

TRABAJO FIN DE MÁSTER

ESTIMACIÓN DE VARIABLES DASOMÉTRICAS A PARTIR DE DATOS LIDAR PNOA EN MASAS REGULARES DE *PINUS HALEPENSIS*, DAROCA (ZARAGOZA)

Autor: Jesús Cabrera Guarinos

***Directores: M^a Teresa Lamelas Gracia y
Juan de la Riva Fernández***

Máster Universitario en

Tecnologías de la información geográfica para la ordenación del territorio: sistemas de información geográfica y teledetección

Diciembre de 2013



**Universidad
Zaragoza**

**Departamento de Geografía
y Ordenación del Territorio**



Resumen

Este trabajo pretende evaluar la adecuación de los datos LiDAR ofrecidos por el Plan Nacional de Ortofotografía Área (PNOA) para la estimación de variables dasométricas sobre masas regulares de *Pinus halepensis*. Para ello, se ha elegido una zona piloto en los montes "Dehesa de los Enebrales" y "Valdá y Carrilanga", ubicados en el término municipal de Daroca (Zaragoza). La metodología empleada se basa en el establecimiento de modelos de regresión lineal múltiple entre las variables dasométricas, obtenidas a partir de una muestra de 61 parcelas tomadas en campo, y una colección de variables LiDAR, obtenidas de la extracción de estadísticos de la nube de puntos LiDAR de dichas parcelas. Para el establecimiento y validación de los modelos de regresión se empleó la técnica de validación cruzada dejando uno fuera (Leave-one-out cross-validation LOOCV). Los coeficientes de determinación corregidos, que indican la variabilidad explicada por cada modelo, han sido 0,867 para la estimación del volumen, 0,854 para el área basimétrica, 0,858 para la densidad y 0,799 para la altura media. Finalmente, la espacialización de los modelos establecidos ha permitido la cartografía de las variables dasométricas estimadas.

Palabras Clave: LiDAR, PNOA, inventario forestal, variables dasométricas y regresión lineal múltiple.

Abstract

*This Master Thesis evaluates the suitability of the LiDAR data provided by the National Plan for Aerial Orthophotography (PNOA) to estimate dasometric variables of even-aged stands of *Pinus halepensis*. In order to do so, a pilot area, located in "Dehesa de los Enebrales" and "Valdá y Carrilanga" woods, in Daroca municipality (Zaragoza), was chosen. The applied methodology is based on the establishment of multiple linear regression models relating dasometric variables, obtained from a sample of 61 field plots, with a collection of LiDAR variables, obtained from the statistics of the LiDAR point cloud in those plots. A leave-one-out cross-validation (LOOCV) was performed with the objective of selecting and validating the obtained models. The coefficients of determination corrected, indicating the variability explained by each model, were 0.867 for volume estimation, 0.854 for basal area, 0.858 for density and 0.799 for average height. Last but not least, the spatialization of the selected models allowed dasometric variables mapping.*

Key Words: LiDAR, PNOA, forest inventory, dasometric variables and multiple linear regression.

Índice

1.	Introducción	pág. 1
1.1.	Antecedentes	pág. 1
1.2.	Hipótesis y Objetivos.....	pág. 2
1.3.	Materiales y métodos	pág. 2
1.3.1	Área de estudio	pág. 2
1.3.2	Datos LiDAR.....	pág. 4
1.3.3	Datos de campo	pág. 11
1.3.4	Modelos predictivos	pág. 20
1.3.5	Representación cartográfica de variables modeladas .	pág. 23
2.	Desarrollo analítico: resultados	pág. 23
2.1.	Pretratamientos y extracción de estadísticos LiDAR	pág. 23
2.2.	Datos de campo.....	pág. 24
2.2.1.	Planificación del inventario de campo	pág. 24
2.2.2.	Adquisición de datos de campo.....	pág. 28
2.2.3.	Obtención de variables dasométricas	pág. 29
2.3.	Modelo de estimación del volumen	pág. 32
2.4.	Modelo de estimación del área basimétrica.....	pág. 34
2.5.	Modelo de estimación de la densidad.....	pág. 37
2.6.	Modelo de estimación de la altura media.....	pág. 39
2.7.	Representación cartográfica de variables modeladas	pág. 42
3.	Discusión	pág. 42
4.	Conclusiones	pág. 44
5.	Agradecimientos	pág. 45
6.	Bibliografía	pág. 46
7.	Anexos	pág. 48
	Anexo 1: Cartografía.	
	Anexo 2: Descripción funcional del software FUSION.	
	Anexo 3: Correlaciones entre variables de campo y LiDAR.	

1. INTRODUCCIÓN.

1.1. Antecedentes.

El conocimiento de las masas forestales es fundamental para una correcta gestión y ordenación de las mismas. En muchos casos, no basta con un inventario cualitativo del monte, sino que es necesaria una valoración cuantitativa, a través de la estimación de variables dasométricas. Tradicionalmente, esta estimación se ha realizado mediante técnicas de muestreo sistemático por parcelas. Este tipo de inventario utiliza la información recogida en una pequeña parte de la superficie (parcelas inventariadas) para la estimación de variables en la totalidad del monte, cometiendo un error asociado a esa fracción de muestreo. Para la correcta elaboración de un inventario de estas características, se requiere un muestreo piloto previo, en el que se estima la variabilidad de la masa y, en función de esta, se establecen las parcelas de inventario necesarias para alcanzar un error de muestreo determinado. Teniendo en cuenta los errores de muestreo requeridos habitualmente (Boletín Oficial de Aragón Nº 230 del 26/11/2012), el trabajo de campo demandado para no superarlos es desmesurado. A este hecho hay que sumar la situación económica actual y el cada vez menor valor de nuestros montes en términos económicos, que hace que en muchas ocasiones su gestión sea inviable, con el riesgo que ello conlleva para la persistencia de los mismos. Ante esta situación no deberíamos permanecer impasibles, siendo necesario buscar alternativas viables a los inventarios clásicos, explotando, para ello, las oportunidades que nos ofrecen las nuevas tecnologías.

A este respecto, la teledetección ofrece diferentes técnicas que pueden resultar de gran interés, entre las que destacan las imágenes satelitales ópticas, la tecnología SAR (*Synthetic Aperture Radar*) y la tecnología LiDAR (*Light Detection And Ranging*).

Las imágenes de satélite recogen información de la cubierta terrestre en múltiples longitudes de onda del espectro electromagnético, optimizando el proceso de estratificación inventarial, debido a la diferente respuesta espectral que presenta cada tipo de cubierta. Cuanto menor sea la variabilidad del estrato identificado, menor será la intensidad de muestreo del mismo y por consiguiente su coste se verá reducido (Cuevas *et al.*, 2008).

Por su parte, la tecnología LIDAR aporta una nueva perspectiva a los inventarios forestales, ya que ofrece de forma directa información tridimensional de toda la superficie a inventariar, desapareciendo la fracción de muestreo. El tratamiento de esta información mediante técnicas de muestreo en dos fases con estimador de regresión, hace posible la estimación de variables cuya medición resulta costosa, gracias a la correlación que mantienen con la información LiDAR. La primera fase de esta técnica de muestreo consiste en la obtención de las variables independientes en toda la superficie (información que ofrece el sensor). En la segunda fase se toman un número relativamente pequeño de parcelas, en las que se mide tanto la variable objetivo (dependiente), como las variables independientes, y se correlacionan en un modelo de regresión (Cochran, 1963). Esta metodología supone una notable reducción de las parcelas de muestreo o, lo que es lo mismo, una reducción de los recursos necesarios (Condés *et al.* 2013).

Por este motivo, este trabajo se centra en el estudio de la aplicabilidad de esta técnica de muestreo a las variables independientes obtenidas a partir de los datos LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA). Resulta de gran interés estudiar la idoneidad de estos datos para la estimación de parámetros dasométricos, en primer lugar, para dar valor a una información que ya ha sido capturada, y, en segundo lugar, para proponer posibles variaciones en cuanto a las características de captura de estos datos (periodicidad, densidad de pulsos, número de retornos, etc.).

Desde los últimos años de la década de los 90, diversos autores han demostrado, en numerosos artículos, la utilidad de los sensores LiDAR para la estimación de variables dasométricas. En el norte de Europa, Naesset (1997) demostró la posibilidad de establecer modelos de estimación del volumen sobre masas de pino silvestre (*Pinus sylvestris*) y abeto rojo (*Picea abies*), incluyendo como variable predictora la altura media de los retornos. Posteriormente, Naesset (2002) obtuvo resulta-

dos satisfactorios en la estimación de diferentes variables dasométricas (altura dominante, altura media, volumen, densidad de pies/ha, área basimétrica y diámetro medio) empleando, en este caso, diversos estadísticos obtenidos de la nube de puntos LiDAR. En Estados Unidos existen estudios más recientes acerca de la aplicabilidad de estos sensores activos en la estimación de biomasa (Li *et al.*, 2008) y parámetros referentes a combustibilidad de masas arbóreas (Andersen *et al.*, 2005).

Cabe destacar también, otra corriente enfocada a la estimación de parámetros dendrométricos, tanto en el norte de Europa (Hyyppä *et al.*, 1999), como en Estados Unidos (Popescu, 2007). No obstante, estos enfoques basados en la individualización de cada árbol que compone la masa forestal, requieren de una mayor densidad de pulsos LiDAR, por lo que no son aplicables a los datos utilizados en el presente trabajo, tal y como veremos con posterioridad en el apartado 1.3.2 Datos LiDAR.

En los estudios anteriormente citados, se observa que las variables dasométricas que se estiman con mayor precisión son las que tienen una estrecha relación con la altura del árbol (altura dominante, altura media, volumen, etc.), siendo peores las estimaciones para variables como la densidad de pies por hectárea o el diámetro medio cuadrático. Sin embargo, estos resultados se deben tomar con cautela, porque las singulares condiciones de nuestros sistemas forestales (muy diferentes a las masas monoespecíficas y completamente regulares del norte de Europa), así como las posibles diferencias en los sensores empleados en cada caso, pueden hacer variar la precisión de las estimaciones.

En España, las referencias a trabajos de esta temática no son tan numerosas como en el norte de Europa, pero encontramos algún estudio orientado a la estimación de biomasa empleando datos, tanto de elevación como de intensidad, de los retornos del escáner láser (García *et al.*, 2010), así como estudios que tratan de relacionar, de forma directa, la propagación de incendios forestales con la estimación de la densidad de copas a partir de datos LiDAR (Riaño *et al.*, 2004). Sin embargo, los ejemplos de estudios que hayan utilizado los datos LiDAR PNOA en el ámbito forestal son escasos (Montealegre *et al.*, 2013).

1.2. Hipótesis y objetivos.

La hipótesis de partida es que es posible estimar distintas variables dasométricas de masas forestales monoespecíficas regulares a partir de información capturada por sensores activos LiDAR. Por tanto, el objetivo principal del presente trabajo es evaluar la idoneidad de los datos LiDAR-PNOA para la estimación de distintas variables dasométricas de masas regulares de pino carrasco (*Pinus halepensis*) mediante el establecimiento de una serie de modelos predictivos.

Los objetivos secundarios se resumen en los siguientes:

- Aproximación a la zona para un mayor conocimiento de los montes objeto de estudio.
- Pretratamiento de los datos LiDAR PNOA con objeto de normalizar los valores de elevación para la extracción de estadísticos de la nube de puntos.
- Diseño y ejecución del inventario de campo para la estimación de la altura individual de cada árbol y el cálculo de variables dasométricas.
- Establecimiento de modelos predictivos que relacionen la información de variables obtenidas en campo con las estadísticas de la nube de puntos LiDAR.
- Cartografía de variables dasométricas a partir de los datos LiDAR PNOA.

1.3. Materiales y métodos.

1.3.1. Área de estudio.

El área objeto de estudio está constituida por los montes denominados “Dehesa de los Enebrales” y “Valdá y Carrilanga”. Ambos se encuentran en el término municipal de Daroca, provincia de Zaragoza (ver Figura 1 y Mapa 1: Localización, en Anexo 1), siendo la superficie total de los mismos 964 y 138 ha, respectivamente.



Figura 1. Localización del área de estudio.

Desde el punto de vista geológico, Daroca se sitúa en el sector centro-oriental de la Cordillera Ibérica, más conocido como Ibérica zaragozana, entre las sierras de Santa Cruz y Herrera, concretamente en la depresión de Calatayud-Daroca.

El monte “Dehesa de los Enebrales”, fue catalogado como de utilidad pública ya en el primer borrador del Catálogo de Montes de Utilidad Pública de la provincia de Zaragoza, elaborado en 1901 por el Distrito Forestal de Zaragoza, siéndole asignado el nº107 de dicho catálogo. Por su parte, el monte “Valdá y Carrilanga” es un monte consorciado (nº de elenco Z-3081), consorcio cuyas bases fueron aprobadas por el Patrimonio Forestal del Estado en 1955.

El monte “Dehesa de los Enebrales” y la zona denominada “Valdá”, ambos colindantes en buena parte de sus límites, conforman un monte de origen diluvial que a modo de contrafuerte se extiende al norte del río Jiloca y paralelamente al cauce del mismo. Dicho monte, presenta cuatro vertientes bien diferenciadas, partiendo todas ellas de la divisoria central del monte que va desde los 960 a los 940 metros de altitud, de Sureste a Noroeste (como la mayoría de sierras de la zona). En general, presenta un relieve erosionado, con numerosos barrancos. La pendiente aumenta conforme descendemos en cota, oscilando entre el 10% y el 40%, llegando a fuertes escarpes en las zonas bajas del monte (próximas al camino de Manchones), donde la pendiente supera el 50% y, en general, el estrato arbóreo es ralo (ver Mapa 2: Orografía, en Anexo 1).

Por su parte “Carrilanga”, separado del monte “Dehesa de los Enebrales” por la N-234, conforma una ladera de exposición solana, que parte de un rafe rocoso situado a 980 metros de altitud. Esta ladera desciende hasta la carretera N-234 y N-330, siendo su cota mínima 860 metros. El relieve es marcadamente erosionado y la pendiente oscila entre el 20 y el 40%, siendo mayor en la zona norte, próxima al rafe rocoso. En general, la elevada pendiente del terreno se ve atenuada por la presencia de pequeños bancales agrícolas abandonados, de unos 5 o 10 metros de anchura, que escalonan regularmente la ladera, permitiendo la evolución edáfica suficiente para el desarrollo de la actual masa forestal (ver Mapa 2: Orografía, en Anexo 1).

La vegetación que puebla ambos montes es principalmente una masa pura de pino carrasco (*Pinus halepensis*) procedente de repoblación.

El monte “Dehesa de los Enebrales” fue repoblado entre los años 1908 y 1920, en base al proyecto de restauración hidrológico-forestal que ordenó el Estado, con motivo de su inclusión en el Catálogo de Montes de Utilidad Pública. Así, la edad actual de la masa ronda los 100 años, haciendo que la densidad de esta sea muy variable, en función de las condiciones particulares que ha soportado cada zona (tratamientos de mejora, condicionantes bióticos, abióticos, etc.). En la tabla 1 se muestra un breve resumen de las principales variables dasométricas del monte “Dehesa de los Enebrales”, obtenido a partir de las 52 parcelas inventariadas en el mismo.

Tabla 1. Resumen de las principales variables dasométricas del monte “Dehesa de los Enebrales”. Dg: diámetro cuadrático medio; Hm: altura media; N: densidad de pies por hectárea; G: Área basimétrica; Vcc: Volumen maderable con corteza por hectárea.

Características	Media	Máximo	Mínimo	Desviación típica
Dg (cm)	31,4	49,0	23,8	4,9
Hm (m)	13,0	16,1	9,1	1,2
N (pies/ha)	336,8	806,4	14,1	162,9
G (m^2/ha)	23,5	37,3	2,7	7,2
Vcc (m^3/ha)	119,5	195,6	13,0	38,4

En el monte “Dehesa de los Enebrales”, concretamente en algunos fondos de barranco y en general en zonas donde el régimen hídrico edáfico lo permite, aparecen formaciones de frondosas como el quejigo (*Quercus faginea*) y la encina (*Quercus ilex*), que, en ocasiones, han colonizado ciertos rodales de pino carrasco, creando un sotobosque más o menos denso. Además, incluso en dicho monte encontramos una masa mixta de pino y quercíneas. El origen de dicha masa se remonta a un antiguo consorcio de repoblación (nº de elenco Z-3060), cuyas bases fueron aprobadas en 1954 por el Patrimonio Forestal del Estado, pese a ello, no se llevó a cabo hasta los años 1975-1979, cuando se repoblaron con pino las zonas donde la encina no ofrecía una cobertura del suelo suficiente, creando una masa mixta conformada por un mosaico de, en general, rodales puros de encina y de pino.

El monte “Valdá y Carrilanga”, en base a lo establecido en el consorcio que lo originó (nº de elenco Z-3081), fue repoblado durante los años 1956 y 1957, conformando actualmente una masa de unos 56 años de edad, y, por ello, más homogénea que la anterior. El resumen de las principales variables dasométricas, obtenido a partir de las 9 parcelas inventariadas en dicho monte, se muestra en la tabla 2.

Tabla 2. Resumen de las principales variables dasométricas del monte “Valdá y Carrilanga”. Dg: diámetro cuadrático medio; Hm: altura media; N: densidad de pies por hectárea; G: Área basimétrica; Vcc: Volumen maderable con corteza por hectárea.

Características	Media	Máximo	Mínimo	Desviación típica
Dg (cm)	20,8	26,0	17,7	3,0
Hm (m)	9,5	11,9	6,0	1,6
N (pies/ha)	817,4	1471,3	14,1	401,2
G (m^2/ha)	25,6	36,6	0,8	11,4
Vcc (m^3/ha)	113,7	179,4	2,1	54,0

Del área total descrita, conscientes de la limitación para estimar variables dasométricas en masas mixtas y teniendo en cuenta el objetivo del presente trabajo, se seleccionaron las masas puras de pino carrasco sin importar la presencia de sotobosque, ocupando estas un total de superficie de 750 hectáreas (ver Mapa 3: Vegetación, en Anexo 1).

1.3.2. Datos LiDAR.

Introducción al LiDAR.

El LiDAR es un sistema activo de detección remota basado en un escáner láser. Los sensores activos, son aquellos que emiten energía sobre el objeto y reciben la señal reflejada por el mismo. La base teórica del funcionamiento de un sensor LiDAR es sencilla: el sensor mide el tiempo que la luz láser emitida tarda en ir y volver a un objeto en el cual rebota (distanciómetro láser). Como las coordenadas y la dirección exacta de emisión de cada pulso láser son conocidas, el sensor calcula el espacio recorrido por cada pulso de luz y por consiguiente, la tripleta de coordenadas de cada retorno del láser en las diferentes superficies (Vosselman y Maas, 2010).

Existen diferentes clasificaciones de la tecnología LiDAR. Una de las más comunes diferencia entre las distintas plataformas empleadas para la captura de los datos: satelital, aeroportado, terrestre y terrestre móvil. El sensor empleado en la toma de datos LiDAR-PNOA es un sensor aeroportado, en el que la emisión de pulsos a una elevada frecuencia, combinado con el desplazamiento de la aeronave, permite la obtención de información tridimensional de la superficie.

Para conocer con exactitud tanto las coordenadas del sensor, como la orientación de este, y en definitiva, para poder ubicar correctamente cada tripleta de coordenadas, se hace necesaria la utilización de un GPS diferencial y un sistema de medición inercial IMU (*Inertial Measurement Unit*):

- GPS diferencial: es un tipo de receptor que además de recibir y procesar la información de los satélites, recibe y procesa, simultáneamente, otra información adicional procedente de una estación terrestre situada en un lugar cercano y reconocido por el receptor. Esta información complementaria permite corregir las inexactitudes que se puedan introducir en las señales que el receptor recibe de los satélites. En este caso, la estación terrestre transmite al receptor GPS los ajustes que es necesario realizar en todo momento, este los contrasta con su propia información y realiza las correcciones almacenando los datos con una gran exactitud.
- IMU: es un dispositivo electrónico que mide e informa acerca de la velocidad, orientación y fuerzas gravitacionales de un aparato, usando una combinación de acelerómetros y giróscopos.

La característica fundamental que hace de la tecnología LiDAR una herramienta de gran utilidad en el ámbito del inventario forestal, es la capacidad multi-retorno de un mismo pulso. Cuando el pulso láser llega al terreno, se comporta de forma diferente dependiendo de las características de los objetos que se encuentra:

- Superficie sólida: el pulso se refleja completamente y regresa al avión (1 retorno).
- Superficie de agua: el pulso láser es absorbido, por lo que no se obtiene información.
- Vegetación: generalmente el pulso emitido por el sensor genera múltiples retornos, ya que parte del pulso se refleja en el árbol (retorno 1) y el resto del pulso sigue incidiendo hasta encontrar otro obstáculo, que puede ser otra parte del árbol, matorral o el propio suelo (retorno 2, 3 y sucesivos), así hasta que la superficie que encuentre sea completamente sólida y el pulso regrese completamente al sensor (Figura 2).

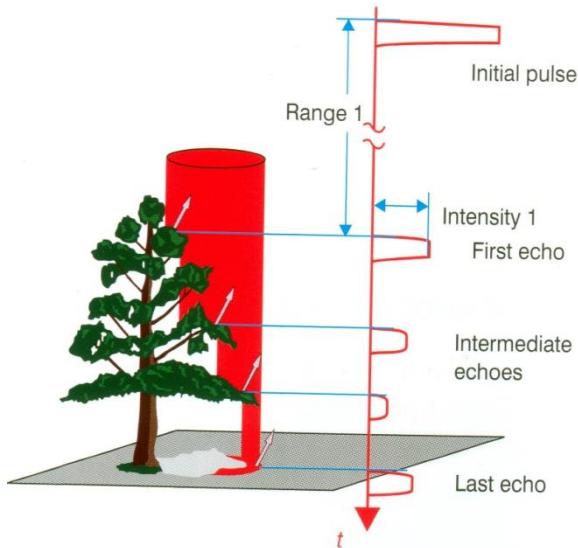


Figura 2. Múltiples retornos LiDAR cuando el pulso atraviesa un árbol (Fuente: Vosselman y Maas, 2010).

El número máximo de retornos se ve limitado, además de por la superficie objetivo, por las características del sensor.

Si el pulso láser rebotara sobre la primera superficie con la que contacta, sería imposible obtener retornos procedentes del suelo en una masa arbórea y por tanto, solo dispondríamos de un modelo digital de superficie de copas, no pudiendo conocer la altura respecto al suelo de cada retorno.

Se debe tener en cuenta que el sensor trabaja con una elevada frecuencia, por lo que es posible generar modelos de gran detalle, muy difíciles de obtener con otras tecnologías (Figura 3).

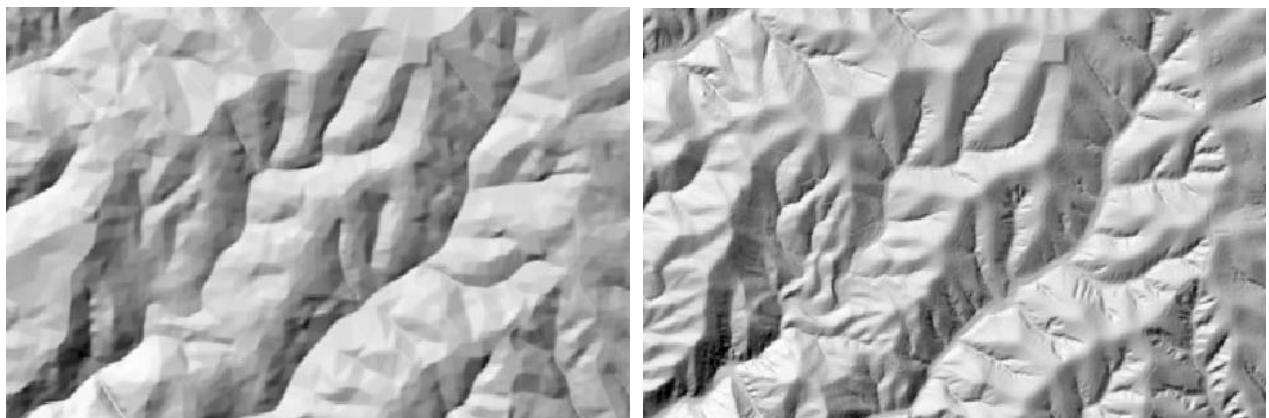


Figura 3. Izq. Modelo digital de elevaciones (MDE) del IGN, resolución 5x5 metros. Drcha. MDE del IGN elaborado con tecnología LiDAR, resolución 5x5 metros.

Descripción del vuelo y datos LiDAR.

Para el presente trabajo, como ya se ha mencionado anteriormente, se han empleado los datos LiDAR PNOA. El proyecto PNOA es una iniciativa del Instituto Geográfico Nacional (IGN) como respuesta a la directiva europea INSPIRE (*Infrastructure for Spatial Information in the European Community*). El proyecto tiene por objetivo lograr una cobertura completa, homogénea, periódica y continua de España, con ortofotografías y modelos digitales del terreno de alta resolución, para ello cuenta con el respaldo de la Administración General del Estado y de ciertas Administraciones Autonómicas. Con objeto de lograr esta cobertura digital y gracias a la colaboración entre diferentes Comunidades Autónomas y Ministerios, el IGN puso en marcha en 2009 la toma de datos LiDAR para buena parte del territorio español (Figura 4).

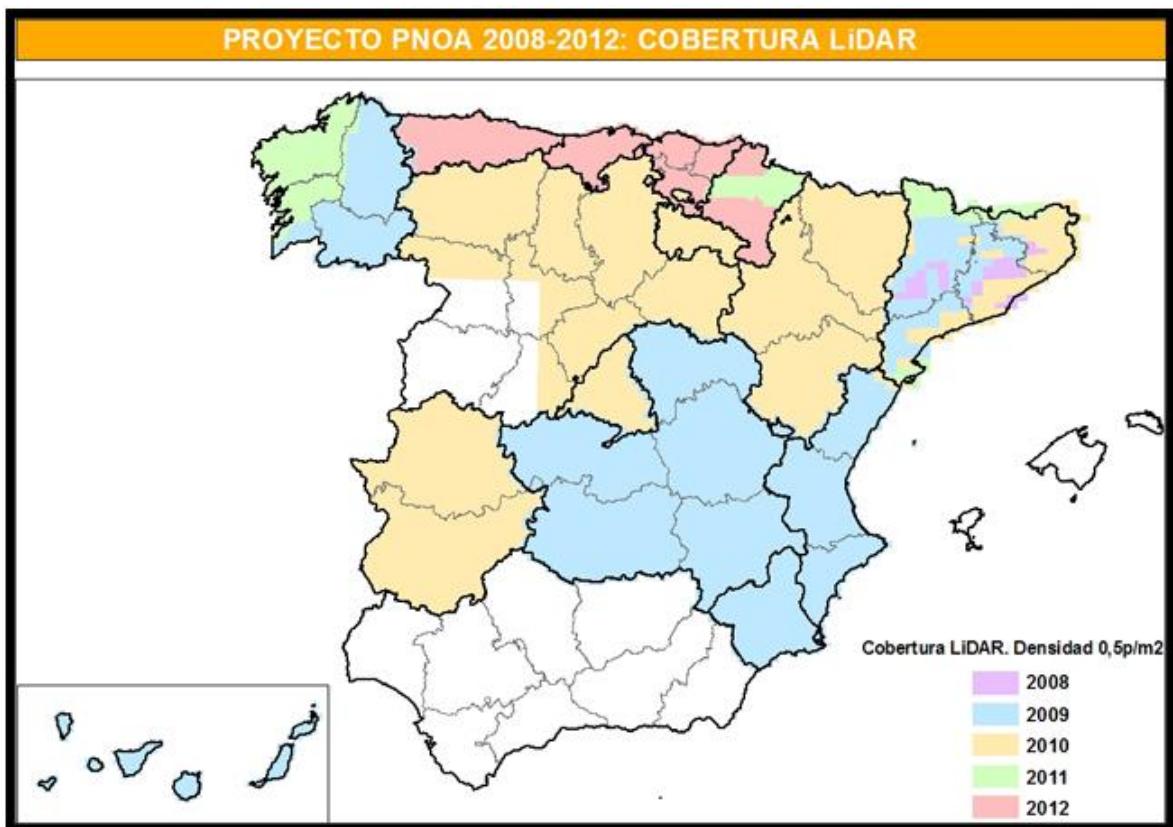


Figura 4. Coberturas LiDAR-PNOA (Fuente: http://www.ign.es/PNOA/vuelo_lidar.html).

En concreto, los datos LiDAR con los que se realizó el presente trabajo fueron tomados durante los meses de agosto y octubre del año 2010. Pese a haber cierto desfase temporal con los datos de campo (2013), este no se consideró importante, ya que, en ese intervalo de tiempo, no se han producido cambios significativos en la estructura forestal. Las únicas perturbaciones recientes, que han afectado a la zona de estudio, fueron ciertos derribos fruto de la ciclogénesis explosiva que sufrió el norte peninsular en el año 2009, luego estas variaciones se encuentran recogidas en la información capturada por el sensor.

El sensor LiDAR empleado fue un Leica ALS 50. Los datos recogidos por dicho sensor, según el IGN, deben ajustarse a las siguientes especificaciones:

- Máximo FOV permitido para planificar 50° efectivos.
 - Frecuencia de escaneado mínima de 70 Hz, debiendo alcanzar un mínimo de 40 Hz con un FOV de 50°.
 - Frecuencia de pulso de 45 kHz.
 - Densidad promedio de 0,5 puntos del primer retorno por metro cuadrado (tramos 2 km de pasada).
 - Sensor calibrado con una antigüedad menor de 12 meses.
 - Recubrimiento transversal $\geq 15\%$.
 - Longitud máxima de las pasadas 3 hojas MTN50 (Figura 5).
 - Pasadas transversales de ajuste altimétrico.
 - Precisión general altimétrica $RMSE_z \leq 0,20$ m.
 - Discrepancia altimétrica entre pasadas $\leq 0,40$ m.
 - Distancia a estaciones de referencia < 40 km.

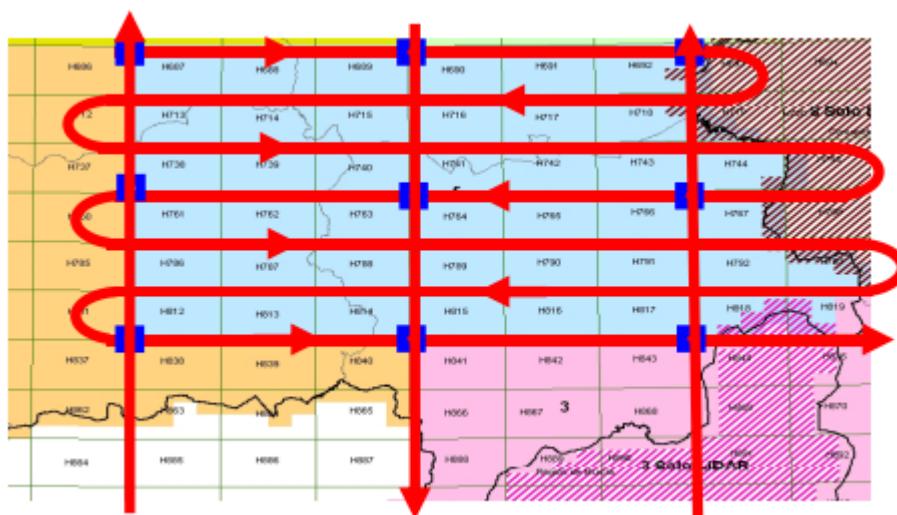


Figura 5. Ejemplo de planificación de vuelo PNOA (Fuente: Ojeda, 2011).

El resultado del vuelo se plasma en un fichero en formato “.las” de 2 x 2 km, en el que aparecen todos los retornos captados por el sensor. Estos retornos están georreferenciados según el sistema geodésico ETRS89, mediante proyección UTM, su atributo de altura se refiere a altura elipsoidal y no se encuentran clasificados. Únicamente son dos las clases que aparecen, clase “7” conformada por los puntos clasificados como ruido y clase “1” conformada por el resto de puntos.

Pretratamiento de datos LiDAR.

Estos ficheros “.las”, tal y como los proporciona el IGN, no pueden ser utilizados para la extracción de variables estadísticas. Como se ha comentado en el apartado anterior, estos ficheros contienen la totalidad de retornos, que a modo de nube de puntos, han sido recogidos por el sensor. Esta información presenta errores, ya que pueden interponerse elementos extraños impropios de la superficie terrestre y su cubierta vegetal o antrópica. Estos retornos, de en general altura muy superior a la del suelo, pueden hacer variar los estadísticos extraídos de la nube de puntos. Por otra parte, la

nube de puntos no está clasificada, por lo que no se conoce el origen de los retornos, es decir, si provienen de la superficie terrestre o de un elemento situado sobre esta. Además, la altura de cada retorno está referida al elipsoide de referencia y no a la altura sobre el suelo, que es la realmente determinante a la hora de estimar variables dasométricas.

Así pues, para corregir estas deficiencias se deben realizar los siguientes procesos:

- Extracción de retornos clase “7”, debidos a ruido.
- Clasificación de los puntos en “suelo” y “no suelo” y generación de un MDE a partir de los puntos de suelo.
- Normalización de la nube de puntos para obtener las alturas sobre el nivel del suelo y extracción de estadísticos.

Extracción de retornos clase “7”, debidos a ruido.

Primeramente, utilizando la herramienta “BCAL” del software ENVI 5.0, se seleccionaron los puntos clasificados como clase “1”, obviando los de clase “7”. Tras este proceso, teóricamente los retornos deberían ser de la superficie terrestre o de elementos situados sobre la misma.

Sin embargo, posteriormente, se observó la presencia de datos erróneos, por lo que se creyó conveniente depurarlos. Ocurría que ciertos puntos no clasificados como ruido (clase “7”), presentaban una altura sobre el suelo exageradamente elevada, del orden de cien metros. Para su depuración, se generó un ráster con la variable estadística elevación máxima de cada píxel, para poder ubicar los puntos con información aberrante (ver Mapa 4: Ruido información LiDAR, en Anexo 1). Una vez identificados, se clasificaron como clase “7” empleando ArcGIS 10.1, mediante la generación del perfil de la nube de puntos en ese píxel (Figura 6). Posteriormente se volvieron a seleccionar en ENVI 5.0 solo los puntos de clase “1”.

