

TESIS DE LA UNIVERSIDAD
DE ZARAGOZA

2023

215

Estela Pérez Cardiel

Teledetección multisensor para la identificación temprana consistente de cultivos en los regadíos de Aragón

Director/es

De La Riva Fernández, Juan Ramón
Casterad Seral, María Auxiliadora

<http://zaguan.unizar.es/collection/Tesis>

ISSN 2254-7606



Prensas de la Universidad
Universidad Zaragoza

© Universidad de Zaragoza
Servicio de Publicaciones

ISSN 2254-7606



Universidad
Zaragoza

Tesis Doctoral

TELEDETECCIÓN MULTISENSOR PARA LA
IDENTIFICACIÓN TEMPRANA CONSISTENTE DE
CULTIVOS EN LOS REGADÍOS DE ARAGÓN

Autor

Estela Pérez Cardiel

Director/es

De La Riva Fernández, Juan Ramón
Casterad Seral, María Auxiliadora

UNIVERSIDAD DE ZARAGOZA
Escuela de Doctorado

Programa de Doctorado en Ordenación del Territorio y Medio Ambiente

2022



Universidad
Zaragoza

Tesis Doctoral

TELEDETECCIÓN MULTISENSOR PARA LA IDENTIFICACIÓN TEMPRANA CONSISTENTE DE CULTIVOS EN LOS REGADÍOS DE ARAGÓN

Autor

Estela Pérez Cardiel

Director/es

Juan de la Riva Fernández
M^a Auxiliadora Casterd Seral

Universidad de Zaragoza
Geografía y Ordenación del Territorio

2022

La autora de esta tesis doctoral disfrutó para su desarrollo de la financiación del Programa de ayudas FPU del Ministerio de Universidades. Referencia de la ayuda FPU15/04783. Desea hacer constar, por tanto, su agradecimiento

Teledetección multisensor para la identificación temprana consistente de cultivos en los regadíos de Aragón



Universidad Zaragoza

Estela Pérez Cardiel

Directores: Juan de la Riva Fernández y M^a Auxiliadora Casterad Seral

TESIS DOCTORAL

2022

Departamento de Geografía y Ordenación del Territorio

Agradecimientos

Durante los años que he realizado esta Tesis Doctoral han sido muchas las personas y entidades a las que desde estas líneas debo agradecer su colaboración, ayuda y apoyo.

En primer lugar, quiero agradecer de manera destacada a mis directores de investigación –la Dra. M^a Auxiliadora Casterad Seral y el Dr. Juan de la Riva Fernández–, por la confianza que depositaron en mí, por su apoyo incondicional, por sus consejos, por su paciencia y además por sus valiosas aportaciones. También quisiera agradecer de manera destacada al Dr. Marcos Rodríguez Mimbrero que, sin ser director de esta investigación, su asesoramiento, disponibilidad y colaboración desinteresada ha sido esencial para el desarrollo de esta.

Al Dr. Darío Domingo Ruíz por su colaboración en las calurosas jornadas de campo del verano-otoño de 2019.

Asimismo, quiero agradecer a todos los miembros del Grupo de Investigación GEOFOREST-IUCA y a los profesores del Departamento de Geografía y Ordenación del Territorio por acogerme, permitirme hacer uso de sus equipos y darme apoyo en los momentos más complicados del desarrollo de esta tesis. Además, quiero agradecer a las profesoras que me han ayudado y permitido iniciarme en la labor docente. Quiero mostrar mi gratitud de forma particular a la Dra. Raquel Montorio Llovería por ser un apoyo profesional y personal fundamental dentro del departamento.

No quisiera olvidarme del Dr. Enrique Ruiz Budría y de la Dra. Estela Nadal Romero por introducirme en el mundo de la investigación y en cierta forma por ayudarme a conseguir la ayuda predoctoral.

Al Departamento de Sistemas Agrícolas, Forestales y Medio Ambiente del Centro de Investigación y Tecnología Agroalimentaria de Aragón, personalizando en este caso el agradecimiento en su antigua jefa de unidad la Dra. Dolores Quílez Sáez de Vitieri por permitirme disponer de sus instalaciones e infraestructuras y por hacerme sentir como una más de la unidad. Además, me gustaría agradecer a Rosa Gómez Báguena por su total disponibilidad cuando he necesitado de su ayuda.

