar valores superiores a 90 aunque alguno de los factores adopte un valor medio, tiene la importante la ventaja de permitir modificar el peso de cada factor de acuerdo con los criterios de los técnicos forestales y de los gestores del territorio. La complejidad de este índice radica, por tanto, en la dificultad de fijar unos pesos ajustados y objetivos según experiencias reales que se adapten bien al efecto parcial de cada factor y a la realidad del territorio evaluado.

Por último, señalar dos posibles mejoras sobre el índice de aptitud I_{aptP} , el mejor de los dos propuestos en este trabajo, que pueden abordarse en futuros trabajos de investigación:

- (i) El índice de cantidad de biomasa I_{BRF} podría incorporar información sobre la necesidad de tratamientos selvícolas en las masas forestales estudiadas, de forma que no se prime únicamente la cantidad potencial de recurso existente, sino también la pertinencia de extraer en ese momento el recurso.

garantizado la recogida de 18,2 tons/ha (0,7 tons/ha más que la cantidad más alta encontrada en la bibliografía), garantizándose un aporte de nutrientes al suelo de este material de 7,8 tons/ha.

- (ii) Dado que los índices parciales considerados identifican factores muy influyentes en el coste de explotación del recurso, se debería intentar reclasificar estas variables –o los pesos asignados– en función del coste de extracción expresado en €/tons. De esta manera se podría obtener cartografía del coste real de la extracción del recurso en cada punto del territorio analizado.

***CAPÍTULO 6:
CONCLUSIONES GENERALES
Y LÍNEAS DE FUTURO***

6.1. Conclusiones generales

Nuestro modo de vida actual descansa sobre la energía. La energía ha sido la responsable del nivel de desarrollo actual y, a buen seguro, condicionará también el desarrollo de los próximos años. El concepto de “dependencia energética”, tan utilizado en los últimos tiempos, resume perfectamente la relación existente entre la calidad de vida alcanzada en los países occidentales y la energía.

Dos son las cuestiones principales que afectan al modelo energético actual, principalmente basado en el uso de los combustibles fósiles y, dentro de éstos, en el petróleo:

- En primer lugar, sus consecuencias ambientales. Hoy en día, nadie pone en duda la relación existente entre los millones de toneladas de CO₂ vertidas a la atmósfera desde los inicios de la actividad industrial con el efecto invernadero, y, por consiguiente, con el cambio climático. A este respecto, la única duda razonable que queda es valorar la proporción que esta actividad antrópica tiene en el calentamiento global y si todavía es posible evitar rebasar un determinado umbral que marcaría el desastre. En este sentido, desde la firma del Protocolo de Kyoto, hace ya 12 años, las distintas Administraciones de carácter supranacional y nacional, primero, y regionales y locales, después, vienen adoptando medidas con objeto de reducir las emisiones de dióxido de carbono, basadas principalmente en el ahorro energético y en el impulso de fuentes menos contaminantes, como la controvertida energía nuclear y las renovables. Junto a esta acción de los poderes públicos es necesario también subrayar la participación activa en los últimos años de la sociedad en general, cada vez más concienciada con la problemática medioambiental y, por lo tanto, más exigente y vigilante con todas las cuestiones que le rodean, incluyendo el origen de la energía. Como muestra de este último punto basta con recordar algunas de las campañas publicitarias lanzadas recientemente por las principales empresas energéticas españolas, en las que el “origen verde” de la energía y el respeto medioambiental son principales tarjetas de presentación ante el gran público; otro ejemplo más reciente se encuentra en el sector del automóvil, que ha dejado de utilizar los reclamos de velocidad y potencia de los coches para presentar como dato más importante su bajo consumo y su baja tasa de emisiones a la atmósfera.

- La segunda cuestión refiere al precio de la energía y a la seguridad del suministro futuro, cuestiones íntimamente relacionadas con la incertidumbre existente sobre las reservas de petróleo. A este respecto, la teoría formulada en 1956 por Hubbert, conocida como *Teoría del pico de Hubbert*, señalaba que entre los años 1995 y 2000 se alcanzaría el máximo de producción mundial. A partir de este pico, el modelo preveía que la producción de este recurso descendiera tan rápido como había crecido, siendo factores limitantes el coste económico de la extracción y la energía necesaria para ello. Aun siendo objeto de numerosos debates, esta teoría sobre el fin de la era del petróleo abundante y barato está aceptada⁵⁵ tanto por la comunidad científica como, lo que es más importante, por las propias empresas petroleras, siendo la única discusión cuándo se producirá exactamente ese pico. En este sentido, si bien las previsiones más optimistas –las de la industria del petróleo– aseguran que el pico no se alcanzará hasta el final del presente siglo, las más realistas efectuadas por la *Association for the Study of Peak Oil and Gas (ASPO)*, formada por científicos de diversas universidades e instituciones globales, aseguran que acaecerá en torno a 2010, es decir, en la actualidad, con lo que las previsiones de Hubbert solamente habrían errado en una decena de años. Las variables que controlan el desplazamiento en el tiempo del momento de inflexión de la producción de petróleo son principalmente el aumento de eficiencia en las técnicas de extracción y el descubrimiento de nuevas reservas petrolíferas, por parte de la producción, y las medidas de eficiencia-ahorro energético y la bajada de demanda debido a crisis económicas, por parte del consumo.

Sin embargo, la subida en el precio del barril de petróleo experimentada a lo largo de 2007 y en el primer semestre de 2008, producida principalmente –a diferencia de las crisis de 1973 y 1979 en las que los motivos políticos fueron los responsables– por el espectacular incremento de la demanda, especialmente por parte de China e India, unida a la negativa (o incapacidad) de los principales países productores de incrementar la producción, sugieren que las predicciones de la *ASPO* son mucho más acertadas que las defendidas por algunas empresas petroleras. En este sentido, los analistas

⁵⁵ La *Teoría del pico de Hubbert* predijo con éxito el momento en que Estados Unidos alcanzó su máximo de producción: 1970.

coinciden en que la principal razón por la que el precio del barril de crudo Brent se sitúa en la actualidad por debajo de los 100 dólares se debe, más que al aumento de la producción, a la caída del consumo consecuencia de la crisis económica mundial. Aun así, a pesar de la crisis actual, el barril de petróleo sigue conservando un precio similar al que tenía antes de la fuerte subida de 2007.

Además de la influencia que el petróleo tiene en el mantenimiento de nuestra calidad de vida (electricidad, calefacción, combustible para los coches...), su incidencia en la marcha de la economía en general manifiesta una relación directa, tal y como ha quedado demostrado en la actual crisis económica. Así, diversos expertos consultados por Pérez (2007) para la redacción del artículo “Vivir (bien) con el petróleo a 100 dólares”, establecían la siguiente cadena de acontecimientos: la subida del precio del petróleo dispara la inflación – una alta inflación conduce a una subida de los tipos de interés – si suben los tipos, las hipotecas se encarecen y se reduce el consumo – la reducción del consumo lleva a la bajada de los beneficios empresariales y, con ellos, de las inversiones – menores beneficios e inversión empresariales abocan al aumento del paro – el aumento del desempleo genera la reducción del consumo...

En este contexto, el uso de la biomasa residual forestal como recurso energético para producir energía eléctrica y térmica puede jugar un papel relevante en las dos cuestiones señaladas:

- Respecto a la problemática ambiental: al tener un balance neutro en cuanto a la producción de CO₂, ya que las cantidades emitidas en su combustión son iguales o inferiores a las fijadas durante su formación. Además, como se ha señalado en la introducción, durante la producción y recolección de este material se generan otros beneficios medioambientales, también importantes, como la mejora del estado de las masas forestales, ayudando a su conservación y su regeneración, y la disminución del riesgo de incendios y de su severidad, siendo responsables los fuegos forestales de importantes emisiones. En relación a este último aspecto, los datos obtenidos en esta investigación han servido para desarrollar otros trabajos en los que se analiza la relación entre la cantidad de biomasa residual y la severidad de fuego, estableciéndose modelos predictivos (García-Martín *et al.*, 2007, 2008).

- Respecto al precio de la energía y a la seguridad de suministro en el futuro: al ayudar a reducir la dependencia del petróleo en un momento en que la tendencia del precio de éste sólo puede ser de aumento debido a que se está cada vez más cerca de –o se ha alcanzado ya– la temida caída de la producción. Asimismo, al igual que el resto de las energías renovables, la utilización de la biomasa residual forestal contribuye a implantar un modelo de producción energética descentralizado y diversificado, reforzándose así la seguridad de suministro al no depender únicamente de combustibles fósiles. Junto a esto hay que recordar los beneficios económicos y sociales de poner en valor este recurso natural endógeno, al estimular la fijación de la población del medio rural mediante la generación de empleo y la mejora de las infraestructuras locales.

El actual coste de producción de energía, principalmente de electricidad, mediante la utilización de biomasa residual forestal es mayor que mediante la utilización de combustibles fósiles e incluso que de otras energías renovables como, por ejemplo, la eólica. Sin embargo, la energía de la biomasa presenta la ventaja de su disponibilidad constante frente a otras renovables de carácter más variable como la eólica o la hidroeléctrica, ya que la biomasa conserva su energía hasta el momento de su utilización. Esta propiedad hace que la biomasa sea la energía renovable más fácil de gestionar, permitiendo crear un *stock* energético para los momentos en que las otras fuentes, renovables o no, no se encuentren disponibles. Esto, junto con el más que previsible y cercano aumento de los precios de la energía, de los derechos de emisión de gases con efecto invernadero y de las primas a la explotación de las energías renovables, hace que sea predecible la rentabilidad a corto-medio plazo de la explotación de las masas forestales que presenten un balance energético positivo (Lorente, 2009). Si, además, se añaden los beneficios sociales y medioambientales de su utilización, se concluye la necesidad de estar preparados, conociendo aquellas masas forestales con mayor potencial para su aprovechamiento como punto de partida de una planificación energética basada en el desarrollo sostenible.

La presente tesis doctoral **ha desarrollado una metodología** que permite superar una de las principales barreras identificadas para la utilización de la biomasa residual forestal como fuente de energía: el desconocimiento de la cantidad disponible de este recurso en una masa forestal. Esta metodología se ha basado en la hipótesis de que es posible estimar la biomasa residual forestal mediante el uso de imágenes de

teledetección y de trabajo de campo, hipótesis sustentada en la extensa bibliografía científica existente en el ámbito de la utilización de imágenes de satélite en cuestiones forestales. Las principales aportaciones de este trabajo de investigación residen en la fracción de la biomasa estudiada, debido a que no existen referencias a cerca de la estimación de este parámetro, y en aumentar las experiencias en medios mediterráneos, donde la heterogeneidad de sus bosques dificulta la obtención de modelos predictivos precisos y robustos de variables forestales. La selección del área de estudio, la provincia de Teruel, respondió a que esta provincia es potencialmente un escenario ideal para verificar las hipótesis de los beneficios medioambientales y socioeconómicos del empleo de los residuos forestales para la producción de energía, dada su importante superficie forestal y el carácter rural de su estructura demográfica y económica. No obstante, la validación de estas premisas queda fuera del objetivo de este trabajo, por lo que esta cuestión no ha sido abordada.

Dos han sido los tipos de imágenes considerados para cumplir con el objetivo planteado: ópticas, procedentes del sensor TM situado sobre la plataforma satelital Landsat 5, y radar, obtenidas a partir del sensor ASAR del satélite Envisat. Sin embargo, el peso dado en el trabajo a unas y a otras ha sido muy diferente, debido principalmente a la imposibilidad de aplicar sobre las imágenes radar procesos de normalización topográfica, lo que hace que las escenas consideradas no sean válidas para establecer un modelo predictivo robusto. Con esto, la utilización de las imágenes ASAR en el trabajo ha quedado reducida a un carácter meramente exploratorio de su sensibilidad para el estudio de la fracción de biomasa considerada, ya que la gran mayoría de experiencias previas se han llevado a cabo para la estimación de *AGB*, aun conociéndose que la respuesta recogida de las masas forestales en este tipo de imágenes depende principalmente del follaje y de las ramas de los árboles.

En el **Capítulo 2** se han mostrado y aplicado un conjunto de métodos para obtener las variables necesarias para ajustar el modelo de estimación perseguido. La principal aportación en este apartado es la metodología aplicada para la obtención de la información de la biomasa residual en el área de estudio. Esta metodología, basada en el muestreo en dos fases de Parresol (1999), se ha mostrado útil para obtener datos susceptibles de ser relacionados con la información espectral proporcionada por las imágenes de satélite y con el resto de variables auxiliares de tipo espacial consideradas, minimizándose el trabajo de campo, que, en muchas ocasiones, se convierte en la tarea más costosa en tiempo y dinero de cualquier trabajo de investigación. Es de destacar que

el método aplicado permite considerar toda el área de estudio, eliminándose así cualquier sesgo espacial en los resultados obtenidos. Los modelos de regresión ajustados a partir de los datos obtenidos en el muestreo de campo para cada una de las cuatro especies consideradas resultaron muy satisfactorios, al presentar todos ellos un R^2_a superior a su respectiva forma alométrica y siempre por encima de 0,90, siendo válidas estas ecuaciones para ser aplicadas a un alto número de las parcelas del IFN-2 de Teruel, debido a que el rango de *dbh* muestreado en cada especie fue muy amplio. Además, se ha comprobado que el grado de ajuste de las ecuaciones por especie es mayor que el que se alcanza con una ecuación de la misma forma pero considerando conjuntamente toda la muestra. En cuanto a los métodos aplicados para obtener las variables que actúan como predictoras en el modelo (radiométricas, topográficas y forestales), debe señalarse la sencillez, pertinencia y rigor de todos ellos para derivar la información buscada, siendo quizás los más complicados los aplicados en el preprocesamiento de las imágenes radar. La adopción de estos métodos fácilmente replicables por otros grupos de trabajo o por personal de las Administraciones Públicas, responde a la voluntad expresada en los objetivos de generar una metodología sencilla y extrapolable, tanto en el espacio como en el tiempo, que permita inventariar la biomasa forestal residual en otros territorios distintos al estudiado.

En el **Capítulo 3** se han estudiado las relaciones existentes entre la biomasa residual forestal y todas las variables dependientes consideradas, estableciéndose diferentes modelos de regresión mediante el uso de variables radiométricas derivadas de la imagen Landsat de junio de 1994 y, en el caso de algunos de los modelos de regresión logística, incluyéndose también una de las variables forestales consideradas. Estos modelos, validados siempre con al menos el 20% de las parcelas consideradas en sus respectivas muestras, han servido para cartografiar la biomasa del área de estudio, siendo todas ellas sometidas también a procesos de validación independientes para determinar cuál ofrece mejores resultados. A continuación se enumeran las principales conclusiones de este capítulo, retomadas de las parciales incluidas en los apartados correspondientes:

- 1. La heterogeneidad espacial-radiométrica de los bosques mediterráneos juega un papel esencial para obtener modelos estimativos precisos y operativos de biomasa residual forestal.*

Esta conclusión, esperada desde el principio, se confirma en los resultados obtenidos en los tres métodos aplicados para extraer la información de las variables

dependientes y crear distintos grupos de parcelas en función de su heterogeneidad. Así, tanto con el método que combina el uso de ventanas fijas de tamaño 3x3 píxeles con el CV de Pearson, como mediante la utilización de áreas forestales homogéneas delimitadas a partir de fotografía de alta resolución y/o a partir de técnicas de segmentación y ventanas fijas, las correlaciones entre la biomasa residual con las variables espectrales aumentan conforme lo hace la homogeneidad espacial de las parcelas, lográndose ajustar ecuaciones adecuadas para espacializar la variable estudiada solamente cuando se consideran grupos de parcelas muy homogéneos.

II. Las variables radiométricas obtenidas de las imágenes Landsat se erigen en las más adecuadas de todas las consideradas para estimar la biomasa residual forestal.