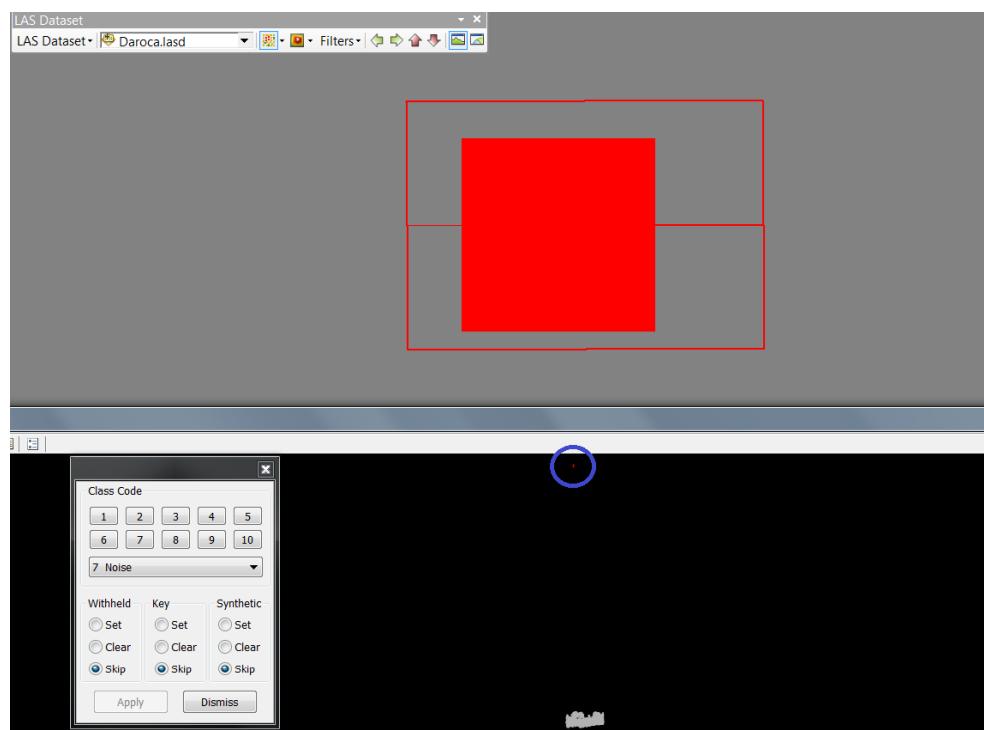


Figura 6. Inspección visual de retorno con información aberrante (círculo azul) y reclasificación del mismo.

Clasificación de los puntos en “suelo” y “no suelo” y generación de MDE a partir de los puntos de suelo.

El siguiente paso, fue la selección de los puntos reflejados por el suelo, empleando el comando “GroundFilter” del software FUSION LDV v.3.20, desarrollado por el Departamento de Agricultura y el Servicio Forestal de Estados Unidos para el estudio de los bosques. Este comando aplica un algoritmo iterativo de clasificación, adaptado de Kraus y Pfeifer (1998), que, en principio, genera

una superficie por mínimos cuadrados usando todos los puntos (surface 1). Esta primera superficie, se situará entre el verdadero suelo y el dosel arbóreo, de manera que los puntos de suelo se encontrarán bajo la misma y los puntos de vegetación sobre ella. Así, el algoritmo calcula los pesos de todos los puntos, en función de la distancia entre el punto y la superficie, según la siguiente asignación:

$$P_i = \begin{cases} 1 & v_i \leq g \\ \frac{1}{1 + (a(v_i - g)^b)} & g < v_i \leq g + w \\ 0 & g + w < v_i \end{cases}$$

Los parámetros “a” y “b” toman el valor por defecto de 1 y 4, respectivamente, ya que así se obtienen buenos resultados en la mayoría de los casos.

Variando los parámetros “g” y “w” se modifica la distancia máxima para que los puntos intervengan en el cálculo de la superficie siguiente (Figura 7). Este proceso se ejecuta en 5 ocasiones, aunque el número de iteraciones se puede variar aplicando la opción “iterations” en el comando.

Finalmente, tras realizar el número indicado de iteraciones, todos los puntos que cumplan las dos primeras condiciones son considerados de suelo. También se puede configurar la tolerancia para definir los puntos de suelo después de la última iteración (opción “tolerance”).

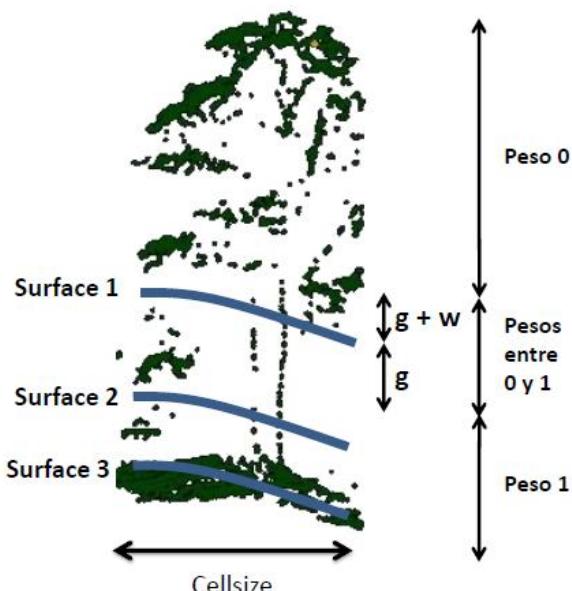


Figura 7. Asignación de pesos a cada retorno en función de valores de “g” y “w” (Fuente: Rodríguez y Fernández, 2013).

Una vez generado el archivo en formato “.lda” en el que se encuentran los puntos de suelo, se debe proceder a la generación del MDE. Para ello, se empleó el comando “GridSurfaceCreate” del software FUSION, en el que, introduciendo el archivo en formato “.lda” y un tamaño de celda de salida, se genera el MDE en formato “.dtm”.

Para asignar los valores de “g” y “w”, al no disponer de datos reales de campo con los que validar la precisión de la clasificación generada, se optó por realizar un análisis visual de los resultados en función de la presencia de rugosidades o irregularidades en los modelos de superficie generados. Para percibir con mayor detalle las irregularidades, se aplicó un sombreado al MDE mediante la herramienta “Hillshade” de ArcGIS 10.1.

Normalización de la nube de puntos para obtener las alturas sobre el nivel del suelo y extracción de estadísticos.

Tras la generación del MDE, se obtuvieron las alturas respecto al suelo de todos los retornos, proceso conocido como normalización (Figura 8). Para ello se empleó el comando “GridMetrics”, que genera un archivo “.csv” en el que figuran las variables estadísticas de cada píxel del área de estudio, es decir, las variables independientes que utilizaremos para extrapolar el modelo a toda la superficie, lo que equivale a la primera fase del muestreo en dos fases (Cochran, 1963). En este caso, el tamaño del píxel en el que se engloban los resultados fue de 25 metros, lo que equivale a una superficie de 625 m², similar a los 706,86 m² que ocupa una parcela de campo. Es importante que el tamaño del píxel para el que se calculan las estadísticas sea similar al tamaño de la parcela con la que se trabaja, para que las variables estadísticas calculadas en una y otra sean comparables. Esta afirmación es tanto más importante cuanto mayor sea la heterogeneidad del monte a escala de detalle. Si eligiéramos un tamaño menor de píxel las estadísticas tendrían mayor variabilidad y no se podrían asociar a la información obtenida en la parcela de campo.

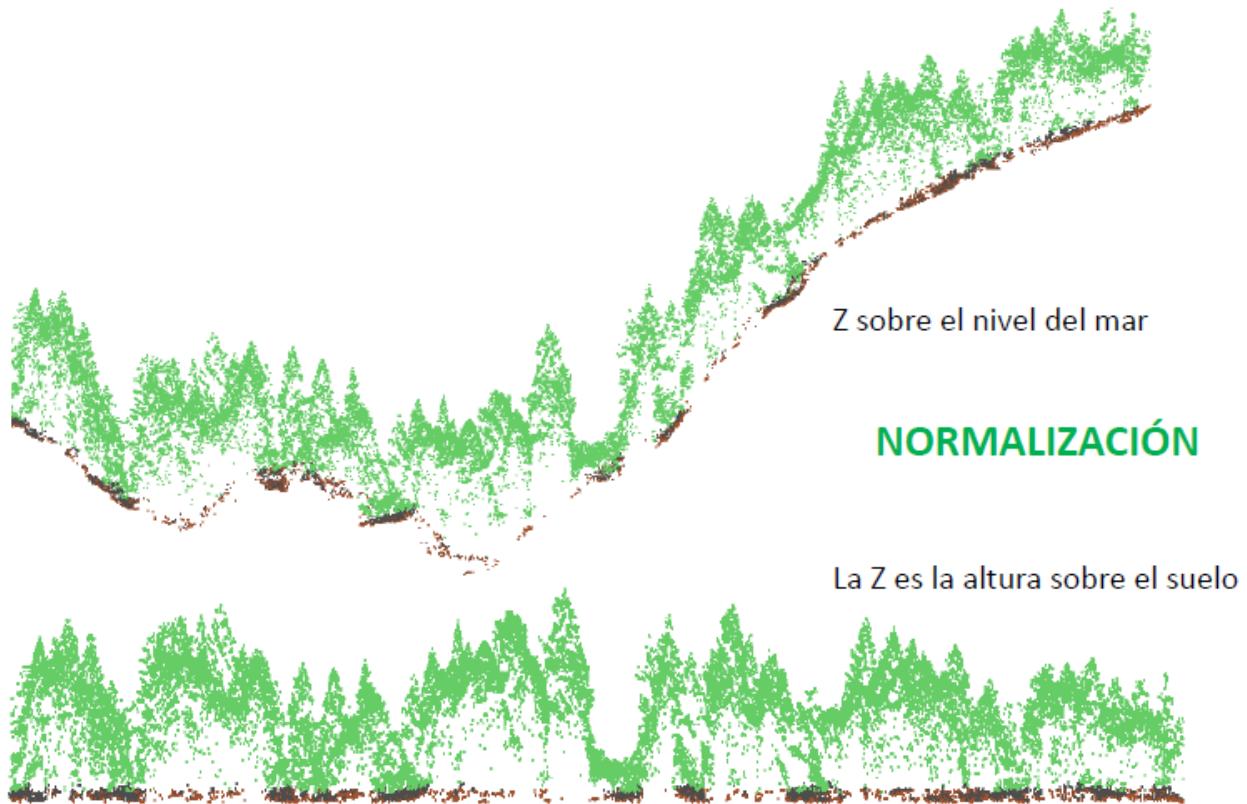


Figura 8. Normalización de la nube de puntos LiDAR (Fuente: Rodríguez y Fernández, 2013).

El fichero “.csv” generado, mediante la herramienta “AddXYData” de ArcGIS 10.1, se transformó en una capa vectorial de puntos y, posteriormente, con la herramienta “Point shapefile to raster”, se convirtió a formato raster, asignando la variable a representar y el paso de malla determinado.

Para obtener los estadísticos LiDAR de cada parcela (segunda fase del muestreo), primero, una vez inventariadas todas las parcelas, se extrajo la nube de puntos de cada una, mediante el comando “ClipData” de FUSION, comando que automáticamente normaliza la nube de puntos, incluyendo en él el MDE generado. Así, se obtiene un archivo “.las” normalizado por cada parcela muestreada. Finalmente, mediante el comando “CloudMetrics”, también de FUSION, se obtuvieron las variables independientes, extrayendo en un archivo “.csv” todos los estadísticos de cada parcela, que son los que se emplearan para el ajuste con las variables obtenidas en campo (variables dependientes).

Tanto para ejecutar el comando “CloudMetrics”, como el comando “GridMetrics”, es necesario aplicar un umbral de altura mínima. Si un determinado retorno presenta una altura normalizada menor a esta altura mínima, dicho retorno no será contabilizado en los estadísticos. En el monte “Dehesa de los Enebrales”, el umbral se estableció en 6 metros de altura y, en “Valdá y Carrilanga”,

en 3 metros. Estos valores responden a la información recopilada durante el inventario de campo, en el que se observó que el sotobosque emergente en algunos rodales del monte “Dehesa de los Enebrales” presentaba, en general, una altura inferior a 6 metros. También se advirtió de la ejecución de podas en el monte “Valdá y Carrilanga”, podas que en ningún caso superaban los 3 metros.

De no haber actuado así, los estadísticos hubiesen variado por la presencia o no de podas o sotobosque, no influyendo ninguno de estos dos factores en las variables a estimar, lo que hubiese generado errores en los modelos de estimación.

En el Anexo 2, se muestra una descripción detallada de los comando del software FUSION empleados para el pretratamiento de los datos LiDAR.

1.3.3. Datos de campo

Planificación del inventario de campo

El inventario de campo forma parte de la segunda fase del muestreo (ver apartado “1.1 Antecedentes”). El objetivo de este es cuantificar de forma precisa ciertos parámetros dasométricos (variables dependientes) sobre una pequeña fracción de la superficie total. Para ello, se inventarián, de forma precisa, cierto número de parcelas de campo, cuya ubicación debe conocerse con la mayor precisión posible. En base a la información obtenida en dichas parcelas, se ajustarán los modelos de estimación para toda la superficie, por lo que el inventario debe recoger toda la variabilidad de esta, para minimizar los errores de extrapolación. Así, la planificación del inventario consta de las siguientes fases:

- Estratificación.
- Elección del número y tamaño de las parcelas.
- Segregación de rodales no objetivo.
- Clasificación en áreas homogéneas.
- Asignación de parcelas por categorías.
- Distribución de parcelas.

Estratificación.

Una de las ventajas que presenta el inventario LiDAR, frente al clásico, es la sencilla estratificación. En el inventario tradicional, la superficie se debe dividir en estratos lo más homogéneos posibles en cuanto a especie y estructura de la masa, lo que conlleva un conocimiento previo exhaustivo de la zona, o de lo contrario unos malos resultados. Sin embargo, empleando datos LiDAR las variaciones de estructura de la masa ya entran en juego en el modelo, mediante determinados estadísticos, por lo que sólo es necesario estratificar en función de especie, ya que cada especie, debido a su diferente arquitectura, presentará una distribución diferente de los retornos.

En este caso, se va a realizar un solo estrato, ya que son masas con diferente edad y estructura, pero de la misma especie principal.

Elección del número, forma y tamaño de las parcelas.

Con el empleo de la técnica del muestreo en dos fases con estimador de regresión, el número de parcelas no depende de la variabilidad del monte ni de su superficie, sino que se determina en base a la validez estadística del modelo de estimación a generar. Universalmente, se establece que en modelos de regresión lineal, el tamaño adecuado de la muestra depende del número de variables independientes según la siguiente relación:

$$\text{Tamaño muestral} = 20 \times (\text{Nº de variables independientes})$$

En general, según estudios previos (Naesset, 2002) son tres o menos las variables predictoras empleadas, por lo que se estableció 60 como número mínimo total de parcelas.

Se eligió la forma circular por el fácil replanteo de esta, ya que para ello solo se necesita obtener la localización de un punto, el centro de la parcela.

Para la elección del tamaño de las parcelas, se tuvo en consideración la densidad del monte y la significación de los estadísticos LiDAR que se obtendría para cada parcela. Observando los valores de densidad en campo, como primera aproximación, y consultando la base de datos del Tercer Inventory Forestal Nacional (IFN3) disponibles en la página web del Ministerio de Agricultura, Alimentación y Medioambiente (<http://www.magrama.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/ifn3.aspx>) para la zona de estudio, se consideró que con un radio de 15 metros el número de pies por parcela era mayor a 15 en todo caso, considerando este valor suficiente. Además los 706,86 m² de superficie que comprende la parcela, también se consideraron suficientes para que los estadísticos LiDAR fueran significativos, ya que como mínimo incluiría unos 300 retornos (teniendo en cuenta los 0,5 pulsos/m² de densidad que se indican en las especificaciones técnicas).

Segregación de rodales no objetivo.

Para no incluir en el inventario zonas pobladas por quercíneas, se estableció un proceso de identificación y delimitación cartográfica de estas zonas. Como ya se ha comentado, estos pequeños rodales de quercíneas ocupan, en general, el fondo de algunos barrancos del monte “Dehesa de los Enebrales” y su delimitación no es sencilla.

Como solución a este problema, se planteó el uso de los propios datos LiDAR para discriminar este tipo de masas. Para ello, primero se pensó en los estadísticos LiDAR que más podrían acusar el diferente tipo de estructura de estos dos tipos de masas (quercíneas y pinares). Las masas de quercíneas en monte bajo, como es el caso del área de estudio, presentan una mayor continuidad vertical que los pinares, lo que puede traducirse en un menor coeficiente de curtosis, una mayor rango intercuartílico, un mayor coeficiente de variación, etc. Para determinar el mejor o peor ajuste de cada variable se utilizó una ortofotografía de alta resolución, perfiles de la nube de puntos LiDAR (Figura 9) y el conocimiento previo de la zona de estudio. Así, se generaron diferentes capas ráster de dichas variables mediante el comando “GridMetrics” (ver apartado 1.3.2 Datos LiDAR) y mediante un proceso empírico de ensayo/error se estudió la adecuación de estas y otras variables. Para una precisa delimitación, una vez seleccionada la variable más adecuada y sobre la capa ráster de la misma, se fotointerpretaron estos rodales, utilizando como fondo la ortofotografía, quedando recogidos en una capa vectorial (capa “quercíneas”).



Figura 9. Distribución puntos LiDAR: Izq. Encinar. Drcha. Pinar adulto.

Clasificación en áreas homogéneas.

El pequeño tamaño muestral hace que una distribución regular que vendría dada por la realización de un muestreo sistemático no asegure la representatividad de la muestra. Los modelos de estimación deben recoger toda la variabilidad que potencialmente puede presentar el área de estudio, por lo que se diseñó una categorización de la zona, en base a la cual se establecerán el número de parcelas de cada clase.

En primer lugar, se establecieron las variables que podrían derivar en un tipo de masa diferente o que afectaran a la toma de datos LiDAR, es decir variables que pudieran alterar los resultados del modelo. Así, se consideró que algunas variables como la fracción de cabida cubierta (FCC) o la

altura dominante, influyen enormemente en las variables dasométricas de una masa, y que variables como la pendiente o la presencia de sotobosque pueden influir en la precisión del MDE. En la figura 10 se observa como en la zona oeste, con elevada pendiente y presencia de sotobosque, las irregularidades son notablemente mayores que en la zona este.

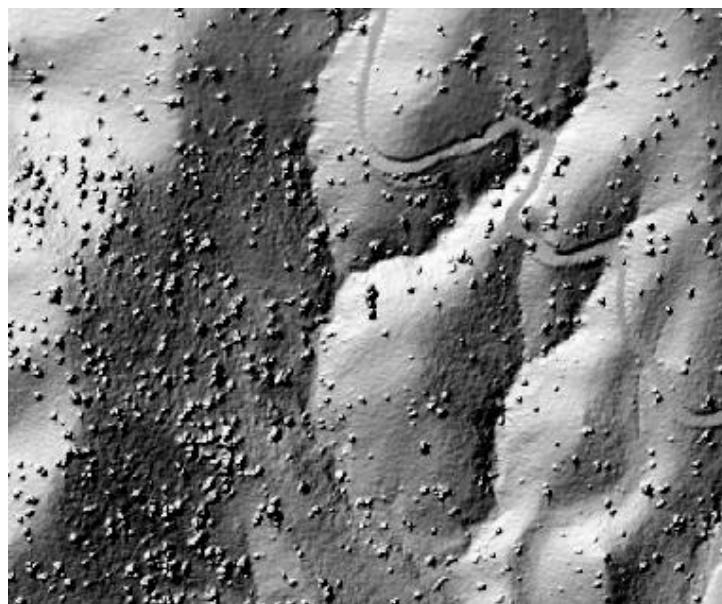


Figura 10. Sombreado del MDE.

Como no se disponía de ninguna cartografía previa de dichas variables se estudió el uso de los propios datos LiDAR para esta segmentación, seleccionando las variables más adecuadas.

Posteriormente se creó un capa ráster con cada una de estas variables y se reclasificó, mediante “Reclassify” de ArcGIS 10.1, para que cada intervalo fuese representativo de cierta superficie del monte.

Una vez obtenidas dichas capas ráster se realizó una superposición, sumándolas mediante la herramienta “Raster Calculator” de ArcGIS 10.1., de manera que cada categoría presentara una numeración única que indicase sus características. Es importante que a la hora de realizar este proceso todos los rasters presenten la misma extensión espacial y el mismo tamaño de celda, para evitar el solape de celdas que dará lugar a imprecisiones en la capa ráster final.

Asignación de parcelas por categorías.

A las capas ráster generadas, una por cada monte, se les extrajo las zonas pobladas por quercíneas, para así contar solo con las zonas de pinar. Para este paso, se crearon dos capas vectoriales con el área de interés de cada monte (capas “área de estudio”), eliminando la capa “quercíneas” de las capas vectoriales de cada monte, mediante la herramienta “Erase” de ArcGIS 10.1. Posteriormente con estas capas vectoriales se recortaron las capas ráster empleando la herramienta “Extract by Mask”.

Utilizando las capas ráster resultantes se calculó la superficie objeto de inventario de cada categoría. El número de parcelas a inventariar en cada categoría se estableció en función de la superficie ocupada por cada una.

Distribución de las parcelas.

Una vez calculado el número de parcelas de cada categoría, se seleccionó aleatoriamente la localización de cada una. Con el objeto de evitar el denominado “efecto borde” de las masas forestales, se llevó a cabo un proceso de extracción de áreas colindantes a espacios abiertos y a masas de quercíneas, para así evitar también que parte de la parcela esté ocupada por especies de este género.

El efecto borde, consecuencia de la colindancia con espacios abiertos o masas de menor altura, genera que los pies afectados por este efecto presenten un mayor diámetro que los inclusos en la

masa, debido principalmente a la mayor fracción de copa viva de los pies afectados, fruto de una mayor exposición solar.

Para eliminar este efecto, primero se obtuvieron las capas vectoriales de los elementos que podrían ocasionarlo. Así, las capas empleadas fueron: la de quercíneas (obtenida previamente en este mismo apartado, 1.3.3 Datos de campo), la de caminos y cortafuegos (obtenida del Sistema de Información Territorial de Aragón) y la de áreas ralas o desarboladas. Esta última capa, se generó a partir de la capa ráster creada en base a lo expuesto en este mismo apartado (1.3.3 Datos de campo) para la clasificación de la zona de estudio en áreas homogéneas, seleccionando las celdas que presentasen una FCC estimada menor al 20% y transformando esta selección en polígonos, utilizando la herramienta “Raster to Polygon” de ArcGIS 10.1.

Posteriormente, se generaron las áreas de influencia de las capas vectoriales empleadas para localizar el efecto borde, mediante la herramienta “Buffer”, estableciendo una distancia de 50 metros. Estas capas buffer, que representan las posibles áreas de influencia del efecto borde, se unieron mediante la herramienta “Union”, para luego extraerlas de la capa “área de estudio” mediante la herramienta “Erase”, obteniendo como resultado la capa vectorial del área a muestrear.

Finalmente, extrayendo dicha capa vectorial, mediante la herramienta “Extract by Mask”, a la capa ráster que representa la clasificación de la zona de estudio en áreas homogéneas, se obtuvieron las zonas a muestrear de cada categoría. A continuación, se crearon diversas capas vectoriales a partir de la selección de los píxeles que componen cada categoría, creando tantas capas como categorías a muestrear, empleando para ello la herramienta “Raster to Polygon”. Por último, mediante la herramienta “Create Random Points” se crearon tantos puntos aleatorios en cada capa como parcelas correspondían a cada categoría.

Como resultado se obtienen diversas capas de puntos con todas las parcelas a inventariar. El modelo cartográfico empleado para la distribución de las parcelas de campo se muestra en la figura 11:

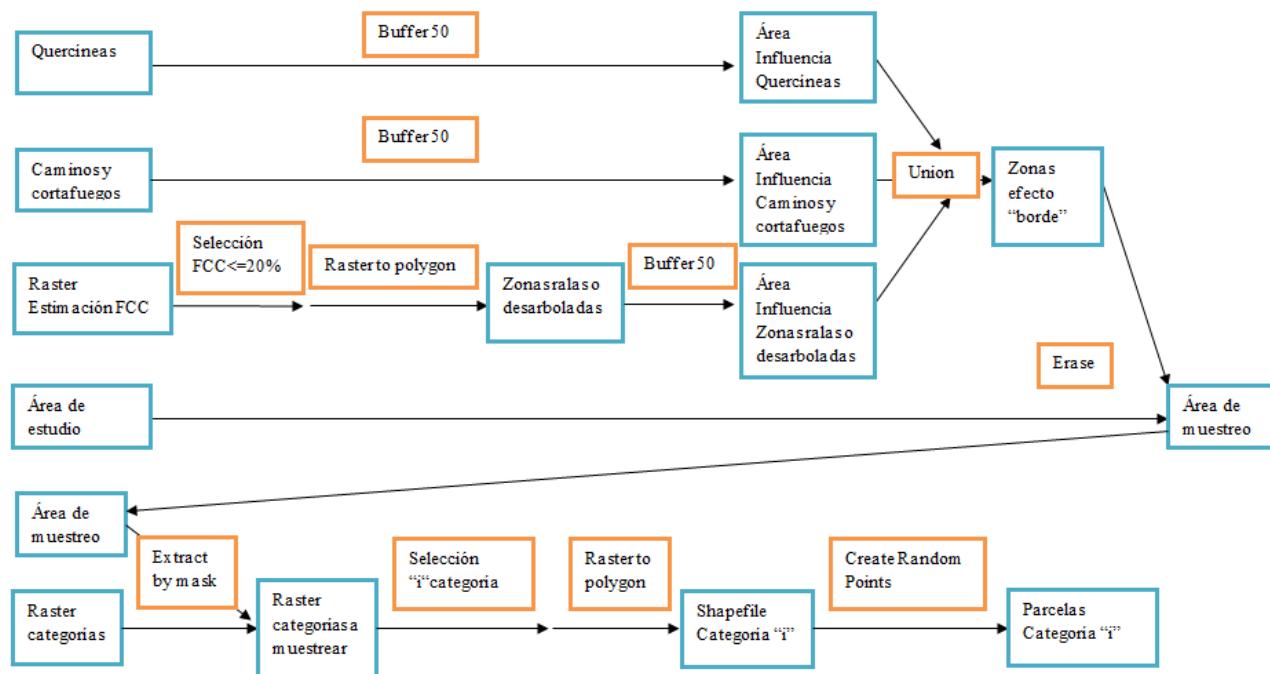


Figura 11. Modelo cartográfico empleado para la distribución de las parcelas de campo.

Adquisición de datos de campo.

La ejecución del trabajo de campo se llevó a cabo durante los meses de junio y julio de 2013. El personal encargado de su materialización fue un equipo formado por al menos dos personas, en el que al menos una de ellas tenía cierta experiencia en el empleo del material de inventario.

El material empleado fue el siguiente:

- Una cinta métrica de 25 metros de longitud.
- Dos cintas diamétricas (o métricas en su defecto).
- Dos hipsómetros Suunto.
- Cinco jalones.
- Post-its numerados y agujas.
- Estadillos de campo (Figuras 14 y 15).
- GPS de mano.
- GPS diferencial Leica.

La metodología seguida en el levantamiento de las parcelas fue la siguiente:

Primero, para realizar una primera aproximación a las parcelas, se localizaron en la cartografía generada a tal efecto (ver Mapa 6: Parcelas inventariadas, en Anexo 1), para después, mediante el GPS de mano localizarla de forma más precisa (aprox. 2-3 metros). Posteriormente, empleando un GPS-GNSS de precisión centimétrica, modelo GS15 de Leica, se tomó el punto preciso del centro de las parcelas, procurando que la precisión de la captura fuese lo mejor posible, para que los estadísticos extraídos de la nube de puntos concuerden con la posición exacta de estas.

Dependiendo de la cobertura móvil, necesaria para la realización de la corrección diferencial, y de la cobertura satelital, la precisión varía considerablemente, por lo que primó la obtención de una mayor precisión frente al replanteo del punto exacto de localización teórica de la parcela.

Con respecto al replanteo de la parcela, en primer lugar se fijó un jalón en el centro de la parcela, y haciendo uso de la cinta métrica se establecieron cuatro más en los límites de esta (radio 15 metros), distribuidos adecuadamente con el fin de evitar dudas en la inclusión de los pies más alejados.

En relación a las mediciones realizadas, se obtuvo el diámetro normal (a 1,3 metros de altura) de todos los pies de la parcela, fijando a cada uno un post-it con su número. Para facilitar y homogeneizar la medición de los diámetros normales, cada operario midió a qué parte de su cuerpo correspondían esos 1,3 metros y así siempre medir el diámetro a esa altura.

Para la medición de las alturas, al objeto de obtener una muestra significativa, se eligieron cuatro pies de forma aleatoria (árboles tipo), a ser posible un pie de cada clase diamétrica presente con mayor frecuencia en el monte (22,5-27,4; 27,5-32,4; 32,5-37,4; 37,5-42,4). Este dato previo se obtuvo tras la inspección del IFN3 (El post-it es la forma de conocer visualmente el diámetro del pie en cuestión, para facilitar la selección). A estos cuatro pies seleccionados se les midió la altura total y la altura hasta la primera rama viva, empleando para ello el hipsómetro. También se les asignó un parámetro de forma para estimar su volumen (Figura 12).

El procedimiento para obtener su altura es sencillo (Figura 13):

1. El operario, se debe colocar a la distancia que a priori más se asemeje a la altura del árbol, 15 o 20 metros en este caso (depende del hipsómetro). Se debe intentar que desde esta posición se observe tanto la copa como la base del fuste y, a ser posible, se esté en curva de nivel con el árbol.
2. Se lanza una visual al ápice del árbol y se toma la lectura que marca la intersección de la línea horizontal del hipsómetro con la escala correspondiente a la distancia elegida.
3. Se lanza otra visual a la base del árbol y se toma de la misma forma la lectura correspondiente en la escala.
4. La altura se obtendrá restando las dos medidas tomadas en la escala si las lecturas son una positiva y otra negativa, y sumándolas si son las dos positivas o negativas.

Finalmente, tomando como radio 5 metros, se contabilizaron los pies de regenerado, que, aunque no se emplearon en las estimaciones con datos LiDAR, resultan de interés para la planificación de los tratamientos forestales. Así mismo, mientras se realizaba la medición o al finalizar la misma, dependiendo del número de componentes del equipo, se recopiló información general de la parcela

como altura de poda, cubierta de sotobosque y su altura, cubierta de regenerado y sus características, presencia de daños y agentes causantes, pedregosidad y superficie erosionada y tipo de esta. Para evitar cierta subjetividad y facilitar la estimación de la cobertura de sotobosque se insertó un croquis en el estadillo.

En las figuras 14 y 15 se muestran los estadillos empleados para la recopilación de los datos de campo.

Obtención de variables dasométricas.

En base a los datos de campo obtenidos se calcularon los parámetros dasométricos de cada parcela. Los parámetros obtenidos han sido los siguientes: volumen con corteza, área basimétrica, densidad y altura media.

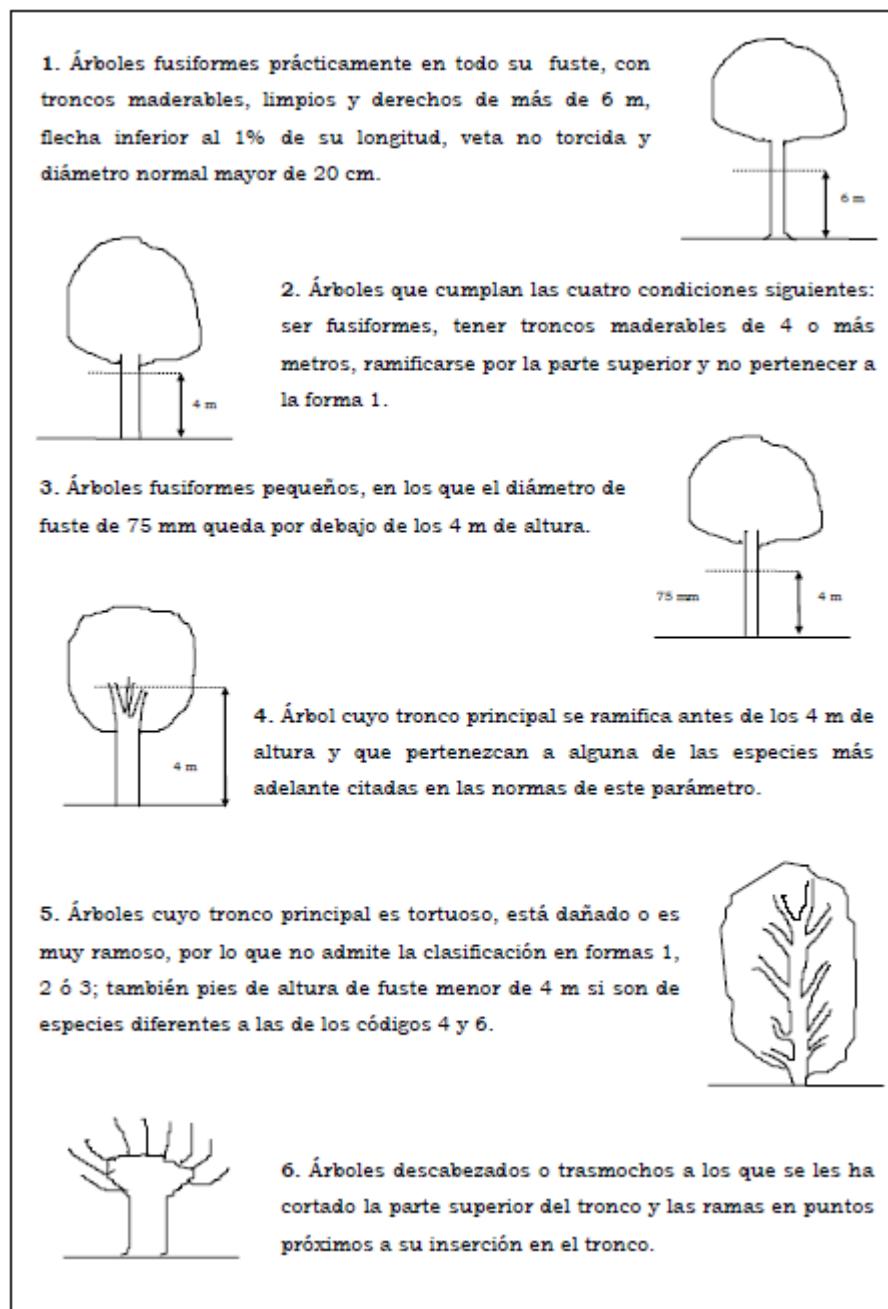


Figura 12. Parámetro de forma (Fuente: IFN3).