A la Dirección General de Producción Agraria del Gobierno de Aragón, personalizando el agradecimiento en el técnico Dr. Samuel Esteban Rodríguez por facilitarme la información requerida y estar siempre disponible cuando he tenido alguna duda.

A la Comunidad de Regantes de Almudevar por facilitarme la información sobre cultivos y parcelas. Agradecer también a todos los agricultores –Jesús Labarta, Vicente Betran, Rafael Asso, Antonio Sanz, Manuel Laliena y Mariano Barrio– que de forma desinteresada me han permitido hacer el trabajo de campo en sus parcelas.

A todos los compañeros del departamento Daniel Borini, Olga Rossero, Aldo Arranz, Darío Domingo, Adrián Jiménez, Ricardo Badía, Andrea Urgilez, María Royo, Alberto Serrano, Samuel Barrao, Raúl Hoffren, Carmen Bentué, Eduardo Pérez, Gonzalo Fernández

y Sergio Romero a todos gracias por las conversaciones en los cafés, por haber soportado mis incertidumbres con la tesis y el agradable ambiente de trabajo.

Finalmente, agradecer a mi familia, a mis padres y hermanas por educarme, apoyarme y por respetar mis ausencias. A Julián por apoyarme incondicionalmente y por su ánimo constante día a día durante estos años, sin él, esta etapa final hubiese sido inalcanzable. A Darío por portarse super bien y saber que tenía que esperar, ahora mi tiempo es tuyo.

ÍNDICE GENERAL

I.	Introducción.....	1
I.1	Antecedentes y justificación.....	1
I.1.1	Teledetección en agricultura.....	1
I.1.2	Retos de la digitalización en el marco de la Política Agrícola Común.....	5
I.1.3	Los regadíos en Aragón y las dobles cosechas.....	6
I.2	Objetivos.....	11
I.3	Estructura de la memoria.....	11
II.	Cultivos y área de estudio.....	13
II.1	Características de los cultivos.....	13
II.1.1	Maíz.....	13
II.1.2	Girasol.....	17
II.2	Área de estudio.....	21
II.2.1	Regadíos en el valle del Ebro en Aragón.....	21
II.2.2	Zona Regable de La Violada.....	23
III.	Comparación y evaluación de los datos obtenidos desde los sensores sequoia a bordo de un UAV y MSI de Sentinel 2 mediante espectro-radiometría de campo.....	26
III.1	Material y métodos.....	26
III.1.1	Adquisición y preparación de datos.....	28
III.1.1.1	Temporalidad en la adquisición de datos.....	28
III.1.1.2	Medidas de espectro-radiometría de campo.....	29
III.1.1.3	Imágenes UAV.....	33
III.1.1.4	Imágenes de satélite Sentinel 2.....	38
III.1.2	Procesado de datos.....	40
III.1.2.1	Procesado de los datos hiperespectrales obtenidos con espectro-radiómetro.....	40
III.1.2.2	Procesado de datos de UAV.....	40
III.1.2.3	Obtención de los índices de vegetación.....	42
III.1.3	Comparación de la reflectividad y de los índices de vegetación.....	45
III.1.3.1	Comparación de espectro-radiometría de campo con Sentinel 246	
III.1.3.2	Comparación de espectro-radiometría de campo con UAV.....	48
III.1.3.3	Comparación de Sentinel 2 con UAV.....	49
III.1.4	Análisis estadístico.....	50
III.2	Resultados.....	54
III.2.1	Comparación de espectro-radiometría de campo con Sentinel 2.....	54
III.2.2	Comparación de espectro-radiometría de campo y UAV.....	61
III.2.3	Comparación de Sentinel 2 y UAV.....	67
III.2.4	Comparación de sensores en el escenario 4.....	73
III.2.4.1	Homogeneidad de la información espectral de Sequoia por cultivo y estadio.....	73
III.2.4.2	Comparación de Sentinel 2 y UAV.....	77
III.3	Discusión.....	84