De todos los modelos ajustados a lo largo del Capítulo 3, sólo los dos primeros, obtenidos con las dos muestras de parcelas mayores y mediante regresión logística (el menos exigente de los métodos de regresión empleados), logran incluir una variable no radiométrica, en concreto una de las dos consideradas de naturaleza forestal, COD_MADUREZ. La utilidad de las variables topográficas calculadas resulta nula, ya que en los dos métodos en los que se analiza su inclusión –el que utiliza ventanas fijas y el que emplea áreas forestales homogéneas delimitadas a partir de fotografía aérea– estas variables presentan poca correlación con la biomasa, siendo significativas en contadas ocasiones y disminuyendo esta significación o desapareciendo a medida que aumenta la homogeneidad de las parcelas.

III. La relación entre la biomasa forestal residual y las variables radiométricas derivadas de la imagen Landsat es predominantemente de carácter curvilínea.

Los gráficos de dispersión ajustados con los diferentes grupos de parcelas en los tres métodos muestran que las relaciones entre estos dos tipos de variables son mayoritariamente no lineales, constituyéndose como excepción los índices de vegetación NDVI, los de la familia SAVI, el MSI y el GI. Este resultado indica que la mayoría de las variables radiométricas analizadas presentan un punto de saturación a partir del cual no son capaces de predecir con éxito cantidades de biomasa superiores, hecho constatado en otros trabajos que utilizan el mismo tipo de variables para estimar AGB. Sin embargo, el umbral de saturación de una misma variable no es igual en todos los métodos de extracción empleados. Así, el método que presenta unos umbrales de saturación más altos es el de las ventanas fijas de 3x3 píxeles, donde se empieza a observar este problema a partir de 50 tons/ha, mientras que en los dos que utilizan áreas homogéneas este umbral se sitúa sobre 40 tons/ha. En cuanto a las variables que presentan

preferentemente una relación lineal con la biomasa, es necesario señalar que ésta característica sólo se ha podido constatar para los valores máximos de la muestra empleada, por lo que no se puede asegurar que con valores superiores esta relación se transforme en curvilínea. Por último, subrayar que este carácter preferente de no linealidad en las relaciones entre la biomasa residual y las variables radiométricas hace que sea necesario aplicar numerosas transformaciones, aunque sencillas, para ajustar modelos de regresión lineal múltiple.

IV. El alto grado de auto-correlación entre las variables radiométricas no permite el ajuste de modelos de estimación multivariantes.

La consideración de un gran número de variables radiométricas tenía por objeto identificar una variable independiente con gran capacidad de explicación de la varianza de la biomasa residual forestal, pudiendo ser el resto explicada mediante el uso de otra u otras variables radiométricas. Sin embargo, tal y como se ha observado en los tres métodos aplicados para extraer la información, las elevadas auto-correlaciones existentes entre las variables radiométricas más relacionadas con la biomasa residual, mayores cuanto más alta es la homogeneidad espacial de las parcelas, impidieron ajustar de forma generalizada modelos multivariantes de regresión logística y lineal. Las únicas excepciones se dan en la regresión logística cuando se emplea el grupo con mayor contenido de parcelas, es decir, el utilizado como exponente de la máxima heterogeneidad presente en la muestra, y en algún caso aislado de las 5 pruebas de modelos de regresión lineal múltiple llevados a cabo en los tres métodos de extracción de la información. No obstante, en estos contados casos, el coeficiente de determinación apenas incrementa su valor al añadir la segunda variable, ya que ésta explica casi la misma porción de la varianza de la dependiente que la seleccionada en primer lugar. Finalmente, señalar que esta alta auto-correlación es la causante de que, dependiendo de la subdivisión utilizada, la variable radiométrica seleccionada en el método de regresión por pasos sucesivos sea una u otra, aunque siempre relacionada con el contenido de humedad de la vegetación, lo que hace que el modelo tenga una similar capacidad de predicción. Con esto, se concluye que a pesar de haber considerado diferentes partes del espectro electromagnético y un importante número de índices relacionados con variables biofísicas de la vegetación, no es posible utilizar más de una conjuntamente en el mismo modelo, ya sea porque a pesar de expresar distinta información están igualmente relacionadas con la biomasa residual, o porque no lo están suficientemente para ser integradas en un modelo de regresión.

V. Las variables radiométricas ópticas relacionadas con el contenido de agua de la vegetación son las mejores para estimar la biomasa residual forestal.

Independientemente del método de extracción de la información utilizado, las variables TM5, TM7, TC3, MSI y MID57 obtenidas de la imagen Landsat de junio de 1994 son siempre las más correlacionadas con la biomasa residual forestal, lo que hace que, debido a la alta auto-correlación entre variables radiométricas más útiles y a la baja correlación de las variables topográficas, sean siempre las únicas presentes en los modelos susceptibles de ser utilizados para espacializar la variable estudiada. Diversos trabajos que estudian las relaciones entre imágenes ópticas y la biomasa u otros parámetros forestales continuos también encuentran estas variables como las más útiles. En la presente investigación, este resultado está en relación con el diferente rango dinámico de las bandas originales proporcionadas por el sensor TM a las variaciones de biomasa residual forestal. Como se ha observado en todos los métodos de extracción, las dos bandas originales que registran información en el infrarrojo medio (TM5 y TM7) presentan un mayor rango dinámico que las tres del visible (TM1, TM2 y TM3), por lo que son más útiles para describir y explicar la variabilidad de la variable dependiente. Por su parte, debido los dos motivos señalados, TM4 presenta un grado de correlación con la biomasa muy bajo, independientemente de su rango dinámico. Dado que todos los neocanales fueron derivados de estas seis bandas originales, los resultados obtenidos con ellos están también relacionados con este rango dinámico de las bandas TM ante variaciones de biomasa residual forestal, por lo que TC3, MSI y MID57 son las más correlacionadas. De todas estas variables relacionadas con el contenido de agua de la vegetación, MID57 se erige en la más utilizada en los modelos de regresión curvilíneas y lineales que finalmente son utilizados para derivar cartografía, dado que son los que habitualmente presentan mejor relación entre la capacidad de predicción y el error de estimación. Ésto se debe nuevamente a que MID57 es la que presenta un mayor rango dinámico de este grupo de variables.

VI. El método de extracción que combina el uso de ventanas fijas de 3x3 píxeles con el CV de Pearson es el más adecuado para cartografiar la biomasa residual forestal del área de estudio.

La principal virtud de este método es que permite aislar un grupo de parcelas muy homogéneo, pero suficientemente representativo de toda la provincia de Teruel, para derivar los mejores modelos de estimación de biomasa residual. Esta afirmación se desprende de los resultados obtenidos del proceso de validación de las cartografías derivadas a lo largo del Capítulo 3 y de la comparación de la capacidad de predicción, del

error de estimación y del grado de saturación de las ecuaciones ajustadas en este capítulo. No obstante, tal y como muestran todas estas pruebas, la diferencia entre los resultados alcanzados con los tres métodos es pequeña, con lo que cualquiera de ellos se hubiera podido utilizar para inventariar este recurso mediante la imagen Landsat de 2008. Este hecho muestra la pertinencia de los tres métodos testados para eliminar la influencia que la heterogeneidad de los bosques mediterráneos tiene en el establecimiento de modelos predictivos de parámetros forestales continuos mediante imágenes de teledetección ópticas. Sin embargo, debe advertirse que el método de las ventanas fijas y el CV debe ser aplicado con precaución, ya que de entre los grupos de parcelas en que se divide la muestra en función de su homogeneidad con este método, se debe seleccionar aquel grupo que, siendo buen exponente de esta característica, conserve un número de parcelas suficiente para modelar toda la realidad del área de estudio, evitando crear de esta forma modelos sobre-ajustados a la muestra. Esta circunstancia se observa al comparar los resultados obtenidos mediante este método con los grupos de parcelas de los percentiles 4 y 3, ya que, aunque con la utilización de este segundo grupo más homogéneo se consiguen mejores ecuaciones de regresión, la validación de las cartografías muestra que es donde se produce un mayor error relativo, bastante más alto que en las obtenidas utilizando el grupo del percentil 4, que contiene el doble de parcelas.

VII. Las imágenes ASAR son potencialmente útiles para la estimación de biomasa residual forestal en medios mediterráneos, pero no cumplen con el objetivo de ser utilizadas como parte de una metodología sencilla.

Aunque esta conclusión carece de significación estadística debido al escaso número de parcelas utilizadas en los análisis y a la no aplicación de procesos de normalización topográfica, los resultados muestran que existen relaciones entre la variable estudiada y el coeficiente de retrodispersión proporcionado por estas imágenes. Esta relación es perfectamente lineal, por lo que no existe saturación de la banda C con las cantidades más altas consideradas en la muestra. De este modo, si se establece la equivalencia entre la máxima cifra de biomasa residual considerada en la muestra con *AGB*, este comportamiento parece sugerir que podría ser más adecuado utilizar las imágenes ASAR para estimar esta fracción de biomasa forestal, calculando después *AGB*, que relacionar el coeficiente de retrodispersión directamente con *AGB*, ya que el umbral de saturación parece más alto. Esto resulta coherente con el hecho de que la respuesta de esta banda está relacionada directamente con las ramas y acículas, no con el volumen total del pie arbóreo. No obstante, hay que subrayar la imposibilidad de

extraer conclusiones debido a la falta de significación estadística y a los bajos coeficientes de determinación obtenidos ($<0,5$), que pueden ser debidos a la ausencia de normalización topográfica, a errores en la delimitación de áreas homogéneas forestales y/o al desfase temporal de los datos. Lo que sí se puede concluir tras los análisis efectuados es la importancia que el ángulo de incidencia tiene en la relación entre la biomasa residual y la información proporcionada por estas imágenes. Debido a esto y a la complejidad de las técnicas necesarias para eliminar la influencia de este ángulo, parece más fácil que las Administraciones adopten una metodología basada en la utilización de imágenes ópticas que en imágenes radar para inventariar el recurso estudiado.

En el **Capítulo 4** se ha comprobado que el método de extracción de las ventanas fijas 3x3 y el CV es válido con independencia de la fecha de adquisición de la imagen Landsat dentro del verano. Esta conclusión descansa en los resultados obtenidos al repetir este método aplicado en el Capítulo 3 sobre la imagen de junio de 1994 utilizando las otras dos imágenes disponibles, también coetáneas a la realización del IFN-2, correspondientes a los meses de julio de 1993 y agosto de 1994, complementándose así el análisis en todo el periodo estival. Estos resultados muestran que el método es replicable, ya que proporciona grupos de parcelas en función de su heterogeneidad-homogeneidad radiométrica semejantes en número independientemente de la imagen utilizada, con lo que los análisis son directamente comparables. Los resultados de estos análisis corroboran que cuanto mayor es la homogeneidad radiométrica del entorno de la parcela, mayor correlación existe entre la biomasa residual y las variables radiométricas, siendo similar el grado de correlación obtenido con cada variable radiométrica para cada uno de los 10 grupos de parcelas delimitados en cada imagen. La única salvedad a este patrón la constituyen los neocanales obtenidos a partir de ACP, ya que éstos dependen de las características singulares de cada imagen. Además se constata también el alto grado de auto-correlación de las variables radiométricas, mayor cuanto mayor es la homogeneidad radiométrica.

En este contexto, el grupo de parcelas del percentil 4 vuelve a mostrarse como el mejor para obtener buenos modelos de estimación de la biomasa residual porque en él las correlaciones entre esta variable y las radiométricas permiten derivar ecuaciones de regresión simple con coeficientes de determinación importantes, requisito indispensable al no poderse ajustar regresiones múltiples debido a la alta auto-correlación. En este grupo de las dos imágenes analizadas, al igual en el resto de los grupos representantes de una alta homogeneidad radiométrica del entorno de la parcela, las variables

relacionadas con el contenido de agua de la vegetación se erigen nuevamente como las más correlacionadas, por lo que vuelven a ser las utilizadas en todos los modelos de regresión ajustados, siendo los que emplean las variables MID57 ó TM7 los finalmente seleccionados para derivar cartografía con las dos imágenes empleadas en este capítulo. La similitud entre los valores de R^2 , $RMSE$ y $RMSE_r$ de estos modelos y del $RMSE_r$ obtenido al validar las cartografías, entre ellos y con los obtenidos con la imagen de junio, confirma la estabilidad y la idoneidad tanto del método como de las variables relacionadas con el contenido de agua de la vegetación para estimar la biomasa residual del área de estudio. Además, estos valores de $RMSE_r$ de las cartografías son similares o inferiores a los obtenidos en las cartografías derivadas con la imagen de junio mediante otros dos métodos testados, que utilizaban más parcelas en el ajuste de las ecuaciones. De ésto se deduce que los modelos ajustados con el método de las ventanas fijas de 3x3 y el CV no están sobre-ajustados a la muestra, a pesar del reducido número de parcelas empleado.

Finalmente, para confirmar que la relación biofísica entre el contenido de humedad de la vegetación y la biomasa residual es robusta e independiente de la fecha de adquisición de la imagen Landsat dentro del verano, se comprobó la variación del contenido de humedad en los meses de junio, julio y agosto de las cuatro especies de pino consideradas mediante datos de campo en áreas cercanas tomados de otro proyecto de investigación, siendo el resultado que no existen variaciones significativas. Sin embargo, es justo señalar que para confirmar esto último sería necesario disponer de una mayor muestra estadística y que ésta fuera tomada dentro del área de estudio.

En el **Capítulo 5** se ha obtenido una estimación del contenido de biomasa residual forestal de los bosques de pináceas de la provincia de Teruel a partir de una imagen Landsat de julio de 2008. Para seleccionar el modelo de estimación finalmente aplicado entre los obtenidos con el método de ventanas fijas de 3x3 y el CV con el grupo de parcelas del percentil 4, que han servido para obtener cartografía en los Capítulos 3 y 4, se siguió primero un criterio de temporalidad, lo que llevó a seleccionar los de junio de 1994 porque eran los más cercanos en el calendario anual y, por lo tanto, existía mayor probabilidad de que el contenido en agua de la vegetación en ambas imágenes fuera más similar. Después, para seleccionar entre el modelo curvilíneo o el lineal se tuvieron en cuenta dos criterios: (i) cuál de los dos alcanza con esta imagen mejores resultados en términos de capacidad predictiva y de error de estimación con la muestra y en la cartografía obtenida y (ii) qué tipo de regresión ofrece resultados más estables con las

tres imágenes analizadas. Ambos llevaron a seleccionar el modelo lineal, ya que, a pesar de presentar un R^2 algo inferior, los errores de estimación con la muestra y en la cartografía obtenida eran menores. Además, el $RMSE_r$ obtenido en las cartografías con este tipo de regresiones presentaba resultados más estables en las tres imágenes utilizadas que con el curvilíneo. Una vez aplicado el modelo, se obtuvo información cartográfica y estadística de la biomasa residual forestal presente en las tres escalas de división administrativa en que se divide el territorio turolense: provincial, comarcal y municipal.

En este Capítulo 5 se ha desarrollado también una metodología mediante herramientas SIG para localizar las zonas óptimas para el aprovechamiento del recurso. Esta metodología se revela como útil para espacializar y valorar la posibilidad de explotar la biomasa residual forestal de un determinado espacio desde el punto de vista técnico y económico y sin perjudicar la sostenibilidad ecológica de los bosques. Ésto se logra creando un índice que integra las cuatro variables básicas identificadas, que intervienen en el grado de aptitud de una masa para hacer rentable y sostenible la extracción del recurso. De los dos índices desarrollados, el que opera mediante la suma ponderada de los cuatro factores considerados es el más adecuado, ya que es menos restrictivo, más fácil de interpretar y permite modificar el peso de cada factor de acuerdo con los criterios técnicos; de las cuatro variables consideradas, la cantidad de biomasa y la pendiente resultan las más limitantes para la rentabilidad de la explotación.

Para finalizar este apartado de conclusiones generales cabe reflexionar sobre los diferentes factores que, con independencia de la imagen utilizada, hacen que el error de las cartografías de estimación resultantes se sitúe por encima del 60%. En los siguientes párrafos se ofrece un **inventario-análisis de las posibles fuentes de error**.

1. Imprecisiones en los datos de biomasa residual obtenidos en las parcelas del IFN-2 que son relacionados con los registros de las imágenes Landsat.