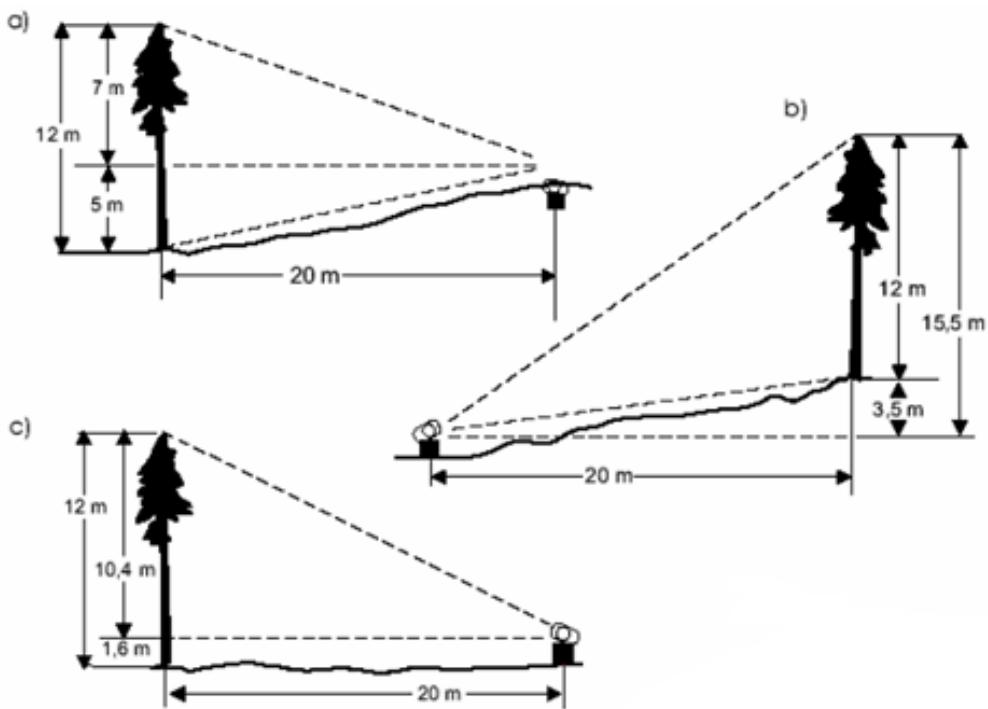


Figura 13. Cálculo de la altura del árbol (Fuente: FAO, 2004).

El volumen con corteza (m^3/ha) se refiere al volumen maderable del fuste principal, desde la base hasta el diámetro mínimo de 7,5 cm, excluidas las ramas. Para la estimación de esta variable, se ha empleado la tarifa de cubicación del IFN3 en la provincia de Zaragoza para pino carrasco. Pese a haber inventariado árboles tipo con parámetro de forma “1”, no se dispone para la especie y provincia tarifa de cubicación para estos, por lo que se aplica la generada para los de forma “2”:

$$Vcc (dm^3) = 0,00094 * (dn)^{1,9209} * (h)^{0,7264}$$

Donde:

dn: diámetro normal del árbol (mm).

h: altura del árbol (m).

Una vez obtenido el volumen de cada pie se realiza el sumatorio de todos ellos y se refiere a la hectárea, según la siguiente expresión:

$$\text{Volumen } \left(\frac{m^3}{ha} \right) = \frac{\sum Vcc_i (m^3)}{S_{parcela}} * 10.000$$

Donde:

Vcc_i : volumen con corteza de cada pie (m^3).

$S_{parcela}$: área de las parcelas inventariadas en (m^2).

Del procedimiento presentado para el cálculo del volumen, se deduce la necesidad de obtener la altura de cada árbol de la parcela, pero, tal y como se ha comentado anteriormente, este valor únicamente se midió en cuatro árboles de cada parcela, por lo que para la estimación de la altura de los árboles no medidos en campo, se ha generado un modelo predictivo generalizado, es decir incluyendo en él todos los árboles tipo inventariados (239 árboles). Este modelo trata de establecer una relación entre la altura de cada árbol (variable dependiente) y otros parámetros medidos en campo (variables independientes), como el diámetro normal o el área basimétrica. Con excepción de la variable dependiente y de las independientes, la metodología seguida para la generación del modelo predictivo es similar a la que se presenta en el siguiente apartado para la generación de mode-

los de estimación de variables dasométricas (1.3.4 Modelos predictivos) por lo que se explicará en el citado apartado.

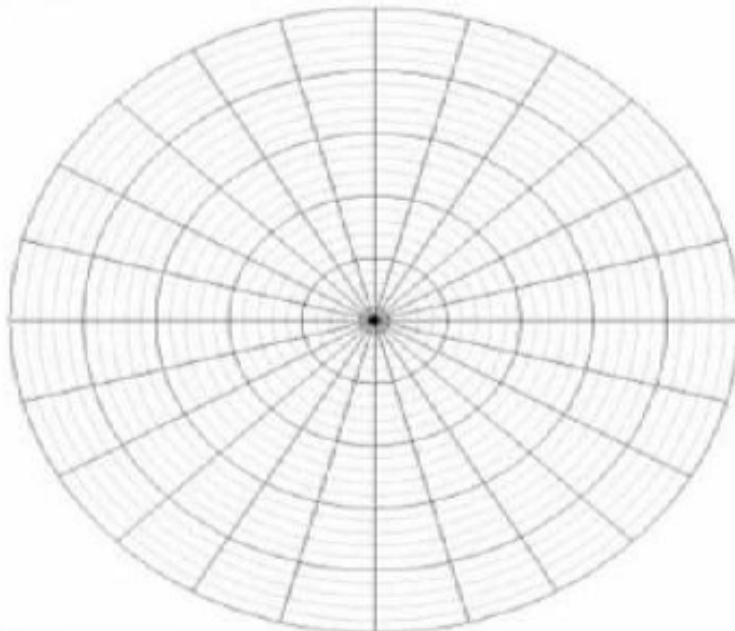


Figura 14. Cara A del estadillo de campo.

Parcela:

Nº	Pies mayores	
	Especie	Dn cm
1		
2		
3		
4		
5		
6		
7		
8		
9		
10		
11		
12		
13		
14		
15		
16		
17		
18		
19		
20		
21		
22		
23		
24		
25		

Nº	Pies mayores	
	Especie	Dn cm
26		
27		
28		
29		
30		
31		
32		
33		
34		
35		
36		
37		
38		
39		
40		
41		
42		
43		
44		
45		
46		
47		
48		
49		
50		

Arboles Tipo				
	Especie	Dn (cm)	H (m)	H 1º rama v.
1				
2				
3				
4				

Regeneración (R=5m)				
Especie	$h < 0,3\text{ m}$	$0,3 < h < 1,3\text{ m}$	$h > 1,3 \text{ y } d < 2,5\text{ cm}$	$h > 1,3 \text{ y } 2,5 < d < 7,5\text{ cm}$

Figura 15. Cara B del estadillo de campo.

El área basimétrica se obtiene sumando las secciones normales (a 1,3 metros de altura) de todos los pies de la parcela y dividiendo entre la superficie de la misma, para finalmente, extrapolarlo a una superficie de una hectárea.

$$G \left(\frac{m^2}{ha} \right) = \frac{\frac{\pi}{4} \sum dn_i^2}{S_{parcela}} * 10.000$$

Donde:

dn_i : diámetro normal de cada pie inventariado en (m).

$S_{parcela}$: Área de las parcelas inventariadas en (m^2).

La densidad, expresada en número de pies por hectárea, se calcula refiriendo a la hectárea los pies contabilizados en la parcela:

$$N \left(\frac{Pies}{ha} \right) = \frac{N_i}{S_{parcela}} * 10.000$$

Donde:

N_i : número de pies en la parcela i.

$S_{parcela}$: área de las parcelas inventariadas en (m^2).

La altura media de cada parcela, se ha obtenido realizando el promedio de las alturas individuales de cada árbol, obtenidas según el modelo de estimación de las alturas de los arboles citado en la descripción del cálculo del volumen.

1.3.4. Modelos predictivos para la estimación de variables.

Una vez obtenidas las variables dependientes, a partir de los datos de campo, y las variables independientes, en el caso de la estimación de la altura de los árboles mediante trabajo de campo, y en el caso de variables dasométricas mediante el tratamiento de los datos capturados por el sensor LiDAR, se relacionaron mediante un modelo de regresión lineal.

Para la generación de los modelos de regresión, primero se preseleccionaron las variables independientes que mejor se correlacionaban con la variable a estimar (coeficiente de correlación de “Spearman” y significación estadística). Posteriormente, estas variables se incluyeron en un proceso de selección, en el que, finalmente, se eligieron el menor número de las que aportasen más información, empleando para ello el método de selección “paso a paso” del paquete “R-Commander” del software estadístico “R”. Una vez seleccionadas las variables independientes se ajustó un modelo de regresión lineal por el método de mínimos cuadrados, empleando también el software “R”. El modelo resultante debe ser significativo, al igual que las variables independientes seleccionadas (niveles de significación del 0,05). Si alguna variable no resultase significativa al nivel establecido, o presentase cierta correlación con otra de mayor significancia, sería excluida del modelo.

Tras establecer el modelo se comprobó el cumplimiento de las hipótesis básicas que debe cumplir un modelo de regresión lineal, empleando para ello las gráficas básicas de diagnóstico del software “R”. En la figura 16 se muestran las gráficas básicas de diagnóstico, conformadas por la gráfica “Residuals vs Fitted”, que representa los residuos frente a los valores predichos; la gráfica “Normal Q-Q”, que muestra los residuos tipificados frente a los cuantiles teóricos de una distribución gausiana; la gráfica “Scale-Location”, que representa la raíz del valor absoluto del residuo frente al valor predicho, y la gráfica “Residuals vs Leverage”, que muestra los residuos tipificados frente a “leverage” (que da idea de la influencia del dato en el modelo) y la distancia de “cook” de cada dato (mostrada mediante líneas rojas discontinuas).

Cuando el diagnóstico gráfico resultó ambiguo, se recurrió a otras pruebas analíticas realizadas mediante el software estadístico “R”.

A continuación se listan las hipótesis básicas de un modelo de regresión lineal (García, 1992), así como las características gráficas y pruebas analíticas empleadas para evaluar su cumplimiento:

- Ausencia de errores de especificación: dichos errores hacen que el modelo de regresión no proporcione un buen ajuste, haciendo que las predicciones sean malas sobre todo fuera del rango de valores observados. Esto puede ser por falta de linealidad o porque existen variables explicativas relevantes que no han sido incluidas en el modelo. Este error se da cuando los parámetros que indican la bondad del ajuste (R^2 corregido, RMSE y sesgo) no son aceptables o cuando las variables predictoras carecen de significancia en el modelo. También podemos validar la relación lineal de las variables realizando el test reset de “no linealidad” o de “Ramsey”, en el que

- si el p-valor es menor de 0,05, se rechaza la hipótesis nula, luego el modelo adolece de errores de especificación, siendo más acertado establecer un modelo cuadrático o cúbico.
- Normalidad: los residuos obtenidos deben presentar una distribución normal. El cumplimiento de esta hipótesis se puede evaluar en el grafico “Normal Q-Q”, observando si los puntos no se desvían de la recta diagonal. También podemos aplicar a los residuos el test de “Shapiro-Wilk”, en el que para aceptar la hipótesis nula, es decir, la normalidad de los residuos, el p-valor debe ser mayor que 0,05.
 - Homocedasticidad: los errores presentan una varianza constante. El gráfico “Escale-Location” facilita la diagnosis de la homocedasticidad, que se cumple cuando la línea representada es horizontal y los puntos presentan una distribución homogénea, sin grandes agrupaciones. Como prueba cuantitativa se aplica el test de “Breush-Pagan”, en el que si el p-valor es inferior a 0.05, se rechaza la hipótesis nula, existiendo heterocedasticidad en el modelo.
 - Independencia: los errores en la medición de las variables explicativas son independientes entre sí. Esta hipótesis se puede verificar observando que la línea que describen los puntos en el grafico “Residuals vs Fitted” sea horizontal. Aplicando el test de “Durbin-Watson” podemos verificarlo cuantitativamente, cumpliendo la hipótesis si el resultado está entre 1 y 3, siendo 2 el valor óptimo.
 - No colinealidad: las variables regresoras son muy dependientes entre sí, y es difícil separar su contribución individual al modelo. En este caso, si una variable es dependiente de otra no tendrá significación en el modelo. Sí se da este caso, los parámetros del modelo se muestran muy inestables, presentando varianzas muy grandes. Aplicando el “factor de inflación de varianza” puede percibirse dicha colinealidad, cuando este factor supera el valor 4.
 - Ausencia de valores atípicos o heterogéneos: existen datos atípicos que se separan de la nube de datos muestrales que pueden influir en la estimación del modelo de regresión o que no se ajustan al modelo. Realizando el test “Bonferroni”, se pueden detectar dichos valores atípicos, y observando el grafico “Residuals vs Leverage” se puede apreciar si estos puntos presentan una distancia de “Cook” inferior a 1, lo que significará que ninguno de ellos resulta influyente en la estimación del modelo.

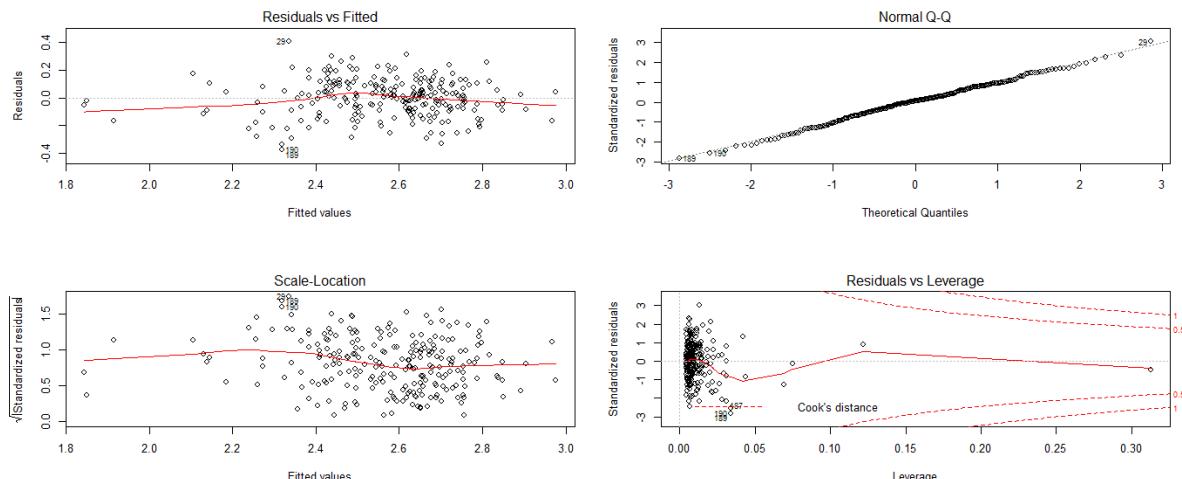


Figura 16. Graficas básicas de diagnóstico.

Se estudió la idoneidad tanto de las variables originales como de nuevas variables generadas mediante la transformación logarítmica de estas. En ocasiones, esta transformación de variables resulta útil para el cumplimiento de las hipótesis básicas de los modelos lineales. Además, en ciertos casos, las relaciones que se establecen entre la variable dependiente y las independientes no son lineales, pero realizando este tipo de transformaciones podemos ajustarlas adecuadamente mediante regresión lineal (Naesset, 2002):

- Si la relación entre variables es exponencial, se puede solucionar mediante regresión lineal aplicando el logaritmo natural a la variable dependiente. El modelo lineal generado, aplicando

la transformación logarítmica inversa (conversión exponencial), será equivalente a un modelo exponencial, en el que intervienen las variables originales:

$$\ln(Y) = \ln(a) + bX \leftrightarrow Y = a * e^{b*X}$$

- Si la relación entre variables es potencial, se puede solucionar mediante regresión lineal aplicando el logaritmo natural a todas las variables. El modelo lineal generado, aplicando la transformación logarítmica inversa, será equivalente a un modelo potencial, en el que intervienen las variables originales:

$$\ln(Y) = \ln(a) + b \ln(X) \leftrightarrow Y = a * X^b$$

En ambos casos, la transformación logarítmica inversa introduce un sesgo (subestimación) en el modelo, ya que el error aditivo, generado en el modelo lineal, se convierte en multiplicativo al aplicar dicha transformación (Baskerville, 1972). Para la eliminación de este sesgo, el resultado final debe ser multiplicado por un factor de corrección (FC), calculado a partir del error estándar de estimación (SEE), según la siguiente expresión (Sprugel, 1983):

$$FC = e^{\frac{SEE^2}{2}}$$

Donde:

$$SEE = \sqrt{\frac{\sum (\ln Y_i - \bar{\ln Y}_i)^2}{N - K - 1}}$$

Siendo "N" el tamaño de la muestra, K el número de parámetros del modelo, $\ln Y_i$ el valor observado y $\bar{\ln Y}$ el valor predicho por el modelo.

De entre los modelos establecidos que cumplen las citadas hipótesis básicas, se seleccionó el modelo óptimo, comparando para ello los estadísticos que indican la bondad del ajuste: el coeficiente de determinación ajustado (R^2 corregido) y la media (sesgo) y la raíz de la media cuadrática de los errores (RMSE). El sesgo evalúa la desviación del modelo respecto a los valores observados, el RMSE analiza la precisión de las estimaciones y el R^2 corregido determina la variabilidad total que es explicada por el modelo, teniendo en cuenta el número de variables. Se debe tener en cuenta que, en modelos cuyas variables han sido transformadas logarítmicamente tanto el sesgo, como el RMSE, no están en las mismas unidades que la variable a estimar, por lo que para hacer comparables estos valores se deben recalcular una vez aplicada la transformación logarítmica inversa al modelo.

Finalmente, debido a que la bondad del ajuste no refleja necesariamente la bondad de una predicción futura (Myers, 1990), es recomendable, para analizar la capacidad predictiva del modelo, realizar una validación del mismo con un conjunto independiente de datos (Kozak y Kozak, 2003). En este caso sólo se dispone de los datos de campo empleados para el ajuste, por lo que se ha realizado para ello un proceso de validación cruzada dejando uno fuera (*Leave-one-out cross-validation LOOCV*), mediante el software estadístico "R". Este procedimiento consiste en extraer en cada iteración una parcela del conjunto muestral, ajustar el modelo (con las mismas variables independientes) y evaluar la estimación en la parcela extraída. Este proceso iterativo se repite tantas veces como parcelas se han tomado, comparando el valor estimado con el valor real, obteniendo así el error cometido en cada una, comparando el sesgo, la RMSE y la media de los R^2 corregidos, con los obtenidos empleando la totalidad de la muestra, se puede validar la capacidad predictiva del modelo. Si dichos parámetros son similares, se descarta el sobreajuste del modelo a los datos de entrenamiento, siendo este útil para fines predictivos. En el caso de modelos con variables transformadas, su validación se realizó manteniendo su forma lineal, sin realizar la transformación logarítmica inversa descrita anteriormente. Una vez validado el modelo, se obtuvieron los coeficientes aplicables a cada variable, realizando para ello la media aritmética de los resultantes en cada iteración.

1.3.5. Representación cartográfica de variables modeladas.

Con los modelos de estimación de variables dasométricas calculados, es posible representar gráficamente sus estimaciones. El método más sencillo, y que menos resultados intermedios genera, consiste en crear un fichero “.csv” con los estadísticos que intervienen en los modelos, empleando para ello el comando “GridMetrics” del software FUSION, para posteriormente convertir este fichero en una capa vectorial de puntos, mediante la herramienta “AddXYData” de ArcGIS 10.1 (ver apartado 1.3.2 Datos LiDAR), y, mediante la calculadora de campos “Field calculator”, aplicar, en un nuevo campo, la ecuación que establece el modelo. Finalmente, empleando la herramienta “Point to raster” generaremos la capa continua que representa la variable dasométrica estimada.

2. DESARROLLO ANALÍTICO: RESULTADOS.

2.1. Pretratamientos y extracción de estadísticos LiDAR.

Los valores de “g” y “w”, empleados en la fase de selección de los puntos de “suelo”, que mejor resultado ofrecen para el área de estudio son -2,5 y 2 respectivamente. En la figura 17 se puede observar el MDE generado con estos parámetros y compararlo con otro MDE generado en el proceso de ensayo/error.

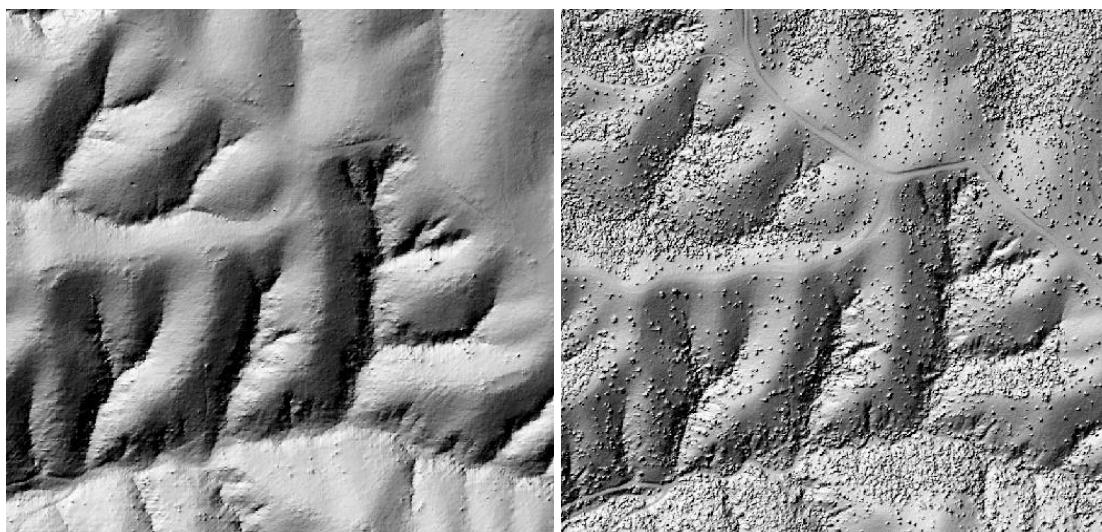


Figura 17. Detalle de algunos sombreados de los MDE generados: Izq. “ g =-2,5 y “ w =2. Dch. “ g =-2 y “ w =2,5.

En general, aumentando el valor de “w”, se incrementaban las irregularidades, y disminuyendo el valor de “g”, el número de puntos clasificados como suelo se veía notablemente disminuido.

Para la generación del MDE, necesario para la normalización de la nube de puntos, se empleó un tamaño de celda de 1 metro, ya que, pese a no disponer de información en todas las celdas, empleando un tamaño mayor (2 o 3 metros) las irregularidades del modelo debidas a una errónea clasificación eran mayores. Esta situación se daba en zonas donde la gran espesura arbórea y arbustiva hace que los retornos de suelo captados por el sensor sean escasos. Además, el problema de no disponer de información en algunas celdas (densidad media de 0,5 pulsos por m^2) se ve corregido por la interpolación con celdas vecinas que realiza el algoritmo en estos casos.

En la tabla 3, se muestra el resumen de los estadísticos LiDAR extraídos para el total de las parcelas inventariadas. De los estadísticos que ofrece el software FUSION se han obviado los no normalizados, como el número total de retornos, el número de primeros retornos, el número de retornos por encima de cierta altura, etc. El solape que se produce entre dos vuelos genera zonas con una mayor densidad de datos, por lo que no es adecuado comparar variables no normalizadas. Se puede observar que los estadísticos cubren un amplio rango de valores, lo que da idea del correcto diseño del inventario de campo, ya que en él se recoge gran parte de la variabilidad presente en la zona de estudio.

Tabla 3. Resumen de los estadísticos LiDAR en las parcelas inventariadas.

Estadísticos	Media	Máximo	Mínimo	Desviación típica
Mínimo	5,87	8,25	3,03	1,21
Máximo	14,49	20,07	5,09	2,66
Media	10,43	13,51	3,66	2,03
Moda	10,43	13,72	3,03	2,25
Desviación estándar	1,79	2,70	0,70	0,40
Varianza	3,37	7,30	0,49	1,44
Coef. variación	0,17	0,27	0,11	0,03
Rango intercuartílico	2,45	3,63	0,88	0,59
Asimetría	-0,22	0,99	-0,92	0,35
kurtosis	2,74	3,81	1,82	0,43
AAD	1,44	2,21	0,55	0,32
Percentil 01	6,35	9,99	3,03	1,33
Percentil 05	7,31	11,18	3,04	1,55
Percentil 10	7,98	11,69	3,05	1,71
Percentil 20	8,90	12,21	3,07	1,89
Percentil 25	9,25	12,47	3,09	1,94
Percentil 30	9,56	12,68	3,11	1,98
Percentil 40	10,07	13,15	3,22	2,02
Percentil 50	10,54	13,66	3,42	2,09
Percentil 60	11,01	14,21	3,68	2,15
Percentil 70	11,46	14,75	3,90	2,21
Percentil 75	11,70	15,09	3,98	2,24
Percentil 80	11,98	15,49	4,05	2,29
Percentil 90	12,65	16,13	4,77	2,34
Percentil 95	13,19	17,38	5,07	2,48
Percentil 99	13,98	19,44	5,08	2,63
Porcentaje de primeros retornos por encima de 3 ó 6 metros	64,04	93,63	4,34	19,45
Porcentaje de retornos por encima de 3 ó 6 metros	48,55	70,58	4,33	13,03
Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos	64,80	95,75	4,34	19,74
Porcentaje de primeros retornos por encima de la media	33,99	52,17	1,86	10,56
Porcentaje de primeros retornos por encima de la moda	32,49	62,44	4,03	11,90
Porcentaje de retornos por encima de la media	25,48	39,81	1,85	7,04
Porcentaje de retornos por encima de la moda	24,51	43,04	4,02	8,41
Porcentaje de retornos por encima de la media respecto del total de primeros retornos	34,00	52,17	1,86	10,56
Porcentaje de retornos por encima de la moda respecto del total de primeros retornos	32,51	62,56	4,03	11,91

2.2. Datos de campo.

2.2.1. Panificación del inventario de campo.

Para la identificación de los rodales de quercíneas se optó por la utilización del Percentil 95 de la altura (P95). La adecuación de esta variable es debida a que estas masas de quercíneas presentan una menor altura que los pinares (pinares adultos de unos 100 años de edad), por lo que estable-

ciendo un límite de 9,5 metros en la variable P95 se discriminaban perfectamente estos dos tipos de masa.

Las variables empleadas para la clasificación en áreas homogéneas de la zona de estudio fueron las siguientes:

- Porcentaje de primeros retornos por encima de una determinada altura respecto del total de primeros retornos: como estimación de la FCC a cierta altura (Hopkinson y Chasmer, 2009).
 - Para el monte “Dehesa de los Enebrales” se consideró una altura de 6 metros para el cálculo de este porcentaje, para así no considerar la posible presencia de sotobosque
 - Para el monte “Valdá y Carrilanga” se consideró una altura de 3 metros para el cálculo de este porcentaje, para que así no influya la ejecución de podas.
- P95: como estimación de determinada altura de la masa, que da idea de la calidad de estación a igualdad de edad.
- Pendiente: obtenida del MDE generado con los propios datos LiDAR.
- Porcentaje de retornos entre 1,5 y 6 metros respecto del total: para estimar la presencia de sotobosque.

Estas variables, una vez convertidas en capas ráster, y para lograr que cada intervalo fuese representativo de cierta superficie del monte, se reclasificaron del siguiente modo:

- Porcentaje de primeros retornos por encima de 6 o 3 metros (en función del monte) respecto del total de primeros retornos:
 - Clase 1.000: $\leq 20\%$ (arbolado ralo o desarbolado).
 - Clase 2.000: $20\% < x \leq 40\%$ (densidad baja).
 - Clase 3.000: $40\% < x \leq 70\%$ (densidad media).
 - Clase 4.000: $> 70\%$ (densidad alta).
- P95^{*}:
 - “Dehesa de los Enebrales”:
 - Clase 100: ≤ 15 metros.
 - Clase 200: > 15 metros.
 - “Valdá y Carrilanga”:
 - Clase 100: $\leq 9,5$ metros.
 - Clase 200: $> 9,5$ metros.
- Pendiente:
 - Clase 10: $\leq 20\%$.
 - Clase 20: $20\% < x \leq 40\%$.
 - Clase 30: $> 40\%$.
- Porcentaje de retornos entre 1,5 y 6 metros respecto al total^{**}:
 - Clase 1: $\leq 15\%$ (ausencia de sotobosque).
 - Clase 2: $> 15\%$ (presencia de sotobosque).

*La reclasificación del P95 es diferente dependiendo del monte, ya que son de edad marcadamente diferenciada y por ello también de altura diferente.

**Este último parámetro sólo se tiene en cuenta en el monte “Dehesa de los Enebrales”, ya que en “Valdá y Carrilanga” no hay sotobosque (ver apartado 1.3.1 Área de estudio). La determinación del nivel crítico de 15% se ha establecido, al igual que la selección y reclasificación de las variables empleadas para la segregación en áreas homogéneas, mediante un proceso empírico de ensayo/error empleando el conocimiento previo de la zona y los perfiles de la nube de puntos LiDAR (Figuras 18 y 19). Obviamente, esta cifra crítica sólo es aplicable al área de estudio en cuestión, igual que la establecida para delimitar rodales de quercíneas.

El resultado de la suma de las capas reclasificadas son dos capas ráster (una por cada monte) en las que el valor de cada celda indica las características de esta: las unidades revelan la presencia o no de sotobosque, las decenas la pendiente media, las centenas la calidad de estación y las unidades de millar la FCC. En el Mapa 5: Áreas homogéneas del Anexo 1, se presenta la localización de las categorías, para ilustrar la gran variedad y heterogeneidad existente en la zona respecto a las varia-

bles de categorización utilizadas. Aunque la calidad de representación no es buena y la interpretación de este mapa es realmente difícil, debido al excesivo número de categorías resultantes, se debe tener en cuenta, que la utilidad de estas capas ráster de categorías no reside en la visualización y ubicación de cada categoría, sino en la obtención de la superficie de cada una, a fin de lograr un muestreo del área de estudio lo más representativo posible.



Figura 18. Perfil de la nube de puntos en rodal con sotobosque.



Figura 19. Perfil de la nube de puntos en rodal sin sotobosque.

Finalmente, tras obtener el área de cada categoría, se asignó el número de parcelas a inventariar en cada una (Tabla 4 y Tabla 5). A las categorías “arbolado ralo o desarbolado” (unidades de millar 1) solo se les asignaron dos parcelas, una en cada monte, debido a su escasa aportación en cuanto a recursos forestales.

En el Mapa 6: Parcelas inventariadas del Anexo 1, se muestra la ubicación final de las parcelas de campo, en el que se puede observar su distribución aleatoria, no mostrando ningún patrón específico. También se observa como en el tercio sur del área de estudio, donde la pendiente es elevada y el estrato arbóreo es ralo, encontramos un menor número de parcelas, ya que como se ha comentado, a estas tipologías de masa solo se les han asignado dos parcelas.

Tabla 4. Superficie y número de parcelas por categoría, “Dehesa de los Enebrales”.

Categoría	Superficie (ha)	Nº parcelas
1.xxx	83,3	1
3.121	70,9	7
3.122	43,8	4
3.132	40,3	4
3.131	31,2	3
3.111	30,8	3
3.221	30,1	3
4.121	29,6	3
2.132	28,3	3
3.231	27,4	3
2.122	21,4	2
3.112	18,3	2
2.121	16,6	2
4.111	15,0	1
3.232	12,3	1
4.221	12,1	1
2.111	11,6	1
2.131	10,3	1
2.112	10,1	1
3.222	10,0	1
4.122	9,8	1
4.131	7,5	1
4.132	6,9	1
4.231	6,6	1
3.211	6,6	1
3.212	5,2	0
4.112	4,0	0
2.231	3,9	0
4.232	3,7	0
2.221	3,6	0
2.232	3,6	0
4.211	3,1	0
4.222	2,9	0
2.222	2,8	0
2.211	1,3	0
2.212	1,1	0
4.212	0,6	0
Total	626,3	52

Tabla 5. Superficie y número de parcelas por categoría, “Valdá y Carrilanga”.

Categoría	Superficie (ha)	Nº parcelas
1.xx0	42,9	1
3.220	11,8	1
4.220	8,9	1
2.120	8,3	1
3.120	7,8	1
3.230	7,1	1
2.130	4,9	1
4.210	4,7	1

Categoría	Superficie (ha)	Nº parcelas
3.210	4,7	1
2.220	3,9	0
2.110	3,8	0
2.230	3,8	0
3.110	3,6	0
3.130	2,8	0
2.210	1,8	0
4.230	1,7	0
4.120	0,6	0
4.110	0,2	0
4.130	0,1	0
Total	123,1	9

2.2.2. Adquisición de datos de campo.

El número total de parcelas inventariadas fue 61, lo que equivale a una fracción de muestreo de 0,58%. La precisión obtenida en la ubicación de las parcelas se muestra en la tabla 6, en la que se observa que el 95% de los puntos presenta una precisión submétrica.

Tabla 6. Precisión planimetría obtenida en la ubicación de las parcelas.