IV. Determinación temprana del IED de maíz y girasol de segunda cosecha con series temporales de imágenes de Sentinel 2 y UAV	89
IV.1 Material y métodos.....	90
IV.1.1 Temporalidad de datos	91
IV.1.1.1 Selección de la ventana temporal óptima para detección de IED	91
IV.1.1.2 Escala temporal	92
IV.1.2 Adquisición y procesamiento de fotografías RGB.....	92
IV.1.3 Recopilación y procesamiento de los datos de detección remota	94
IV.1.3.1 Imágenes multiespectrales.....	94
IV.1.3.2 Índices de vegetación.....	95
IV.1.4 Determinación del Inicio de la Etapa de Desarrollo (IED).....	96
IV.1.4.1 IED a partir de fotografías RGB y la fracción de cobertura vegetal	96
IV.1.4.2 IED a partir de imágenes Sentinel 2 y la técnica de detección del punto de cambio	96
IV.1.4.3 IED a partir de imágenes Sentinel 2 y el ajuste logístico.....	98
IV.1.4.4 IED a partir de imágenes Sentinel 2 y la prueba de Pettitt simulando datos perdidos	99
IV.1.4.5 IED a partir de la combinación de imágenes Sentinel 2 y UAV aplicando la prueba de Pettitt	100
IV.2 Resultados	100
IV.2.1 Determinación de la FCV e IED de referencia	101
IV.2.2 Determinación de IED con la serie temporal de Sentinel 2	102
IV.2.3 Determinación de IED con la serie temporal de Sentinel 2 y la prueba de Pettitt simulando datos perdidos.....	103
IV.2.4 Determinación de IED con la serie temporal de Sentinel 2 - UAV aplicando la prueba de Pettitt	105
IV.3 Discusión.....	109
V. Determinación temprana del IED de maíz y girasol de segunda cosecha con series temporales de imágenes de Sentinel 2 y UAV	113
V.1 Material y métodos.....	114
V.1.1 Selección de parcelas con doble cosecha	115
V.1.2 Procesamiento de imágenes de Sentinel 2	115
V.1.3 Datos meteorológicos.....	117
V.1.4 Detección del IED	118
V.2 Resultados	119
V.2.1 Dobles cosechas y su distribución	119
V.2.2 Variabilidad espacial de la precipitación y temperatura	121
V.2.3 Depuración de las parcelas seleccionadas mediante la prueba de la pendiente de Sen.....	125
V.2.4 Comportamiento de la prueba de Pettitt	125
V.2.5 IED y su distribución en el área de estudio.....	127
V.3 Discusión.....	130

VI. Conclusiones y líneas futuras.	133
VII. Bibliografía.....	139

ÍNDICE DE ANEXOS

Anexo 1. Imágenes utilizadas en esta Tesis.....	157
Anexo 2. Pruebas estadísticas y gráficos de los modelos de regresión lineal por cultivo y etapa del cultivo.....	163
Anexo 3. Fotografías RGB cenitales.....	182
Anexo 4. Imágenes de UAV.....	196
Anexo 5. Cartografía del IED.....	201