A pesar de que los datos de biomasa residual de las parcelas del IFN-2 se obtuvieron utilizando ecuaciones específicas para cada especie presente en el área de estudio, reduciéndose así las imprecisiones que puede introducir el uso de ecuaciones alométricas generales (Lu, 2006), estos datos no están exentos de errores o imprecisiones, que pueden tener su origen en cualquiera de las dos fases de la metodología de muestreo de Parresol (1999), seguida en este trabajo.

Básicamente, se trata de errores generados en el trabajo de campo para la medición de las variables dasométricas *dbh* y altura de los individuos, tanto por los técnicos y operarios encargados de realizar el IFN-2 (primera fase del muestreo de Parresol), como por los componentes del equipo LIGNOSTRUM con los pies apeados por operarios del Departamento de Medio Ambiente del Gobierno de Aragón (segunda fase del muestreo). En este segundo caso, a pesar de las precauciones tomadas, además de fallos en la medida de las variables *dbh* y altura, también se pueden haber cometido errores en el pesado de la biomasa residual correspondiente a cada pie; la incidencia de las imprecisiones propias cometidas en el trabajo de campo tienen una incidencia mayor en el error final, ya que son las que controlan directamente el ajuste de las ecuaciones de estimación de biomasa por pie.

II. Imprecisiones al relacionar los datos de las parcelas del IFN-2 con las imágenes de satélite.

Estas imprecisiones son debidas a la metodología seguida en el IFN-2 para la localización y delimitación de las parcelas en el campo. En efecto, recordemos aquí que la localización del punto de cruce de la malla kilométrica de la cartografía 1:50.000 en el que situar la parcela IFN-2 a inventariar se hizo mediante la fotografía aérea a escala 1:30.000, lo que da idea de la magnitud de los errores que se pudieron cometer. A ello se une la complicada localización en el campo de los puntos de cruce cuando éstos quedaban inscritos en un área homogénea, sin rasgos fácilmente diferenciables en las fotos, teniendo que recurrir a la búsqueda de un accidente geográfico cercano y visible y al trazado de rumbo y distancia al centroide teórico de la parcela. Un error en cualquiera de estos dos pasos suponía la localización de la parcela en un lugar diferente al cruce kilométrico donde se debía inventariar la masa forestal.

Además, cabe destacar el hecho de que el punto exacto de pinchado del rejón, con el que se marcaba el centroide de la parcela a partir del cual se calculaban los círculos concéntricos que la delimitaban, se hacía siguiendo una decisión aleatoria. Aunque este último aspecto es el de menor importancia de los relatados, sí que puede tener una incidencia importante cuando el radio es de 25 m y la parcela se encuentra en una zona muy heterogénea.

Las tres metodologías aplicadas en la presente investigación para asociar la información de campo con los datos de teledetección ayudan a reducir todos estos errores, pero es posible que algunos permanezcan en la muestra final. Así, una parcela

mal localizada unos 90 m en el campo puede haber superado el filtro de las ventanas fijas y el CV y de la segmentación siempre que haya sido localizada en una zona más o menos homogénea, cuando en realidad puede contener datos de otro escenario distinto. Ejemplos de este error son las parcelas 286, 340 y 426, identificadas como *outliers* en el grupo de parcelas del clúster 3 cuando se utilizaba la imagen de junio de 1994. La descripción de estas tres parcelas dada en el IFN-2 no coincidía con lo observado en la fotografía aérea de alta resolución (Figura 3.10), ni con la respuesta espectral esperada (Figura 3.11), lo que sólo puede achacarse a una imprecisión en la localización durante la fase de apeo. La incidencia en el método de delimitación de áreas homogéneas de mayor tamaño que la parcela a partir de fotografía de alta resolución es mucho menor, por cuanto estas áreas crecen de forma continua en el espacio, recogiendo el territorio en torno a la parcela. Sin embargo, esta metodología tampoco está libre de imprecisiones, ya que, si el error en la localización de la parcela hace que ésta se sitúe en una realidad muy diferente, el criterio visual de delimitación de la nueva área también es diferente, no correspondiéndose con los datos de la parcela.

III. Limitaciones relacionadas con la resolución espectral, radiométrica y espacial del sensor TM.

Tal y como se ha mostrado en el Capítulo 1, los sensores TM y ETM+ han sido utilizados ampliamente para la estimación de *AGB* en diferentes regiones. Sin embargo, es preciso señalar que, en ambientes forestales heterogéneos como los mediterráneos, estos sensores presentan ciertas limitaciones en sus características de resolución a la hora de estimar esta variable con precisión (Salvador y Pons, 1998a,b; Lu, 2006).

A este respecto, en primer lugar, destacan las limitaciones de su resolución espacial de 30 m en las bandas reflectivas, que se traduce en que la información radiométrica obtenida corresponda, no tanto a la individual de los árboles, como cuanto a una mezcla de cubiertas de distinta naturaleza dentro en un territorio de 900 m². Esta circunstancia, que se da a nivel de píxel, se ve agravada cuando, como en la presente investigación, se utilizan ventanas de extracción de mayor tamaño, en aras de eliminar la existencia de errores de localización, y se trabaja en bosques caracterizados por una alta heterogeneidad.

La metodología seguida en este trabajo ha tratado de mitigar esta limitación, escogiendo, en primer lugar, únicamente las parcelas del IFN-2 mono-específicas y, en segundo lugar, seleccionando las parcelas más homogéneas desde el punto de vista

radiométrico y, por lo tanto, espacial. De esta manera, se ha perseguido que la formulación de modelos de estimación se basara en la utilización de parcelas donde la relación entre la variable estudiada y la reflectividad no estuviera influenciada por la presencia de otros elementos, garantizándose así que se trataba de una relación biofísica real. En este sentido, el hecho de que las relaciones encontradas se repitan en las tres escenas utilizadas indica que este objetivo se ha cumplido satisfactoriamente.

Sin embargo, es necesario subrayar que, por muy homogéneo que sea el entorno de las parcelas sobre las que finalmente se han obtenido los modelos de estimación, los 9 píxeles finalmente utilizados no corresponden, como se ha indicado, a información individual de los árboles, sino que es segura la presencia de otras realidades como la existencia de vegetación arbustiva, herbácea o de suelo desnudo. Así pues, este inconveniente es insalvable, siendo responsable de parte de la varianza de la variable dependiente que queda sin explicar y de los errores de estimación.

La resolución radiométrica de los sensores TM y ETM+ también incide de forma directa en por qué no se logran mejores coeficientes de determinación. Diseñados para obtener cartografía temática, estos sensores codifican la información radiométrica recibida en 8 bits (256 ND), lo que se relaciona con el hecho de que, para el estudio de las superficies forestales, el rango efectivo de ND en cada banda sea limitado. De esta manera, dado que la información de reflectividad empleada para obtener los modelos está en relación directa con estos ND originales, las variables independientes radiométricas -originales o derivadas- no tienen una capacidad suficiente para explicar de forma precisa todo el recorrido de la variable forestal estudiada, debiéndose a este factor también, tal y como indica Lu (2006) en su revisión sobre la utilización de la teledetección para la estimación biomasa, el problema de saturación a partir de una cierta cantidad de biomasa.

Por último, la mediana resolución espectral de las bandas TM y ETM+, tanto en número (3 en el visible, 1 en el infrarrojo cercano, 2 en el medio de onda corta y 1 en el térmico) como en amplitud (ver Tabla 2.8), limita su capacidad para la detección de ligeras diferencias entre dos zonas de bosque. Debido a ello -y a su resolución radiométrica estándar- dos parcelas con cantidades semejantes de biomasa residual forestal pueden presentar la misma firma espectral, dificultando su diferenciación. Además, otro problema relacionado con esta característica es la importante correlación

entre algunas bandas de registro, especialmente entre aquellas que pertenecen a la misma región del espectro electromagnético.

La solución obvia a estos problemas es el uso de sensores que proporcionen una mayor resolución espacial, de tal manera que el registro se aproxime más a las características del árbol que a una mezcla de cubiertas, y una mayor resolución radiométrica y espectral, ya que se contaría con mayor rango digital para explicar las relaciones entre la variable dependiente y las independientes y con un mayor número de bandas y espectralmente más ajustadas para poder establecer las diferencias radiométricas existentes entre dos parcelas con similar cantidad de biomasa.

La búsqueda de un buen compromiso entre estos tres tipos de resolución en relación con el objetivo del trabajo es siempre una constante en todos los trabajos de teledetección recogidos en la bibliografía, siendo necesario sacrificar, casi siempre, un tipo de resolución en aras de mejorar otra. Además, junto a esto, hay que tener en cuenta las restricciones de tipo económico, tecnológico y temporal, comentadas en el primer capítulo, que afectan a cualquier tipo de proyecto.

Así, en el presente trabajo, la utilización de imágenes de alta resolución espacial como Ikonos y QuickBird -con píxeles entre 1 y 4 m y entre 0,61 y 2,44 m, respectivamente- hubiera permitido una mayor precisión a la hora de medir las características individuales de cada árbol. Sin embargo, se hubiera perdido resolución espectral, al tener estas imágenes únicamente información en 4 bandas distribuidas en el visible y el infrarrojo cercano⁵⁶, y hubieran sido necesarias muchas imágenes para cubrir toda el área de estudio⁵⁷, pudiéndose producir inconsistencias geométricas y radiométricas al ensamblar las imágenes. Por su parte, la utilización de imágenes MODIS hubiera permitido superar los problemas de resolución espectral, manteniéndose en una única imagen toda el área de estudio, ya que estas imágenes están compuestas por 30 bandas distribuidas en el visible, el infrarrojo cercano y el medio y recogen información de un área de 2330 km². Sin embargo, la resolución espacial es mucho menor a la de Landsat (entre 250 m y 1000 m), por lo que la influencia de otras cubiertas diferentes al establecer la relación entre el contenido de las parcelas del IFN-2 y la respuesta radiométrica sería evidente, dificultándose así el encontrar la relación biofísica buscada

⁵⁶ Además de una quinta banda, pancromática, de mayor resolución espacial.

⁵⁷ Cada escena de estos satélites cubre solamente un territorio de 11x11 km en el caso de Ikonos y de 17x225 km en el de QuickBird,

para establecer las ecuaciones de regresión. En el caso de la utilización de imágenes Hyperion, que tienen mayor resolución espectral que MODIS (220 bandas en el continuo comprendido entre el visible y el infrarrojo medio) y, sobre todo, una mayor resolución espacial (30 m), el problema vendría dado por lo reducido de su área de cubrimiento (7,7x42 km en el formato estándar), siendo necesarias muchas imágenes para considerar el área de estudio; además, otro factor negativo a añadir -y no menos importante- sería el elevado coste computacional y temporal de trabajar con el gran volumen de información que se generaría.

De esta manera, a pesar de las limitaciones señaladas, las imágenes Landsat ofrecen un buen compromiso entre estos tres tipos de resolución, teniendo en cuenta, por un lado, el objetivo planteado en esta investigación de proporcionar una metodología sencilla, fácilmente asumible por las distintas Administraciones como herramienta útil para la gestión forestal y para la planificación del territorio, y, por otro, las restricciones tecnológicas y, sobre todo, de tiempo y dinero con que contaba el proyecto. Esta afirmación se basa en los siguientes hechos:

- Su uso en aplicaciones forestales está ampliamente contrastado. Como se ha recogido en el Capítulo 1, de los distintos tipos de imágenes ópticas disponibles, las Landsat son las más utilizadas para las aplicaciones de inventario forestal y de estimación de biomasa a escala regional y local. Esto es así por su capacidad para hacer cartografía y un seguimiento controlado de las condiciones biofísicas forestales de una manera consistente y replicable a esta escala. Como hemos visto, esta masiva utilización de imágenes Landsat se da tanto en trabajos que se desarrollan en medios forestales caracterizados por su homogeneidad y baja complejidad, como es el caso de los medios boreales, como en bosques heterogéneos de estructura espacial compleja, como es el caso de los medios tropicales y los mediterráneos.
- Permiten obtener información de todo el territorio estudiado en una sola escena. De esta manera se evitan las inconsistencias geométricas y radiométricas que se dan cuando es necesario utilizar varias escenas para representar una determinada área de estudio a escala regional.
- Los pretratamientos a aplicar son sencillos y no requieren de una alta especialización. Los procesos de georreferenciación, de corrección radiométrica y de generación de nuevos canales de información espectral son

sencillos con este tipo de imágenes, existiendo herramientas directamente integradas en todos o casi todos los paquetes informáticos de tratamiento de imágenes de satélite, incluso en los más asequibles. Estas tareas son fácilmente abordables con la ayuda de estos programas por personas con conocimientos medios.

- Carácter global y periódico de las imágenes. Existen imágenes Landsat TM o ETM+ para toda España desde mediados de 1982, a razón teórica de casi dos imágenes por mes para cada una de las escenas de las órbitas de observación terrestre (*track*) y filas (*frame*) en que se desglosa el territorio nacional. En la actualidad, Landsat 5 es el que proporciona estas imágenes de modo correcto, ya que Landsat 7 tiene un problema en su *Scan Line Corrector* (SLC) desde 2003 que impide la correcta formación de imágenes. En la actualidad, la NASA está dando los pasos oportunos para la continuidad de este programa mediante la puesta en órbita de un sensor de similares características, denominado OLI. Así, el uso de imágenes Landsat en la presente investigación garantiza la utilidad y perdurabilidad de la metodología desarrollada, pudiendo ser aplicadas las ecuaciones propuestas sobre futuras imágenes para inventariar la biomasa. Además, la metodología expuesta también podrá ser nuevamente replicada y validada con los datos de nuevas ediciones del inventario forestal e imágenes sincrónicas a su realización.
- Facilidad de adquisición. Las imágenes Landsat han sido históricamente fáciles de conseguir a partir de distribuidores autorizados como Eurimage o el USGS, siendo sencilla también la identificación de la escena más adecuada para estudiar un determinado territorio y a un precio siempre competitivo en relación con las imágenes ofrecidas por otras plataformas. En este sentido, destacar que, en la actualidad, y en el contexto del *Plan Nacional de Teledetección*, la descarga de imágenes Landsat de todo el país es gratuita para las Administraciones públicas y centros de enseñanza españoles (ORDEN FOM/956/2008, de 31 de marzo, del Ministerio de Fomento - BOE núm. 85 de 8/4/2008). Por tanto, la metodología aquí desarrollada para la estimación de la biomasa residual forestal a escala regional puede ser replicada por parte de las distintas Administraciones en todo el territorio nacional sin gastos en concepto de adquisición de las imágenes necesarias.

IV. Imprecisiones relacionadas con la heterogeneidad de la muestra.

A lo largo de este trabajo de investigación se han ido adoptando diversas medidas para reducir la heterogeneidad de la muestra a utilizar de biomasa residual forestal, siempre al objeto de eliminar los elementos que pudieran distorsionar las relaciones biofísicas entre esta variable y las explicativas consideradas, disminuyéndose de esta forma el grado de incertidumbre y logrando un mayor ajuste de regresión de las ecuaciones estimativas.

En primer lugar, se tomaron una serie de determinaciones que afectaron al número inicial de parcelas del IFN-2 a considerar en los modelos. Así, el primer filtro que se aplicó para evitar la heterogeneidad de la muestra fue el de seleccionar, de todas las especies presentes en la provincia de Teruel, sólo las pináceas. Como segundo filtro, sólo se utilizaron aquellas parcelas en las que el 100% de los pinos que las componen tenían un diámetro normal y una altura dentro del rango de validez de las ecuaciones de estimación de biomasa residual ajustadas, eliminándose de esta manera cualquier error debido al desconocimiento de las relaciones existentes. Por todo ello, la muestra inicial de parcelas del IFN-2 que contenían al menos 1 pie mayor quedó reducida, mediante este doble filtro, de 1630 a 617, es decir a sólo el 37,85% de la población inicial. Por último, con el objetivo de eliminar la variabilidad de la respuesta radiométrica de los píxeles debido a la mezcla en ellos de pinos de diferentes especies, únicamente las parcelas monoespecíficas de *P. sylvestris*, *P. nigra*, *P. halepensis* o *P. nigra* fueron seleccionadas, reduciéndose así la muestra a 482 parcelas en el caso de las pruebas que se han hecho con la imagen de junio de 1994.