Parcela	Precisión planimetría (m)	Parcela	Precisión planimetría (m)
1	1,004	32	0,157
2	0,093	33	0,109
3	0,444	34	0,116
4	0,487	35	0,276
5	4,053	36	0,091
6	0,630	37	0,021
7	0,587	38	0,178
8	0,128	39	0,583
9	0,137	40	0,150
10	0,396	41	0,101
11	0,108	42	0,100
12	0,207	43	0,120
13	0,129	44	0,103
14	0,597	45	0,108
15	0,506	46	0,124
16	0,427	47	0,008
17	0,168	48	0,030
18	0,190	49	0,223
19	0,454	50	0,002
20	0,115	51	0,117
21	0,082	52	0,102
22	1,107	53	0,031
23	0,152	54	0,009
24	0,693	55	0,116
25	0,204	56	0,014
26	0,029	57	0,084
27	0,019	58	0,108
28	0,033	59	0,128
29	0,623	60	0,364
30	0,142	61	0,428
31	0,032		

La información recopilada en este apartado se empleó para el cálculo de las variables dasométricas: volumen con corteza, área basimétrica, densidad y altura media (ver apartado siguiente 2.2.3. Obtención de variables dasométricas).

2.2.3. Obtención de variables dasométricas.

Para construir el modelo de estimación de la altura de cada árbol, en primer lugar se incluyó únicamente el diámetro normal (dn) medido en campo, estableciéndose dos modelos (modelo 1 y 2). Posteriormente, debido a los bajos coeficientes de correlación obtenidos, se probó a introducir variables de masa, ya que según la literatura consultada, en general mejoran los resultados del modelo (Diéguez-Aranda et al., 2005). Disponíamos pues del área basimétrica de cada parcela (G), variable que se introdujo en los nuevos modelos (modelos 3, 4 y 5). Finalmente, se comprobó que el modelo se ajustaba mejor a los datos utilizando como variables los logaritmos naturales de estas, ya que el parámetro R^2 corregido pasaba de 0,555 a 0,628. En la tabla 7 se muestran las características tenidas en cuenta para la elección del modelo:

Tabla 7. Resumen de los modelos analizados para la estimación de la altura.

Nº	Variable dependiente	Variables independientes	Hipótesis básicas	R^2 corregido	RMSE	Sesgo
1	H	Dn	Sí	0,482	1,932	0,00
2	Ln(H)	Dn	No (normalidad)	-	-	-
3	H	Dn, G	Sí	0,555	1,786	0,00
4	Ln(H)	Dn, G	No (homocedasticidad)	-	-	-
5	Ln(H)	Ln(Dn), Ln(G)	Sí	0,628	1,736*	-0,01*

*Calculados tras aplicar la transformación logarítmica inversa.

En la figura 20 se muestra el resumen del modelo seleccionado (modelo “5”), obtenido del programa estadístico “R”. Se puede observar que tanto el modelo como las variables explicativas, son significativas.

```

Residuals:
    Min      1Q   Median      3Q     Max 
-0.37359 -0.08563  0.00734  0.09354  0.40524 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -0.25377   0.14474 -1.753   0.0809 .  
LN_Dn        0.65986   0.03387 19.483 < 2e-16 *** 
LN_G         0.17894   0.02159   8.288 8.73e-15 *** 
---
Signif. codes:  0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 

Residual standard error: 0.135 on 236 degrees of freedom
Multiple R-squared:  0.6308, Adjusted R-squared:  0.6277 
F-statistic: 201.6 on 2 and 236 DF,  p-value: < 2.2e-16

```

Figura 20. Modelo seleccionado para la estimación de la altura individual.

Para comprobar el cumplimiento de las hipótesis básicas se representaron las gráficas básicas de diagnóstico (Figura 21), en las que se puede observar que el modelo se comporta correctamente.

Una vez seleccionado el modelo, se validó. En la tabla 8, se observa que los estadísticos sesgo, RMSE y R^2 corregido obtenidos mediante la validación cruzada son similares a los generados empleando la totalidad de la muestra, lo que indica que el modelo es válido para la estimación.

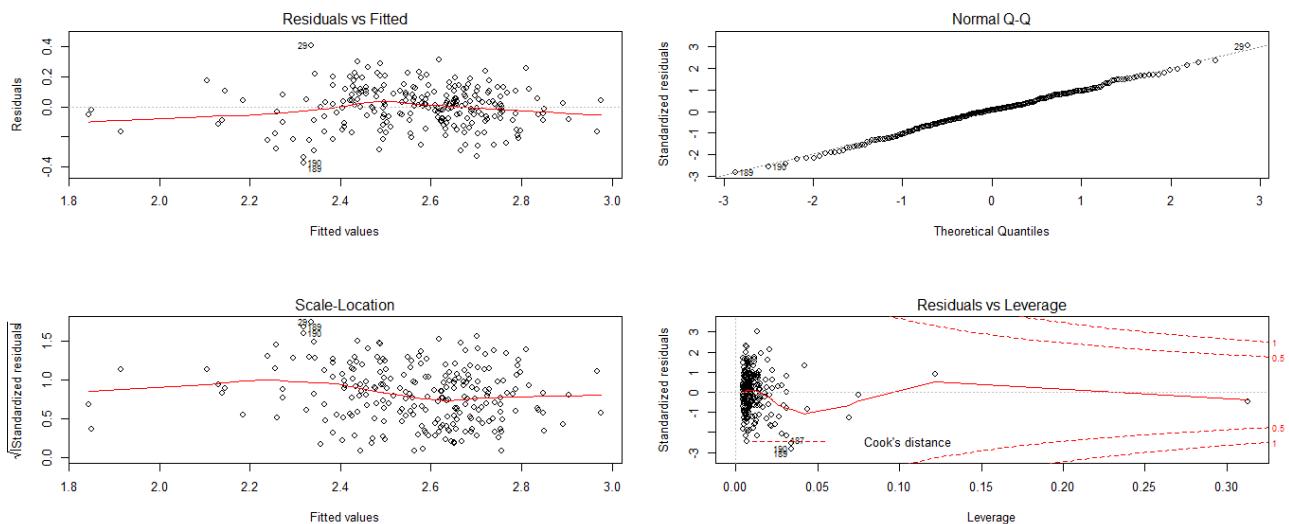


Figura 21. Graficas básicas de diagnóstico del modelo de estimación de la altura individual.

Tabla 8. Validación del modelo lineal de estimación de la altura individual.

Estadísticos	Modelo original	Validación cruzada
Sesgo	-0,01	0,00
RMSE	0,135	0,136
R ² corregido	0,628	0,628

Finalmente, una vez validado el modelo, se recalcularon sus coeficientes empleando los resultados de la validación cruzada y se transformó a un modelo potencial, realizando la transformación logarítmica inversa, todo según lo explicado en el apartado 1.3.4 Modelos predictivos. Siendo este el resultado obtenido:

$$h_i = 0,776 * G^{0,179} * dn_i^{0,660} * CF$$

Donde:

h: altura del árbol (m).

dn_i: diámetro normal del árbol (cm).

G: área basimétrica de la parcela (m²/ha)

CF: coeficiente de corrección del sesgo del modelo, 1,009.

En el modelo obtenido la variable más significativa es el diámetro normal (variable que más información aporta al modelo), presentando una relación directa con la variable a estimar. El área basimétrica de la parcela, siendo menos significativa, también tiene una relación directa con la altura del árbol. Estos resultados son completamente lógicos, ya que el diámetro normal es la única variable individual del modelo, luego debe ser la más significativa. Además, la relación directa, entre diámetro y altura, es obvia, ya que el diámetro aumenta con el paso del tiempo, igual que la altura. La relación directa entre el área basimétrica y la altura, hace que se compense el menor crecimiento diametral de los pies desarrollados en rodales de mayor espesura, haciendo que, a igualdad de diámetro, un árbol presente mayor altura si ha sufrido una mayor competencia. El crecimiento en altura de un árbol no está influenciado por la espesura de la masa (a no ser que este se encuentre completamente dominado o sumergido), sin embargo, su crecimiento diametral sí que se ve drásticamente reducido por la espesura y, en definitiva, por la competencia a la que ha sido sometido.

Tras estimar la altura de cada árbol se procedió a calcular las variables dasométricas de cada parcela, variables que se muestran en la tabla 9. En ella se puede observar el amplio rango de los valores calculados, lo que concuerda con la variabilidad observada en la extracción de los estadísticos LiDAR de cada parcela. Este amplio rango también constata la correcta planificación del inventario de campo, que hace que la variabilidad de la zona de estudio esté bien representada en la muestra inventariada. En las tablas 1 y 2, del apartado 1.3.1 Área de estudio, se muestra un resumen de estas variables, para el monte “Dehesa de los Enebrales” y para el monte “Valdá y Carrilanga”, respectivamente.

Tabla 9. Resumen de las principales variables dasométricas por parcela. Dg: diámetro cuadrático medio; Hm: altura media; N: densidad de pies por hectárea; G: Área basimétrica; Vcc: Volumen maderable con coraza por hectárea.

Parcela	Dg (cm)	Hm (m)	N (pies/ha)	G (m ² /ha)	Vcc (m ³ /ha)
1	30,1	13,4	424,4	30,2	156,4
2	29,6	12,8	367,8	25,3	125,6
3	26,3	12,3	608,3	33,0	164,3
4	27,0	11,9	438,6	25,2	120,3
5	29,4	12,3	282,9	19,3	96,7
6	26,7	12,4	551,7	30,9	154,5
7	28,7	12,8	367,8	23,9	118,6
8	30,7	12,8	212,2	15,7	77,8
9	34,3	14,1	254,6	23,5	127,3
10	30,1	13,1	410,3	29,1	150,4
11	28,7	12,4	424,4	27,5	134,3
12	38,3	15,4	254,6	29,4	170,8
13	30,7	13,0	254,6	18,8	94,7
14	25,0	11,1	481,0	23,7	108,5
15	27,8	11,2	339,5	20,6	97,2
16	24,9	11,8	650,8	31,7	154,3
17	31,7	12,4	212,2	16,8	80,2
18	33,3	13,5	254,6	22,1	112,4
19	36,4	13,8	183,9	19,2	100,8
20	43,5	16,1	127,3	18,9	106,6
21	36,2	13,5	155,6	16,0	82,7
22	35,4	13,3	155,6	15,3	78,8
23	28,9	12,7	396,1	25,9	129,3
24	36,0	14,0	226,4	23,0	124,0
25	28,4	12,1	282,9	17,9	89,0
26	36,2	12,9	99,0	10,2	50,4
27	33,3	14,4	382,0	33,3	179,9
28	31,2	11,2	141,5	10,8	51,5
29	26,9	12,4	509,3	28,9	144,4
30	32,3	13,6	282,9	23,2	123,3
31	35,0	14,6	282,9	27,3	147,0
32	35,8	14,2	212,2	21,3	113,1
33	27,8	12,6	438,6	26,6	131,5
34	35,3	14,5	254,6	25,0	134,8
35	30,3	12,2	282,9	20,4	96,8
36	30,6	12,8	339,5	25,0	126,3
37	33,6	12,5	141,5	12,5	60,8
38	29,0	12,1	339,5	22,4	105,3
39	43,3	15,9	169,8	25,0	140,5

Parcela	Dg (cm)	Hm (m)	N (pies/ha)	G (m ² /ha)	Vcc (m ³ /ha)
40	32,2	13,2	254,6	20,7	104,2
41	27,7	12,3	452,7	27,3	133,8
42	29,8	13,4	466,9	32,6	172,7
43	25,2	12,1	636,6	31,8	152,5
44	30,0	13,6	452,7	32,0	169,2
45	31,0	12,7	254,6	19,2	95,2
46	29,0	12,8	438,6	28,9	145,0
47	49,0	13,5	14,1	2,7	13,0
48	28,5	9,1	127,3	8,1	31,7
49	17,7	9,6	1471,3	36,4	155,5
50	17,8	8,9	1061,0	26,5	109,7
51	24,5	11,9	778,1	36,6	179,4
52	19,8	10,1	1032,7	31,7	141,5
53	19,2	9,2	834,7	24,1	104,7
54	21,6	10,7	933,7	34,3	159,9
55	18,4	8,6	693,2	18,5	75,0
56	22,6	10,2	537,6	21,6	95,2
57	26,0	6,0	14,1	0,8	2,1
58	28,3	13,5	594,2	37,3	195,6
59	25,8	11,9	537,6	28,2	132,8
60	23,8	11,7	806,4	36,0	175,8
61	33,6	13,9	282,9	25,1	132,7

2.3. Modelo de estimación del volumen.

En la tabla 10 se muestran las variables preseleccionadas para la generación de cada modelo. Los coeficientes de correlación empleados para la preselección de variables se pueden consultar en el Anexo 3.

Tabla 10. Variables preseleccionadas para cada modelo.

Nº	Variables	
	Dependiente	Independientes
1	Vcc	Percentil 10, Porcentaje de primeros retornos por encima de 3 ó 6 metros, Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos, Moda y Percentil 75.
2	Ln(Vcc)	Percentil 10, Percentil 80, Porcentaje de primeros retornos por encima de 3 ó 6 metros, Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos y Moda
3	Ln(Vcc)	Ln(Percentil 40), Ln(Porcentaje de retornos por encima de la media), Ln(Porcentaje de primeros retornos por encima de 3 ó 6 metros), Ln(Porcentaje de retornos por encima de la media respecto del total de primeros retornos), Ln(Percentil 99), Ln(Percentil 80)

En la siguiente tabla se muestran las características generales de los modelos generados para la estimación del volumen, una vez seleccionadas las variables que mejor resultado ofrecen.

Como se puede observar, únicamente el modelo “1”, cuyas variables no están transformadas logarítmicamente, cumple las hipótesis básicas de los modelos de regresión lineal. En la figura 22 se muestra el resumen de dicho modelo, obtenido del programa estadístico “R”. Se puede observar el error estándar de estimación (Residual standard error), el R² corregido y los coeficientes del mode-

lo. También podemos observar, que tanto el modelo como las variables explicativas, son significativas.

Tabla 11. Resumen de los modelos analizados para la estimación del volumen.

Nº	Variables		Hipótesis básicas	R ² corregido	RMSE	Sesgo
	Dependiente	Independientes				
1	Vcc	Percentil 10, Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos.	Sí	0,867	14,45	0,00
2	Ln(Vcc)	Percentil 80, Porcentaje de primeros retornos por encima de 3 ó 6 metros.	No (normalidad)	-	-	-
3	Ln(Vcc)	Ln(Percentil 40), Ln(Porcentaje de retornos por encima de la media)	No (normalidad)	-	-	-

Residuals:

Min	1Q	Median	3Q	Max
-30.406	-8.923	-0.971	9.305	46.897

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-53.25388	10.33730	-5.152	3.24e-06 ***
ElevP10	7.85423	1.13300	6.932	3.81e-09 ***
Precent_All_returns_above6_Total_first_returns	1.68545	0.09823	17.159	< 2e-16 ***

Signif. codes:	0 ****	0.001 **	0.01 *	0.05 .
	0.1	'	'	'

Residual standard error: 14.82 on 58 degrees of freedom

Multiple R-squared: 0.8713, Adjusted R-squared: 0.8669

F-statistic: 196.3 on 2 and 58 DF, p-value: < 2.2e-16

Figura 22. Modelo seleccionado para la estimación del volumen.

Para comprobar el cumplimiento de las hipótesis básicas se representaron las gráficas básicas de diagnóstico (Figura 23). Como dichas graficas generan ciertas dudas, se ejecutaron los análisis cuantitativos descritos en el apartado 1.3.4 Modelos predictivos, obteniendo un resultado aceptable en todos ellos (Tabla 12).

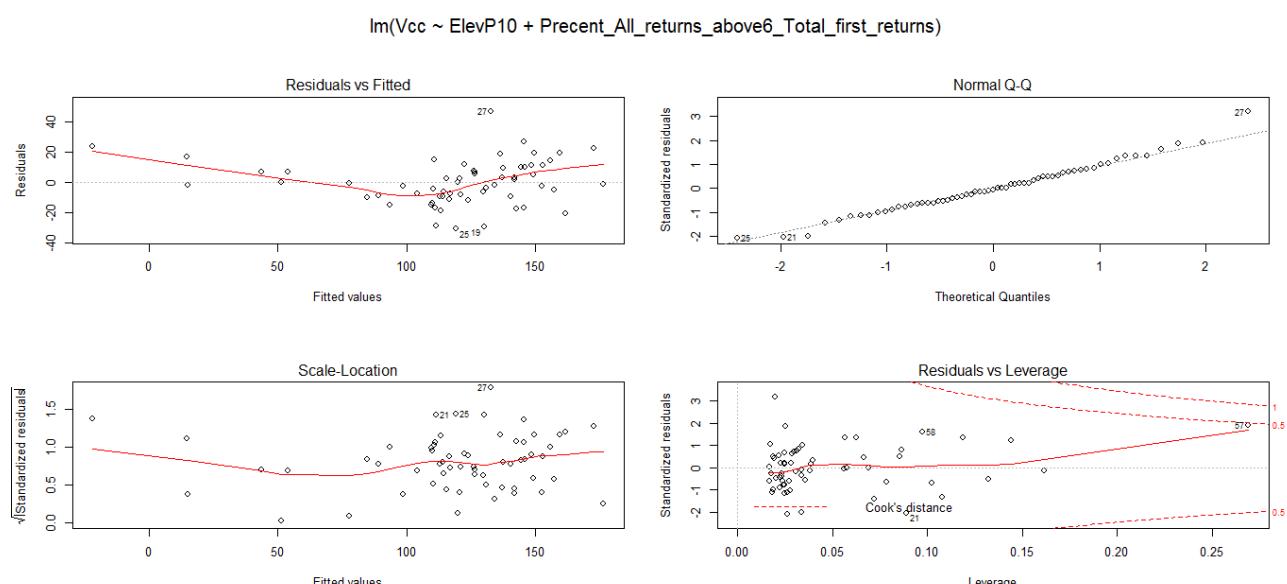


Figura 23. Graficas básicas de diagnóstico del modelo de estimación del volumen.

Tabla 12. Diagnóstico analítico del modelo de estimación del volumen.

	Test reset de “no linealidad”	Test de Shapiro-Wilk	Test de Breush-Pagan	Test de Durbin-Watson	Factor de inflación de varianza	Test de Bonferroni
Estadístico	2,276	0,984	0,216	1,954	1,028	Sin atípicos
P-valor	0,073	0,589	0,642			

Tras seleccionar el modelo, se procedió a su validación. En la tabla 13, se muestra que los estadísticos sesgo, RMSE y R^2 corregido obtenidos mediante la validación cruzada son similares a los generados empleando la totalidad de la muestra, lo que indica que el modelo es válido para la estimación.

Tabla 13. Validación del modelo de estimación del volumen.

Estadísticos	Modelo original	Validación cruzada
Sesgo	0,00	0,16
RMSE	14,45	15,42
R^2 corregido	0,867	0,867

Finalmente, el modelo, una vez recalculados los coeficientes con los obtenidos en el proceso de validación, es el siguiente:

$$Vcc = -53,300 + 7,857 * ElevP10 + 1,686 * \%retornos_1$$

Donde:

Vcc: volumen con corteza por hectárea (m^3/ha).

Percentil 10: percentil 10 de la altura de los puntos LiDAR (m).

%retornos₁: porcentaje de retornos por encima de 3 ó 6 metros (depende del monte) respecto del total de primeros retornos (%).

La variable que mayor información aporta al modelo es el porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos, presentando una relación directa con el volumen. El percentil 10 de la altura de la nube de puntos LiDAR, siendo su significación menor, también presenta una relación directa. El modelo opera de forma lógica, ya que, a mayor porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos, mayor será la superficie del suelo cubierta por el estrato arbóreo y por consiguiente mayor será el volumen maderable por hectárea, y a mayor altura del percentil 10, mayor será el desarrollo de los pies que componen la masa y por tanto también será mayor el volumen que aportan. El percentil 10, puede parecer un percentil excesivamente bajo para la estimación de una variable como el volumen, pero se debe tener en cuenta, que solo se han computado los retornos LiDAR del dosel de copas (con altura mínima de 3 ó 6 metros, dependiendo del monte).

2.4. Modelo de estimación del área basimétrica.

En la tabla 14 se muestran las variables preseleccionadas para la generación de cada modelo. Los coeficientes de correlación empleados para la preselección de variables se pueden consultar en el Anexo 3.

En la tabla 15 se muestran las características generales de los modelos generados para la estimación del área basimétrica, tras la selección de las variables que mejor resultado ofrecen.

Como se puede observar en la tabla 15, solo un modelo cumple las hipótesis básicas de los modelos de regresión lineal. El modelo “1”, solo incumple el requisito de linealidad, pero al presentar el modelo “2” estadísticos de bondad similares, empleando tan solo una variable, se decidió seleccionar este modelo. La inclusión de una segunda variable solo aumenta en un 3,6% la variabilidad

explicada por el modelo. En la figura 24 se muestra el resumen del modelo “2”, obtenido del programa estadístico “R”. Se puede observar el error estándar de estimación (Residual standard error), el R^2 corregido y los coeficientes del modelo. También podemos observar, que tanto el modelo como las variables explicativas, son significativas. En este caso, el término constante (Intercept) no resulta significativo, sin embargo el modelo es igualmente válido, ya que, simplemente, se debe a que su valor es próximo a cero.

Tabla 14. Variables preseleccionadas para cada modelo.

Nº	Variables	
	Dependiente	Independientes
1	G	Percentil 05, Moda, Porcentaje de primeros retornos por encima de 3 o 6 metros y Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos.
2	G	Percentil 05 y Porcentaje de primeros retornos por encima de 3 o 6 metros.
3	Ln(G)	Percentil 10, Percentil 80, Percentil 99, Máximo, Moda, Porcentaje de primeros retornos por encima de 3 o 6 metros, Porcentaje de retornos por encima de 3 ó 6 metros,
4	Ln(G)	Ln(Percentil 40), Ln(Percentil 80), Ln(Máximo), Ln(Modas), Ln(Porcentaje de primeros retornos por encima de 3 o 6 metros), Ln(Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos) y Ln(Porcentaje de retornos por encima de la media respecto del total de primeros retornos).

Tabla 15. Resumen de los modelos analizados para la estimación del área basimétrica.

Nº	Variables		Hipótesis básicas	R^2 corregido	RMSE	Sesgo
	Dependiente	Independientes				
1	G	Percentil 05, Porcentaje de primeros retornos por encima de 3 o 6 metros.	No (linealidad)	0,890	2,55	0,00
2	G	Porcentaje de primeros retornos por encima de 3 o 6 metros.	Sí	0,854	2,96	0,00
3	Ln(G)	Percentil 80, Porcentaje de primeros retornos por encima de 3 o 6 metros.	No (normalidad)	-	-	-
4	Ln(G)	Ln(Percentil 40), Ln(Porcentaje de primeros retornos por encima de 3 o 6 metros)	No (normalidad)	-	-	-

Para comprobar el cumplimiento de las hipótesis básicas se representaron las gráficas básicas de diagnóstico (Figura 25), en las que se puede observar que el modelo se comporta de forma normal. Sin embargo, para cerciorarnos se realizaron los análisis cuantitativos descritos en el apartado 1.3.4 Modelos predictivos (Tabla 16), obteniendo un resultado satisfactorio en todos ellos.

Una vez seleccionado el modelo, se validó. En la tabla 17, se observa que los estadísticos sesgo, RMSE y R^2 corregido obtenidos mediante la validación cruzada son similares a los generados empleando la totalidad de la muestra, lo que indica que el modelo es válido para la estimación.

Finalmente, el modelo, una vez recalculados los coeficientes con los obtenidos en el proceso de validación, es el siguiente:

$$G = -0,192 + 0,375 * \%retornos_2$$

Donde:

G: área basimétrica (m^2/ha).

%retornos₂: porcentaje de primeros retornos por encima de 3 o 6 metros (en función del monte) (%).

```

Residuals:
    Min      1Q   Median      3Q     Max
-7.3954 -2.2137 -0.1813  2.1354  7.8701

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.18884   1.33723 -0.141   0.888
Percent_first_returns_above_6 0.37535   0.01999 18.774 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3.013 on 59 degrees of freedom
Multiple R-squared:  0.8566, Adjusted R-squared:  0.8542
F-statistic: 352.5 on 1 and 59 DF,  p-value: < 2.2e-16

```

Figura 24. Modelo de estimación del área basimétrica.

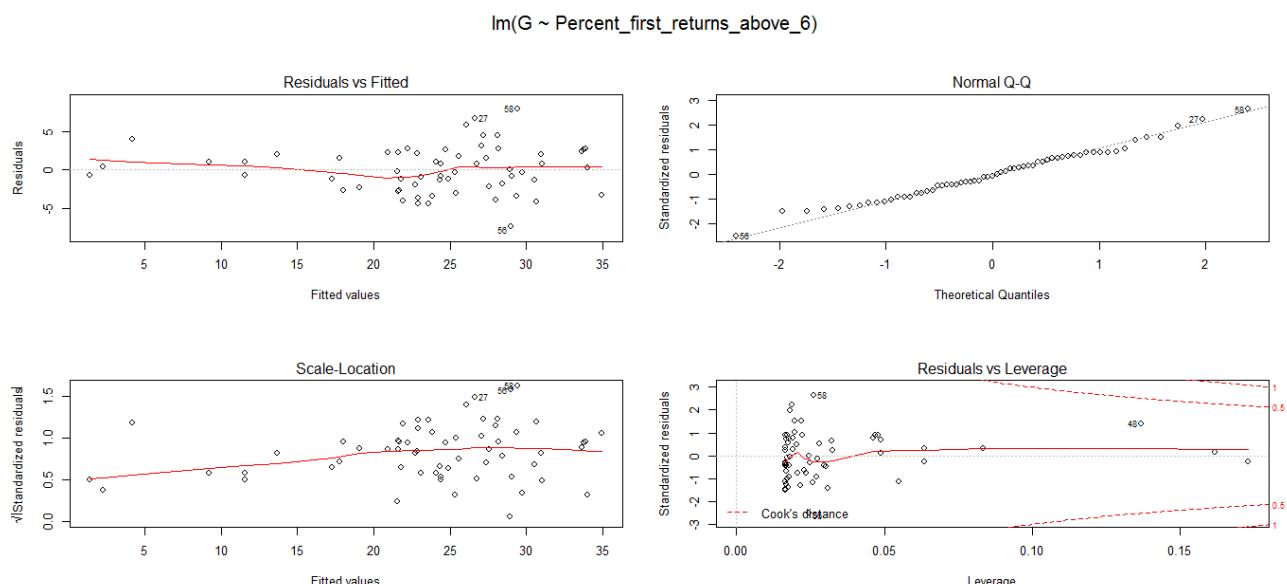


Figura 25. Graficas básicas de diagnóstico del modelo de estimación del área basimétrica.

Tabla 16. Diagnóstico analítico del modelo de estimación del área basimétrica.

	Test reset de “no linealidad”	Test de Shapiro-Wilk	Test de Breush-Pagan	Test de Durbin-Watson	Factor de inflación de varianza	Test de Bonferroni
Estadístico	1,222	0,987	2,459	1,864	Modelo univariable	Sin atípicos
P-valor	0,274	0,782	0,117			

Tabla 17. Validación del modelo lineal de estimación del área basimétrica.

Estadísticos	Modelo original	Validación cruzada
Sesgo	0,00	0,01
RMSE	2,96	3,05
R ² corregido	0,854	0,854

La única variable independiente que conforma el modelo es el porcentaje de primeros retornos por encima de 3 o 6 metros, presentando una relación directa con la variable a estimar. Así, el modelo es coherente, ya que a mayor porcentaje de primeros retornos por encima de 3 o 6 metros, mayor será la superficie ocupada por el estrato arbóreo y mayor será el área basimétrica del rodal.

El modelo no incluye ninguna variable referida a la altura de la masa. Se podría pensar que este tipo de variables debieran estar incluidas en el modelo, ya que la altura de la masa, guarda relación con el diámetro medio, y este, junto con la densidad, determina el área basimétrica de un rodal. Sin embargo, en general, a mayor altura y mayor desarrollo de los pies, la densidad de estos es menor, por lo que se compensa el mayor diámetro medio de las masas más adultas (mayor altura), con la mayor densidad de las masas más jóvenes (menor altura), haciendo que el área basimétrica sea similar, no siendo muy influyentes en el modelo las variables relacionadas con la altura de la masa.

2.5. Modelo de estimación de la densidad.

En la tabla 18 se muestran las variables preseleccionadas para la generación de cada modelo. Los coeficientes de correlación empleados para la preselección de variables se pueden consultar en el Anexo 3.

Tabla 18. Variables preseleccionadas para cada modelo.

Nº	Variables	
	Dependiente	Independientes
1	N	Mínimo, Percentil 90, Porcentaje de primeros retornos por encima de 3 o 6 metros y Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos.
2	Ln(N)	Porcentaje de primeros retornos por encima de 3 o 6 metros y Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos
3	Ln(N)	Ln(Porcentaje de primeros retornos por encima de 3 o 6 metros).
4	Ln(N)	Ln(Percentil 95), Ln(Porcentaje de primeros retornos por encima de 3 o 6 metros).

En la tabla 19 se muestran las características generales de los modelos generados, una vez seleccionadas las variables que mejor resultado ofrecen.

Tabla 19. Resumen de los modelos analizados para la estimación de la densidad.

Nº	Variables		Hipótesis básicas	R^2 corregido	RMSE	Sesgo
	Dependiente	Independientes				
1	N	Percentil 90, Porcentaje de primeros retornos por encima de 3 o 6 metros.	No (normalidad)	-	-	-
2	Ln(N)	Porcentaje de primeros retornos por encima de 3 o 6 metros.	No (normalidad)	-	-	-
3	Ln(N)	Ln(Porcentaje de primeros retornos por encima de 3 o 6 metros).	No (linealidad)	0,760	-	-
4	Ln(N)	Ln(Percentil 95), Ln(Porcentaje de primeros retornos por encima de 3 o 6 metros).	Sí	0,858	113,93*	1,92*

*Calculados tras aplicar la trasformación logarítmica inversa.

Como se puede observar en la tabla 19, solo un modelo (modelo “4”) cumple las hipótesis básicas de los modelos de regresión lineal, además es este el que mejores estadísticos de bondad del

ajuste presenta. El RMSE puede parecer elevado, pero se debe tener en cuenta que el número de pies por hectárea presenta una gran variabilidad en la zona de estudio (desviación típica en las 61 parcelas, 271,22 pies/ha), por lo que un RMSE de 113,93 pies/ha es aceptable.

Se incluyó la variable percentil 95 de la altura, pese a su baja correlación, por el siguiente razonamiento lógico. Existen masas, que presentando una densidad notablemente menor a otras, poseen una superficie ocupada por el dosel arbóreo similar, es decir, un similar porcentaje de primeros retornos por encima de una altura determinada, debido al mayor desarrollo de las copas en estas masas. Por ello, incluyendo el percentil 95 de la altura, que da idea de la altura de la masa y por tanto, indirectamente, del desarrollo de los pies, es posible discernir entre masas, que teniendo el mismo porcentaje de primeros retornos sobre una altura determinada, presentan un número de pies por hectárea sensiblemente diferente. En este caso, el razonamiento anterior es corroborado con unos buenos estadísticos de ajuste.

En la figura 26 se muestra el resumen del modelo “4”, obtenido del programa estadístico “R”. Se puede observar el error estándar de estimación (Residual standard error), el R^2 corregido y los coeficientes del modelo. También podemos observar, que tanto el modelo como las variables explicativas, son significativas.

```

Residuals:
    Min      1Q   Median      3Q     Max
-0.63167 -0.17480 -0.03574  0.20109  0.95964

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 3.00183  0.47942  6.261 5.03e-08 ***
LN_Percent_first_returns_above_6 1.47047  0.07726 19.033 < 2e-16 ***
LN_ElevP95  -1.25567  0.19558 -6.420 2.74e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.3088 on 58 degrees of freedom
Multiple R-squared: 0.8623, Adjusted R-squared: 0.8575
F-statistic: 181.6 on 2 and 58 DF,  p-value: < 2.2e-16

```

Figura 26. Modelo de estimación de la densidad.

Para comprobar el cumplimiento de las hipótesis básicas se representaron las gráficas básicas de diagnóstico (Figura 27). En la gráfica “Residuals vs Leverage”, se puede observar que la parcela “57” hace desviarse visiblemente el trazo rojo, por lo que se realizaron las pruebas analíticas descritas en el apartado 1.3.4 Modelos predictivos (Tabla 20). Tras aplicar el test de “Bonferroni” la parcela “57” no se consideró como valor atípico. Dicho test destacó la parcela “48” como atípica, pero se puede observar que su distancia de “cook” es inferior a uno, por lo que su influencia en la estimación del modelo no es considerable. El resultado del resto de pruebas analíticas fue aceptable.

Tras seleccionar el modelo, se procedió a su validación. En la tabla 21, se muestra que los estadísticos sesgo, RMSE y R^2 corregido obtenidos mediante la validación cruzada son similares a los generados empleando la totalidad de la muestra, lo que indica que el modelo es válido para la estimación.

Finalmente, el modelo, una vez recalculados los coeficientes y realizada la transformación logarítmica inversa, es el siguiente:

$$N = 20,247 * \%retornos_2^{1,470} * ElevP95^{-1,257} * CF$$

Donde:

N: densidad (pies/ha).

%retornos₂: porcentaje de primeros retornos por encima de 3 o 6 metros (%).

Percentil 95: percentil 95 de la altura de los puntos LiDAR (m).

CF: coeficiente de corrección del sesgo del modelo, 1,045.

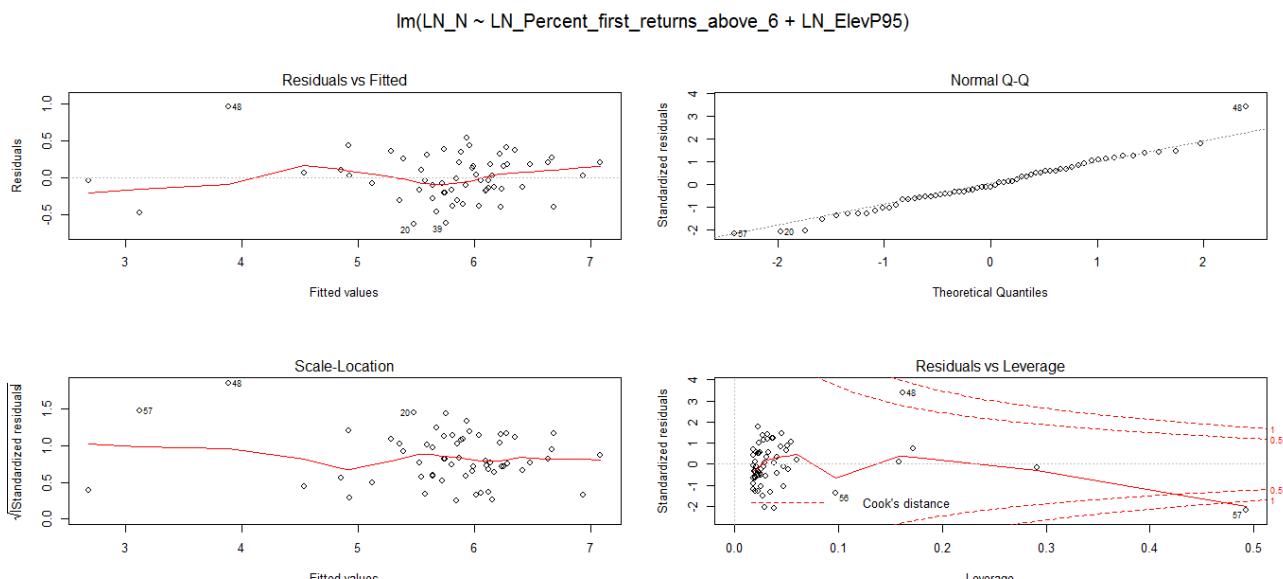


Figura 27. Graficas básicas de diagnóstico del modelo de estimación de la densidad.