ÍNDICE DE FIGURAS

Figura I-1. Diferencia de las superficies de cultivo en los años 1956 y 2021 en una zona entre los municipios de Esplús y Tamarite de Litera (Huesca).....	8
Figura I-2. Estimación de superficie (ha) y producciones (t) de maíz en España por Comunidades Autónomas en 2021. Extraído del informe de “Transferencia de resultados de la red de ensayos de maíz y girasol en Aragón. Campaña 2021”.....	9
Figura I-3. Superficie de maíz en Aragón por provincias en desde 2014 a 2020.....	9
Figura I-4. Superficie de girasol en Aragón por provincias en 2018, 2019 y 2020.....	10
Figura II-1. Ciclo del crecimiento y desarrollo del maíz semiprecoz (FAO 400) de regadío en Almodívar (Huesca) durante el año 2019. La curva muestra la evolución temporal del NDVI. Elaboración propia.	14
Figura II-2. Variabilidad de la cubierta vegetal del maíz en función de su ciclo.....	15
Figura II-3. Firmas espectrales del maíz según su estadio en la fase de desarrollo (V1-V8).....	17
Figura II-4. Ciclo del crecimiento y desarrollo del girasol de ciclo corto de regadío en Almodívar (Huesca) durante el año 2019. La curva muestra la evolución temporal del NDVI.	18
Figura II-5. Variabilidad de la cubierta vegetal del girasol en función de su ciclo.....	19
Figura II-6. Firmas espectrales del girasol según su estadio en la fase de desarrollo (VE-R1)..	20
Figura II-7. Localización de las áreas de estudio. Imagen de Sentinel 2 de fecha 30 de julio de 2019 representada en falso color (IC, rojo y verde).....	22
Figura II-8. Superficie declarada en la PAC con doble cosecha en Aragón. Fuente: Declaraciones PAC 2018 y 2019.....	22
Figura II-9. Localización de la Zona Regable de La Violada y parcelas de estudio. Imagen de Sentinel 2 de fecha 30 de julio de 2019 representada en falso color IC, rojo y verde (RGB).....	23
Figura II-10. Fotografías de parcela de maíz con ciclo corto (G), ciclo largo (G’), de girasol (L) y de maíz de ciclo corto (H).	24
Figura III-1. Flujo de trabajo general para comparar y evaluar los sensores Sequoia a bordo de un UAV y MSI de Sentinel 2A y 2B.....	27
Figura III-2. Calendario de adquisición de datos con espectro-radiómetro, UAV y Sentinel 2 para los años 2018 y 2019.....	28
Figura III-3. Medición de la reflectividad sobre maíz en estadio V2 con espectro-radiómetro portátil ASDFieldSpec4.....	31
Figura III-4. Panel de referencia Spectralon® utilizado en las campañas de campo y ejemplo de su reflectividad.	31

Figura III-5.	Esquema de las medidas realizadas con el espectro-radiómetro de campo.....	32
Figura III-6.	UAV eBee Classic con el que se han realizado los vuelos (información obtenida (Sensefly Ltd, 2014).....	33
Figura III-7.	Cámara Sequoia y sensor Sunshine (información obtenida de Parrot Sequoia, 2017).....	34
Figura III-8.	Función de respuesta espectral de Sequoia.	34
Figura III-9.	Ejemplo de la planificación de uno de los vuelos en parcela H de la Zona de Riego de La Violada.....	35
Figura III-10.	Ubicaciones de los puntos de control para georreferenciación en las parcelas de estudio sobrevoladas con UAV.....	37
Figura III-11.	Ejemplo de punto de control rectangular (izquierda) y de punto de control en arqueta de riego (derecha) en imágenes RGB de UAV.....	37
Figura III-12.	Imagen del panel para calibración de la cámara Sequoia.....	37
Figura III-13.	Función de la respuesta espectral de los sensores MSI de Sentinel 2A y 2B.....	40
Figura III-14.	Comparación de las medidas de espectro-radiómetro de campo con el píxel de Sentinel 2. Imagen de falso color RGB (IC, Rojo y Verde) de MSI de Sentinel 2 del 2/08/2019.	47
Figura III-15.	Comparación de la medida puntual de espectro-radiómetro de campo con el promedio de píxeles de Sequoia.....	48
Figura III-16.	Imágenes en falso color RGB (IC, Rojo y Verde) de MSI Sentinel 2 (izquierda) y de Sequoia (derecha) de 02/08/2019.....	49
Figura III-17.	Función de la respuesta espectral del sensor Sequoia y las homólogas del sensor MSI de los satélites Sentinel 2A y 2B.....	50
Figura III-18.	Diagrama de dispersión de la reflectividad en cada banda espectral entre las medidas de ASD y Sentinel 2 (n=68).....	56
Figura III-19.	Diagrama de dispersión de cada IV obtenidos con ASD y Sentinel 2 (n=68).....	57
Figura III-20.	Gráficos de residuos estandarizados en las bandas obtenidos al aplicar el modelo lineal en función de los AGDD y líneas de tendencia.	58
Figura III-21.	Gráficos de residuos estandarizados en los IV obtenidos al aplicar el modelo lineal en función de los AGDD y líneas de tendencia.	59
Figura III-22.	Diagramas de cajas de los valores de reflectividad en cada banda espectral y de los valores de los IV para ambos sensores ASD y Sentinel 2 (n=68). Umbral de significación según test Wilcoxon $p < 0,05$	61
Figura III-23.	Diagrama de dispersión de cada banda espectral. (n=82).....	62
Figura III-24.	Diagrama de dispersión de cada IV. Valores de índice producto de la reflectividad medida por ASD en el eje X contra valores de índice producto de la reflectividad medida por Sequoia en el eje Y (n=82).....	63
Figura III-25.	Gráficos de residuos estandarizados de las bandas obtenidos al aplicar el modelo lineal en función de los AGDD.	65
Figura III-26.	Gráficos de residuos estandarizados de los IV obtenidos al aplicar el modelo lineal en función de los AGDD.....	65
Figura III-27.	Diagrama de caja de los valores de reflectividad en cada banda espectral y valores de los IV para ambos sensores ASD y Sequoia y resultados del test de Wilcoxon (n=82).....	67
Figura III-28.	Diagrama de dispersión de la reflectividad en cada banda espectral entre medidas Sentinel 2 y UAV (n=22).....	68
Figura III-29.	Diagrama de dispersión de cada IV entre medidas Sentinel 2 y UAV (n=22).....	69