El segundo conjunto de medidas se ha encaminado a reducir la heterogeneidad espectral de la muestra de parcelas, que es fruto de la heterogeneidad espacial de su entorno. La fragmentación forestal típica de los ambientes mediterráneos hace que, en muchas ocasiones, la reflectividad extraída del entorno de cada parcela del IFN-2 no se corresponda solamente con los pies arbóreos contenidos, siendo fruto de la combinación de la respuesta espectral de distintas realidades también presentes en ese espacio, como, por ejemplo, matorrales, herbáceas o suelo desnudo. Las distintas técnicas aplicadas a partir de recursos estadísticos, de fotografía de alta resolución o de técnicas de segmentación, han mostrado cómo, siempre que se reduce la heterogeneidad espacial de la muestra, las correlaciones existentes entre la biomasa residual y las variables espectrales se incrementan, respetándose en todo momento la naturaleza de las relaciones observadas cuando todas las parcelas son utilizadas y erigiéndose siempre

las variables radiométricas relacionadas con la humedad como las que mayor grado de correlación alcanzan.

No obstante lo anterior, un cierto grado de heterogeneidad se conserva en las muestras utilizadas debido a dos factores íntimamente relacionados:

- Que las cuatro especies de pino han sido utilizadas de forma conjunta en la muestra. Aunque la variabilidad en la respuesta espectral de estas especies es pequeña a la hora de afrontar otras técnicas de teledetección comunes como la clasificación digital, supervisada o no, puede ser lo suficientemente importante como para influir en la estimación de parámetros biofísicos, conservándose una cierta varianza en la muestra que hace decrecer el grado de ajuste de las ecuaciones estimativas.

La solución a este problema es aparentemente sencilla: ajustar una ecuación para cada una de cuatro las especies consideradas. Sin embargo, debe recordarse aquí que la mejor cartografía se ha logrado teniendo en cuenta solamente las 68 parcelas más homogéneas. El desglose de esta muestra por especies hace que el número disponible para cada una de ellas sea realmente pequeño⁵⁸, con lo que las ecuaciones que se obtendrían estarían fuertemente sobre-ajustadas a la muestra y serían mucho menos representativas de todo el área de estudio que la finalmente utilizada para inventariar este recurso en la provincia de Teruel.

- Que las cuatro especies consideradas se distribuyen de forma distinta en la provincia de Teruel. Cada una de las masas forestales de estas especies están controladas y afectadas por distintos parámetros biofísicos, como la existencia de diferentes micro-climas, suelos, litologías etc. y/o diferentes parámetros topográficos, como la elevación, la pendiente y la orientación. Todos estos factores pueden controlar la cantidad de biomasa residual que produce un determinado pie, por lo que introducen cierta varianza en la muestra de partida que impide el ajuste de ecuaciones estimativas más precisas.

⁵⁸ Por ejemplo, la distribución por especies de la muestra utilizada con la imagen de junio quedó de la siguiente manera: 9 de *P. sylvestris*, 34 de *P. halepensis*, de 23 *P. nigra* y 2 de *P. Pinaster*.

Asimismo, además de este extremo, también hay que considerar que esta heterogeneidad de factores también influye en la reflectividad de la parcela registrada por el sensor que es relacionada con los datos de biomasa. Así, por ejemplo, la respuesta reflectiva de dos parcelas con idéntica cantidad de biomasa residual y una estructura espacial semejante en la que es visible el suelo desnudo no será la misma en función de la naturaleza de ese suelo.

En principio, cabría esperar mejores estimaciones si se hubiera trabajado a una escala más de detalle en lugar de a nivel provincial. Sin embargo, esta metodología hubiera alargado mucho más el proceso y no se hubiera respetado la premisa enunciada en los objetivos de crear una metodología sencilla y fácilmente extrapolable a otros territorios a escala regional, ya que tendría un carácter mucho más local.

6.2. Líneas futuras de trabajo

El aumento del precio de la energía debido al agotamiento del petróleo y la necesidad de reducir el nivel de emisiones de CO₂ para evitar el desastre climático son dos de las principales razones del crecimiento actual –y, sobre todo, venidero– de las energías renovables. A la espera de futuras innovaciones tecnológicas, que en estos momentos se están desarrollando, la energía de la biomasa es la única renovable que garantiza la posibilidad de tener disponible una reserva energética lista para ser utilizada en momentos de escasez de otras fuentes, por lo que adquiere un gran poder estratégico. Además de estas características generales de la energía de la biomasa, el aprovechamiento de los residuos forestales presenta la ventaja de mejorar el ecosistema del bosque y de paliar la ocurrencia de incendios y reducir su severidad, en un contexto en el que se prevé el agravamiento de ambos hechos debido, principalmente, al incremento global de la temperatura.

Esta tesis doctoral ha incidido en el desarrollo de una metodología que, mediante el uso de trabajo de campo, de técnicas de teledetección y de sistemas de información geográfica, permita conocer el potencial energético de los bosques de un territorio a escala regional. La mejora cualitativa y/o cuantitativa de los métodos aplicados sobre estos tres pilares redundará, ineludiblemente, en los resultados obtenidos.

Así, en cuanto al trabajo de campo, el desarrollo de regresiones para estimar la biomasa residual forestal de las especies no contempladas en la investigación permitirá obtener una caracterización más completa de la cantidad potencial de este recurso en el territorio. Además, la obtención de varias ecuaciones de regresión por cada especie –en atención a su diferente dispersión geográfica dentro de la región y/o de su distinta orientación, pendiente y altitud– podría también resultar interesante para reducir la variabilidad de la muestra, obteniéndose resultados aún más precisos en la estimación de la biomasa residual presente en las parcelas del IFN. Por último, en esta misma línea de aumentar la precisión de la cantidad de recurso contenida en cada parcela del IFN que luego es relacionada con la información espectral, sería interesante desarrollar ecuaciones específicas para los pies menores, labor que, para ser operativa, implica el necesario registro en campo de las dimensiones de estos pies por parte de los operarios del IFN en el levantamiento de las parcelas.

Respecto de la teledetección, la utilización de técnicas de radiometría de campo en condiciones de adquisición controladas puede jugar un papel fundamental para, en primer lugar, verificar las relaciones biofísicas entre la biomasa residual forestal y las variables espectrales encontradas en los modelos empleados para estimar cartografía y, en segundo lugar, para la identificación de rangos del espectro continuo no reconocidos en este trabajo, debido a las limitaciones de las imágenes de satélite, que permitan incrementar la capacidad de estimación. Estas dos cuestiones podrán ser abordadas directamente sobre los datos de reflectividad del espectro continuo proporcionados por el radiómetro o a partir de nuevas dimensiones de la información espectral de las muestras derivadas mediante la aplicación de técnicas hiperespectrales específicas, como la técnica del *Continuum removal* o el cálculo de la primera derivada estándar. En el caso de encontrarse modelos empíricos de estimación más precisos con esta información, éstos se podrán aplicar con imágenes hiperespectrales proporcionadas, por ejemplo, por los sensores MODIS y MERIS para cartografiar la biomasa residual en regiones más amplias que la aquí considerada. Sin embargo, la menor resolución espacial de estos sensores haría necesario, en medios mediterráneos, el empleo de técnicas de análisis subpíxel para garantizar la precisión de las cartografías obtenidas.

Asimismo, como se deduce de la bibliografía citada y del somero tratamiento hecho en este trabajo con imágenes radar, se debe seguir indagando a cerca de la utilidad de las imágenes SAR en banda C para estimar biomasa residual forestal, no sólo

a partir del análisis de la información del coeficiente de retrodispersión, sino también mediante el uso de técnicas interferométricas y polarimétricas.

Finalmente, el método desarrollado en el último capítulo para determinar las zonas que presentan una elevada aptitud para el aprovechamiento, abordado con técnicas SIG, debe ser mejorado mediante la integración de nuevas variables de fuerte impronta espacial y económica, como, por ejemplo, la necesidad de tratamientos selvícolas en las masas forestales, y mediante el añadido de rutinas de análisis espacial y de cálculo que permitan conocer, para cualquier punto del territorio, tanto la cantidad de residuos existentes y sus características como los sistemas tecnológicos más adecuados para su recolección y aprovechamiento, ofreciéndose una valoración económica lo más ajustada posible. Se trata de crear una herramienta útil a la hora de planificar el territorio.

***CAPÍTULO 7:
BIBLIOGRAFÍA***

- Alonso, E., Asín, J. y Pascual, J. (2005): "Biomasa residual forestal: regresiones para las especies del género *Pinus* existentes en la provincia de Teruel". En Sociedad Española de Ciencias Forestales (Ed.), *La ciencia forestal: respuestas para la sostenibilidad. 4º Congreso Forestal Español*, Sociedad Española de Ciencias Forestales, Zaragoza (CD-Rom).
- Allen, R.G., Pereira, L.S., Raes, D. y Smith, M. (1998): *Crop Evapotranspiration. Guidelines for computing crop water requirements*. FAO Irrigation and Drainage Paper nº 56, Food and Agriculture Organization of the United Nations (FAO), Rome, 465 pp.
- Álvarez, A. (2004): *Estudio sobre la utilización de la biomasa con fines energéticos: análisis metodológico sobre abastecimiento y costes*. Consejería de Medio Ambiente de la Junta de Castilla y León, Valladolid.
- Anaya, J.A., Chuvieco, E. y Palacios, A. (2008): "Estimación de biomasa aérea en Colombia a partir de imágenes MODIS". *Revista de Teledetección*, Vol. 30, pp. 5-22.
- Anaya, J.A., Chuvieco, E. y Palacios-Orueta, A. (2009): "Aboveground biomass assessment in Colombia: A remote sensing approach". *Forest Ecology and Management*, Vol. 257, pp. 1237-1246.
- Ardö, J. (1992): "Volume quantification of coniferous forest compartments using spectral radiance recorded by Landsat Thematic Mapper". *International Journal of Remote Sensing*, Vol. 13, pp. 1779-1786.
- ASEMFO (2004): *Informe ASEMFO: Los bosques como sumideros de carbono. Propuestas de actuación*. Asociación Nacional de Empresas Forestales (ASEMFO). Disponible en: <http://www.asemfo.org/empresas/asemfo/estudios/INFORME%20DE%20ASEMFO.pdf>.
- Asikainen, A., Björheden, R. y Nousiainen, I. (2002): "Cost of wood energy". En J. Richardson, R. Björheden, P. Hakkila, A.T. Lowe, y C.T. Smith (Eds.), *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*, Forestry Sciences Vol. 71, Kluwer Academic Publishers, Dordrecht, pp. 125-157.
- Askne, J.I.H., Dammert, P.B.G., Ulander, L.M.H. y Smith, G. (1997): "C-band repeat-pass interferometric SAR observations of the forest". *IEEE Transactions on geoscience and remote sensing*, Vol. 35, pp. 25-35.
- Austin, J.M., Mackey, B.G. y Van Niel, K.P. (2003): "Estimating forest biomass using satellite radar: an explanatory study in a temperate Australian Eucalyptus forest". *Forest Ecology and Management*, Vol. 176, pp. 575-583.
- Badía, D., Ibarra, P., Longares, L.A. y Martí, C.I. (2007): "La diversidad edáfica en Aragón". En Sociedad Española de la Ciencia del Suelo (Ed.), *XXVI Reunión Nacional de suelos de la Sociedad Española de la Ciencia del Suelo*, Sociedad Española de la Ciencia del Suelo, Durango (CD-Rom).
- Balzter, H. (2001): "Forest mapping and monitoring with interferometric synthetic aperture radar (InSAR)". *Progress in Physical Geography*, Vol. 25, pp. 159-177.
- Balzter, H., Luckman, A., Skinner, L., Rowland, C. y Dawson, T. (2007a): "Observations of forest stand top height and mean height from interferometric SAR and LiDAR over a conifer plantation at Thetford Forest, UK". *International Journal of Remote Sensing*, Vol. 28, pp. 1173-1197.

- Balzter, H., Rowland, C.S. y Saich, P. (2007b): "Forest canopy height and carbon estimation at Monks Wood National Nature Reserve, UK, using dual-wavelength SAR interferometry". *Remote Sensing of Environment*, Vol. 108, pp. 224-239.
- Baret, F. y Guyot, G. (1991): "Potentials and limits of vegetation indices for LAI and PAR assessment". *Remote Sensing of Environment*, Vol. 35, pp.161-173.
- Bartelink, H.H. (1997): "Allometric relationships for biomass and leaf area of beech (*Fagus sylvatica L*)". *Annals of Forest Science*, Vol. 54, pp. 39-50.
- Baulies, X. y Pons, X. (1995): "Approach to forestry inventory and mapping by means of multi-spectral airborne data". *International Journal of Remote Sensing*, Vol. 16, pp. 61-80.
- Beaudoin, A., Le Toan, T., Goze, S., Nezry, E., Lopes, A., Mougin, E., Hsu, C.C., Han, H.C., Kong, J.A. y Shin, R.T. (1994): "Retrieval of forest biomass from SAR data". *International Journal of Remote Sensing*, Vol. 15, pp. 2777-2796.
- Bergen, K., Colwell, J. y Sapio, F. (2000): "Remote sensing and forestry: collaborative implementation for a new century of forest information solutions". *Journal of Forestry*, Vol. 98, pp. 4-9.
- Borsboom, N.W.J., Hektor, B., McCallum, B. y Remedio, E. (2002): "Social implications of forest energy production". En J. Richardson, R. Björheden, P. Hakkila, A.T. Lowe, y C.T. Smith (Eds.), *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*, Forestry Sciences Vol. 71, Kluwer Academic Publishers, Dordrecht, pp. 265-297.
- Bortolot, Z.J. y Wynne, R.H. (2005): "Estimating forest biomass using small footprint LiDAR data: An individual tree-based approach that incorporates training data". *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 59, pp. 342-360.
- Brandtberg, T., Warner, T.A., Landenberger, R.E. y McGraw, J.B. (2003): "Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America". *Remote Sensing of Environment*, Vol. 85, pp. 290-303.
- Bravo, F., Río, M. y Peso, C. (2002): *El Inventario Forestal Nacional. Elemento clave para la gestión forestal sostenible*. Fundación General de la Universidad de Valladolid, Valladolid, 191 pp.
- Brown, S.L., Schroeder, P. y Kern, J.S. (1999): "Spatial distribution of biomass in forest of the eastern USA". *Forest Ecology and Management*, Vol. 123, pp. 81-90.
- Calle, A., Casanova, J.L. y Romo, A. (2005): "An integrated system for fire detection and monitoring, in real time, using MSG and MODIS data". En J. de la Riva, E. Chuvieco, y F. Pérez-Cabello, (Eds.), *Proceedings of the 5th International Workshop on Remote Sensing and GIS application to Forest Fire Management: Fire Effects Assessment*, EARSeL y Universidad de Zaragoza, Zaragoza, pp. 153-156.
- Calvao, T. y Palmeirin, J.M. (2004): "Mapping Mediterranean scrub with satellite imagery: biomass estimation and spectral behaviour". *International Journal of Remote Sensing*, Vol. 25, pp. 3113-3126.
- Castel, T., Martínez, J.M., Beaudoin, A., Wegmüller, U. y Strozzi, T. (2000): "ERS INSAR data for remote sensing hilly forested areas". *Remote Sensing of Environment*, Vol. 73, pp. 73-86.
- Castel, T., Beaudoin, A., Stach, N., Stussi, N., Le Toan, T. y Durand, P. (2001): "Sensitivity of space-borne SAR data to forest parameters over sloping terrain.