Tabla 20. Diagnóstico analítico del modelo de estimación de la densidad.

	Test reset de “no linealidad”	Test de Shapiro-Wilk	Test de Breush-Pagan	Test de Durbin-Watson	Factor de inflación de varianza	Test de Bonferroni
Estadístico	0,931	0,983	6,025	1,462	1,173	Parcela 48
P-valor	0,400	0,579	0,052			No influyente

Tabla 21. Validación del modelo de estimación de la densidad.

Estadísticos	Modelo original	Validación cruzada
Sesgo	0,00	0,00
RMSE	0,30	0,34
R ² corregido	0,858	0,857

La variable que más información aporta al modelo es el porcentaje de primeros retornos por encima de 3 o 6 metros, presentando una relación directa con la densidad. Por el contrario, el percentil 95 de la altura de la nube de puntos LiDAR presenta una relación inversa. Así, el modelo establecido se comporta de manera natural, ya que al aumentar el porcentaje de primeros retornos por encima de 3 o 6 metros, aumentará la superficie cubierta por el estrato arbóreo y por consiguiente el número de pies por hectárea, y al aumentar el percentil 95 de la altura, aumentará la altura general del rodal y por tanto el desarrollo de los árboles, haciendo que el número de estos por hectárea disminuya.

2.6. Modelo de estimación de la altura media.

En la tabla 22 se muestran las variables preseleccionadas para la generación de cada modelo. Los coeficientes de correlación empleados para la preselección de variables se pueden consultar en el Anexo 3.

En la tabla 23 se muestran las características generales de los modelos generados, tras seleccionar las variables que mejor resultado ofrecen.

Tabla 22. Variables preseleccionadas para cada modelo.

Nº	Variables	
	Dependiente	Independientes
1	Hm	Percentil 70 y Percentil 90
2	Ln(Hm)	Percentil 70 y Percentil 90
3	Ln(Hm)	Ln(Percentil 50), Ln(Media)

Tabla 23. Resumen de los modelos analizados para la estimación de la altura media.

Nº	Variables		Hipótesis básicas	R ² corregido	RMSE	Sesgo
	Dependiente	Independientes				
1	Hm	Percentil 70	No (Linealidad)	0,720	-	-
2	Ln(Hm)	Percentil 70	No (normalidad)	-	-	-
3	Ln(Hm)	Ln(Percentil 50)	Sí	0,799	0,903*	0,017*

*Calculados tras aplicar la trasformación logarítmica inversa.

Como se puede observar en la tabla 23, solo un modelo (modelo “3”) cumple las hipótesis básicas de los modelos de regresión lineal, siendo este el que mejores estadísticos de ajuste presenta. En la figura 28 se muestra el resumen de dicho modelo, obtenido del programa estadístico “R”. Se puede observar el error estándar de estimación (Residual standard error), el R² corregido y los coeficientes del modelo. También podemos observar, que tanto el modelo como las variables explicativas, son significativas.

```

Residuals:
    Min      1Q   Median      3Q     Max 
-0.144452 -0.051131 -0.005575  0.058512  0.174058

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 1.12110   0.09009 12.44 <2e-16 ***
LN_ElevP50  0.59569   0.03844 15.49 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.07227 on 59 degrees of freedom
Multiple R-squared:  0.8027, Adjusted R-squared:  0.7994 
F-statistic: 240.1 on 1 and 59 DF,  p-value: < 2.2e-16

```

Figura 28. Modelo de estimación del número de la altura media.

Para comprobar el cumplimiento de las hipótesis básicas se representaron las gráficas básicas de diagnóstico (Figura 29). Debido a las dudas que generaban dichas gráficas, se ejecutaron los análisis cuantitativos descritos en el apartado 1.3.4 Modelos predictivos, obteniendo un resultado satisfactorio en todos ellos (Tabla 24).

Tras seleccionar el modelo, se realizó la validación del mismo. En la tabla 25, se muestra que los estadísticos sesgo, RMSE y R² corregido obtenidos mediante la validación cruzada son idénticos a los generados empleando la totalidad de la muestra, lo que indica que el modelo es válido para la estimación.

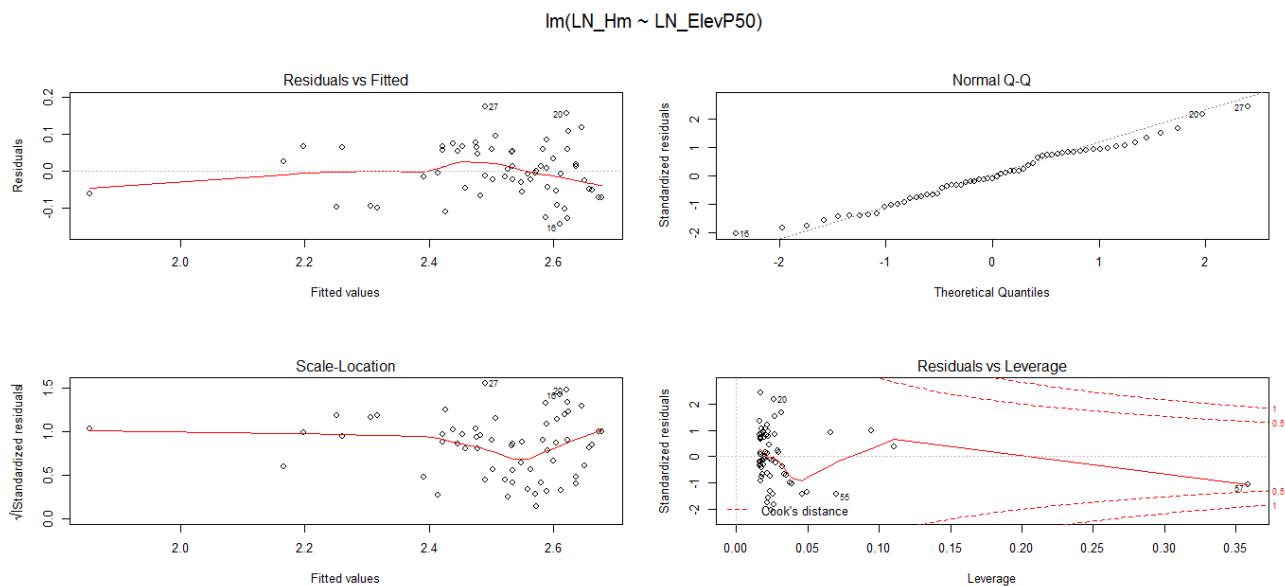


Figura 29. Graficas básicas de diagnóstico del modelo de estimación de la altura media.

Tabla 24. Diagnóstico analítico del modelo de estimación de la altura media.

	Test reset de “no linealidad”	Test de Shapiro-Wilk	Test de Breush-Pagan	Test de Durbin-Watson	Factor de inflación de varianza	Test de Bonferroni
Estadístico	2,252	0,985	0,107	2.014	Modelo univariable	Sin atípicos
P-valor	0,139	0,649	0,744			

Tabla 25. Validación del modelo de estimación del número de la altura media.

Estadísticos	Modelo original	Validación cruzada
Sesgo	0,00	0,00
RMSE	0,07	0,07
R ² corregido	0,799	0,799

Finalmente, el modelo, una vez recalculados los coeficientes y realizada la transformación logarítmica inversa, es el siguiente:

$$Hm = 3,065 * ElevP50^{0,596} * CF$$

Donde:

Hm: altura media (m).

Percentil 50: percentil 50 de la altura de los puntos LiDAR (m).

CF: coeficiente de corrección del sesgo del modelo, 1,003.

El percentil 50 de la altura de la nube de puntos LiDAR es la única variable dependiente del modelo, presentando como es lógico una relación directa con la altura media de los pies del rodal. Se puede pensar que el percentil 50 de la altura de la nube de puntos LiDAR resulta un percentil bajo para la estimación de la altura media de la masa, sin embargo, se debe tener en cuenta que para su cálculo solo se han tenido en cuenta los retornos LiDAR de más de 3 ó 6 metros de altura respecto al suelo (dependiendo del monte), lo que, en general, equivale a tener en consideración únicamente los retornos referentes al dosel de copas.

2.7. Representación cartográfica de variables modeladas.

En el Anexo 1, Mapas del 7 al 10, se muestra la representación cartográfica de cada una de las variables estimadas mediante los modelos generados en los apartados anteriores.

Como las ecuaciones de estimación no parten del origen, las estimaciones son en algunos casos negativas (en zonas ralas o desarboladas), por lo que, antes de rasterizar la capa de puntos, se seleccionaron los de valor negativo y se les asignó el valor cero.

Para facilitar la visualización de las estimaciones, se ha aplicado un sombreado gris con transparencia a las zonas excluidas del área de estudio (ver apartado 1.3.1 Área de estudio), proporcionando un mayor peso visual a los resultados sin perder la referencia espacial de estos.

En los diferentes mapas creados, se observa como los valores estimados son normales, no observando en ningún caso valores extremos que indiquen una estimación errónea. En general, se percibe que, como es lógico, las zonas en las que las estimaciones de la altura y la densidad o el área basimétrica son elevadas, también lo son las del volumen. Se aprecia como el sector sur del monte “Dehesa de los Enebrales” presenta unas existencias notablemente menores, este hecho es debido al relieve escarpado de la zona que hace que la cobertura arbórea sea escasa, igual que sucede en las áreas ocupadas por caminos o cortafuegos. Observando los mapas de variables estimadas y el Mapa 2: Orografía, podemos apreciar como, en general, las mayores estimaciones de alturas, densidades y por tanto de volúmenes se dan en zonas llanas o cóncavas, como fondos de barrancos o planicies, hecho propiciado por el mayor desarrollo edáfico en estos lugares. Tanto en el Mapa 9: Densidad estimada, como en el Mapa 10: Altura media estimada, se observa el marcado contraste existente, respecto a estas dos variables, entre el monte “Dehesa de los Enebrales” y el monte “Valdá y Carrillanga”, contraste completamente lógico debido a la diferente edad de estas masas. Tanto en el Mapa 9: Densidad estimada, como en el Mapa 8: Área basimétrica estimada, se observa una zona en el monte “Dehesa de los Enebrales” (coordenadas X: 631.500 Y: 4.554.000) de gran espesura, donde, en campo, se observó que nunca se habían realizado tratamientos de mejora en la masa, alertando de la presencia de gran cantidad de pies “gemelos” o “hermanados”, es decir, pies que compiten en el mismo antiguo hoyo de repoblación.

3. DISCUSIÓN.

La minuciosa planificación del inventario de campo, ha hecho que este cumpla el objetivo para el que fue diseñado, obteniendo una muestra completamente representativa del área de estudio. En el Mapa 11: Áreas fuera del rango muestral del Anexo 1, se puede observar, a modo de ejemplo, las áreas que se encuentran fuera del rango de aplicación del modelo para la estimación del volumen (rojo), considerando este rango como el establecido por los datos muestrales (2,1-195,6 m³/ha). Se observa, como tan solo algunas zonas (un 1% de la superficie), donde la ausencia de arbolado hace que el volumen sea cero, se encuentran fuera de dicho rango, lo que pone en evidencia el correcto diseño del inventario, minimizando así los posibles errores generados por la extrapolación de los resultados.

Los resultados logrados en el ajuste de los modelos de estimación han sido muy similares a los obtenidos por otros autores (García, 2010, Li, 2008 y Naesset, 2002), empleando una metodología de trabajo semejante, siendo además notablemente menor el número de variables independientes empleadas (Tabla 26).

Como se puede observar en la tabla 26, el ajuste de los modelos para la estimación del volumen, área basimétrica y densidad ha sido similar, ofreciendo un buen coeficiente de determinación corregido, en torno a 0,86. Sin embargo, el coeficiente de determinación corregido del modelo empleado para la estimación de la altura media ha sido algo inferior, 0,799. Las variables LiDAR empleadas para la estimación de las variables dasométricas han sido similares respecto a las empleadas por otros autores (Li, 2008 y Naesset, 2002). En general, en los modelos establecidos se incluyen al menos un estadístico referente a altura (m) y otro referente a distribución horizontal de la nube de puntos (densidad o porcentaje de retornos LiDAR por encima de una altura determinada).

A diferencia del estudio elaborado por García (2010), en el que el empleo de diversos estadísticos referentes a la distribución vertical de la nube de puntos LiDAR (coeficiente de variación, asimetría o desviación típica) es muy frecuente, en el presente estudio, no ha resultado significativo ningún estadístico de este tipo. También cabe destacar que en los estudios citados anteriormente, siempre se ha realizado una transformación logarítmica de las variables, a diferencia del que se presenta, en el que solo se ha recurrido a ella para la estimación de la densidad y la altura media.

Tabla 26. Resumen de los modelos obtenidos García, 2010, Li, 2008, Naesset, 2002 y el presente trabajo. (V: volumen, G: área basimétrica, N: pies/ha, Hm: altura media, Hd: altura dominante, % retornos: densidad de puntos LiDAR a una determinada altura)

Autores	Variable dependiente	Variables Independientes	Coeficientes de determinación
García, 2010	Ln(V)	Ln(media), Ln(asimetría), Ln(desv. típica) y Ln(%retornos)	0,897
	Ln(G)	Ln(media), Ln(moda), Ln (percentil 30) y Ln(asimetría)	0,883
	Ln(N)	Ln(percentil 70), Ln(percentil 80), Ln(mediana), Ln(percentil 95), Ln(asimetría), Ln(coef. variación) y Ln(%retornos)	0,798
Li, 2008	Ln(V)	Media, coef. variación y % retornos	0,670-0,880
Naesset, 2002	Ln(V)	Ln(percentil 30), Ln(percentil 50), Ln(percentil 60) y Ln(% retornos)	0,800
	Ln(G)	Ln(percentil 50), Ln(percentil 60) y Ln (% retornos)	0,690
	Ln(N)	Ln(percentil 0), Ln(máximo) y Ln (% retornos)	0,650
	Ln(Hd)	Ln(percentil 90) y Ln(percentil 50)	0,860
Cabrera, 2013	V	% retornos y percentil 10	0,867
	G	% retornos	0,854
	Ln(N)	Ln(% retornos) y Ln(percentil 95)	0,858
	Ln(Hm)	Ln(percentil 50)	0,799

Generalmente, como puede apreciarse en la tabla 26, los mejores ajustes se obtienen para variables como el volumen, área basimétrica y alturas, siendo peores los ajustes para variables como la densidad o el diámetro medio. En este trabajo, el modelo obtenido para la estimación de la densidad (pies/ha) ha logrado un mejor ajuste que en el resto de estudios citados. Este hecho puede deberse a la especie objeto de estudio, ya que en las masas de pino carrasco, por el marcado carácter heliófilo de la especie, no es habitual la presencia de pies dominados o sumergidos. La presencia de pies dominados es difícilmente detectable por el sensor, no reflejándose esta en los estadísticos generados. Sin embargo, la escasa aportación de estos pies en términos de volumen o área basimétrica, hace que las estimaciones de estas variables no se vean afectadas.

El modelo obtenido para la estimación de la altura media, a diferencia del resto de estudios citados, no ha resultado ser el que mejor ajuste presenta (Tabla 26). *A priori*, parece lógico, que una variable como la altura obtenga un ajuste extraordinario, ya que está completamente correlacionada con las alturas de la nube de puntos que proporciona el sensor LiDAR. En este caso, este peor ajuste, puede deberse a las imprecisiones y errores generados por la estimación de la altura individual de cada árbol (a partir de áboles tipo), ya que en el resto de estudios se ha medido la altura de todos y cada uno de los pies que componen la muestra, siendo en estos casos la precisión en la obtención de la altura general de la parcela mucho mayor.

Al igual que ocurre con la altura individual, el volumen unitario con corteza también ha sido estimado, no empleando tarifas de cubicación diseñadas específicamente para el monte en cuestión, sino empleando las establecidas por el IFN 3 para la provincia de Zaragoza. Así, además de los errores introducidos por el modelo de predicción, hay que considerar la existencia de los generados en la estimación de la variable de campo.

Aparentemente, no hay razón para pensar que el desfase temporal existente entre la toma de datos LiDAR y datos de campo (3 años) haya sido influyente en la validez de los resultados del presente trabajo, ya que, como se ha comentado, en ese lapso no ha habido cambios significativos en la estructura de la masa.

En cuanto al cálculo de los errores cometidos en el tipo de muestreo empleado en este trabajo, no se ha encontrado ninguna referencia. Cochran (1963) describe esta técnica como un muestreo en dos fases, con estimador de regresión, pero las ecuaciones que desarrolla para el cálculo de los errores solo tienen validez para regresiones lineales simples. Otros autores (Naesset, 2002 y Li, 2008) solo consideran los errores estadísticos del modelo ajustado, ya que realmente se obtiene información LiDAR de toda la superficie, desapareciendo el error de muestreo. Así, utilizan los estadísticos de bondad del ajuste del modelo (R^2 corregido, RMSE y sesgo), obtenidos del proceso de validación cruzada, para evaluar el error de las estimaciones. Sin embargo, esta práctica no proporciona el error cometido en toda el área, sino el cometido considerando solamente los datos muestrales, por lo que si la muestra ofrece un ajuste extraordinario, pero no es representativa del monte, los errores reales que cometeremos serán mucho mayores que los que estaremos estimando con los citados estadísticos de bondad del ajuste. Así, ante la dificultad que plantea establecer una metodología para el cálculo de errores en muestreos de dos fases con regresiones lineales múltiples, y más aún con regresiones potenciales y exponenciales, quizás la solución sea, como se ha planteado en este trabajo, adquirir una muestra completamente representativa de la población, haciendo que los estadísticos que indican la bondad del ajuste del modelo sean aplicables a toda el área de estudio.

4. CONCLUSIONES.

Los resultados ofrecidos por este trabajo reafirman la hipótesis de partida del mismo, mostrando la utilidad de los datos LiDAR PNOA para el inventario de masas regulares de pino carrasco. La metodología empleada tanto para el diseño del inventario de campo, como para el establecimiento de los modelos de estimación, ha resultado adecuada, obteniendo precisas estimaciones de variables como el volumen, área basimétrica, densidad y altura media para toda la zona de estudio, encontrándose un elevado porcentaje de esta (99%) dentro del rango de aplicación de la regresión, minimizando así los errores debidos a la extrapolación de las estimaciones. En este sentido, cabe destacar la utilidad de los estadísticos LiDAR en la estratificación y planificación del inventario de masas forestales, permitiendo, como se ha demostrado en este trabajo, realizar un muestreo en cierto modo dirigido, discriminando tipologías de masa a escala de detalle, con un mínimo trabajo de campo. También es importante resaltar, que se ha conseguido establecer una metodología adecuada para que la presencia de sotobosque no altere los resultados, haciendo además innecesaria la estratificación por este motivo, con la optimización de recursos que ello conlleva. Así mismo, no se debe olvidar, lo que hasta ahora, empleando los métodos de inventario tradicional, era impensable, y es que estos resultados se obtienen de forma continua para toda la superficie y a una escala de gran detalle, ofreciendo un gran avance en la planificación y gestión de masas forestales.

El buen ajuste de los modelos de estimación generados, pone de manifiesto, no solo la adecuación de la metodología empleada, sino también, y aún más importante, la correlación existente entre los estadísticos obtenidos de la nube de puntos LiDAR y las variables dasométricas. Concretamente, han sido los percentiles (bajo, medio o alto, según la variable a estimar) y el porcentaje de retornos LiDAR por encima de una altura determinada, los estadísticos LiDAR que mejor ajuste han proporcionado en los modelos establecidos.

El empleo de una cobertura de datos LiDAR tres años anterior a la toma de datos de campo, no ha afectado a la existencia de altas y significativas correlaciones entre las variables obtenidas en campo y las obtenidas a partir de los datos LiDAR, por lo que se cree que este hecho no es influyente en la obtención de unos buenos resultados. Sin embargo, a la hora de la interpretación de los modelos generados, sí que se debe tener en cuenta ese desfase, ya que de haber contado con una cobertura LiDAR simultánea a los datos de campo, probablemente, tanto las variables seleccionadas, como, evidentemente, los coeficientes de los modelos hubieran sido otros.

Como ya se ha comentado, ante la división de opiniones que genera el cálculo de errores, se ha concluido, viendo la representatividad de la muestra, fruto del estricto diseño del muestreo, que los estadísticos de bondad del ajuste (R^2 corregido, el RMSE y sesgo), obtenidos del proceso de validación cruzada, son aplicables al total de la población, dando idea de los errores y la variabilidad explicada por el modelo en toda el área de estudio. De todos modos, se cree necesario el desarrollo de una técnica adecuada para este fin, ya que los estadísticos de bondad del ajuste no son comparables con el error calculado en un inventario tradicional, ya que no consideran el tamaño muestral, ni la variabilidad, ni extensión de la zona a inventariar, siendo estos factores enormemente influyentes en la precisión de las estimaciones. De no ser posible el desarrollo de esta técnica, deberían ser los mismos organismos encargados de ratificar estos inventarios quienes se amoldasen a estas nuevas metodologías, estableciendo nuevas directrices para su aprobación, marcando así los niveles críticos de tamaños y representatividad muestrales y de los citados estadísticos de ajuste.

Los posibles errores introducidos por la estimación de las variables de campo volumen y altura, no deben lastrar los resultados del presente trabajo, ni, en definitiva, la posibilidad de estimar estas variables a partir de datos LiDAR, ya que, aunque no se citen, están presentes en la gran mayoría de inventarios forestales. Comúnmente, variables como el volumen, biomasa, crecimientos corrientes o altura, se obtienen a partir de pequeñas muestras o modelos de estimación de ámbito regional.

Se debe considerar que los resultados obtenidos en este trabajo demuestran la utilidad de los datos LiDAR PNOA en el inventario de masas regulares monoespecíficas, no siendo extrapolable dicha afirmación a otras tipologías de masa, debido a la dificultad que plantea la discriminación entre especies y clases diamétricas a partir de datos LiDAR. En este sentido, sería deseable que se estudiara la utilidad de estos datos en otras masas, irregulares, pluriespecíficas, montes bajos, etc., así como, en inventarios de grandes superficies, donde el uso de esta tecnología podría suponer un aumento en la precisión de los resultados y una disminución en los costes. Así mismo, teniendo en cuenta que la cobertura LiDAR PNOA va a ser un producto presumiblemente periódico, sería deseable evaluar la adecuación de los modelos ya generados, empleando las futuras coberturas LiDAR. También, en la misma línea, sería deseable la evaluación de la aplicabilidad de los modelos generados en este trabajo a masas de similares características. *A priori*, parece lógico que los modelos ya generados para los montes objeto de estudio, obtendrían resultados similares en masas de características análogas, igualmente, parece lógico que, sobre todo en montes cuya variabilidad haga que estén presentes en él todas las clases de edad (para minimizar la extrapolación), el ajuste del modelo tras el paso del tiempo y empleado la cobertura LiDAR actualizada, fuera similar al obtenido en primera instancia. Sin embargo, en el caso concreto del presente estudio, se debe tener en cuenta el hándicap del desfase temporal existente entre datos LiDAR y datos de campo, ya que estamos relacionando las variables dasométricas actuales con datos LiDAR 3 años anteriores a estas, afectando posiblemente a las dos hipótesis anteriores. De todos modos, se cree conveniente evaluar dichas conjeturas, en este y en otros trabajos similares, ya que de constatarse, se obtendrían datos de gran valor a muy bajo coste, posibilitando la gestión de un mayor número de masas forestales.

Como último propósito, este trabajo pretende servir de estímulo, promoviendo así el uso, en el ámbito del inventario forestal, de la técnica aquí descrita, ya que solo el paso del tiempo y la expansión de su empleo acabarán por demostrar realmente su utilidad. Como se ha comentado a lo largo del trabajo, ya hay disponible una cobertura LiDAR para la mayor parte del territorio español, por lo que está en nuestra mano sacar el mayor provecho posible a estos datos.

5. AGRADECIMIENTOS.

El trabajo que aquí se presenta, no hubiera sido posible, o por lo menos no en los términos temporales establecidos, sino hubiera sido por la inestimable ayuda de familiares y amigos, que han hecho del trabajo de campo un labor más amena, y sobre todo más breve de lo que hubiese sido sin su apoyo. Por eso quiero agradecer a mi madre, Alicia, a mi novia, Belén, y a mis tíos, Antonio y José Antonio, el tiempo que han dedicado a ayudarme en esta tarea. Mención especial y un enorme agradecimiento requiere mi padre, Ángel, quien me ha acompañado en todo momento, no faltando

ni un solo día de inventario, colaborando en todo lo que estaba en su mano y, como es habitual en él, esforzándose al máximo para hacer las cosas lo mejor posible.

También quisiera agradecer el esfuerzo realizado por la Dr. Teresa Lamelas, directora de este trabajo, y el doctorando Antonio Montealegre, quienes me ayudaron tanto en la realización del trabajo de campo, como en la resolución de los problemas que, como en todo trabajo, iban surgiendo.

Por último, también quisiera agradecer al Dr. Juan de la Riva, codirector de este trabajo, el esfuerzo realizado para la obtención de los datos LiDAR de partida, y, en definitiva, el tiempo invertido en todo tipo de gestiones, tiempo que en ocasiones no se valora, sin él este trabajo tampoco hubiese sido posible.

6. BIBLIOGRAFÍA:

- Andersen, H. E., McGaughey, R. J. y Reutebuch, S. E. (2005). *Estimating forest canopy fuel parameters using LiDAR data*. Remote Sensing of Environment, Vol. 94 (4), pp. 441-449.
- Baskerville, G.L. (1972). *Use of logarithmic regression in the estimation of plant biomass*. Can. J. For. Res. 2, 49-53.
- Cochran, W. (1963): *Técnicas de muestreo*. Continental S.A, Mexico D.F.
- Condés, S., Fernández-Landa, A. y Rodríguez, F. (2013). *Influencia del inventario de campo en el error de muestreo obtenido en un inventario con tecnología LiDAR*. 6º Congreso Forestal Español, Vitoria, junio de 2013.
- Diéguez-Aranda, U., Barrio Anta, B., Castedo Dorado F. y Álvarez González, J. G. (2005). *Relación altura-diámetro generalizada para masas de Pinus sylvestris L. procedentes de repoblación en el noroeste de España*. Invest Agrar: Sist Recur For, Vol. 14(2), pp. 229-241.
- FAO (2004). National forest inventory. Field manual. Working Paper 94/E. Roma. Disponible en <http://www.fao.org/docrep/008/ae578e/ae578e06.htm> (último acceso 8 de noviembre de 2013).
- García, A. (1992). Estadística Aplicada: Conceptos Básicos. Madrid, Editorial UNED.
- García, D. (2010). *Estimación de variables de interés forestal basada en datos LIDAR en el monte número 117 del C.U.P. Término Municipal de Cuenca*. Madrid, Universidad Politécnica de Madrid.
- García, M., Riaño, D., Chuvieco, E. y Danson, F. M. (2010). *Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data*. Remote Sensing of Environment, Vol. 114 (4), pp.816-830.
- Hopkinson, C.; Chasmer, L. (2009). *Testing LiDAR models of fractional cover across multiple forest ecozones*. Remote Sensing of Environment 113: 275-288.
- Hyppä, J. e Inkinen, M. (1999). *Detecting and estimating attributes for single trees using laser scanner*. The Photogrammetric Journal of Finland, Vol. 16 (2), pp. 27-42.
- Kraus, K. y Pfeifer, N. (1998). *Determination of terrain models in wooded areas with airborne laser scanner data*. ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 53(4), pp.193-203.
- Kozak, A. y Kozak, R.A. (2003). *Does cross validation provide additional information in the evaluation of regression models?* Can. J. For. Res. 33: 976'987.
- Li, Y., Andersen, H.-E. y McGaughey, R. (2008). *A comparison of statistical methods for estimating forest biomass from light detection and ranging data*. Western Journal of Applied Forestry, Vol. 23 (4), pp.223-231.
- Montealegre, A, Lamelas, M.T., Tanase, M. y De la Riva, J. (2013): *Forest fire severity assessment using LiDAR data in a Mediterranean environment*. Proceedings of the 9th EARSeL Forest Fire Special Interest Group Workshop. Coombe Abbey, Warwickshire, UK, 15-17 October 2013, pp. 107-111.

- Myers, R. H. (1990). *Classical and Modern Regression with Applications*. PWS-Kent Publishing Company.
- Næsset, E. (2002). *Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data*. Remote Sensing of Environment, Vol. 80 (1), pp. 88–99.
- 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 (2), pp. 49–56.
- Ojeda, J.C. (2011). PNOA- LiDAR Plan Nacional de Ortofotografía Aérea. Mesa redonda de Globalgeo 2011 Barcelona: Salón Internacional de la Geomática y Geotelemática, Barcelona, España. Disponible en http://www.ign.es/PNOA/docum/Mesa_redonda_GlobalGeo2011.pdf (último acceso 14 de noviembre de 2013).
- Popescu, S. C. (2007). *Estimating biomass of individual pine trees using airborne LiDAR*. Biomass & Bioenergy, Vol. 31 (9), no. 9, pp. 646-655.
- Riaño, D., Chuvieco, E., Condés, S., González-Matesanz, J., Ustin, S.L. (2004). *Generation of crown bulk density for Pinus sylvestris L. from lidar*. Remote Sens. Environ. 92, 345-352.
- Rodríguez, F y Fernández, A. (2013). Introducción a la tecnología y visualización de datos. Material docente del “Curso práctico de Aplicaciones Forestales de la Tecnología LIDAR. Agresta S. Coop. y Dielmo 3D.
- Sprugel, D. G. (1983). *Correcting for Bias in Log-Transformed Allometric Equations*. Ecology 64:209–210.
- Vosselman, G. & Maas, H. G. (2010). *Airborne and Terrestrial Laser Scanning*. Dunbeath: Whittles publishing.

7. ANEXOS

Anexo 1: Cartografía.

Mapa 1: Localización.

Mapa 2: Orografía.

Mapa 3: Vegetación.

Mapa 4: Ruido información LiDAR.

Mapa 5: Áreas homogéneas.

Mapa 6: Parcelas inventariadas.

Mapa 7: Volumen estimado.