Figura III-30.	Gráficos de residuos estandarizados de las bandas obtenidos al aplicar el modelo de regresión lineal en función de los AGDD.....	71
Figura III-31.	Gráficos de residuos estandarizados de los IV obtenidos al aplicar el modelo de regresión lineal en función de los AGDD.....	71
Figura III-32.	Diagrama de caja de los valores de reflectividad en cada banda espectral y valores de los IV para ambos sensores Sentinel 2 y Sequoia.....	73
Figura III-33.	Desviación estándar de los valores de reflectividad obtenidos por Sequoia en función de los píxeles Sentinel 2 en los diferentes estadios del cultivo de maíz. El valor anotado en la parte superior de los gráficos refiere al número de muestras.	74
Figura III-34.	Desviación estándar de los valores de reflectividad obtenidos por Sequoia en función de los píxeles Sentinel 2 en los diferentes estadios del cultivo de girasol. El valor anotado en la parte superior de los gráficos refiere al número de muestras.	74
Figura III-35a.	Desviación estándar de los IV obtenidos a partir de Sequoia en función del píxel Sentinel 2 en los diferentes estadios del cultivo para maíz. El valor anotado en la parte superior de los gráficos refiere al número de muestras.....	75
Figura III-35b.	Desviación estándar de los IV obtenidos a partir de Sequoia en función del píxel Sentinel 2 en los diferentes estadios del cultivo para girasol. El valor anotado en la parte superior de los gráficos refiere al número de muestras.....	76
Figura III-36.	Diagrama de dispersión de la reflectividad en cada banda espectral para todos los píxeles Sentinel de las parcelas entre medidas de MSI y UAV (n=3240).....	77
Figura III-37.	Diagrama de dispersión de los IV para todos los píxeles Sentinel de las parcelas entre medidas de MSI y UAV (n=3240).	78
Figura III-38.	Gráficos de dispersión de residuos estandarizados de las bandas obtenidos al aplicar el modelo de regresión lineal para los píxeles Sentinel de todas las parcelas en función de los AGDD.	81
Figura III-39.	Gráficos de dispersión de residuos estandarizados de los IV obtenidos al aplicar el modelo de regresión lineal para los píxeles Sentinel de todas las parcelas en función de los AGDD.	81
Figura III-40.	Diagrama de caja y prueba d de Cohen de los valores de reflectividad en cada banda espectral y valores de los IV para ambos sensores, MSI de Sentinel 2 y Sequoia (n=3240).	84
Figura IV-1.	Flujo de trabajo general para determinar el IED.....	90
Figura IV-2.	Momentos de realización de las fotografías RGB en campo, obtención de datos de Sentinel 2 y de UAV. El área sombreada en verde corresponde con el periodo en el que se necesitan datos para calcular el IED mediante el método DPC.	91
Figura IV-3.	Fotografía original (izquierda) e imagen recortada ajustada al área de muestreo para extraer la información de FCV.....	93
Figura IV-4.	Estimación de la FCV: imagen utilizada (RGB), imagen de área verde (GA) e imagen del área más verde (GGA) tratadas con BreedPix.	94
Figura IV-5.	Gráficos de los resultados de la función maxcurv con el método de la distancia perpendicular.	99
Figura IV-6.	Gráfico del método de las distancias perpendiculares.....	99
Figura IV-7.	Ejemplo de datos perdidos generados (-) cuando se comienza con la imagen de los días julianos 174 y 184.....	100