- Theory and experiment". *International Journal of Remote Sensing*, Vol. 22, pp. 2351-2376.
- Castel, T., Guerra, F., Caraglio, Y. y Houllier, F. (2002): "Retrieval biomass of a large Venezuelan pine plantation using JERS-1 SAR data. Analysis of forest structure impact on radar signature". *Remote Sensing of Environment*, Vol. 79, pp. 30-41.
- Cayuela, L., Rey Benayas, J.M. y Echeverría, C. (2006): "Clearance and fragmentation of tropical montane forests in the Highlands of Chiapas, Mexico (1975-200)". *Forest Ecology and Management*, Vol. 226, pp. 208-218.
- Chen, J.M., Govind, A., Sonnentag, O., Zhang, Y.Q., Barr, A., y Amiro, B. (2006): "Leaf area index measurements at Fluxnet-Canada forest sites". *Agricultural and Forest Meteorology*, Vol. 140, pp. 257-268.
- Chuvieco, E. (1996): *Fundamentos de teledetección espacial*. Rialp, Madrid, 568 pp.
- Chuvieco, E. (Ed.) (1999): *Remote sensing of large wildfires in the European Mediterranean Basin*. Springer-Verlag, Heidelberg, 212 pp.
- Chuvieco, E. (2002): *Teledetección ambiental. La observación de la tierra desde el espacio*. Ariel, Barcelona, 586 pp.
- Chuvieco, E., Deshayes, M., Stach, N., Cocero, D., Riano, D. (1999): "Short-term fire risk: Foliage moisture content estimation from satellite data". En E. Chuvieco (Ed.), *Remote sensing of large wildfires in the European Mediterranean Basin*, Springer, Heidelberg, pp. 17-38.
- Chuvieco E., Riaño D., Aguado I. y Cocero D. (2002): "Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: applications in fire danger assessment". *International Journal of Remote Sensing*, Vol. 23, pp. 2145-2162.
- Chuvieco, E., Aguado, I., Cocero, D., y Riaño, D. (2003): "Design of an empirical index to estimate fuel moisture content from NOAA-AVHRR analysis in forest fire danger studies". *International Journal of Remote Sensing*, Vol. 24(8), pp. 1621– 1637.
- Chuvieco, E., Cocero, D., Riaño, D., Martín, M.P., Martínez-Vega, J., de la Riva, J. y Pérez-Cabello, F. (2004): "Combining NDVI and Surface Temperature for the estimation of live fuel moisture content in forest fire danger rating". *Remote Sensing of Environment*, Vol. 92, pp. 322–331.
- Chuvieco, E., Bosque, J., Pons, X., Conesa, C., Santos, J.M., Gutiérrez Puebla, J., Salado, M.J., Martín, M.P., de la Riva, J., Ojeda, J. y Prados, M.J. (2005): "¿Son las Tecnologías de la Información Geográfica (TIG) parte del núcleo de la Geografía?". *Boletín de la A.G.E.*, Vol. 40, pp. 35-55.
- Chuvieco, E., Riaño, D., Danson, F.M. y Martín, P. (2006): "Use of a radiative transfer model to simulate the postfire spectral response to burn severity". *Journal of Geophysical Research*, Vol. 111, G04S09.
- Cohen, W.B., Maerspergers, T.K., Spies, T.A. y Oetter, D.R. (2001): "Modelling forest cover attributes as continuous variables in a regional context with Thematic Mapper data". *International Journal of Remote Sensing*, Vol. 22, pp. 2279-2310.
- Colby, J.D. (1991): "Topographic normalization in rugged terrain". *Photogrammetric Engineering and Remote Sensing*, Vol. 57, pp. 531-537.
- Consejo de la Unión Europea (1995): "Reunión nº 1.850, 1 de junio de 1995 – Resolución del Consejo sobre el Libro verde. Por una política energética de la Unión Europea".

- En A. Mourelatou y I. Smith (2004), *Energía y medio ambiente en la Unión Europea*, Ministerio de Medio Ambiente, Madrid, 67 pp.
- Comisión de las Comunidades Europeas (1997): *Energía para el Futuro: Fuentes de Energía Renovables. Libro Blanco para una Estrategia y un Plan de Acción Comunitarios*. COM(97) 599 final, Comisión de las Comunidades Europeas, Bruselas, 59 pp.
- Comisión de las Comunidades Europeas (1998): *Consolidar la integración medioambiental en la política energética comunitaria. Comunicación de la Comisión*. COM(1998) 571 final, Comisión de las Comunidades Europeas, Bruselas, 20 pp.
- Comisión de las Comunidades Europeas (2006): *Libro Verde: Estrategia europea para una energía sostenible, competitiva y segura*. COM(2006) 105 final, Comisión de las Comunidades Europeas, Bruselas, 22 pp.
- Crist, E.P., Laurin, R. y Cicone, R.C. (1986): "Vegetation and soils information contained in transformed Thematic Mapper data". En *Proceedings of IGARSS '86 Symposium*, 1465-70, Ref. ESA SP-254, Paris.
- Crow, T.R. y Laidly, P.R. (1980): "Alternative models for estimating woody plant biomass". *Canadian Journal of Forest Research*, Vol. 10, pp. 367-370.
- de la Riva, J. (1997): *Los montes de la Jacetania. Caracterización física y explotación forestal*. Consejo de Protección de la Naturaleza de Aragón, Zaragoza, 358 pp.
- De Santis y Chuvieco, E. (2007): "Burn severity estimation from remotely sensed data: Performance of simulation versus empirical models". *Remote Sensing of Environment*, Vol. 108, pp. 422-435.
- Del Río, M., Rivas, J.C., Condés, S., Martínez-Millán, J., Montero, G., Cañellas, I., Ordóñez, C., Pando, V., San Martín, R. y Bravo, F. (2002): "BASIFOR: aplicación informática para el manejo de bases de datos del Segundo Inventario Forestal Nacional". En F. Bravo, M. Del Río y C. Del Peso (Eds.), *El Inventario Forestal Nacional Elemento Clave para la Gestión Forestal Sostenible*, Fundación General de la Universidad de Valladolid, Valladolid, pp. 181-191.
- Departamento de Agricultura y Alimentación (2007): *Anuario Estadístico Agrario de Aragón de 2003, 2004, 2005*. Departamento de Agricultura y Alimentación, Zaragoza. Disponible en: <http://www.aragon.es> [consulta: 4 de diciembre de 2007].
- Devereux, B.J., Amable, G.S. y Posada, C.C. (2004): "An efficient image segmentation algorithm for landscape analysis". *International Journal of Applied Earth Observation and Geoinformation*, Vol. 6, pp. 47-61.
- Díaz, L. y Romero, C. (2004): *La captura de carbono y la gestión forestal*. Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria - Ministerio de Ciencia y Tecnología, Madrid, 79 pp.
- Dobson, M.C. (2000): "Forest Information from Synthetic Aperture Radar". *Journal of Forestry*, Vol. 98, pp. 41-43.
- Dobson, M.C., Ulaby, F.T., LeToan, T., Beaudoin, A., Kasischke, E.S. y Christensen, N. (1992): "Dependence of radar backscatter on coniferous forest biomass". *IEEE Transactions on Geosciences and Remote Sensing*, Vol. 30, pp. 412-415.
- Domínguez, J. (2002): *Los sistemas de información geográfica en la planificación e integración de energías renovables*. Colección de documentos Ciemat, Ciemat, Madrid, 159 p.p.

- Domínguez, J., Ciria, P., Esteban, L.S., Sánchez, D. y Lasry, P. (2003): "Evaluación de la biomasa potencial como recurso energético en la región de Navarra (España)". *GeoFocus*, Vol. 3, pp. 1-10.
- Dong, J., Kaufmann, R.K., Myneni, R.B., Tucker, C.J., Kauppi, P., Liski, J., Buermann, W., Alexeyev, V. y Hughes, M.K. (2003): "Remote sensing estimates of boreal and temperate forest woody biomass: Carbon pools, sources, and links". *Remote Sensing of Environment*, Vol. 84, pp. 393-410.
- Donoghuea, D.N.M., Wattc, P.J., Coxa, N.J. y Wilson, J. (2007): "Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data". *Remote Sensing of Environment*, Vol. 110, pp. 509-522.
- Drake, J.B., Dubayah, R.O., Knox, R.G., Clark, D.B. y Blair, J.B. (2002): "Sensitivity of large-footprint lidar to canopy structure and biomass in a neotropical rainforest". *Remote Sensing of Environment*, Vol. 81, pp. 378-392.
- Dubayah, R. y Drake, J.B. (2000): "Lidar Remote Sensing for Forestry". *Journal of Forestry*, Vol. 98, pp. 44-46.
- Ebdon, D. (1982): *Estadística para geógrafos*. Oikos-Tau, Barcelona, 348 pp.
- Eklundh, L., Harrie, L. y Kuusk, A. (2001): "Investigating relationships between Landsat ETM+ sensor data and leaf area index in a boreal conifer forest". *Remote Sensing of Environment*, Vol. 78, pp. 239-251.
- Eklundh, L., Hall, K., Eriksson, H., Ardö, J. y Pilesjö, P. (2003): "Investigating the use of Landsat thematic mapper data for estimation of forest leaf area index in southern Sweden". *Canadian Journal of Remote Sensing*, Vol. 29, pp. 349-362.
- ERDAS (2002): *ERDAS Field Guide. Fifth Edition Translation*. Leica geosystems GIS & Mapping Division, Atlanta, 644 pp.
- Eriksson, H.M., Hall, J.P. y Helynen, S. (2002): "Rationale for forest energy production". En J. Richardson, R. Björheden, P. Hakkila, A.T. Lowe, y C.T. Smith (Eds.), *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*, Forestry Sciences Vol. 71, Springer Netherlands, pp. 1-17.
- ESA (2009): *ESA Earthnet: ENVISAT*. ESA Official website. Disponible en: <http://envisat.esa.int/> [consulta: 9 de abril de 2009].
- Escudero, O. y Franchès, M.J. (Coor.) (2004): *Memoria de síntesis del mapa forestal de Aragón*. Consejo de Protección de la Naturaleza de Aragón, Zaragoza, 119 pp.
- Esteban, L. y Carrasco, J. (2001): "Evaluation of crown biomass production in thinnings of cluster pine (*Pinus pinaster* Ait.) in the Spanish northern plateau". En A.A. Kyritsis, (Ed.), *First World Conference on Biomass for Energy and Industry Vol. II*, pp. 2002-2005.
- Esteban Pascual, L.S., Pérez Ortiz, P., Ciria Ciria, P. y Carrasco García, J.E. (2004): *Evaluación de los recursos de biomasa forestal en la provincia de Soria. Análisis de alternativas para su aprovechamiento energético*. Colección de documentos Ciemat, Ciemat, Madrid, 109 pp.
- Eurimage (2008): *Landsat. Decades of continuous medium-resolution data. Products and services*. Eurimage, 10 pp. Disponible en: <http://www.eurimage.com>.
- Etxeverría, J. (1999): *Regresión múltiple*. Cuadernos de Estadística, La Muralla, Madrid, 155 pp.

- Falkenström, H. y Ekstrand, S. (2002): "Evaluation of IRS-1C LISS-3 satellite data for defoliation assessment on Norway spruce and Scots pine". *Remote Sensing of Environment*, Vol. 82, pp. 208-223.
- Fazakas, Z., Nilsson, M. y Olsson, H. (1999): "Regional forest biomass and wood volume estimation using satellite data and ancillary data". *Agricultural and Forest Meteorology*, Vol. 98-99, pp. 417-425.
- Felicísimo, A.M. (2003): *Modelos Digitales del terreno. Cuaderno de teoría*. Material didáctico del Máster "Tecnologías de la información geográfica para la ordenación del territorio: sistemas de información geográfica y teledetección". Universidad de Zaragoza, 106 pp.
- Fiorucci, P., Gaetani, F., Lanorte, A. and Lasaponara, R. (2005): "Remote Sensing technology coupled with meteorological forecast data for wildland fire danger assessment". En J. de la Riva, E. Chuvieco, y F. Pérez-Cabello (Eds.), *Proceedings of the 5th International Workshop on Remote Sensing and GIS application to Forest Fire Management: Fire Effects Assessment*, EARSeL y Universidad de Zaragoza, Zaragoza, pp. 119-123.
- Foody, G.M., Green, R.M., Lucas, R.M., Curran, P.J., Honzak, M. y Do Amaral, I. (1997): "Observations on the relationship between SIR-C radar backscatter and the biomass of regenerating tropical forest". *International Journal of Remote Sensing*, Vol. 18, pp. 687-694.
- Foody, G.M., Cutler, M.E., McMorrow, J., Pelz, D., Tangki, H., Boyd, D.S. y Douglas, I. (2001): "Mapping the biomass of Bornean tropical rain forest from remotely sensed data". *Global Ecology and Biogeography*, Vol. 10, pp. 379-387.
- Foody, G.M., Boyd, D.S. y Cutler, M. (2003): "Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions". *Remote Sensing of Environment*, Vol. 85, pp. 463-474.
- Franklin, S.E. (2001): *Remote sensing for sustainable forest management*. Taylor & Francis-CRC Press, New York, 424 pp.
- Franklin, J. y Hiernaux, P.Y.H. (1991): "Estimating foliage and woody biomass in Sahelian and Sudanian woodlands using a remote sensing model". En D. Lu, (2006): "The potential and challenge of remote sensing-based biomass estimation". *International Journal of Remote Sensing*, Vol. 27, pp. 1297-1328.
- Fransson, J.E.S. (1999): "Estimation of stem volume in boreal forests using ERS-1 C- and JERS-1 L-band SAR data". *International Journal of Remote Sensing*, Vol. 20, pp. 123-137.
- Frohn, R.C. y Hao, Y. (2006): "Landscape metric performance in analyzing two decades of deforestation in the Amazon Basin of Rondonia, Brazil". *Remote Sensing of Environment*, Vol. 100, pp. 237-251.
- GAMMA Remote Sensing AG (2008): *Differential Interferometry and Geocoding Software – DIFF&GEO*. GAMMA Remote Sensing AG, Gümligen, 83 pp.
- Garañeda, R.J. y Bengoa, L. (2005) "Estudio de disponibilidad en seis zonas de Castilla y León". En Sociedad Española de Ciencias Forestales (Ed.), *La ciencia forestal: respuestas para la sostenibilidad. 4º Congreso Forestal Español*, Sociedad Española de Ciencias Forestales, Zaragoza (CD-Rom).
- García-Martín, A., Pérez-Cabello, F., de la Riva Fernández, J. y Montorio Llovería, R. (2008): "Estimation of crown biomass of Pinus spp. from Landsat TM and its effect

on burn severity in a Spanish fire scar". *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 1, pp. 254-265.

- García-Martín, A., Pérez-Cabello, F., de la Riva Fernández, J. y Montorio Llovería, R. (2007): "Estimation of crown biomass in the context of forest fires management in Mediterranean areas". En I. Gitas y C. Carmona-Moreno (Eds.), *Proceedings of the 6th International Workshop of the EARSeL Special Interest Group on Forest Fires: Towards an operational use of remote sensing in forest fire management*, EARSeL, Aristotle University of Thessaloniki, Joint Research Centre y Universidad de Alcalá, Thessaloniki, p.p. 78-82.
- Garestier, F. (2006): *Évaluation du potentiel de la technique PolInSAR pour l'estimation des paramètres physiques de la végétation en conditions satellitaires*. Observatoire Aquitain des Sciences de l'Univers - ONERA, Bordeaux, Tesis doctoral, 154 pp.
- Gaveau, D.L.A. (2002): "Modelling the dynamics of ERS-1/2 coherence with increasing woody biomass over boreal forest". *International Journal of Remote Sensing*, Vol. 23, pp. 3879-3885.
- Gemmel, F.M. (1995): "Effects of forest cover, terrain, and scale on timber volume estimation with Thematic Mapper data in a Rocky Mountain site". *Remote Sensing of Environment*, Vol. 51, pp. 291-305.
- Gerylo, G.R., Hall, R.J., Franklin, S.E. y Smith, L. (2002): "Empirical relations between Landsat TM spectral response and forest stands near Fort Simpson, Northwest Territories, Canada". *Canadian Journal of Remote Sensing*, Vol. 28, pp. 68-79.
- Gilbert, M.A., González-Piqueras, J. y García-Haro, J. (1997): "Acerca de los índices de vegetación". *Revista de Teledetección*, Vol. 8, pp. 1-10.
- Gilbert, M.A., González-Piqueras, J., García-Haro, F.J. y Meliá, J. (2002): "A generalized soil-adjusted vegetation index". *Remote Sensing of Environment*, Vol. 82, pp. 303-310.
- Gitelson, A.A., Kaufman, Y.J., Stark, R. y Rundquist, D. (2002): "Novel algorithms for remote estimation of vegetation fraction". *Remote Sensing of Environment*, Vol. 80, pp. 76-87.
- Gobierno de Aragón – IDAE (1997): *Las energías renovables en Aragón. Datos de diagnóstico y perspectivas para una planificación y toma de decisiones*. Gobierno de Aragón – IDAE, Zaragoza, 183 pp.
- Gobierno de Aragón – CIRCE (1997): *Atlas de biomasa para usos energéticos de Aragón*. Gobierno de Aragón, Zaragoza, 213, pp.
- Goetz, S. (2002): "Recent advances in remote sensing of biophysical variables. An overview of the special issue". *Remote Sensing of Environment*, Vol. 79, pp. 145-146.
- González Cano, J.M., Oria de Rueda, J.A. y Pérez de Vicente, R. (2001): *Inventario abierto de los bosques singulares del sector S.E. de la provincia de Teruel*. Consejo de Protección de la Naturaleza de Aragón, Zaragoza, 165 pp.
- Goodwin, N.R., Coops, N.C. y Culvenor, D.S. (2006): "Assessment of forest structure with airborne LiDAR and the effects of platform altitude". *Remote Sensing of Environment*, Vol. 103, pp. 140-152.
- Gower, S.T., Kucharik, C.J. y Norman, J.M. (1999): "Direct and indirect estimation of leaf area index, f(APAR), and net primary production of terrestrial ecosystems". *Remote Sensing of Environment*, Vol. 70, pp. 29-51.