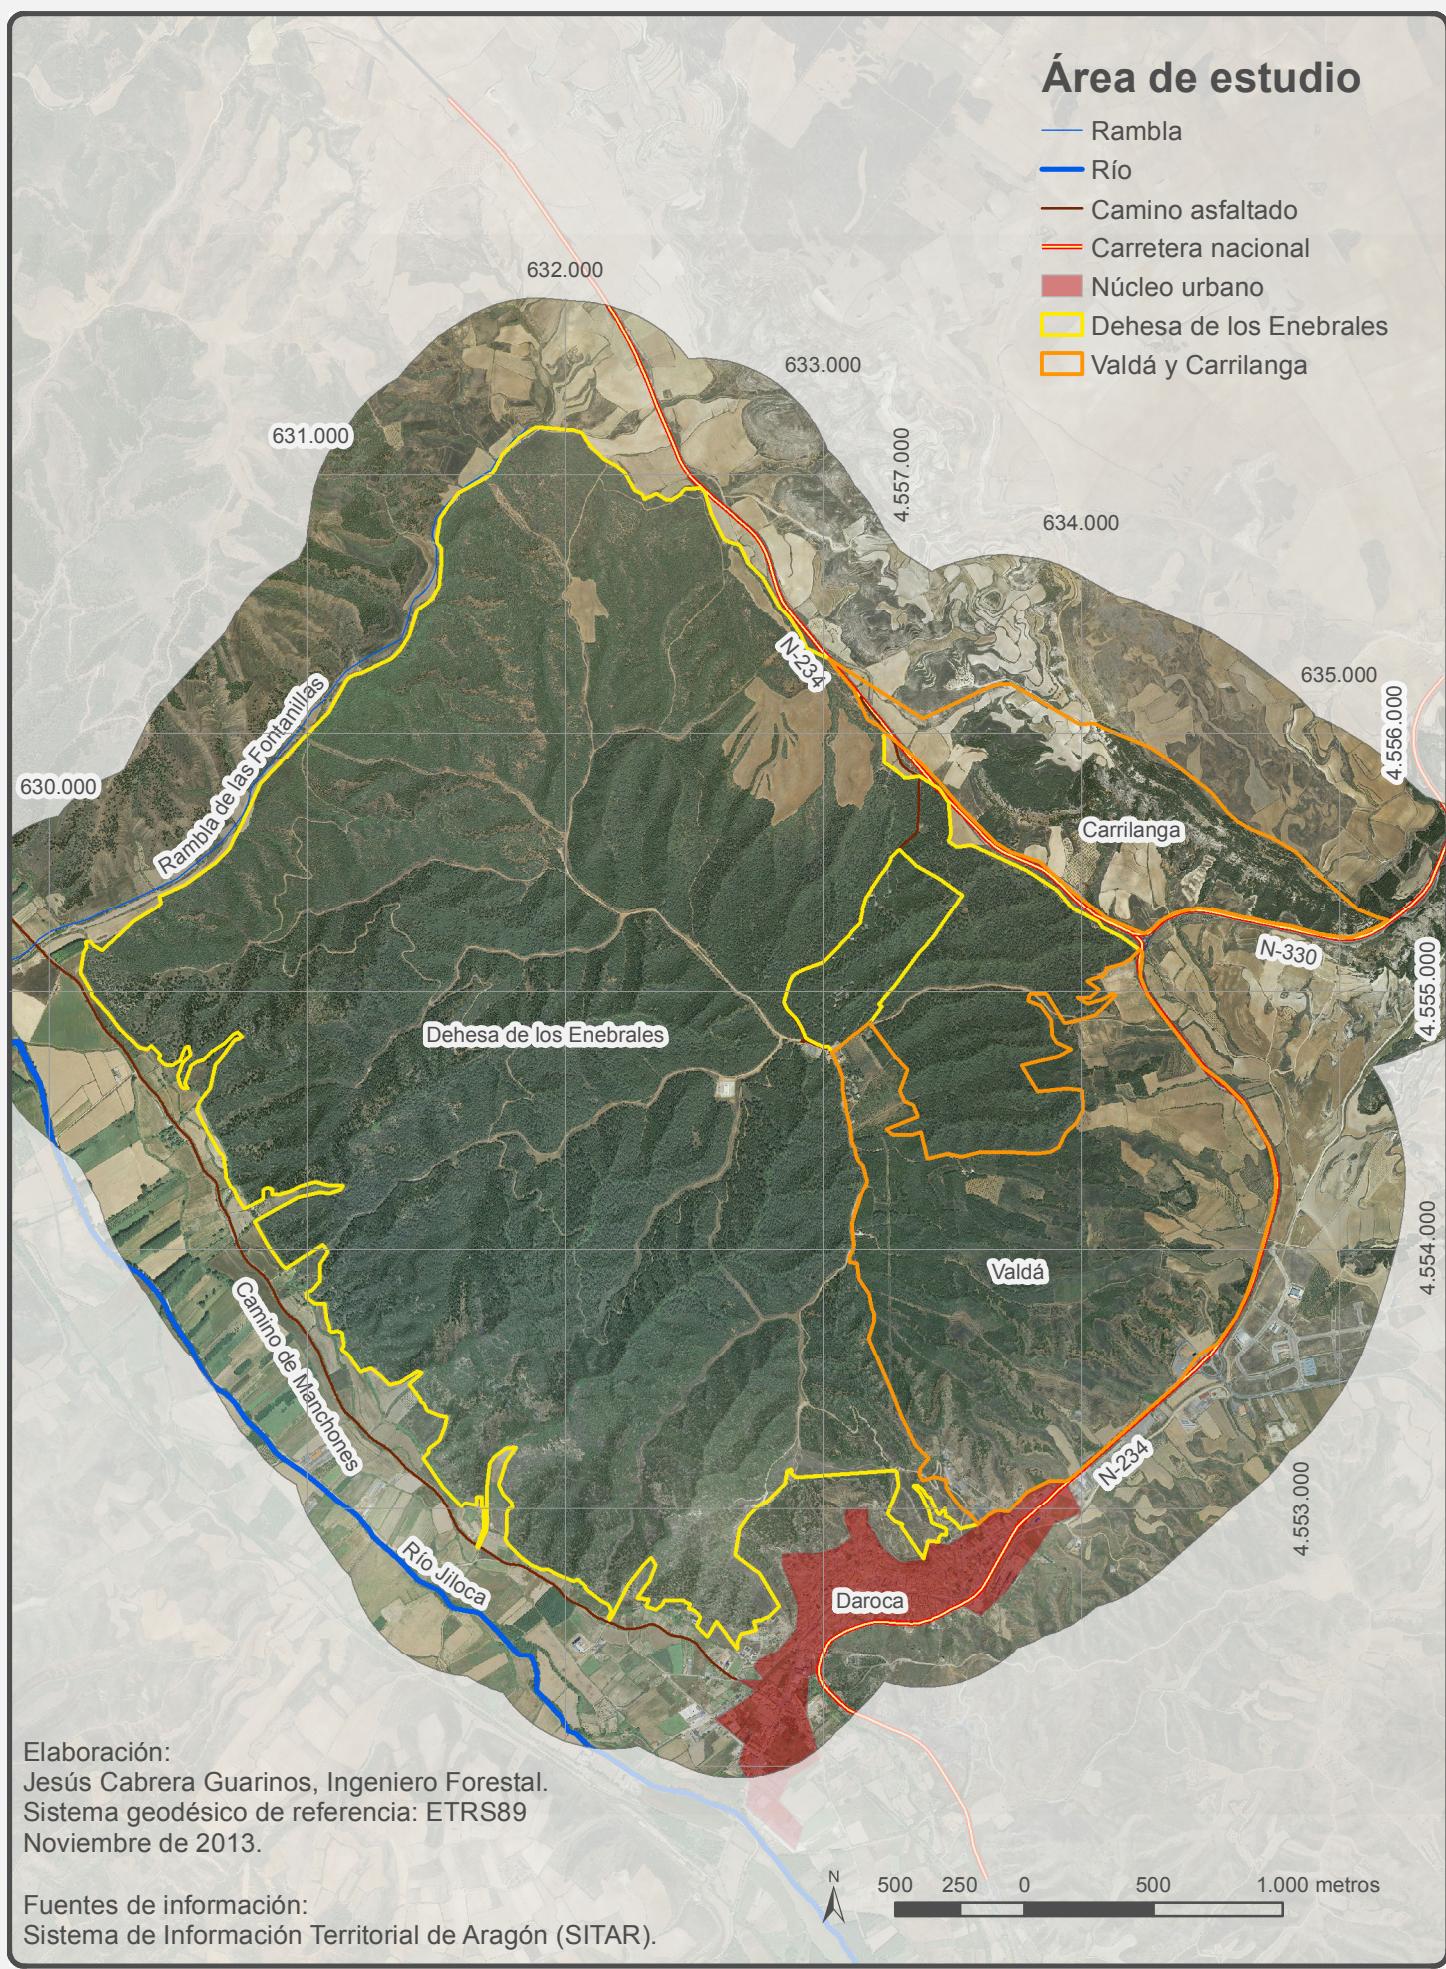
Mapa 8: Área basimétrica estimada.

Mapa 9: Densidad estimada.

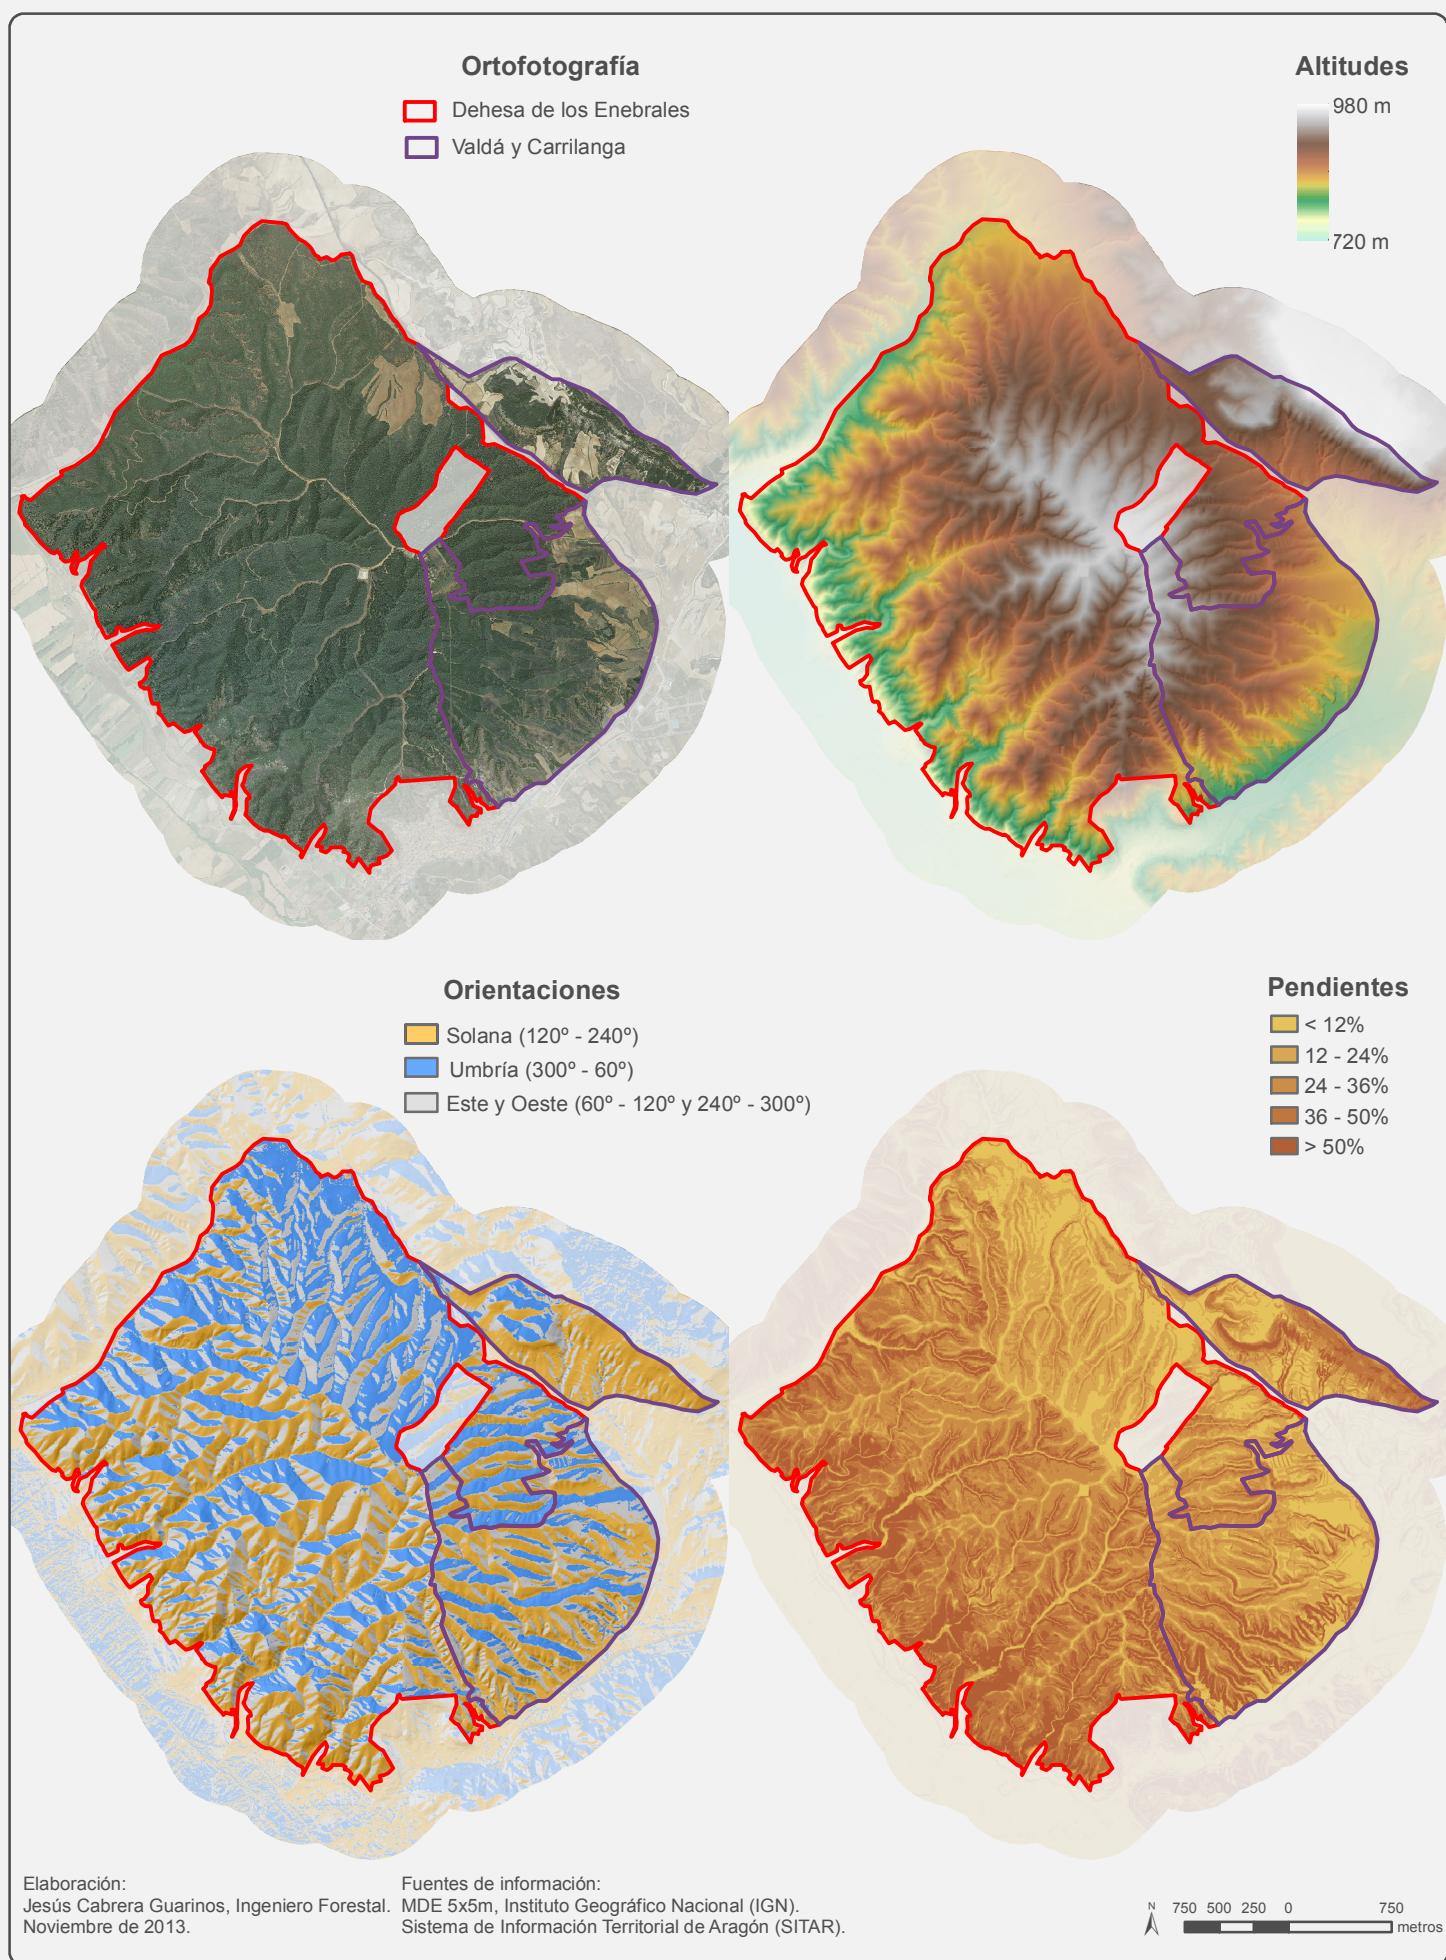
Mapa 10: Altura media estimada.

Mapa 11: Áreas fuera del rango muestral.

Mapa 1: Localización



Mapa 2: Orografía

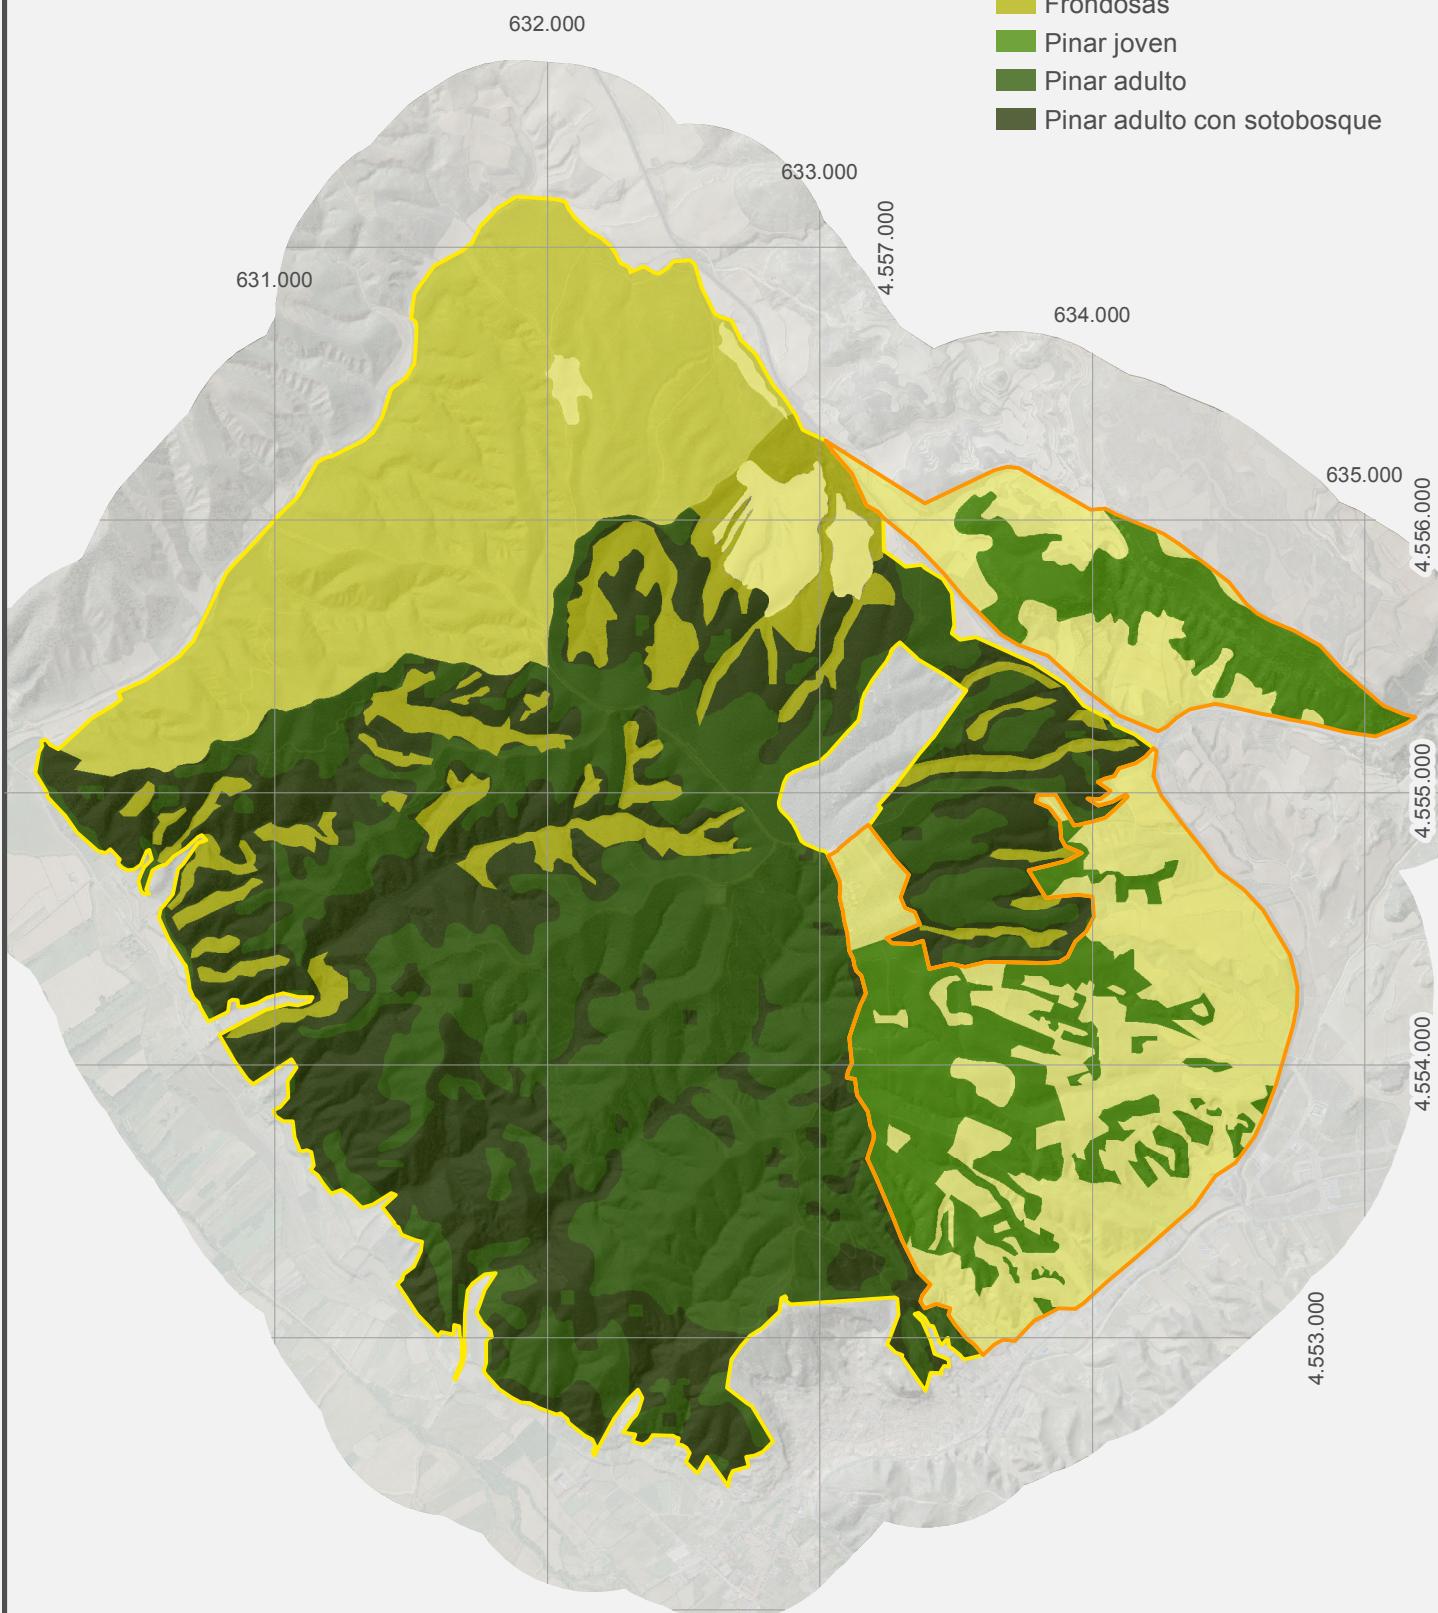


Mapa 3: Vegetación

Área de estudio Formaciones vegetales

Dehesa de los Enebrales No repoblado
Valdá y Carrilanga

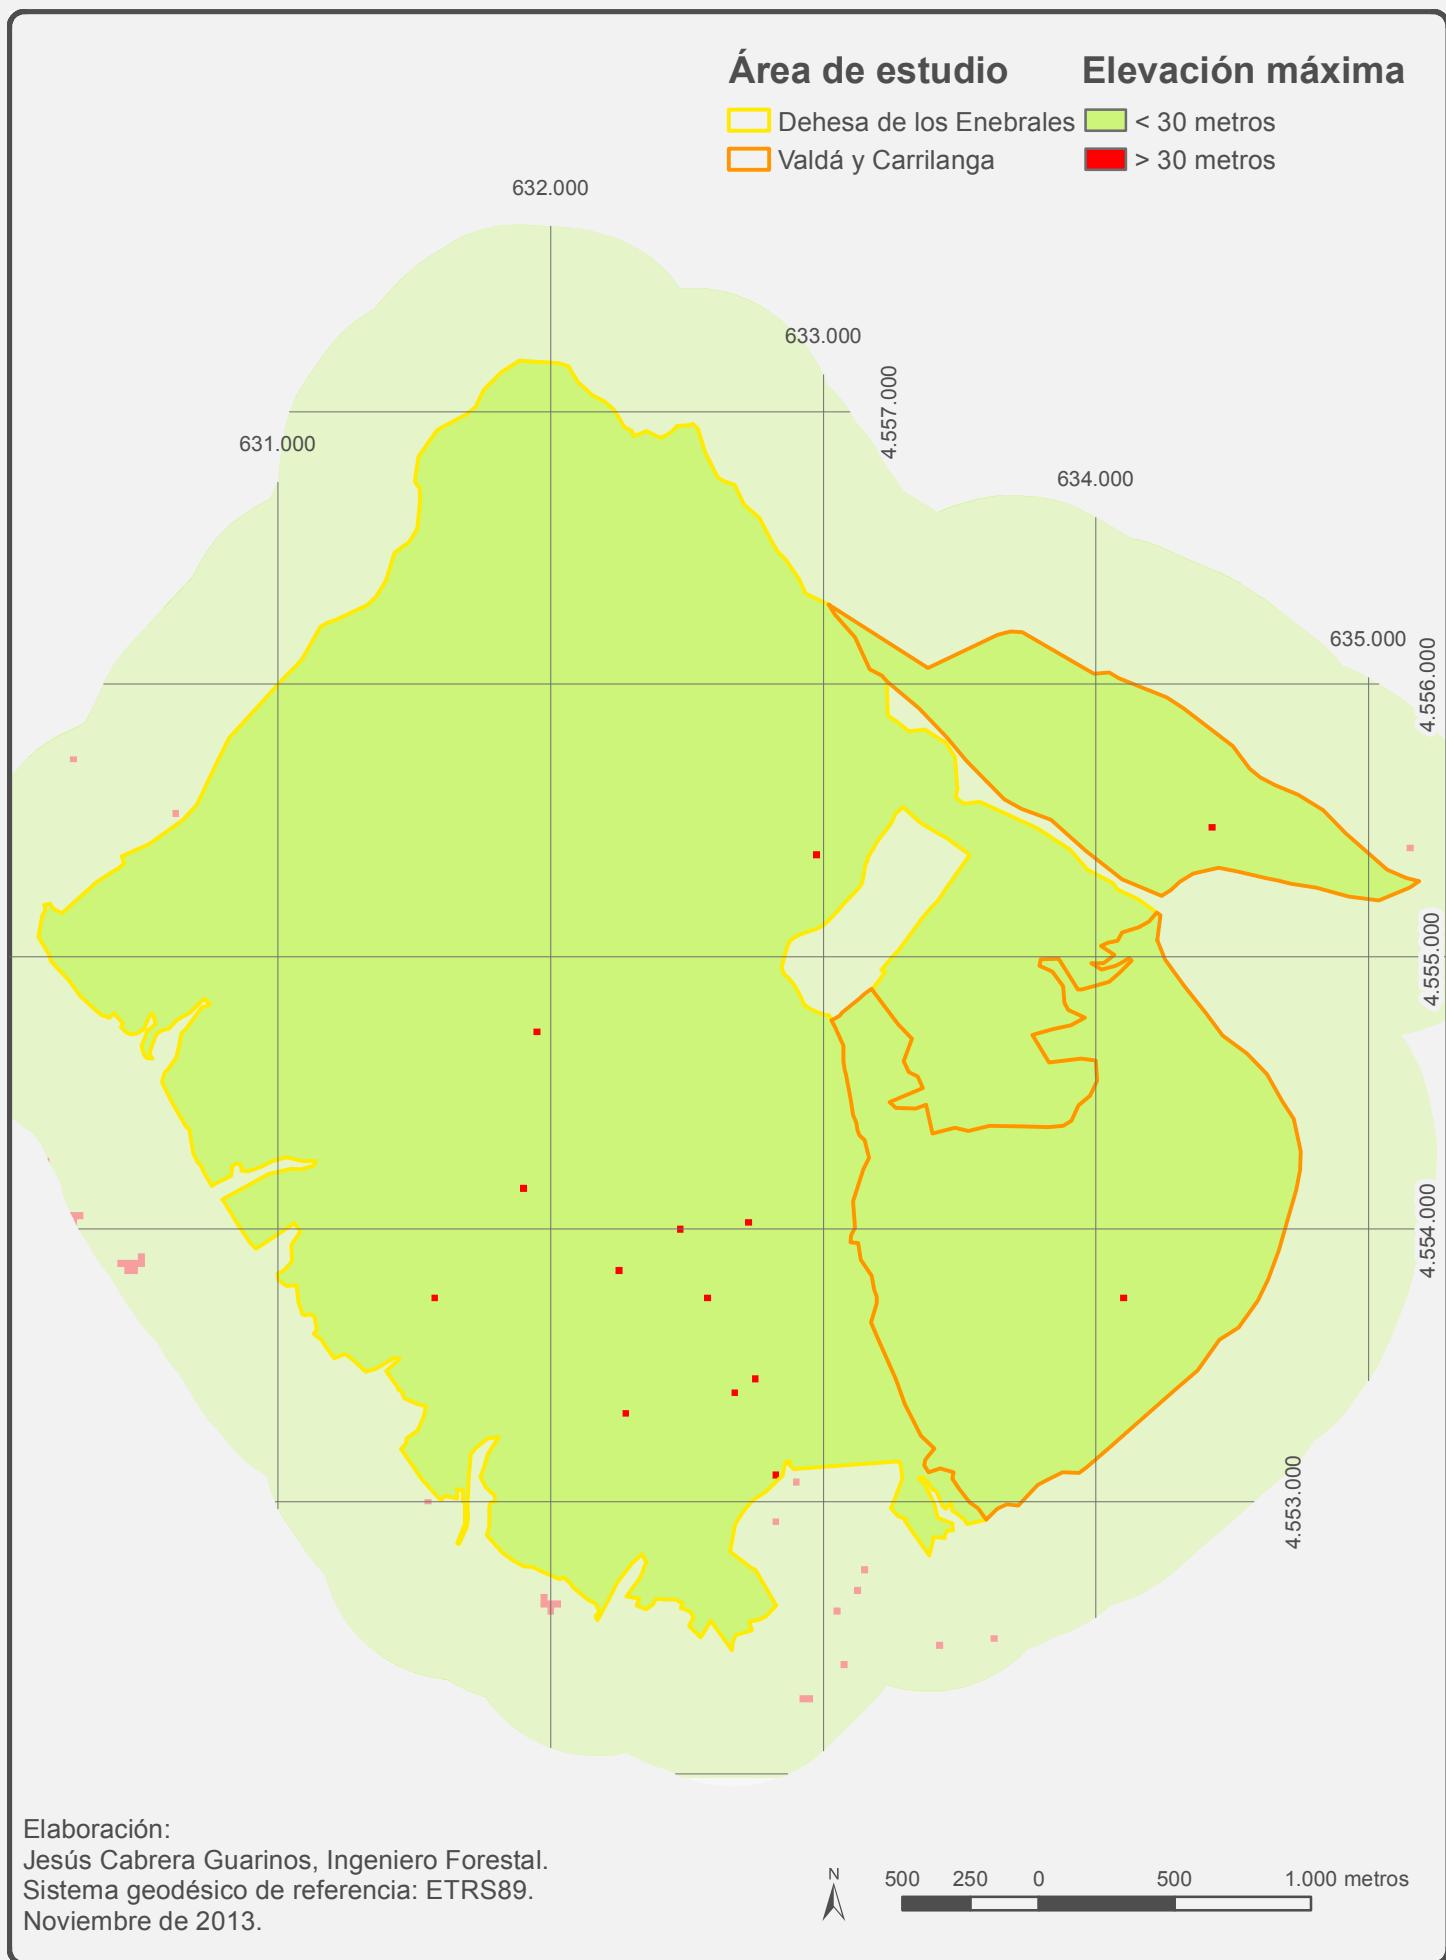
Masa mixta
Frondosas
Pinar joven
Pinar adulto
Pinar adulto con sotobosque



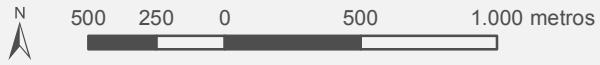
Elaboración:
Jesús Cabrera Guarinos, Ingeniero Forestal.
Sistema geodésico de referencia: ETRS89.
Noviembre de 2013.

N 500 250 0 500 1.000 metros

Mapa 4: Ruido Información LiDAR



Elaboración:
Jesús Cabrera Guarinos, Ingeniero Forestal.
Sistema geodésico de referencia: ETRS89.
Noviembre de 2013.