- Gracia C., Burriel J.A., Ibàñez J.J., Mata T. y Vayreda J. (2004): *Inventari Ecològic i Forestal de Catalunya*. CREAf, Bellaterra. Disponible en: <http://www.creaf.uab.es/>, [consulta: febrero de 2004].
- Guillén, J.A. (2005a): "Forestal". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 29.
- Guillén, J.A. (2005b): "Población y empleo". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 21-26.
- Guillén, J.A. (2005c): "Agricultura". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 27-28.
- Guillén, J.A. (2005d): "Comercio". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 41.
- Guillén, J.A. (2005e): "Turismo". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 37-40.
- Guillén, J.A. (2005f): "Infraestructuras y transportes". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 43-44.
- Guillén, J.A. (2005g): "Infoestructuras". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 42.
- Guillén, J.A. y Lozano, M.V. (Coord.) (2005): *Atlas de Teruel. Una visión práctica del territorio*. Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, 49 pp.
- Gutiérrez, M. y Peña, J.L. (1990): *Las formas del relieve de la provincia de Teruel*. Cartillas Turolenses, Instituto de Estudios Turolenses - Diputación Provincial de Teruel, Teruel, 66 pp.
- Haapanen, R., Ek, A.R., Bauer, M.E. y Finley, A.O. (2004): "Delineation of forest/non forest land use classes using nearest neighbour methods". *Remote Sensing of Environment*, Vol. 89, pp. 265-271.
- Hagner, O. (2002): "Combined estimation of forest parameters from high and medium resolution satellite imagery and forest inventory data". *Proceedings of the ForestSAT Symposium on Operational Tools in Forestry Using Remote Sensing Techniques*, Edinburgh, pp. 5-9.
- Hair, J.F., Anderson, R.E., Tatham, R.L. y Black, W.C. (1999): *Análisis multivariante*. Prentice Hall Iberia, Madrid, 799 pp.
- Hakkila P. (2003): *Developing technology for large-scale production of forest chips*. Wood Energy Technology Programme 1999-2003. Technology programme report 5/2003, Interim report, Tekes, Helsinki, 54 pp.
- Hakkila, P. y Parikka, M. (2002): "Fuel resources from the forest". En J. Richardson, R. Björheden, P. Hakkila, A.T. Lowe, y C.T. Smith (Eds.), *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*, Forestry Sciences Vol. 71, Kluwer Academic Publishers, Dordrecht, pp. 19-48.

- Hall, R.J., Skakun, R.S., Arsenault, E.J. y Case, B.S. (2006): "Modeling forest stand structure attributes using Landsat ETM+ data: application to mapping of aboveground biomass and stand volume". *Forest Ecology and Management*, Vol. 225, pp. 378-390.
- Häme, T., Salli, A., Andersson, K. y Lohi, A. (1997): "A new methodology for the estimation of biomass of conifer-dominated boreal forest using NOAA AVHRR data". *International Journal of Remote Sensing*, Vol.18, pp. 3211–3243.
- Heikkilä, J., Nevalainen, S. y Tokola, T. (2002): "Estimating defoliation in boreal coniferous forests by combining Landsat TM, aerial photographs and field data". *Forest Ecology and Management*, Vol. 158, pp. 9-23.
- Henderson, F.M. y Lewis, A.J. (1998): *Principles and Applications of imaging radar. Manual of Remote Sensing, Third Edition, Volume 2*. John Wiley & Sons, New York, 866 pp.
- Hill, R.A. y Thomson, A.G. (2005): "Mapping woodland species composition and structure using airborne spectral and LiDAR data". *International Journal of Remote Sensing*, Vol. 26, pp. 3763-3779.
- Howard, J.A. (1991): *Remote Sensing of Forest Resources*. Chapman & Hall, Londres, 420 pp.
- Hsu, C.C., Han, H.C., Shin, R.T., Kong, J.A., Beaudoin, A. y Le Toan, T. (1994): "Radiative transfer theory for polarimetric remote sensing of pine forest at P band". En Le Toan, T. y Floury, N. (1998): "On the retrieval of forest biomass from SAR data", *Proceedings of the 2nd International Symposium of Retrieval of Bio- and Geophysical Parameters from SAR data for Land applications*, ESA Publications Division, Noordwijk, pp. 595–600.
- Huang, S. y Siegert, F. (2004): "ENVISAT multisensor data for fire monitoring and impact assessment". *International Journal of Remote Sensing*, Vol. 25, pp. 4411-4416.
- Huete, A.R. (1988): "A soil-adjusted vegetation index (SAVI)". *Remote Sensing of Environment*, Vol. 25, pp. 295–309.
- Hyde, P., Dubayah, R., Peterson, B., Blair, J.B., Hofton, M., Hunsaker, C., Knox, R. y Walker, W. (2005): "Mapping forest structure for wildlife habitat analysis using waveform lidar: Validation of montane ecosystems". *Remote Sensing of Environment*, Vol. 96, pp. 427-437.
- Hyypä, H.J. y Hyypä, J.M. (2001): "Effects of stand size on the accuracy of remote sensing-based forest inventory". *IEEE Transactions on Geosciences and Remote Sensing*, Vol. 39, pp. 2613-2621.
- Hyypä, J., Hyypä, H., Inkinen, M., Engdahl, M. y Linko, S. (2000): "Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes". *Forest Ecology and Management*, Vol. 128, pp. 109–120.
- IDAE (1999): *Plan de fomento de las energías renovables en España*. Instituto para la Diversificación y Ahorro de la Energía, Ministerio de Ciencia y Tecnología, Madrid, 271 pp.
- IDAE (2005a): *Plan de Energías Renovables en España 2005-2010*. Instituto para la Diversificación y Ahorro de la Energía, Ministerio de Industria, Turismo y Comercio, Madrid, 345 pp.

- IDAE (2005b): *Resumen del Plan de Energías Renovables en España 2005-2010*, Instituto para la Diversificación y Ahorro de la Energía, Ministerio de Industria, Turismo y Comercio, Madrid, 80 pp.
- IDAE (2007): *Energía de la biomasa*. Instituto para la Diversificación y Ahorro de la Energía, Ministerio de Industria, Turismo y Comercio, Madrid, 134 pp.
- Israelsson, H., Askne, J. y Sylvander, R. (1994): "Potential of SAR for forest bole volume estimation". *International Journal of Remote Sensing*, Vol. 15, pp. 2809-2826.
- Jakubauskas, M.E. (1996): "Thematic mapper characterization of lodgepole pine seral stages in Yellowstone National Park, USA". *Remote Sensing of Environment*, Vol. 56, pp. 118-132.
- Jarabo Friedrich, F. (1999): *La energía de la biomasa*, S.A.P.T. Publicaciones Técnicas, S.L., Madrid, 135 pp.
- Jia, G.J., Burke, I.C., Kaufmann, M.R., Goetz, A.F.H., Kindel, B.C. y Pu, Y. (2006): "Estimates of forest canopy fuel attributes using hyperspectral data". *Forest Ecology and Management*, Vol. 229, pp. 27-38.
- Joosten, R., Schumacher, J., Wirth, C. y Sculte, A. (2004): "Evaluating tree carbon predictions for beech (*Fagus sylvatica* L.) in western Germany". *Forest Ecology and Management*, Vol. 189, pp. 87-96.
- Kasischke, E.S., Melack, J.M. y Dobson, M.C. (1997): "The use of imaging radars for ecological applications- a review". *Remote Sensing of Environment*, Vol. 59, pp. 141-156.
- Keith, H., Barret, D. y Keenan, R. (2000): *Review of allometric relationships for estimating woody biomass for New South Wales, the Australian Capital Territory, Victoria, Tasmania and South Australia*. National Carbon accounting System, Technical Report nº 5B, Australian Greenhouse Office, Canberra, 123 pp.
- Kellendorfer, J.M., Dobson, M.C., Vona, J.D. y Clutter, M. (2003): "Toward precision forestry: plot-level parameter retrieval for slash pine plantations with JPL AIRSAR". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 41, pp. 1571-1582.
- Kergoat, L., Lafont, S., Douville, H., Berthelot, B., Dedieu, G., Planton, S. y Royer, J.F. (2002): "Impact of doubled CO₂ on global-scale leaf area index and evapotranspiration: Conflicting stomatal conductance and LAI responses". *Journal of Geophysical Research*, Vol.107.
- Ketterings, Q.M., Coe, R., van Noordwijk, M., Ambagau, Y. y Palm, C.A. (2001): "Reducing uncertainty in the use of allometric biomass equations for predicting above-ground biomass in mixed secondary forests". *Forest Ecology and Management*, Vol. 146, pp. 199-209.
- Key, C.H. y Benson, N. (2006): *Landscape assessment. Sampling and analysis methods*. USDA Forest Service, General Technical Report, RMRS-GTR-164-CD.
- Kilpeläinen, P. y Tokola, T. (1999): "Gain to be achieved from stand lineation in Landsat TM image-based estimates of stand volume". *Forest Ecology and Management*, Vol. 124, pp. 105-111.
- Koukoulas, S. y Blackburn, G.A. (2005) "Mapping individual tree location, height and species in broadleaved deciduous forest using airborne LIDAR and multi-spectral remotely sensed data". *International Journal of Remote Sensing*, Vol. 26, pp. 431-455.

- Kuntz, S. y Siegert, F. (1999): "Monitoring of deforestation and land use in Indonesia with multitemporal ERS data". *International Journal of Remote Sensing*, Vol. 20, pp. 2835-2853.
- Kurvonen, L., Pulliainen, J. y Hallikainen, M. (1999): "Retrieval of biomass in boreal forest from multitemporal ERS-1 and JERS-1 SAR images". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 37, pp. 198-205.
- Kurvonen, L., Pulliainen, J. y Hallikainen, M. (2002): "Active and passive microwave remote sensing of boreal forest". *Acta Astronautica*, Vol. 51, pp. 707-713.
- Labrecque, S., Fournier, R.A, Luther, J.E. y Piercey, D.E. (2003): "A comparison of three approaches to map forest biomass from Landsat-TM and inventory data in Western Newfoundland". En *Proceedings of 25th Canadian Symposium on Remote Sensing*. Montreal.
- Labrecque, S., Fournier, R.A, Luther, J.E. y Piercey, D.E. (2006): "A comparison of four methods to map biomass from Landsat-TM and inventory data in Western Newfoundland". *Forest Ecology and Management*, Vol. 226, pp. 129-144.
- Lasaponara, R., Lanorte, A. y Pignatti, S. (2006): "Multiscale fuel type mapping in fragmented ecosystems: preliminary results from hyperspectral MIVIS and multispectral Landsat TM data". *International Journal of Remote Sensing* Vol. 27, pp. 587-593.
- Le Toan, T. (2002): *BIOMASCA: Biomass monitoring mission for Carbon Assessment. A proposal in response to the ESA Second Call for Earth Explorer Opportunity Missions*, ESA-Earth Explorers, 74 pp.
- Le Toan, T. y Floury, N. (1998): "On the retrieval of forest biomass from SAR data". *Proceedings of the 2nd International Symposium of Retrieval of Bio- and Geophysical Parameters from SAR data for Land applications*, ESA Publications Division, Noordwijk, pp. 595-600.
- Le Toan, T., Beaudoin, A., Riou, J. y Guyon, D. (1992): "Relating forest biomass to SAR data". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 30, pp. 403-411.
- Le Toan, T., Picard, G., Martínez, J.M., Melon, P. y Davidson, M. (2002): "On the relationships between radar measurements and forest structure and biomass". *Proceedings of the 3rd International Symposium of Retrieval of Bio- and Geophysical Parameters from SAR data for Land applications*, ESA Publications Division, Noordwijk, pp. 3-12.
- Le Toan, T., Quegan, S., Woodward, I., Lomas, M., Delbart, N. y Ghislain, P. (2004): "Relating radar remote sensing of biomass to modelling of forest carbon budgets". *Climatic Change*, Vol. 67, pp. 379-402.
- Leboeuf, A., Beaudoin, A., Fournier, R.A., Guindon, L., Luther, J.E. y Lambert, M.C. (2007): "A shadow fraction method for mapping biomass of northern boreal black spruce forests using QuickBird imagery". *Remote Sensing of Environment*, Vol. 110, pp. 488-500.
- Lefsky, M.A., Harding, D., Cohen, W.B., Parker, G. y Shugart, H.H. (1999): "Surface Lidar Remote Sensing of Basal Area and Biomass in Deciduous Forests of Eastern Maryland, USA". *Remote Sensing of Environment*, Vol. 67, pp. 83-98.
- Lehtonen, A., Mäkipää, R., Heikkinen, J., Sievänen, R. y Liski, J. (2004): "Biomass expansion factors (BEFs) for Scots pine, Norway spruce and birch according to

- stand age for boreal forests". *Forest Ecology and Management*, Vol. 188, pp. 211-224.
- Lillesand T.M. y Kiefer, R.W. (2000): *Remote sensing and image interpretation*. John Wiley & Sons, Inc., New York, 724 pp.
- Longares, L.A. (2005): "Vegetación". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 11.
- Lorente, J.M. (2009): "Situación energética y sector forestal: un análisis desde la perspectiva aragonesa". *Foresta*, Vol. 43-44, pp. 132-139.
- Lozano, M.V. (2005a): "Relieve e hidrología". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 6-8.
- Lozano, M.V. (2005b): "Climatología". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 9-10.
- Lu, D. (2005): "Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon". *International Journal of Remote Sensing*, Vol. 26, pp. 2509-2525.
- Lu, D. (2006): "The potential and challenge of remote sensing-based biomass estimation". *International Journal of Remote Sensing*, Vol. 27, pp. 1297-1328.
- Lu, D. y Batistella, M. (2005): "Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon". *Acta Amazonica*, Vol. 35, pp. 249-257.
- Lu, D., Batistella, M. y Moran, E. (2005): "Satellite estimation of aboveground biomass and impacts of forest stand structure". *Photogrammetric Engineering and Remote Sensing*, Vol. 71, pp. 967-974.
- Lu, D., Mausel, P., Brondízio, E. y Moran, E. (2004): "Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin". *Forest Ecology and Management*, Vol. 198, pp. 149-167.
- Lucas, R.M., Honzák, M., Do Amaral, I., Curran, P.J. y Foody, G.M. (2002): "Forest regeneration on abandoned clearances in central Amazonia". *International Journal of Remote Sensing*, Vol. 23, pp. 965-988.
- Luckman, A., Baker, J., Honzák, M y Lucas, R (1998): "Tropical forest biomass density estimation using JERS-1 SAR: seasonal variation, confidence limits, and application to image mosaics". *Remote Sensing of Environment*, Vol. 63, pp. 126-139.
- Magnusson, M. y Fransson, J.E.S. (2005): "Estimation of forest stem volume using multispectral optical satellite and tree height data in combination". *Scandinavian Journal of Forest Research*, Vol. 20, pp. 431-430.
- Mäkelä, H. y Pekkarinen, A. (2001): "Estimation of timber volume at the sample plot level by means of image segmentation and Landsat TM imagery". *Remote Sensing of Environment*, Vol. 77, pp. 66-75.
- Mäkelä, H. y Pekkarinen, A. (2004): "Estimation of forest stand volumes by Landsat TM imagery and stand-level field-inventory data". *Forest Ecology and Management*, Vol. 196, pp. 245-255.

- Mallinis, G., Koutsias, N., Makras, A. y Karteris, M. (2004): "Forest parameters estimation in a European Mediterranean landscape using remotely sensed data". *Forest Science*, Vol. 50, pp. 450-460.
- Maselli, F. y Chiesi, M. (2006): "Evaluation of statistical methods to estimate forest volume in a Mediterranean Region". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 44, pp. 2239-2250.
- Mather, P.M. (1987): *Computer processing of remotely sensed images: an introduction*. John Wiley, Chichester, 360 pp.
- McDonald, E.R., Wu, X., Caccetta, P. y Campbell, N., (2000): "Illumination correction of Landsat TM data in South East NSW". En *Proceedings of the 10th Australasian Remote Sensing and Photogrammetry Conference*, Adelaide (CD-Rom).
- McNeil Technologies (2003): *Biomass Resource Assessment and Utilization Options for Three Counties in Eastern Oregon*. Oregon Department of Energy, Salem, 177 pp.
- McRoberts, R.E. y Tomppo, E.O. (2007): "Remote sensing support for national forest inventories". *Remote Sensing of Environment*, Vol. 110, pp. 412-419.
- Mette, T., Papathanassiou, K.P., Hajnsek, I. y Zimmermann, R. (2003): "Above Ground Forest Biomass Estimation using Fully Polarimetric / Interferometric Radar Data". En *Proceedings Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry (POLinSAR'03)*. ESA-ESRIN, Frascati, Italy. Disponible en: <http://earth.esa.int/polinsar> [consulta: agosto de 2009].
- Mette, T., Papathanassiou, K., Hajnsek, I., Pretzsch, H. y Biber, P. (2004a): "Applying a common allometric equation to convert forest height from Pol-InSAR data to forest biomass". En *Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS '04)*, pp. 269-272.
- Mette, T., Papathanassiou, K. y Hajnsek, I. (2004b): "Biomass estimation from polarimetric SAR interferometry over heterogeneous forest terrain". En *Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS '04)*, pp. 511-514.
- Meyer, P., Itten, K.I., Kellenbenberger, T., Sandmeier, S. y Sandmeier, R. (1993): "Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment". *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 48, pp. 17-28.
- Mickler, R.A., Earnhardt, T.S. y Moore, J.A. (2002): "Regional estimation of current and future biomass". *Environmental Pollution*, Vol. 116, pp. S7-S16.
- Ministerio de Industria, Turismo y Comercio (2008): *La Energía en España 2007*. Ministerio de Industria, Turismo y Comercio, Madrid, 229 pp.
- Ministerio de Medio Ambiente (1996): *Segundo Inventario Forestal Nacional (1986-1995): Aragón, Teruel*. Ministerio de Medio Ambiente, Madrid, 223 pp.
- Ministerio de Medio Ambiente (2007): *Inventario Forestal Nacional*. Ministerio de Medio Ambiente, Madrid. Disponible en: <http://www.mma.es/> [consulta: 21 de diciembre de 2007].
- Moghaddam, M., Dungan, J.L. y Acker, S. (2002): "Forest variable estimation from fusion of SAR and multispectral optical data". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 40, pp. 2176-2187.

- Montero, G., Ruiz-Peinado, R. y Muñoz, M. (2005): *Producción de biomasa y fijación de CO₂ por los bosques españoles*. Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria - Ministerio de Ciencia y Tecnología, Madrid, 270 pp.
- Moreau, S. y Le Toan, T. (2003): "Biomass quantification of Andean wetland forages using ERS satellite SAR data for optimizing livestock management". *Remote Sensing of Environment*, Vol. 84, pp. 477-492.
- Mourelatou, A. y Smith, I. (2004): *Energía y medio ambiente en la Unión Europea*, Ministerio de Medio Ambiente, Madrid, 67 pp.
- Mutanga, O. y Skidmore, A.K. (2004): "Narrow band vegetation indices overcome the saturation problem in biomass estimation". *International Journal of Remote Sensing*, Vol. 25, pp. 3999-4014.
- Mutlu, M., Popescu, S.C., Stripling, C. y Spencer, T. (2008): "Mapping surface fuel models using lidar and multispectral data fusion for fire behavior". *Remote Sensing of Environment*, Vol. 112, pp. 274-285.
- Muukkonen, P. y Heiskanen, J. (2005): "Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data". *Remote Sensing of Environment*, Vol. 99, pp. 434-447.
- Muukkonen, P. y Heiskanen, J. (2007): "Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: A possibility to verify carbon inventories". *Remote Sensing of Environment*, Vol. 107, pp. 617-624.
- NASA (2008): *The Landsat Program*. NASA Official website. Disponible en: <http://landsat.gsfc.nasa.gov/> [consulta: 24 de enero de 2008].
- Næsset, E., (1997): "Determination of mean tree height of forest stands using airborne laser scanner data". *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 52, pp. 49-56.
- NCGIA (National Center for Geographic Information and Analysis) (1997): *NCGIA Core Curriculum in GIS Science*. En Escolano, S.: *Asignatura: 1.3. Nociones básicas sobre los SIG*. Material didáctico del Master "Tecnologías de la información geográfica para la ordenación del territorio: Sistemas de información geográfica y Teledetección". Universidad de Zaragoza.
- Nelson, R., Ranson, K.J., Sun, G., Kimes, D.S., Kharuk, V. y Montesano, P. (2009): "Estimating Siberian timber volume using MODIS and ICESat/GLAS". *Remote Sensing of Environment*, Vol. 113, pp. 691-701.
- Nilsson, M. (1996): "Estimation of tree heights and stand volume using an airborne lidar system". *Remote Sensing of Environment*, Vol. 56, pp. 1-7.
- Palacios-Orueta, A., Chuvieco, E., Parra, A. y Carmona-Moreno, C. (2005): "Biomass burning emissions: a review of models using Remote-Sensing data". *Environmental Monitoring and Assessment*, Vol. 104, pp. 189-209.
- Paloscia, S., Macelloni, G., Pampaloni, P. y Sigismondi, S. (1999): "The potential of C- and L-Band in estimating vegetation biomass: the ERS-1 and JERS-1 experiments". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 37, pp. 2107-2110.
- Palumbo, I., Kucera, J., Barbosa, P., O'Brien, V.W. y Valentín, R. (2006): "Using SEVIRI geostationary imagery for active fires analysis and burned biomass estimation: a case study in a Mediterranean ecosystem". En D.X. Viegas (Ed.), *Proceedings of V*

- Internacional Conference on Forest Fire Research*, Elsevier B.V., Amsterdam (CD-ROM).
- Pardo, A. y Ruiz, M.A. (2005): *Análisis de datos con SPSS 13 Base*. Mc Graw Hill, Madrid, 600 pp.
- Parra, A. (2005): *Estimación de niveles de severidad del fuego a partir de datos hiperespectrales EO-1 HYPERION*. Universidad de Alcalá, Tesis doctoral, 254 pp.
- Parresol, B.R. (1999): *Assessing tree and stand biomass: A review with examples and critical comparisons*. *Forest Science*, Vol. 45, pp. 573-593.
- Pascual, J., Ramírez, J., Fernández-Manso, A., Lahoz, J.M. y García, D (2006): "Location of optimal zones for forest residual biomass harvesting". En *Proceedings of the 7th Seminar on Remote Sensing and GIS Applications in Forest Engineering*, Curitiba (CD-Rom).
- Pascual Puigdevall, J., García Galindo, D. y García-Martín, A. (2007): "Optimum stands for forest residual biomass harvesting: development of a spatial index". En Maniatis, K., Grimm, H.P., Helm, P. y Grassi, A. (Eds.): *Proceedings of the 15th European Biomass Conference and Exhibition: From Research To Market Deployment*, ETA-Renewable Energies- WIP Renewable Energies, Florence pp.353-360 (CD-Rom).
- Pekkarinen, A. (2002): "Image segment-based spectral features in the estimation of timber volume". *Remote Sensing of Environment*, Vol. 82, pp. 349-359.
- Pellicer, F. y de la Riva, J.R. (1999): *Banco de Datos del Agua en Aragón (BADAAR)*. Departamento de Geografía y Ordenación del Territorio - Diputación General de Aragón, Zaragoza (CD-ROM).
- Peña, J.L., Pellicer, F., Julián, A., Chueca, J., Echeverría, M.T., Lozano, M.V. y Sánchez, M. (2002a): *Mapa Geomorfológico de Aragón*. Consejo de Protección de la Naturaleza de Aragón, Zaragoza, 54 pp.
- Peña, J.L., Cuadrat, J.M. y Sánchez, M. (2002b): *El clima de la provincia de Teruel*. Cartillas Turolenses, Instituto de Estudios Turolenses - Diputación Provincial de Teruel, Teruel, 91 pp.
- Perala, D.A. y Alban, D.H. (1994): *Allometric biomass estimators for aspen-dominated ecosystems in the Upper Great Lakes (NC-314)*. North Central Forest Experiment Station - U.S. Forest Service, 38 pp.
- Pérez, C. (2007): "Vivir (bien) con el petróleo a 100 dólares". En *EL PAÍS.com* – Sección de Economía (artículo publicado el 11 de noviembre de 2007). Disponible en: <http://www.elpais.com/articulo/economia/Vivir/bien/petroleo/dolares/elpepueco/2007/1111elpepieco/2/Tes>.
- Pérez-Cabello, F. (2002): *Paisajes forestales y fuego en el Prepirineo occidental oscense. Un modelo regional de re-construcción ambiental*. Consejo de Protección de la Naturaleza de Aragón, Zaragoza, 358 pp.
- Pérez-Cabello, F. (2003): *Tratamiento digital de las imágenes de satélite: realces, corrección radiométrica, extracción de parámetros físicos y transformaciones aplicadas a la imagen*. Material didáctico del Máster "Tecnologías de la información geográfica para la ordenación del territorio: Sistemas de información geográfica y Teledetección", Universidad de Zaragoza.
- Pérez-Cabello, F., de la Riva Fernández, J., Montorio Llovería, R. y García-Martín A. (2006): "Mapping erosion-sensitive areas after wildfires using fieldwork, remote

- sensing, and geographic information systems techniques on a regional scale". *Journal of Geophysical Research*, Vol. 111, G04S10.
- Persson, A., Holmgren, J. y Söderman, U. (2002): "Detecting and measuring individual trees using an airborne laser scanner". *Photogrammetric Engineering and Remote Sensing*, Vol. 68, pp. 925-932.
- Phua, M.H. y Saito, H. (2003): "Estimation of biomass of a mountainous tropical forest using Landsat TM data". *Canadian Journal of Remote Sensing*, Vol. 29, pp. 429-440.
- Phua, M.H., Tsuyuki, S., Furuya, N. y Lee, J.S. (2008): "Detecting deforestation with a spectral change detection approach using multitemporal Landsat data: A case study of Kinabalu Park, Sabah, Malaysia". *Journal of Environmental Management*, Vol. 88, pp. 784-795.
- Pierce, L.L., Running, S.W. y Riggs, G.A. (1990): "Remote detection of canopy water stress in coniferous forest using the NSOO1 Thematic Mapper simulator and the thermal infrared multispectral scanner". *Photogrammetric Engineering and Remote Sensing*, Vol. 56, pp. 579-586.
- Pilli, R., Anfodillo, T. y Carrer, M. (2006): "Towards a functional and simplified allometry for estimating forest biomass". *Forest Ecology and Management*, Vol. 237, pp. 583-593.
- Popescu, S.C. (2007): "Estimating biomass of individual pine trees using airborne lidar". *Biomass and Bioenergy*, Vol. 31, pp. 646-655.
- Popescu, S.C., Wynne, R.H. y Nelson, R.F. (2003): "Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass". *Canadian Journal of Remote Sensing*, Vol. 29, pp. 564-577.
- Porté, A., Trichet, P., Bert, D. y Loustau, D. (2002): "Allometric relationships for branch and tree woody biomass of Maritime pine (*Pinus pinaster* Ait.)". *Forest Ecology and Management*, Vol. 158, pp. 71-83.
- Pozo, D., Olmo, F.J. y Alados-Arboledas, L. (1997): "Fire detection and growth monitoring using a multitemporal technique on AVHRR mid-infrared and thermal channels". *Remote Sensing of Environment*, Vol. 60, pp. 111-120.
- Proisy, C., Coutron, P. y Fromard, F. (2007): "Predicting and mapping mangrove biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images". *Remote Sensing of Environment*, Vol. 109, pp. 379-392.
- Pu, R., Yu, Q., Gong, P. y Biging, G.S. (2005): "EO-1 Hyperion, ALI and Landsat 7 ETM+ data comparison for estimating forest crown closure and leaf area index". *International Journal of Remote Sensing*, Vol. 26, pp. 457-454.
- Puig Sales, R. (1985): *La biomasa como energía renovable. Recuperación de recursos de los residuos*. Ersa, Madrid, 200 pp.
- Pulliainen, J.T., Kurvonen, L. y Hallikainen, M.T. (1999): "Multitemporal behavior of L- and C-band SAR observations of boreal forest". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 37, pp. 927-937.
- Qi, J., Chehbouni, Al., Huete, A. R., Kerr, Y. H., y Sorooshian, S. (1994): "A modified soil adjusted vegetation index (MSAVI)". *Remote Sensing of Environment*, Vol. 48, pp. 119-126.

- Quegan, S., Le Toan, T., Yu, J.J., Ribbes, F. y Floury, N. (2000): "Multitemporal ERS SAR analysis applied to forest mapping". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 38, pp. 741-753.
- Querol, J.V. (1995): *Ecogeografía y explotación forestal en las serranías de Albarracín y Gúdar-Maestrazgo*. Consejo de Protección de la Naturaleza de Aragón, Zaragoza, 280 pp.
- Radeloff, V.C., Mladenoff, D.J. y Boyce, M.S. (1999): "Detecting Jack Pine Budworm Defoliation Using Spectral Mixture Analysis: Separating Effects from Determinants". *Remote Sensing of Environment*, Vol. 69, pp. 156-169.
- Raison, R.J. (2002): "Environmental sustainability of forest energy production". En J. Richardson, R. Björheden, P. Hakkila, A.T. Lowe, y C.T. Smith (Eds.), *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*, Forestry Sciences Vol. 71, Kluwer Academic Publishers, Dordrecht, pp. 159-263.
- Ranson, K.J. y Sun, G. (2000): "Effects of environmental conditions on boreal forest classification and biomass estimates with SAR". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 38, pp. 1242-1252.
- Ranta, T. (2005): "Logging residues from regeneration fellings for biofuel production- a GIS based availability analysis in Finland". *Biomass and Bioenergy*, Vol. 28, pp. 171-182.
- Rauste, Y. (2005): "Multi-temporal JERS SAR data in boreal forest biomass mapping". *Remote Sensing of Environment*, Vol. 97, pp. 263-275.
- Reese, H., Nilsson, M., Sandström, P. y Olsson, H. (2002): "Applications using estimates of forest parameters derived from satellite and forest inventory data". *Computers and Electronics in Agriculture*, Vol. 37, pp. 37-55.
- Riaño, D., Chuvieco, E., Salas, J. y Aguado, I. (2003): "Assessment of different topographic corrections in Landsat-TM data for mapping vegetation types". *IEEE Transactions on Geosciences and Remote Sensing*, Vol. 41, pp. 1056-1061.
- Richardson, J., Björheden, R., Hakkila, P., Lowe, A.T. y Smith C.T. (Eds.) (2002): *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*. Forestry Sciences Vol. 71, Kluwer Academic Publishers, Dordrecht, 344 pp.
- Riggs, G.A. y Running, S.W. (1991): "Detection of Canopy Water Stress in Conifers Using the Airborne Imaging Spectrometer". *Remote Sensing of Environment*, Vol. 35, pp. 51-68.
- Rivas-Martínez, S. (Coord.) (1987): *Memoria del mapa de series de vegetación de España 1:400.000*. ICONA, Madrid, 268 pp.
- Rock, B.N., Vogelmann, J.E., Willians, D.L., Vogelmann, A.F. y Hoshizaki, T. (1986): *Remote detection of forest damage*. *Bioscience*, Vol. 36, pp. 439-445. En E. Chuvieco (1996), *Fundamentos de teledetección espacial*, Rialp, Madrid, 568 pp.
- Roller, N. y Bergen, K. (2000): "Integrating data and information for effective forest management". *Journal of Forestry*, Vol. 98, pp. 61-63.
- Rondeaux, G., Steven, M. y Baret, F. (1996): "Optimization of soil-adjusted vegetation indices". *Remote Sensing of Environment*, Vol. 55, pp. 95-107.
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W. y Harlan, J.C. (1974): *Monitoring the vernal advancement of retrogradation of natural vegetation. Type III, Final Report*, NASA/GSFC, Greenbelt, 371 pp.