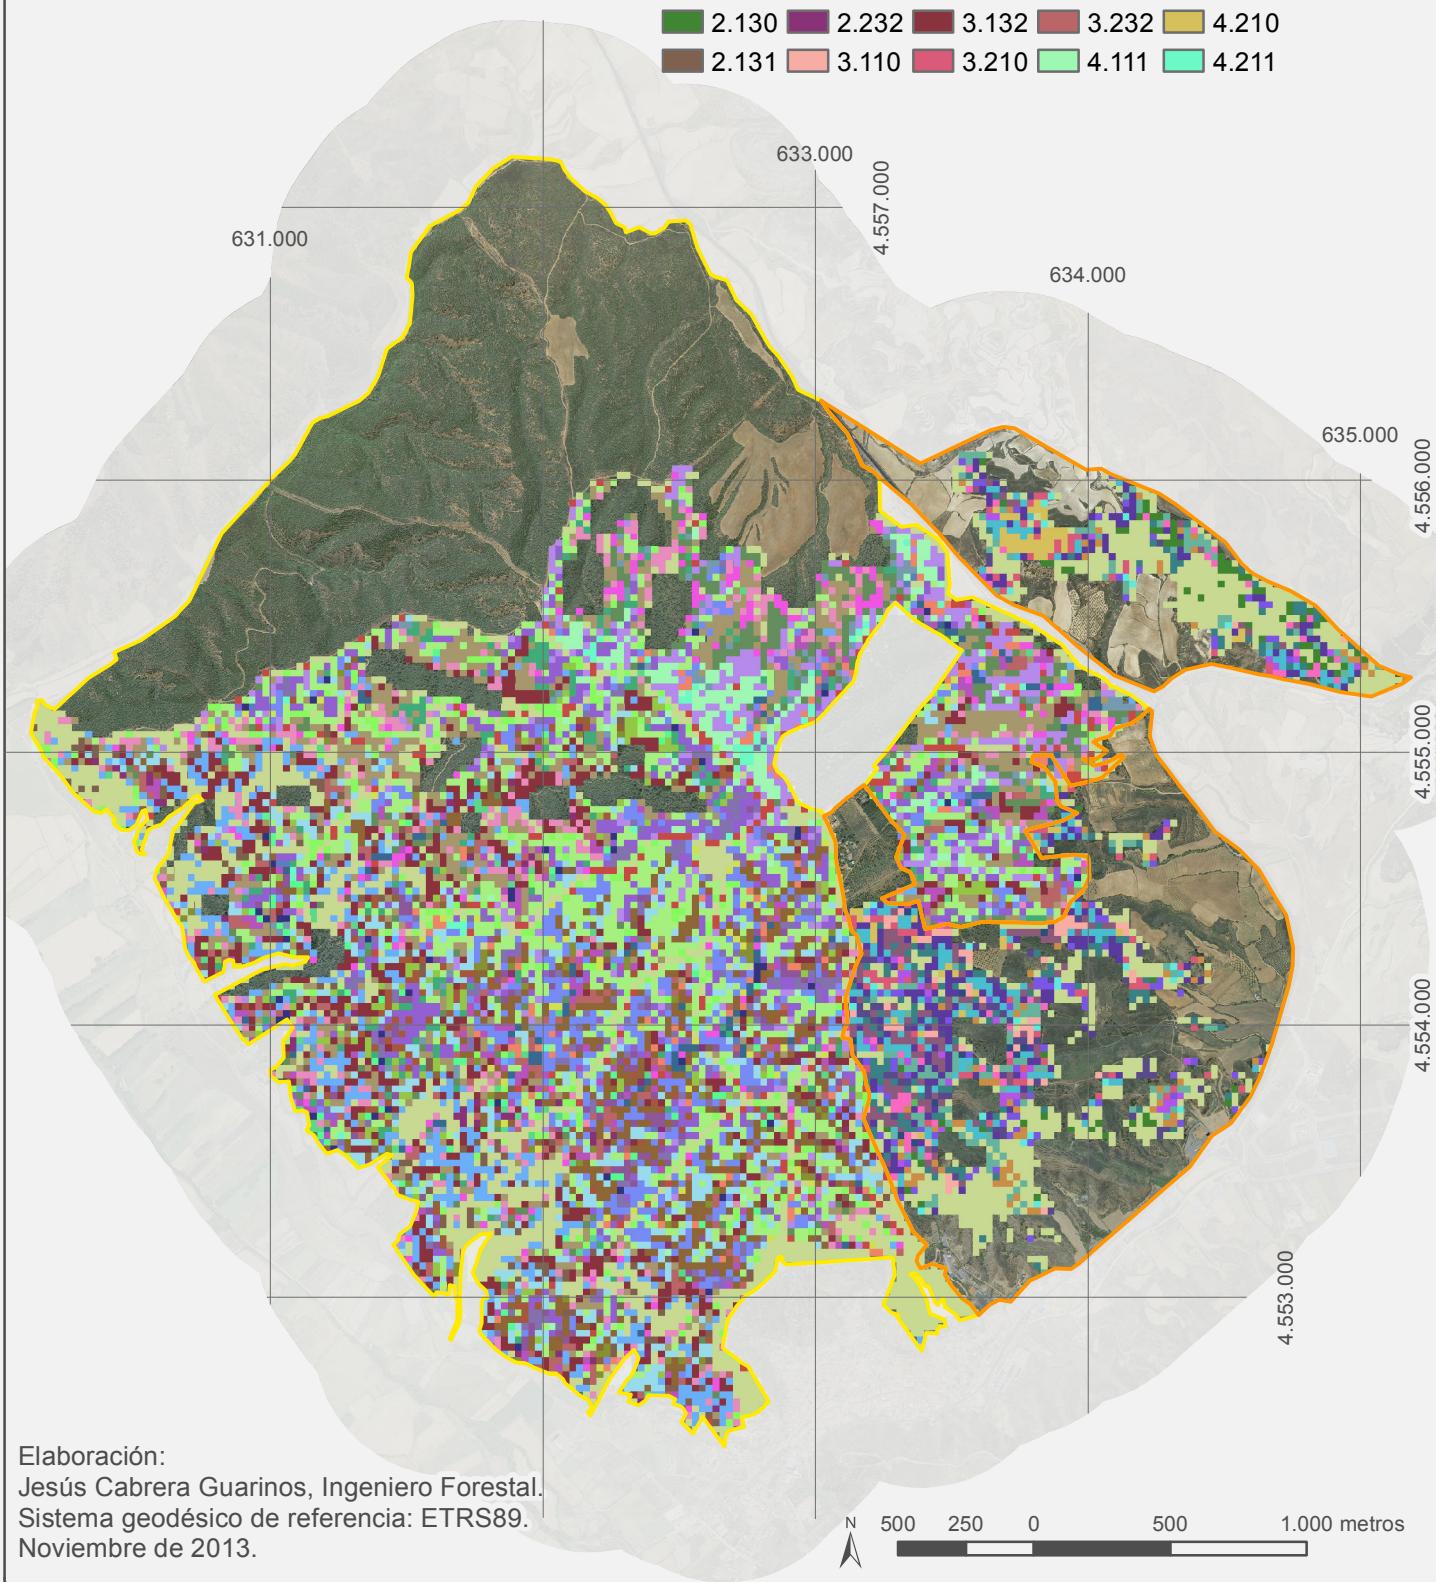
Mapa 5: Áreas Homogéneas

Área de estudio

Dehesa de los Enebrales
Valdá y Carrilanga

Categorías

1.xxx	2.132	3.111	3.211	4.112	4.212
2.110	2.210	3.112	3.212	4.120	4.220
2.111	2.220	3.120	3.220	4.121	4.221
2.112	2.221	3.121	3.221	4.122	4.222
2.120	2.222	3.122	3.222	4.130	4.230
2.121	2.230	3.130	3.230	4.131	4.231
2.122	2.231	3.131	3.231	4.132	4.232
2.130	2.232	3.132	3.232	4.210	
2.131	3.110	3.210	4.111	4.211	



Mapa 6: Parcelas Inventariadas

Área de estudio

632.000

633.000

631.000

634.000

635.000

4.557.000

4.556.000

4.555.000

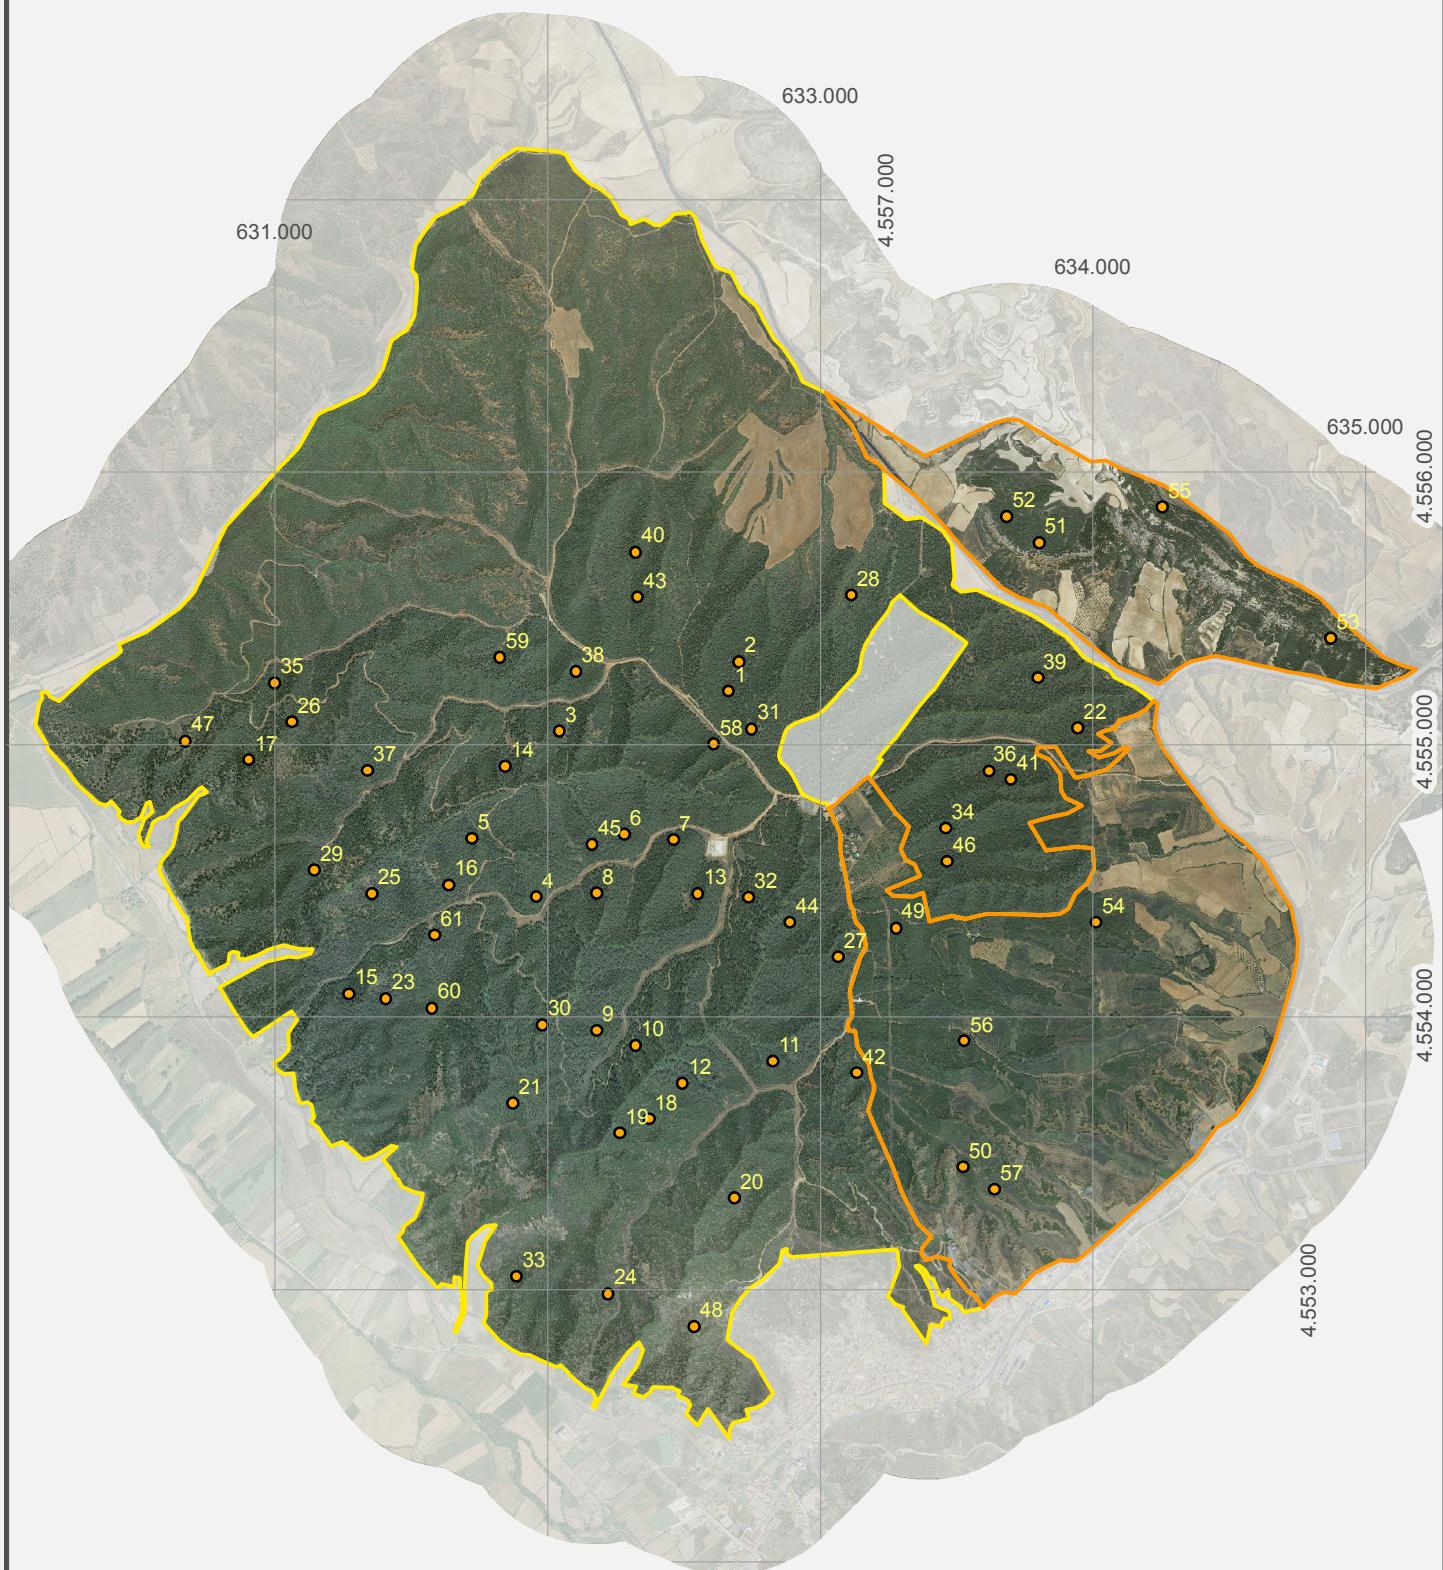
4.554.000

Dehesa de los Enebrales
Valdá y Carrilanga

Localización parcelas

Parcela inventariada

Número de parcela



Elaboración:

Jesús Cabrera Guarinos, Ingeniero Forestal.

Sistema geodésico de referencia: ETRS89.

Noviembre de 2013.



500 250 0 500 1.000 metros

Mapa 7: Volumen estimado

Área de estudio Volumen estimado (m^3/ha)

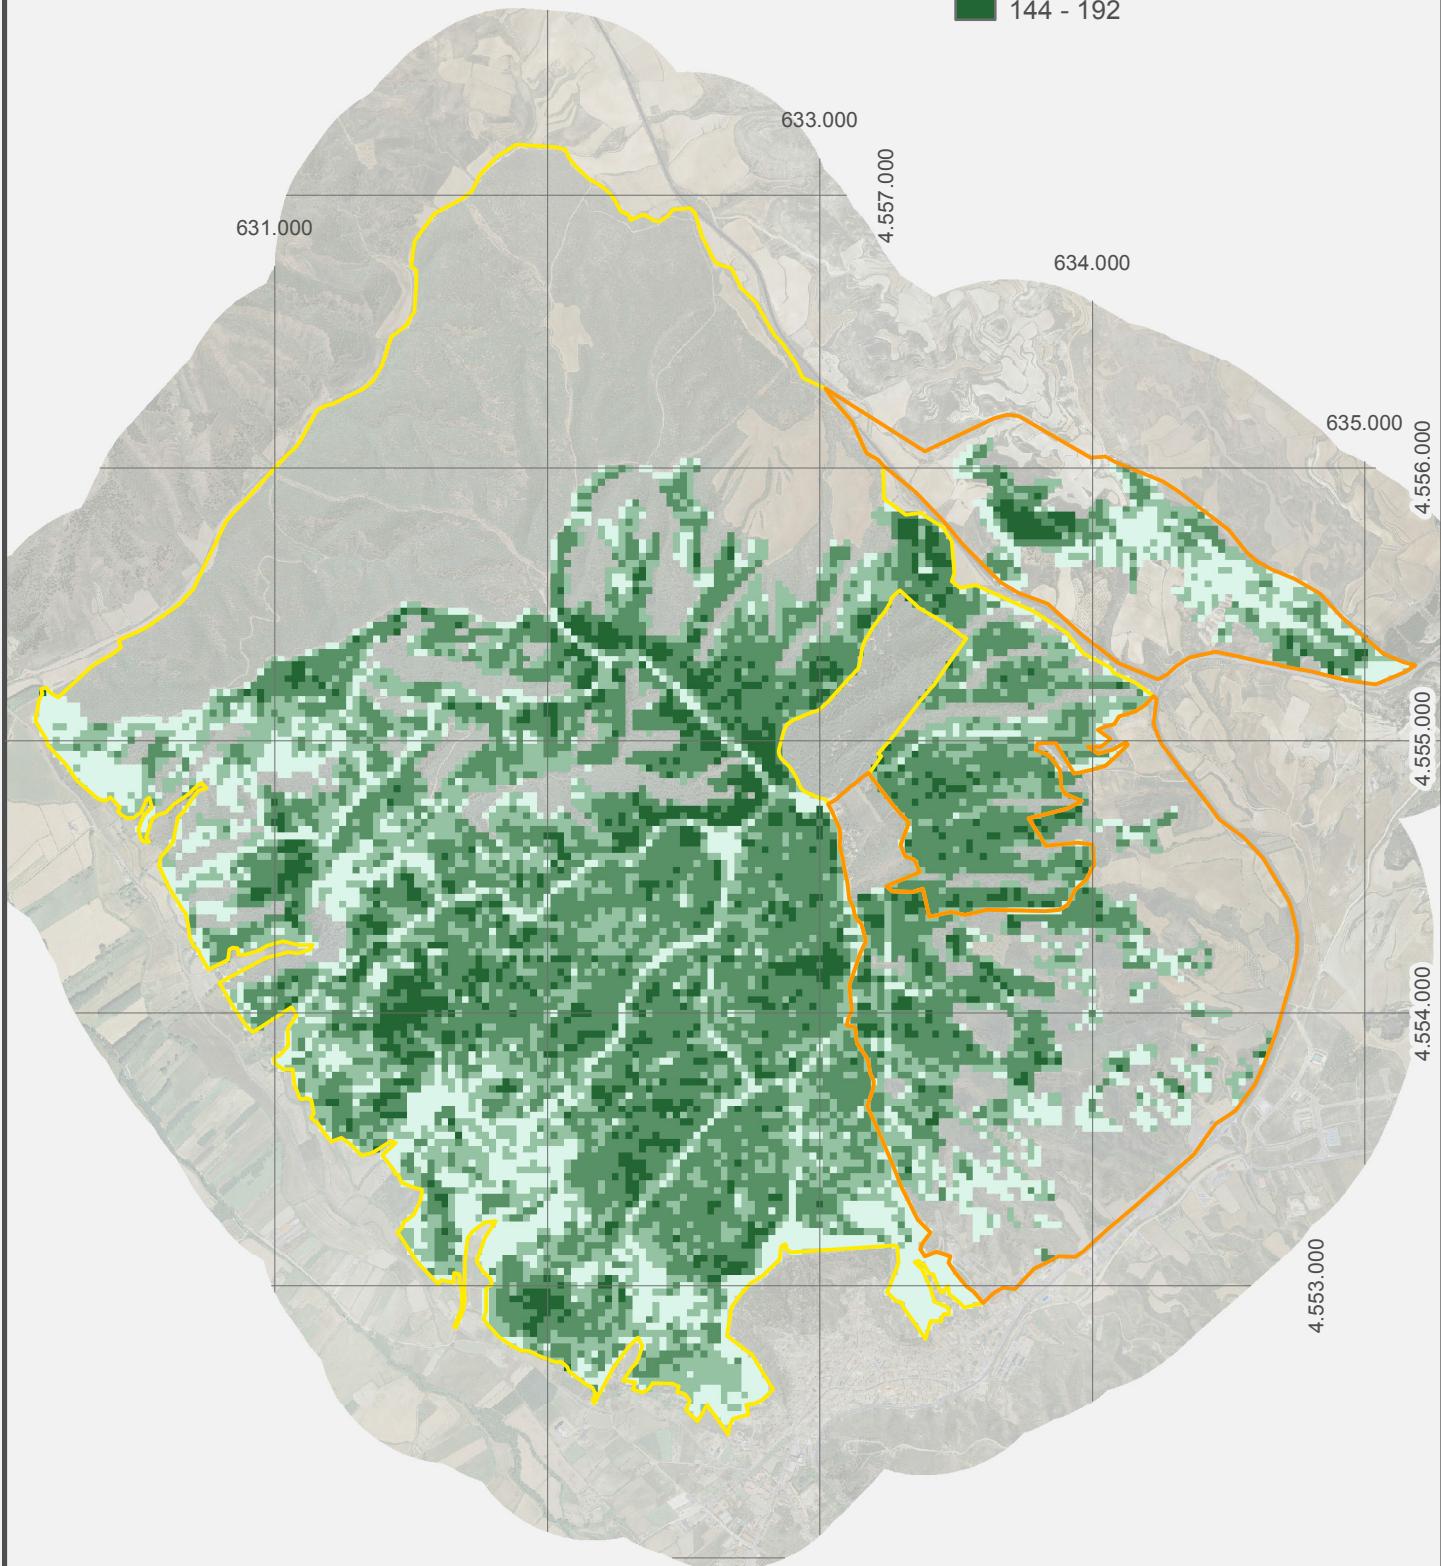
Dehesa de los Enebrales < 48

Valdá y Carrilanga 48 - 96

632.000

96 - 144

144 - 192



Elaboración:

Jesús Cabrera Guarinos, Ingeniero Forestal.

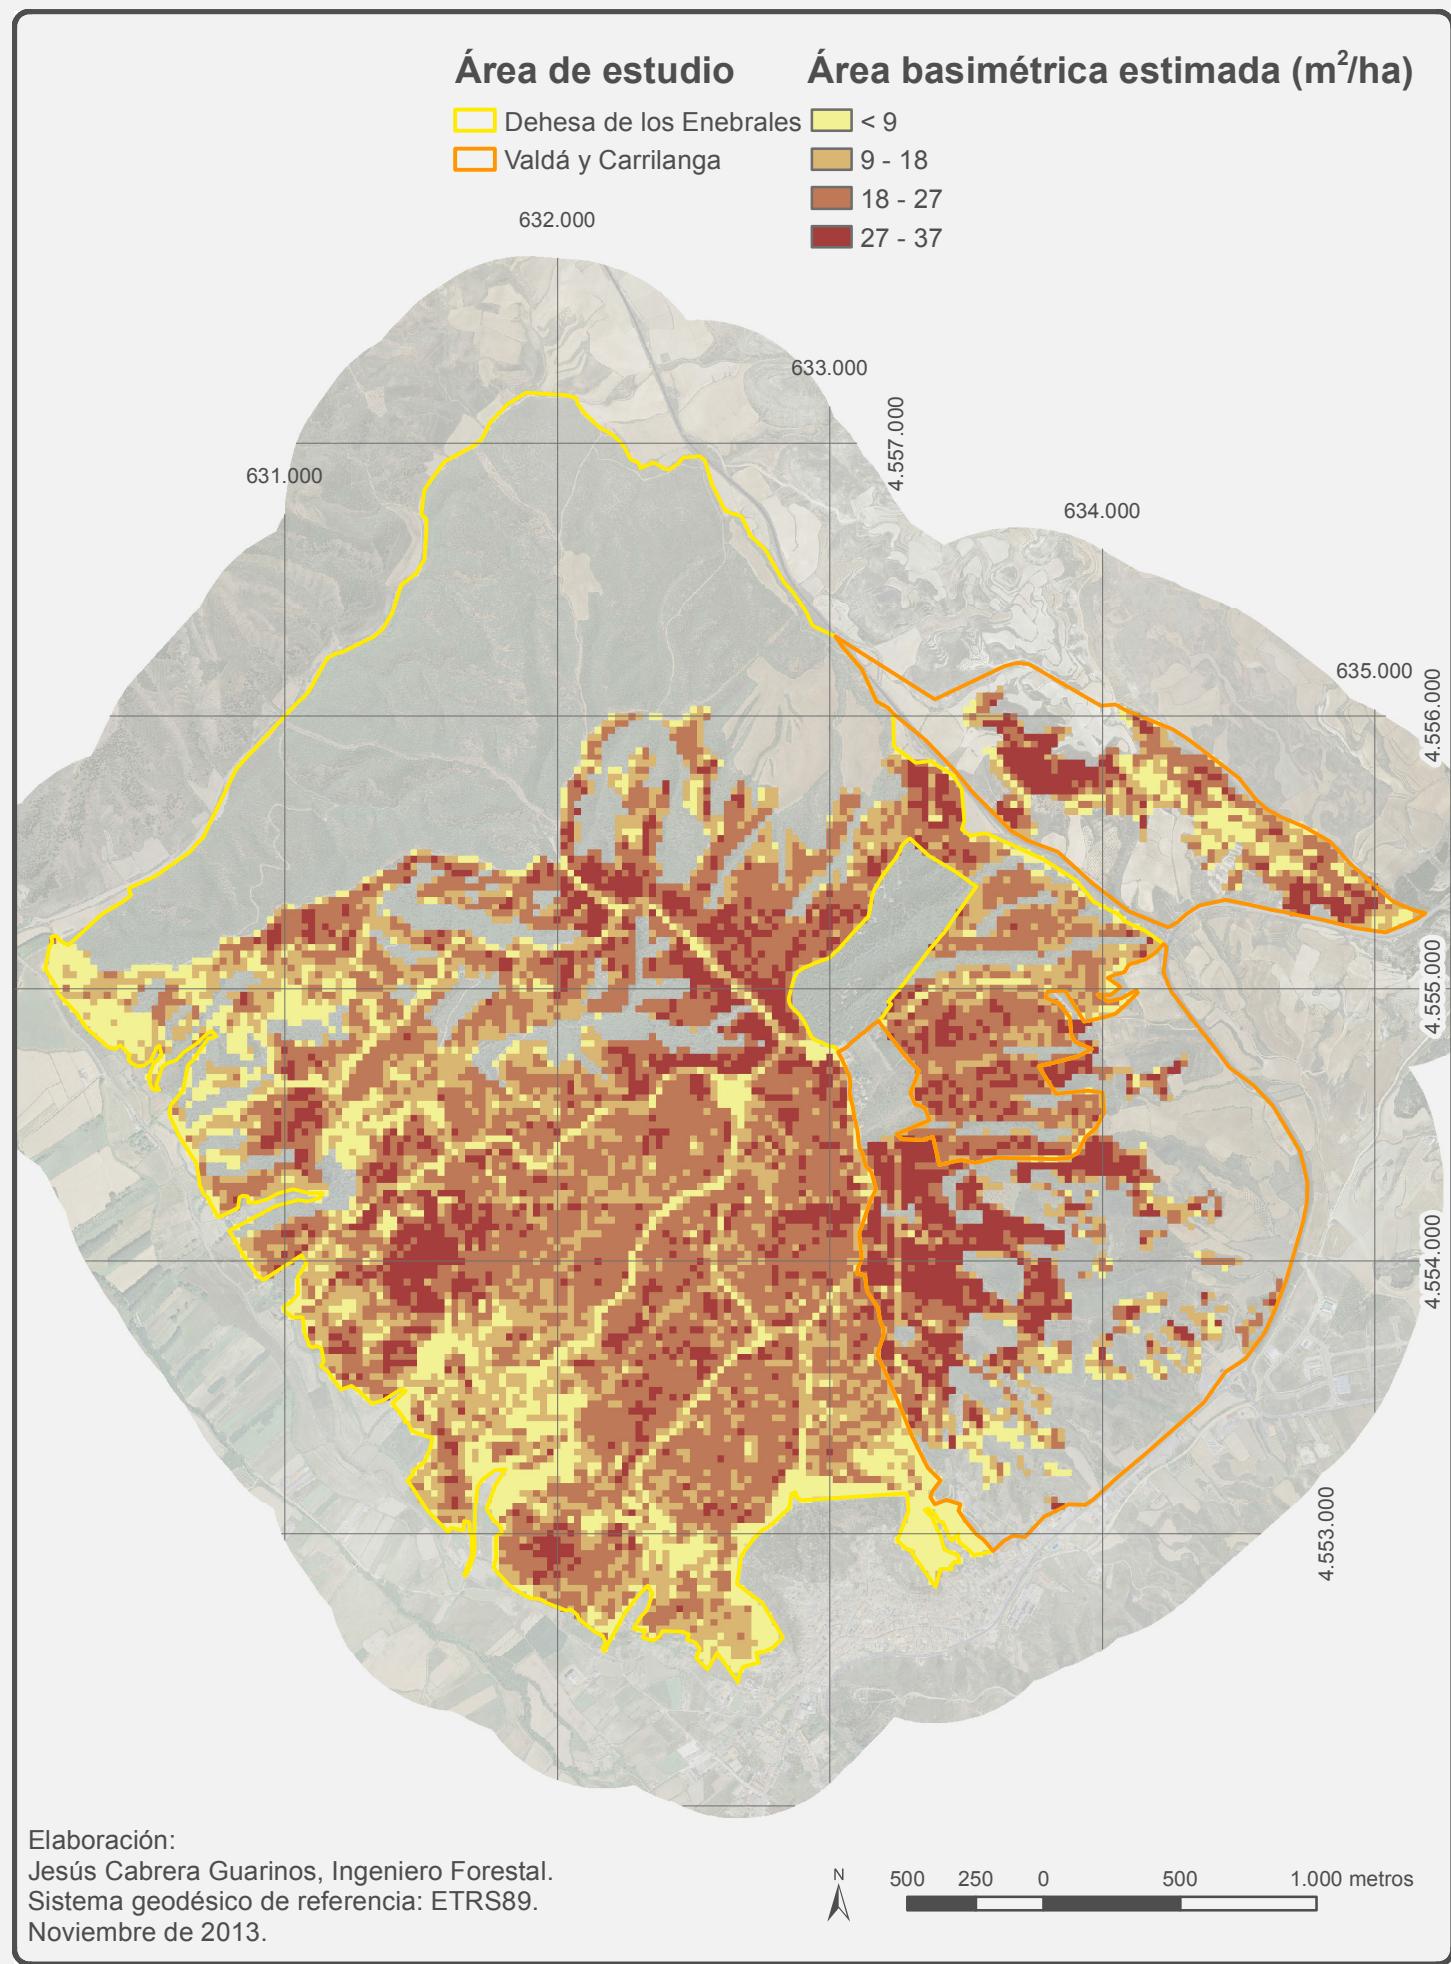
Sistema geodésico de referencia: ETRS89.

Noviembre de 2013.