- Roy, P.S. y Ravan, S.A. (1996): "Biomass estimation using satellite remote sensing data. An investigation on possible approaches for natural forest". *Journal of Biosciences*, Vol. 21, pp. 535-561.
- Roy, D., Lewis, P.E. y Justice, C.O. (2002): "Burned area mapping using multi-temporal moderate spatial resolution data—a bi-directional reflectance model-based expectation approach". *Remote Sensing of Environment*, Vol. 83, pp. 263-286.
- Rubio, P. (2005a): "Presentación de Teruel". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 4-5.
- Rubio, P. (2005b): "Ganadería". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 30.
- Rubio, M. y Royo, L. (2005a): "Sector minero-energético". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 33.
- Rubio, M. y Royo, L. (2005b): "Industria". En J.A. Guillén y M.V. Lozano (Coor.), *Atlas de Teruel. Una visión práctica del territorio*, Caja Inmaculada – Proyecto REVITAL – INTERREG III B SUDOE - FEDER, Teruel, pp. 34-35.
- Ruiz de la Torre, J. (1990): *Mapa forestal de España. Escala 1:200.000. Memoria general*. ICONA, Madrid, 191 pp.
- Running, S.W., Baldocchi, D.D., Turner, D.P., Gower, S.T., Bakwin, P.S. y Hibbard, K.A. (1999): "A global terrestrial monitoring network integrating tower fluxes, flask sampling, ecosystem modeling and EOS satellite data". *Remote Sensing of Environment*, Vol. 70, pp. 108-127.
- Saatchi, S.S., Viane Soares, J. y Salas Alves, D. (1997): "Mapping deforestation and land use in amazon rainforest by using SIR-C imagery". *Remote Sensing of Environment*, Vol. 59, pp. 191-202.
- Saatchi, S.S. y Moghaddam, M. (2000): "Estimation of crown and stem water content and biomass of boreal forest using polarimetric SAR imagery". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 38, pp. 697-709.
- Salvador, R. y Pons, X. (1998a): "On the applicability of Landsat TM images to Mediterranean forest inventories". *Forest Ecology and Management*, Vol. 104, pp. 193-208.
- Salvador, R. y Pons, X. (1998b): "On the reliability of Landsat TM for estimating forest variables by regression techniques: a methodological analysis". *IEEE Transactions on Geosciences and Remote Sensing*, Vol.36, pp. 1888-1897.
- Salvador, R., Pons, X. y Baulies, X. (1997): "Análisis de imágenes mutiespectrales aerotransportadas para estimar variables estructurales de bosques mediterráneos de *Quercus ilex L*". *Orsis*, Vol. 12, pp. 127-139.
- San Miguel-Ayanz, J. (1996): "Synergy of optical and polarimetric microwave data for forest resource assessment". *International Journal of Remote Sensing*, Vol. 17, pp. 3647-3663.
- Santoro, M., Askne, J., Eriksson, L., Schmillius, C.C., Wiesmann, A. y Fransson, J. (2003): "Seasonal dynamics and stem volume retrieval in boreal forests using JERS-1 backscatter". En M. Owe, G. D'Urso y L. Toullos (Eds.), *Remote Sensing for*

- Agriculture, Ecosystems, and Hydrology IV. Proceedings of the SPIE Volume 4879*, SPIE, pp. 231-242.
- Santoro, M., Eriksson, L., Askne, J. y Schmillius, C. (2006): "Assessment of stand-wise stem volume retrieval in boreal forest from JERS-1 L-band SAR backscatter". *International Journal of Remote Sensing*, Vol. 27, pp. 3425-3454.
- Santos, J.R., Pardi Lacruz, M.S., Araujo, L.S. y Keil, M. (2002): "Savanna and tropical rainforest biomass estimation and spatialization using JERS-1 data". *International Journal of Remote Sensing*, Vol. 23, pp. 1217-1229.
- Sanz, F. y Piñeiro, G. (2003): "Aprovechamiento de la biomasa forestal producida por la cadena monte-industria. Parte I: Situación Actual y Evaluación de Sistemas de Tratamiento". *Revista CIS-Madera*, Vol.10, pp. 6-25.
- Schroeder, P., Brown, S., Mo, J., Birdsey, R. y Cieszewski, C. (1997): *Biomass estimation for temperate broadleaf forests of the US using forest inventory data*. *Forest Science*, Vol. 43, pp. 424-434.
- Sebastián, F. (1999): "Biomasa, Energía Natural". *Tercer Milenio*, Vol. 188.
- Sebastián, F. y Royo, J. (2005): "La biomasa como fuente de energías renovables". En J. Mandado, S. Martínez Cotanda y M. Moreno (Eds.), *Energía y medioambiente. II Seminario Problemática Medioambiental*, Departamento de Ciencias de la Tierra, Universidad de Zaragoza, Zaragoza, 140 pp.
- Serra, L. y Royo, J. (2005): "Cogeneración: un sistema eficiente de producción de electricidad y calor". En J. Mandado, S. Martínez Cotanda y M. Moreno (Eds.), *Energía y medioambiente. II Seminario Problemática Medioambiental*, Departamento de Ciencias de la Tierra, Universidad de Zaragoza, Zaragoza, 140 pp.
- Shimada, M., Rosenqvist, A., Watanabe, M. y Tadono, T. (2005): "The polarimetric and interferometric potencial of ALOS Palsar". En *Proceedings of the 2nd International workshop on applications of polarimetry and polarimetric interferometry (Polinsar)*. ESA-ESRIN, Frascaty.
- Shoshany, M. (2000): "Satellite remote sensing of natural Mediterranean vegetation: a review within an ecological context". *Progress in Physical Geography*, Vol. 24, pp. 153-158.
- Silva, L.C. y Barroso, I.M. (2004): *Regresión logística*. Cuadernos de estadística, La Muralla, Madrid, 173 pp.
- Steininger, M.K. (2000): "Satellite estimation of tropical secondary forest above-ground biomass: data from Brazil and Bolivia". *International Journal of Remote Sensing*, Vol. 21, pp. 1139-1157.
- Svoray, T., Shoshany, M., Curran, P.J., Foody, G.M. y Perevolotsky, A. (2001): "Relationship between green leaf biomass volumetric density and ERS-2 SAR backscatter of four vegetation formations in the semi-arid zone of Israel". *International Journal of Remote Sensing*, Vol. 22, pp. 1601-1607.
- Tansey, K.J., Luckman, A.J., Skinner, L., Balzter, H., Strozzi, T. y Wagner, W. (2004): "Classification of forest volume resources using ERS tandem coherence and JERS backscatter data". *International Journal of Remote Sensing*, Vol. 25, pp. 751-758.
- Ter-Mikaelian, M.T., Korzukhin, M.D. (1997): "Biomass equations for sixty-five North American tree species". *Forest Ecology and Management*, Vol.97, pp. 1-24.

- Thenkabail, P.S., Stucky, N., Griscom, B.W., Ashton, M.S., Diels, J., van der Meer, B. y Enclona, E. (2004): "Biomass estimations and carbon stock calculations in the oil palm plantations of African derived savannas using IKONOS data". *International Journal of Remote Sensing*, Vol. 25, pp. 5447-5472.
- Todd, S.W., Hoffer, R.M. y Milchunas, D.G. (1998): "Biomass estimation on grazed and ungrazed rangelands using spectral indices". *International Journal of Remote Sensing*, Vol. 11, pp. 95-111.
- Tomppo, E., Olsson, H., Ståhl, G., Nilsson, M., Hagner, O. y Katila, M. (2008): "Combining national forest inventory field plots and remote sensing data for forest databases". *Remote Sensing of Environment*, Vol. 112, pp. 1982-1999.
- Tomppo, E., Nilsson, M., Rosengren, M., Aalto, P. y Kennedy, P. (2002): "Simultaneous use of Landsat-TM and IRS-1C WiFS data in estimating large area tree stem volume and aboveground biomass". *Remote Sensing of Environment*, Vol. 82, pp. 156-171.
- Tottrup, C., Rasmussen, M.S., Eklundh, L. y Jönsson, P. (2007): "Mapping fractional forest cover across the highlands of mainland Southeast Asia using MODIS data and regression tree modelling". *International Journal of Remote Sensing*, Vol. 28, pp. 23-46.
- Treitz, P.M. y Howarth, P.J. (1999): "Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems". *Progress in Physical Geography*, Vol. 23, pp. 359-390.
- Treuhaft, R.N., Asner, G.P. y Law, B.E. (2003): "Structure-based forest biomass from fusion of radar and hyperspectral observations". *Geophysical Research Letters*, Vol. 30(9), 1472, doi:10.1029/2002GL016857.
- Trotter, C.M., Dymond, J.R. y Goulding, C.J. (1997): "Estimation of timber volume in a coniferous plantation forest using Landsat TM". *International Journal of Remote Sensing*, Vol. 18, pp. 2209-2223.
- Tuominen, S. y Pekkarinen, A. (2005): "Performance of different spectral and textural aerial photograph features in multi-source forest inventory". *Remote Sensing of Environment*, Vol. 94, pp. 256-268.
- Turner, B.L., Cortina Villar, S., Foster, D., Geoghegan, J., Keys, E., Klepeis, P., Lawrence, D., Macario Mendoza, P., Manson, S., Ogneva-Himmelberger, Y., Plotkin, A.B., Pérez Salicrup, D., Chowdhury, R.R., Savitsky, B., Schneider, L., Schmook, B. y Vance, C. (2001): "Deforestation in the southern Yucatán peninsular region: an integrative approach". *Forest Ecology and Management*, Vol. 154, pp. 353-370.
- Twele, A. y Erasmi, S. (2005): "Evaluating topographic correction algorithms for improved land cover discrimination in mountainous areas of central Sulawesi". En S. Erasmi, B. Cyffka, M. Kappas, (Eds.), *Remote sensing and GIS for environmental studies*, Göttinger Geographische Abhandlungen, Göttingen, Vol. 113, pp. 287-295.
- Ulaby, F.T. y Dobson, M.C. (1989): *Handbook of Radar Scattering Statistics for Terrain*. Artech House, Norwood, 357 pp.
- Van Laake, P.E. y Sánchez-Azofeifa, A. (2004): "Focus on deforestation: zooming in on hot spots in highly fragmented ecosystems in Costa Rica". *Agriculture, Ecosystems & Environment*, Vol. 102, pp. 3-15.
- Vázquez de la Cueva (2005): "Variabilidad en la respuesta espectral de tres tipos de vegetación seleccionados de parcelas del IFN-3". En Arbelo, M., González, A. y

- Pérez, J.C. (Eds.): *Teledetección. Avances en la observación de la Tierra*. Asociación Española de Teledetección, Tenerife, 113-116 pp.
- Velázquez, B. (2006): "Situación de los sistemas de aprovechamiento de los residuos forestales para su utilización energética". *Ecosistemas*, Vol. 15, pp. 77-86.
- Verbesselt, J., Van der Linden, S., Lhermitte, S., Jonckheere, I., van Aardt, J. y Coppin, P. (2006): "Monitoring vegetation water content of grasslands and forest plantations to assess forest fire risk with satellite time-series". En D.X. Viegas (Ed.), *Proceedings of V International Conference on Forest Fire Research*, Elsevier B.V., Amsterdam (CD-ROM).
- Vincini, M. y Frazzi, E. (2003): "Multitemporal evaluation of topographic normalization methods on deciduous forest TM data". *IEEE Transactions on geoscience and remote sensing*, Vol. 41, pp. 2586-2590.
- Wagner, W., Luckman, A., Vietmeier, J., Tansey, K., Balzter, H., Schmullius, C., Davidson, M., Gaveau, D., Gluck, M., Le Toan, T., Quegan, S., Shvidenko, A., Wiesmann, A. y Yu, J.J. (2003): "Large-scale mapping of boreal forest in SIBERIA using ERS tandem coherence and JERS backscatter data". *Remote Sensing of Environment*, Vol. 85, pp. 125-144.
- Wang, C. (2006): "Biomass allometric equations for 10 co-occurring tree species in Chinese temperate forests". *Forest Ecology and Management*, Vol. 222, pp. 9-16.
- Woodhouse, I.H. (2006): *Introduction to Microwave Remote Sensing*. CRC - Taylor & Francis, Boca Raton, 370 pp.
- Wooster, M.J., Zhukov, B. y Oertel, D. (2003): "Fire radiative energy for quantitative study of biomass burning: derivation from the BIRD experimental satellite and comparison to MODIS fire products". *Remote Sensing of Environment*, Vol. 86, pp. 83-107.
- Wu, X., Furby, S. y Wallace, J. (2004): "An approach for terrain illumination correction". En *Proceedings of the 12th Australasian Remote Sensing and Photogrammetry Conference*, Fremantle (CD-ROM).
- Xiao, X, Zhang, Q., Saleska, S., Hutyrá, L., De Camargo, P., Wofsy, S., Frohling, S., Boles, S., Keller, M. y Moore III, B. (2005): "Satellite-based modeling of gross primary production in a seasonally moist tropical evergreen forest". *Remote Sensing of Environment*, Vol. 94, pp. 105-122.
- Yanasse, C.C.F., Sant'Anna, S.J.S., Frery, A.C., Daleles Rennó, C., Viane Soares, J. y Luckman, A.J. (1997): "Exploratory study of the relationship between tropical forest regeneration stages and SIR-C L and C data". *Remote Sensing of Environment*, Vol. 59, pp. 180-190.
- Young, H.E., Strand, L. y Altenberger, R. (1964): "Preliminary fresh and dry weigh tables for seven tree species in Maine". En Hakkila, P. y Parikka, M. (2002): "Fuel resources from the forest". En J. Richardson, R. Björheden, P. Hakkila, A.T. Lowe, y C.T. Smith (Eds.), *Bioenergy from Sustainable Forestry: Guiding Principles and Practice*, Forestry Sciences Vol. 71, Kluwer Academic Publishers, Dordrecht, pp. 19-48.
- Zhang, Q., Pavlic, G., Chen, W., Latifovic, R., Fraser, R. y Cihlar, J. (2004): "Deriving stand age distribution in boreal forests using SPOT VEGETATION and NOAA AVHRR imagery". *Remote Sensing of Environment*, Vol. 91, pp. 405-418.
- Zheng, D., Rademacher, J., Chen, J., Crow, T., Bresee, M., Le Moine, J. y Ryu, S.R. (2004): "Estimating aboveground biomass using Landsat 7 ETM+ data across a

managed landscape in northern Wisconsin, USA". *Remote Sensing of Environment*, Vol. 93, pp. 402-411.

Zheng, D, Heath, L.S. y Ducey, M.J. (2007): "Forest biomass estimated from MODIS and FIA data in the Lake States: MN, WI and MI, USA". *Forestry*, Vol. 80, pp. 265-278.

Zianis, D. y Mencuccini, M. (2004): "On simplifying allometric analyses of forest biomass". *Forest Ecology and Management*, Vol. 187, pp. 311–332.