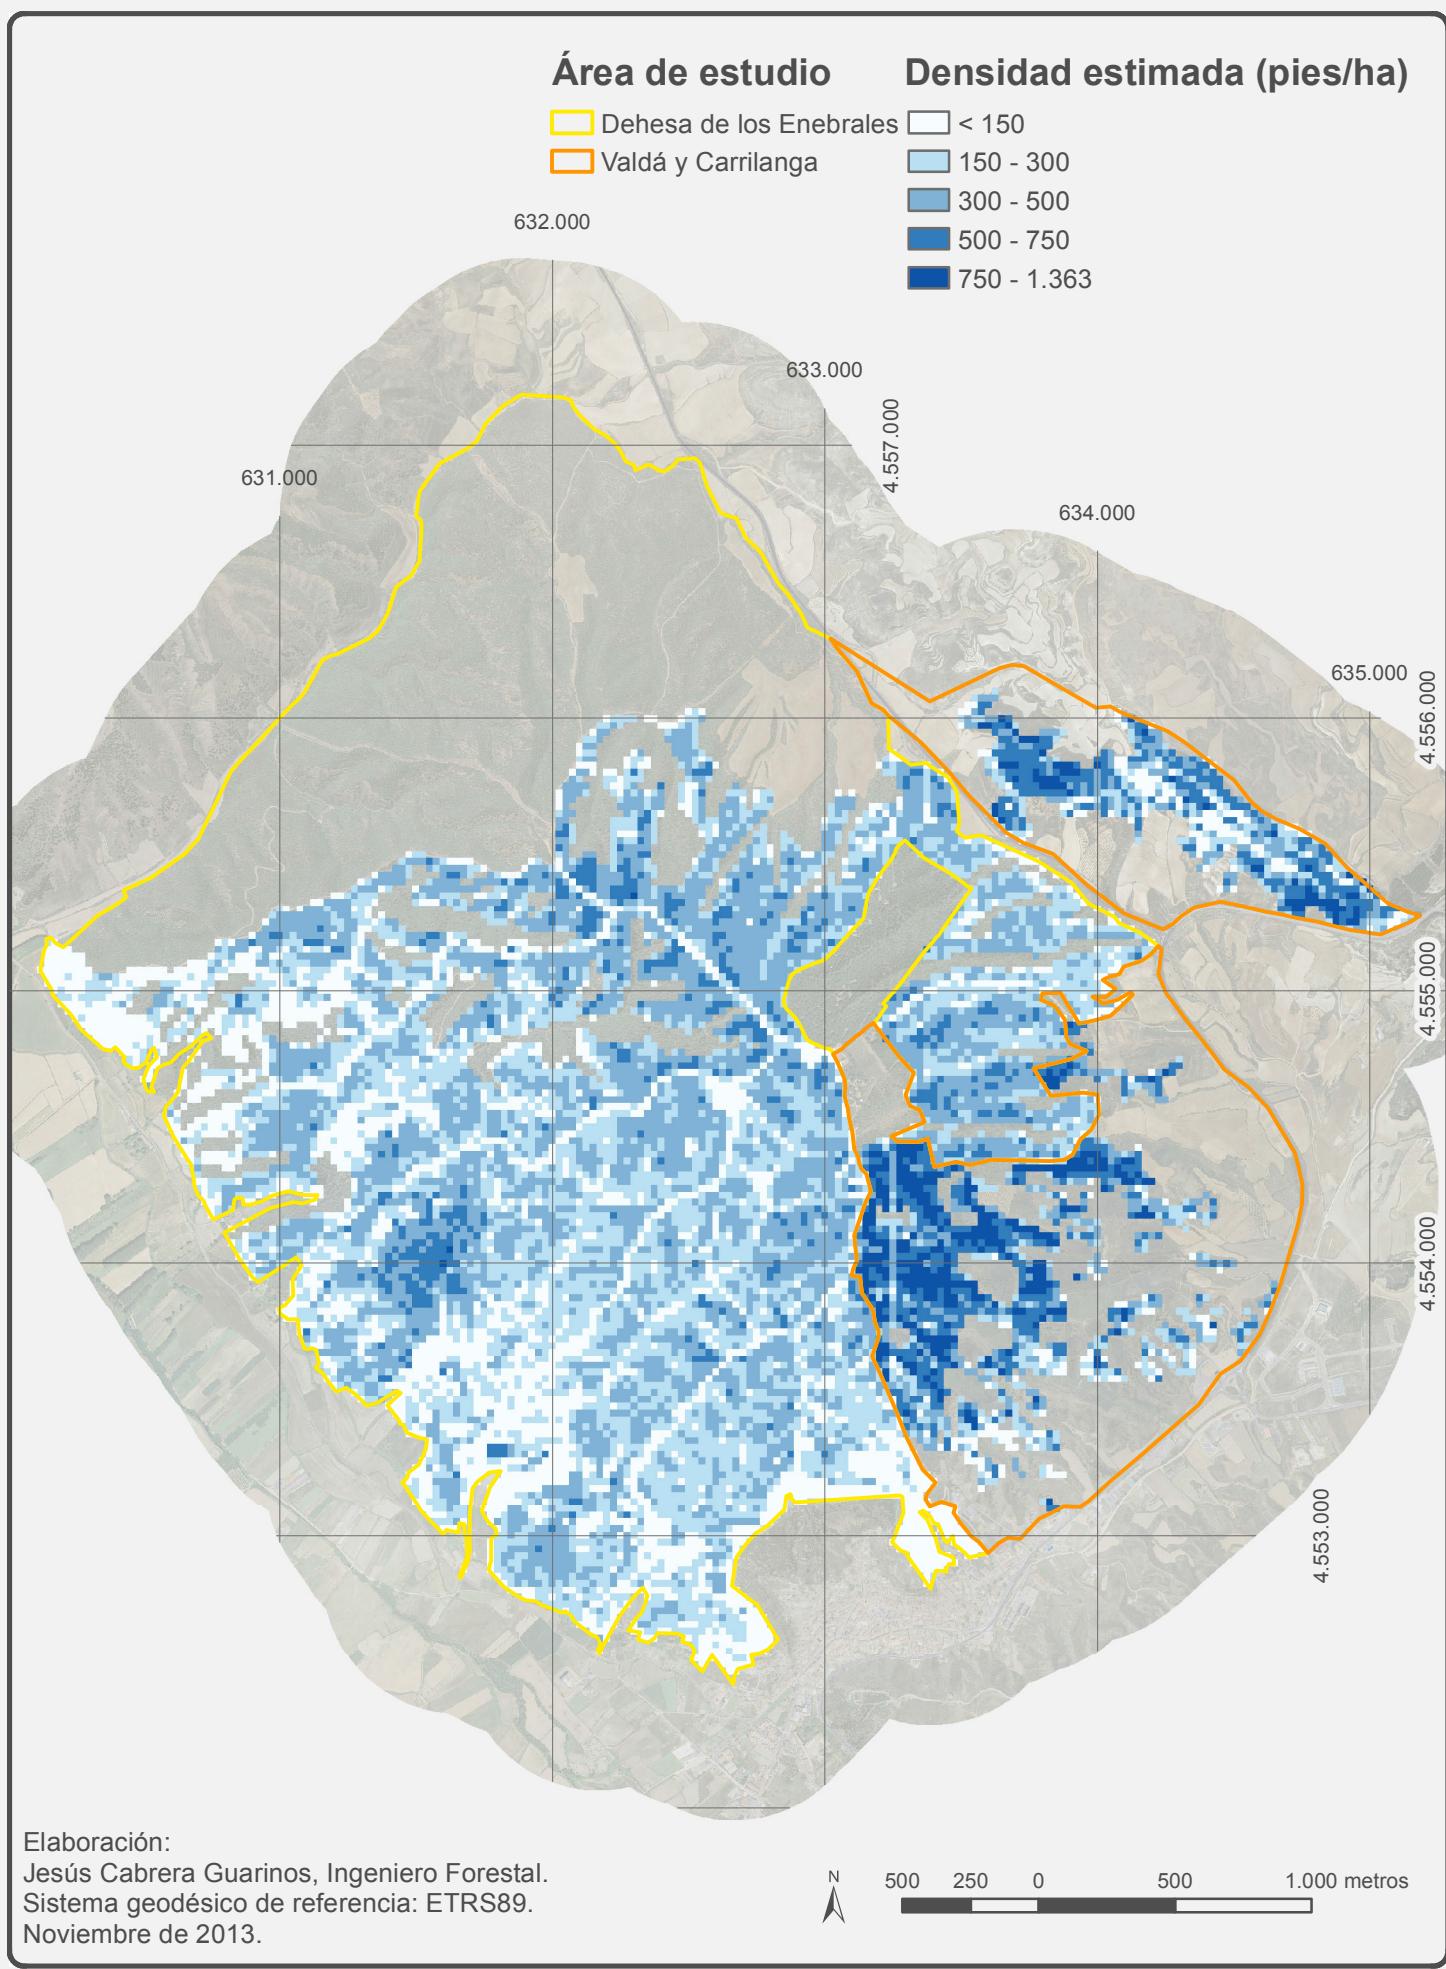


500 250 0 500 1.000 metros

Mapa 8: Área basimétrica estimada



Mapa 9: Densidad estimada



Mapa 10: Altura media estimada

Área de estudio Altura media estimada (m)

Dehesa de los Enebrales	< 9,5
Valdá y Carrilanga	9,5 - 12
	12 - 14,5
	14,5 - 19

632.000

633.000

4.557.000

634.000

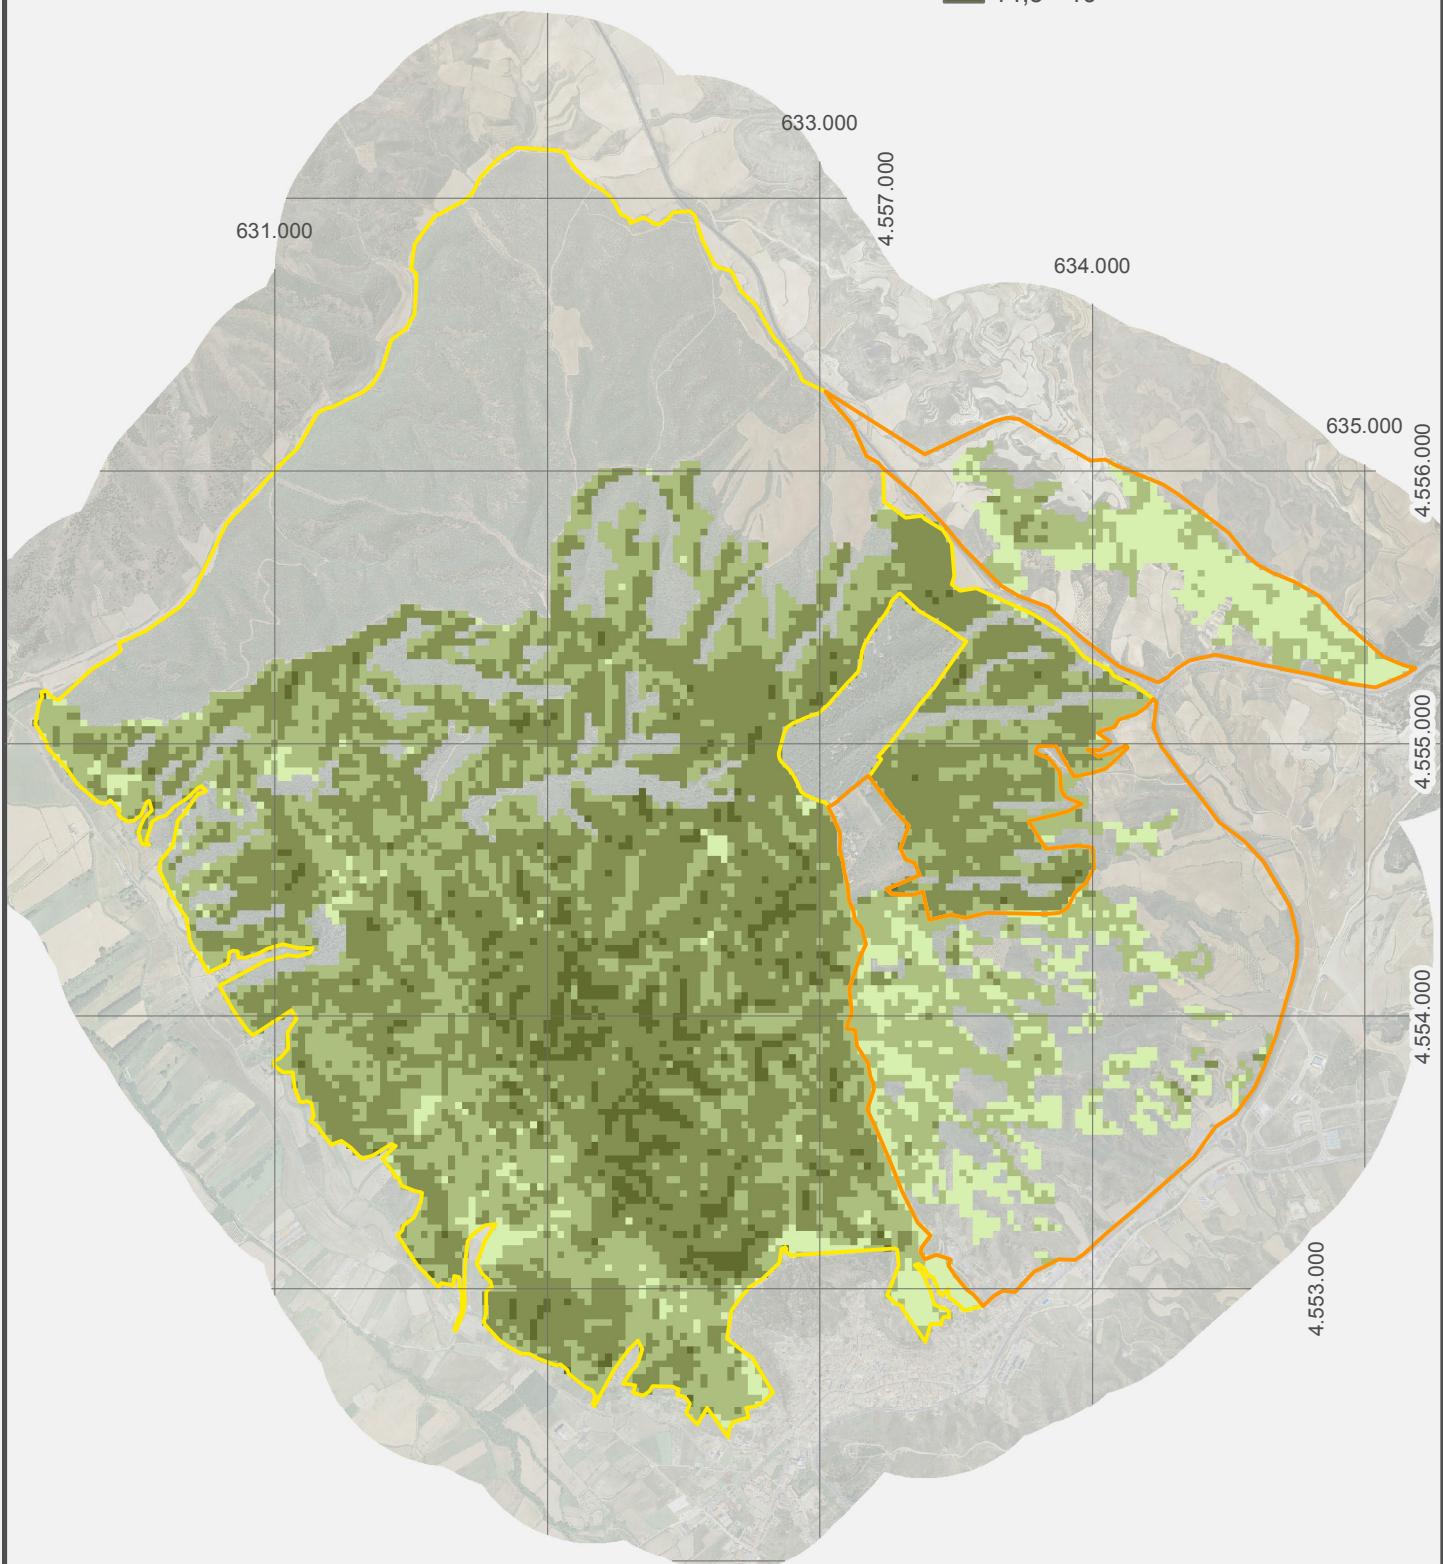
635.000

4.556.000

4.555.000

4.554.000

4.553.000



Elaboración:

Jesús Cabrera Guarinos, Ingeniero Forestal.

Sistema geodésico de referencia: ETRS89.

Noviembre de 2013.

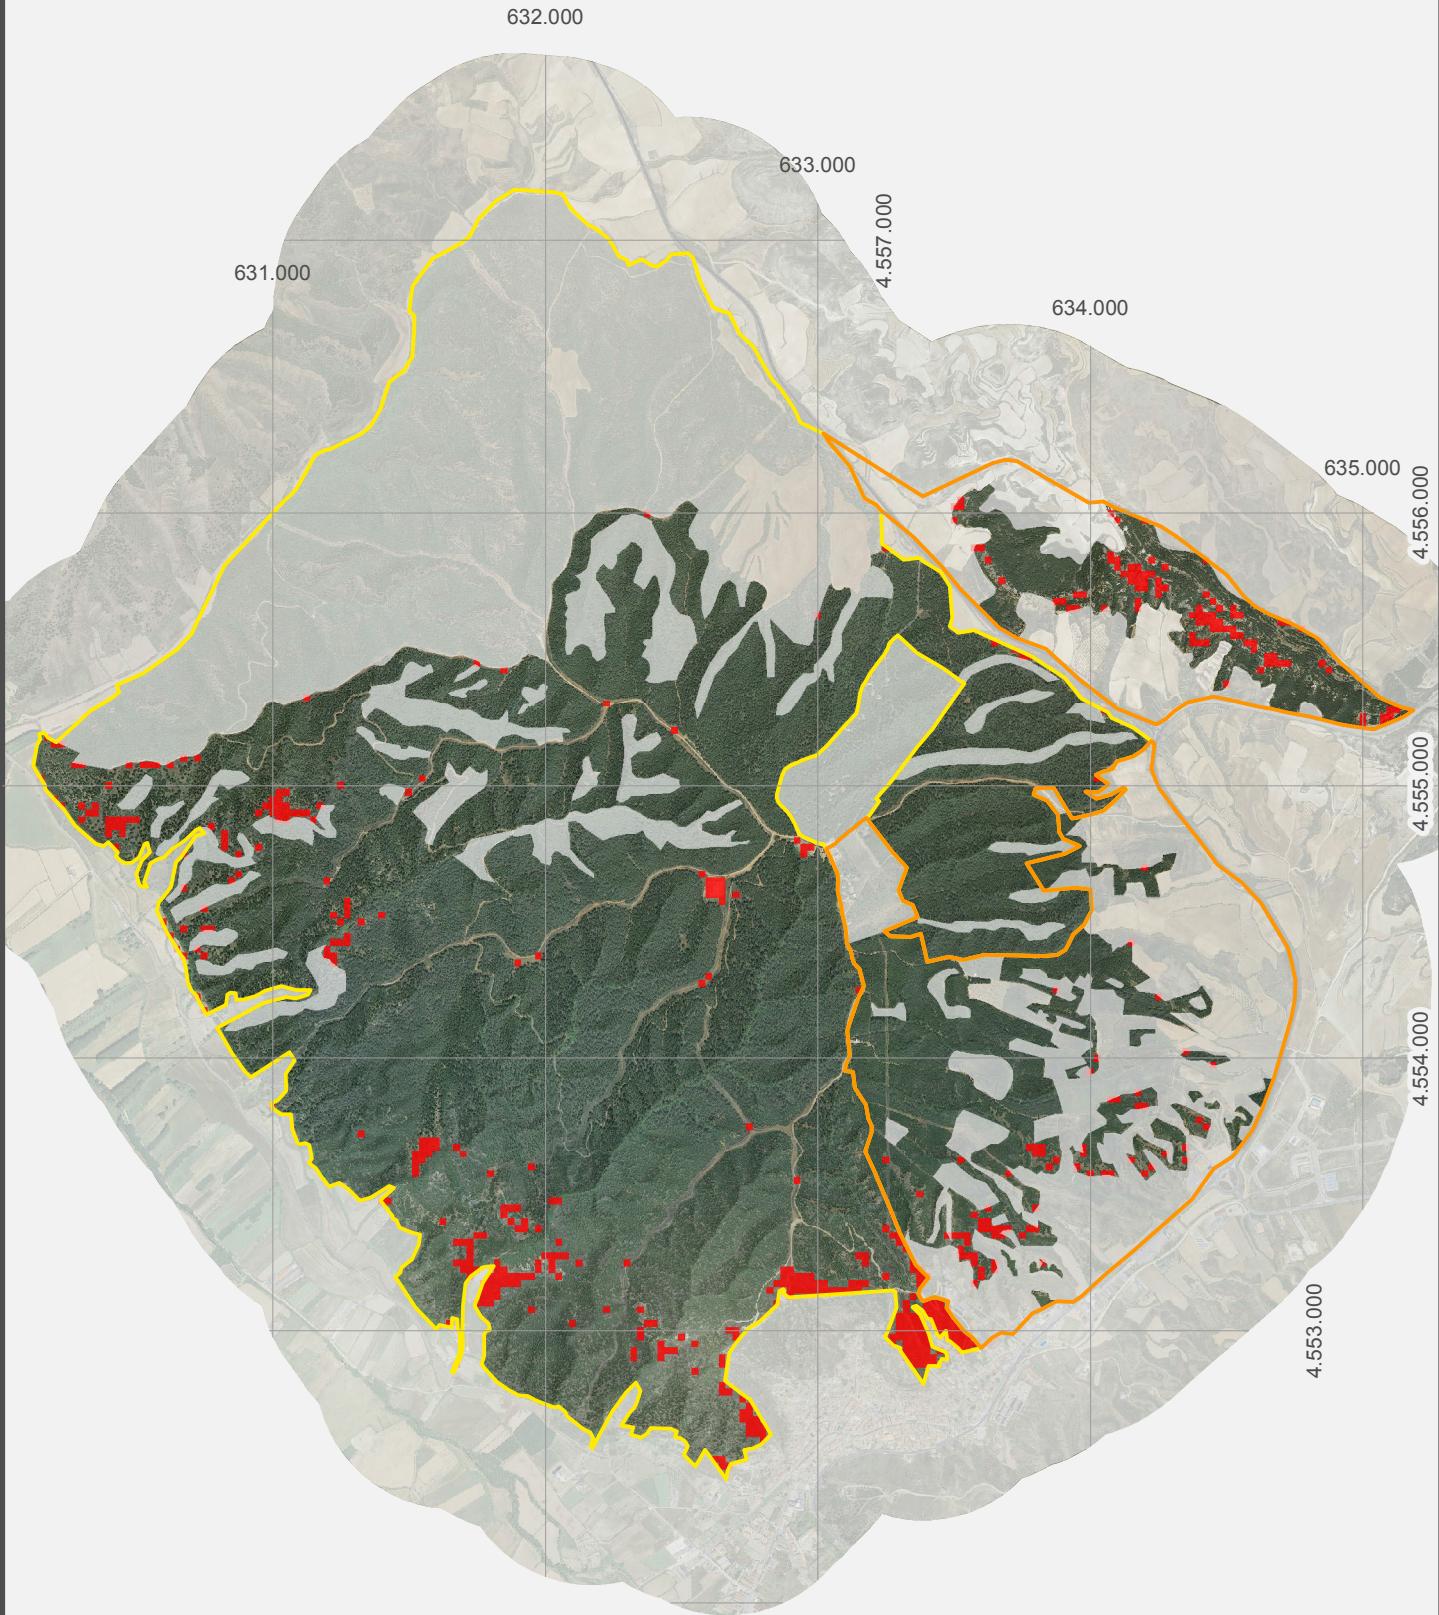


500 250 0 500 1.000 metros

Mapa 11: Áreas fuera del rango muestral

Área de estudio Estimación volumen

Dehesa de los Enebrales Áreas fuera del rango muestral
Valdá y Carrilanga



Elaboración:
Jesús Cabrera Guarinos, Ingeniero Forestal.
Sistema geodésico de referencia: ETRS89.
Noviembre de 2013.

N 500 250 0 500 1.000 metros

Anexo 2: Descripción funcional del software FUSION.

A continuación, se describe el procedimiento seguido para la ejecución de las herramientas del software FUSION, empleadas en el tratamiento de datos LiDAR. Para ejecutar cada herramienta es necesario crear un archivo de comandos en formato “.bat”. Este archivo debe ubicarse en una subcarpeta dentro de la carpeta de instalación del software FUSION.

Para ejecutar el comando desde esta propia carpeta, sin necesidad de llevarlo al intérprete de comandos (cmd.exe) de Windows, es necesario que, como prefijo de cada comando agreguemos “..”. Así, bastará con hacer doble “click” en cada uno, para que se ejecute automáticamente en el intérprete de comandos. El “..” simplemente hace que el comando se ejecute en la carpeta superior, que en este caso será la de instalación de FUSION, donde se debe ejecutar el comando.

Comandos:

- GroundFilter:

La arquitectura del comando es la siguiente:

GroundFilter [switches] (output file) (cell size) (input file)

Este es el comando que finalmente se empleó:

..\\GroundFilter /wparam:2 /gparam:-2,5 Ruta\\suelo.las 1 Ruta*.las

En la siguiente tabla se muestra el significado de cada variable del comando:

Tabla 27. Variables comando GroundFilter.

outputfile	El nombre del archivo LIDAR de salida con los puntos “suelo”.
cellsize	Tamaño de celda para el modelo de superficie intermedio.
datafile	Archivo LIDAR con los datos en “bruto”, sin clasificar, en formato *.las.

Indicando “*.las” como archivo de entrada, el comando se ejecuta tomando todos los archivos de ese formato presentes en la ruta indicada.

Los “switches” son posibles variantes que pueden ser aplicadas en la ejecución del comando.

En este caso los “switches” empleados para el comando Groundfilter fueron los siguientes:

Tabla 28. “switches” empleados en el comando GroundFilter.

gparam:#	Valor del parámetro g para la ecuación de asignación de pesos. El valor por defecto es -2,0.
wparam:#	Valor del parámetro w para la ecuación de asignación de pesos. El valor por defecto es 2,5.

- GridSurfaceCreate:

La arquitectura del comando es la siguiente:

GridSurfaceCreate [switches] (surfacefile) (cellsize) (xyunits) (zunits) (coordsys zone) (horizdatum) (vertdatum) (inputfile)

Este es el comando que finalmente se empleó:

..\\GridSurfaceCreate RUTA\\Suelo.dtm 1 m m 1 0 0 0 RUTA\\Suelo.las

En la siguiente tabla se muestra el significado de cada variable del comando:

Tabla 29. Variables comando GridSurfaceCreate.

surfacefile	Nombre del archivo de salida (*.dtm).
cellsize	Tamaño de la celda de la malla de la superficie.
xyunits	Unidades de los datos LIDAR X e Y: "m" para metros "f" para pies.
zunits	Unidades de los datos LIDAR X e Y: "m" para metros "f" para pies.
coordsys	Sistemas de coordenadas: 0 para desconocido 1 para UTM 2 para SPCS
zone	Zona del sistema de coordenadas (uso) 0 para desconocido
horizdatum	Datum horizontal de la zona: 0 para desconocido 1 para NAD27 2 para NAD83
vertdatum	Datum vertical de la zona: 0 para desconocido 1 para NGVD29 2 para NAVD88 3 para GRS80
datafile	Archivo de datos LIDAR (LDA, LAS, ASCII LIDARDAT) del que se extraerá el *.dtm

En este caso no se empleó ningún "switches". A continuación se muestran los disponibles para este comando:

Tabla 30. "switches" comando GridSurfaceCreate.

median:#	Aplica un filtro basado en la mediana, usando # píxeles vecinos.
smooth:#	Aplica un filtro basado en la media, usando # píxeles vecinos.
slope:#	Filtrar áreas de la superficie con pendiente superior a un porcentaje #.
spike:#	Filtrado final de la superficie eliminando salientes con una pendiente superior a un porcentaje #.
residuals	Cálculo de estadísticas de residuos para todos los puntos.
minimum	Usa el punto de menor elevación de cada celda como la elevación de la superficie.

- ClipData:

Para ejecutar este comando, primero se deben obtener las coordenadas de los extremos de todas las parcelas, para después, incluirlas en un mismo comando.

La arquitectura del comando es la siguiente:

ClipData [switches] (InputSpecifier) (SampleFile) (MinX) (MinY) (MaxX) (MaxY)

Este es el comando que finalmente se empleó en la parcela 1:

```
..\clipdata /shape:1 /dtm:RUTA\mde.dtm /height RUTA\*.las RUTA\1.las 632651,389  
4555179,272 632681,389 4555209,272
```

En la siguiente tabla se muestra el significado de cada variable del comando:

Tabla 31. Variables comando ClipData.

InputSpecifier	Datos LIDAR de partida.
SampleFile	Nombre de salida del archivo que contiene el recorte de los datos LIDAR, en nuestro caso serán las parcelas.
MinX MinY	Coordenadas X e Y de la esquina inferior izquierda del rectángulo que contiene la parcela a extraer.
MaxX MaxY	Coordenadas X e Y de la esquina superior derecha del rectángulo que contiene la parcela a extraer.

En este caso los “switches” utilizados para el comando ClipData fueron los siguientes:

Tabla 32. “switches” comando ClipData.

shape:#	Forma de la parcela a extraer: 0 para rectángulo 1 para círculo
dtm:file	Usa el modelo especificado de superficie para normalizar los datos LIDAR. Se puede usar con /zmin para incluir puntos sobre el zmin especificado o con /zmax para incluir puntos bajo el zmax especificado.
height	Convierte elevaciones de puntos en alturas sobre la superficie, usando el archivo *.dtm especificado.

- CloudMetrics:

La arquitectura del comando es la siguiente:

CloudMetrics [switches] (InputDataSpecifier) (OutputFileName)

Este es el comando que finalmente se empleó, se muestran dos ejemplos, uno de cada monte, variando la altura mínima. Se den incluir en el comando una línea por cada parcela:

```
..\CloudMetrics /above:6 /minht:6 RUTA\1.las RUTA\est_parcelas.csv
```

```
..\CloudMetrics /above:3 /minht:3 RUTA\52.las RUTAest_parcelas.csv
```

En la siguiente tabla se muestra el significado de cada variable del comando:

Tabla 33. Variables comando CloudMetrics.

InputDataSpecifier	Archivo *.las de determinada parcela
OutputFileName	Nombre del archivo que contendrá las estadísticas de cada parcela.

En este caso los “switches” utilizados para el comando CloudMetrics fueron los siguientes:

Tabla 34. “switches” comando CloudMetrics.

above:#	Calcula el porcentaje de primeros retornos sobre la altura # especificada. Se usa como una estimación de la fracción de cabida cubierta.
minht:#	Solamente utiliza para los cálculos, retornos por encima de la altura # indicada.

- GridMetrics:

La arquitectura del comando es la siguiente:

GridMetrics [switches] groundfile heightbreak cellsizze outputfile datafile

Este es el comando que finalmente se empleó, uno para cada monte:

..\gridmetrics /minht:6 RUTA\mde.dtm 6 25 RUTA\estadisticos_6hmin RUTA*.las

..\gridmetrics /minht:3 RUTA\mde.dtm 3 25 RUTA\estadisticos_3hmin RUTA*.las

En la siguiente tabla se muestra el significado de cada variable del comando:

Tabla 35. Variables comando GridMetrics.

groundfile	Nombre del MDE *.dtm.
heightbreak	Altura límite para el cálculo de la cobertura.
cellsize	Tamaño de la celda.
outputfile	Nombre del archivo que contendrá las estadísticas de cada celda.
datafile	Archivos LiDAR *.las

En este caso el “switches” utilizado para el comando GridMetrics fue el siguiente:

Tabla 36. “switches” comando GridMetrics.

minht:#	Solamente utiliza para los cálculos, retornos por encima de la altura # indicada.
---------	---

Anexo 3: Correlaciones entre variables de campo y LiDAR.

A continuación se muestran las correlaciones entre las variables dependientes y las variables independientes. Como la mayoría de las variables no se distribuyen de forma normal se ha empleado el coeficiente de correlación de “Spearman”, el cual no se ve afectado por la transformación logarítmica de las variables, luego los coeficientes que se muestran son aplicables también a las variables transformadas. Para el cálculo de dicho coeficiente de correlación se han empleado las 61 parcelas inventariadas.

**: la correlación es significativa al nivel 0,01 (bilateral).

*: la correlación es significante al nivel 0,05 (bilateral).

Tabla 37. Correlación entre Vcc y las variables independientes (LiDAR).

Variables	Vcc	
	Correlación de “Spearman”	Sig, (bilateral)
Mínimo	,316*	,013
Máximo	,255*	,047
Media	,284*	,027
Moda	,362**	,004
Desviación estándar	-,101	,438
Varianza	-,101	,438
Coef, variación	-,417**	,001
Rango intercuartílico	-,189	,146
Asimetría	-,175	,178
kurtosis	,332**	,009
AAD	-,146	,261
Percentil 01	,500**	,000
Percentil 05	,422**	,001
Percentil 10	,397**	,002
Percentil 20	,363**	,004
Percentil 25	,339**	,008
Percentil 30	,327*	,010
Percentil 40	,298*	,020
Percentil 50	,274*	,032
Percentil 60	,268*	,037
Percentil 70	,258*	,044
Percentil 75	,249	,053
Percentil 80	,240	,063
Percentil 90	,250	,052
Percentil 95	,242	,061
Percentil 99	,230	,074
Porcentaje de primeros retornos por encima de 3 ó 6 metros	,803**	,000
Porcentaje de retornos por encima de 3 ó 6 metros	,755**	,000
Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos	,808**	,000
Porcentaje de primeros retornos por encima de la media	,786**	,000
Porcentaje de primeros retornos por encima de la moda	,446**	,000
Porcentaje de retornos por encima de la media	,710**	,000
Porcentaje de retornos por encima de la moda	,294*	,021

Variables	Vcc	
	Correlación de “Spearman”	Sig, (bilateral)
Porcentaje de retornos por encima de la media respecto del total de primeros retornos	,786**	,000
Porcentaje de retornos por encima de la moda respecto del total de primeros retornos	,446**	,000

Tabla 38. Correlación entre G y las variables independientes (LiDAR),

Variables	G	
	Correlación de “Spearman”	Sig, (bilateral)
Mínimo	,218	,092
Máximo	,088	,500
Media	,109	,402
Moda	,225	,081
Desviación estándar	-,238	,065
Varianza	-,238	,065
Coef. variación	-,397**	,002
Rango intercuartílico	-,294*	,021
Asimetría	-,128	,327
kurtosis	,288*	,024
AAD	-,279*	,029
Percentil 01	,368**	,004
Percentil 05	,276*	,031
Percentil 10	,237	,066
Percentil 20	,198	,126
Percentil 25	,169	,192
Percentil 30	,157	,227
Percentil 40	,126	,334
Percentil 50	,100	,444
Percentil 60	,095	,468
Percentil 70	,084	,520
Percentil 75	,075	,565
Percentil 80	,065	,618
Percentil 90	,075	,567
Percentil 95	,065	,619
Percentil 99	,059	,652
Porcentaje de primeros retornos por encima de 3 ó 6 metros	,889**	,000
Porcentaje de retornos por encima de 3 ó 6 metros	,824**	,000
Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos	,888**	,000
Porcentaje de primeros retornos por encima de la media	,850**	,000
Porcentaje de primeros retornos por encima de la moda	,416**	,001
Porcentaje de retornos por encima de la media	,755**	,000
Porcentaje de retornos por encima de la moda	,248	,054
Porcentaje de retornos por encima de la media respecto del total de primeros retornos	,851**	,000
Porcentaje de retornos por encima de la moda respecto del total de primeros retornos	,415**	,001

Tabla 39. Correlación entre N y las variables independientes (LiDAR),

Variables	N	
	Correlación de “Spearman”	Sig, (bilateral)
Mínimo	-,058	,659
Máximo	-,248	,054
Media	-,253*	,049
Moda	-,113	,388
Desviación estándar	-,398**	,001
Varianza	-,398**	,001
Coef, variación	-,191	,140
Rango intercuartílico	-,371**	,003
Asimetría	-,029	,826
kurtosis	,142	,275
AAD	-,426**	,001
Percentil 01	-,010	,942
Percentil 05	-,089	,495
Percentil 10	-,124	,342
Percentil 20	-,159	,221
Percentil 25	-,191	,140
Percentil 30	-,205	,113
Percentil 40	-,234	,070
Percentil 50	-,261*	,042
Percentil 60	-,261*	,042
Percentil 70	-,271*	,035
Percentil 75	-,274*	,032
Percentil 80	-,281*	,028
Percentil 90	-,280*	,029
Percentil 95	-,289*	,024
Percentil 99	-,282*	,028
Porcentaje de primeros retornos por encima de 3 ó 6 metros	,837**	,000
Porcentaje de retornos por encima de 3 ó 6 metros	,776**	,000
Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos	,826**	,000
Porcentaje de primeros retornos por encima de la media	,764**	,000
Porcentaje de primeros retornos por encima de la moda	,366**	,004
Porcentaje de retornos por encima de la media	,675**	,000
Porcentaje de retornos por encima de la moda	,226	,080
Porcentaje de retornos por encima de la media respecto del total de primeros retornos	,764**	,000
Porcentaje de retornos por encima de la moda respecto del total de primeros retornos	,366**	,004

Tabla 40. Correlación entre Hm y las variables independientes (LiDAR),

Variables	Hm	
	Correlación de “Spearman”	Sig, (bilateral)
Mínimo	,480**	,000
Máximo	,719**	,000
Media	,757**	,000
Moda	,649**	,000

Variables	Hm	
	Correlación de “Spearman”	Sig, (bilateral)
Desviación estándar	,563**	,000
Varianza	,563**	,000
Coef. variación	-,094	,469
Rango intercuartílico	,402**	,001
Asimetría	-,260*	,043
kurtosis	,135	,300
AAD	,537**	,000
Percentil 01	,618**	,000
Percentil 05	,656**	,000
Percentil 10	,684**	,000
Percentil 20	,708**	,000
Percentil 25	,724**	,000
Percentil 30	,731**	,000
Percentil 40	,741**	,000
Percentil 50	,757**	,000
Percentil 60	,754**	,000
Percentil 70	,762**	,000
Percentil 75	,754**	,000
Percentil 80	,749**	,000
Percentil 90	,753**	,000
Percentil 95	,755**	,000
Percentil 99	,727**	,000
Porcentaje de primeros retornos por encima de 3 ó 6 metros	-,212	,102
Porcentaje de retornos por encima de 3 ó 6 metros	-,150	,247
Porcentaje de retornos por encima de 3 ó 6 metros respecto del total de primeros retornos	-,192	,137
Porcentaje de primeros retornos por encima de la media	-,138	,289
Porcentaje de primeros retornos por encima de la moda	,081	,536
Porcentaje de retornos por encima de la media	-,078	,552
Porcentaje de retornos por encima de la moda	,123	,344
Porcentaje de retornos por encima de la media respecto del total de primeros retornos	-,138	,289
Porcentaje de retornos por encima de la moda respecto del total de primeros retornos	,082	,531