Figura IV-8.	Relación entre el día juliano y la FCV estimada en campo para los cultivos de girasol y maíz.	101
Figura IV-9.	Ejemplo de los resultados obtenidos cuando las primeras imágenes que faltan son las de los días julianos 174 y 184.	103
Figura IV-10.	Diferencias del IED determinado para maíz y girasol mediante el método de Pettitt respecto al IDE-referencia para los tres índices de estudio derivados de MSI de Sentinel 2. Nivel de significación $p < 0,05$	104
Figura IV-11.	Diferencias del IED determinado para maíz mediante la prueba de Pettitt respecto al IED-referencia para los tres índices de estudio derivados de MSI de Sentinel y Sequoia en 2019 (serie temporal en días julianos). Nivel de significación $p < 0,05$	106
Figura IV-12.	Diferencias en la serie temporal NDVI e IED del maíz entre el Escenario 1 (serie de datos de MSI de Sentinel 2) y Escenario 2 (serie en la que se sustituyen datos de MSI por datos de Sequoia).	107
Figura IV-13.	Diferencias en la serie temporal NDVI e IED del maíz entre el Escenario 1 (serie de datos de MSI de Sentinel 2) y Escenario 3 (serie en la que se sustituyen datos de MSI por datos de Sequoia).	107
Figura IV-14.	Diferencias en la serie temporal OSAVI e IED del maíz entre el Escenario 1 (serie de datos de MSI de Sentinel 2) y Escenario 7 (serie en la que se sustituyen datos de MSI por datos de Sequoia).	108
Figura IV-15.	Diferencias del IED determinado para girasol mediante el método DPC y los datos de campo para los tres índices de estudio derivados de MSI de Sentinel y Sequoia en 2019 (serie temporal en días julianos). Nivel de significación $p < 0,05$	108
Figura IV-16.	Diferencias en la serie temporal OSAVI e IED del girasol entre la serie de datos de Sentinel 2 y la serie en la que se incorporan datos de Sequoia.....	109
Figura V-1.	Flujo de trabajo general de la metodología para determinar y analizar el IED del maíz y del girasol en el Valle del Ebro en Aragón.....	114
Figura V-2.	Visualización en imagen Sentinel 2 (RGB:7-4-3) de los recintos SIGPAC seleccionados y descartados según tengan uno o más cultivos declarados.....	115
Figura V-3.	Órbitas de paso de Sentinel 2 y teselas utilizadas.....	116
Figura V-4.	Fecha de adquisición de Sentinel 2 y porcentaje de píxeles sin nubes sobre las parcelas de estudio para los años 2018 y 2019.	116
Figura V-5.	Mascara de nubes: a) Imagen Sentinel 2 (RGB 4-3-2); b) máscara de bits QA60 (color salmón) sobre NDVI; c) ampliación de la máscara de nubes realizada manualmente.....	117
Figura V-6.	Localización de las estaciones agrometeorológicas del Sistema de Información Agroclimática para el Regadío (SIAR).	118
Figura V-7.	Parcelas seleccionadas de dobles cosecha con segundo cultivo de girasol y de maíz en 2018 y 2019.	121
Figura V-8.	Carácter de la temperatura y de la precipitación para los años agrícolas 2017-2018 y 2018-2019 (de Cara et al., 2018, 2019).	122
Figura V-9.	Climogramas de la zona de estudio para los años agrícolas 2018 y 2019.	124
Figura V-10.	Ejemplo de parcelas descartadas mediante la pendiente de Sen. Ortofoto de PNOA de 2018.	124
Figura V-11.	Series temporales de NDVI para dos parcelas de las teselas TYM, en 2018, y TXM, en 2019.....	125

Figura V-12.	p-values de la prueba de Pettitt en función del número de datos de la serie temporal de NDVI y del momento en el que se produce el punto de cambio.....	126
Figura V-13.	p-values de la prueba de Pettitt en función de los cultivos.....	126
Figura V-14.	IED por cultivos.	127
Figura V-15.	Distribución del IED de las dobles cosechas de maíz y girasol en el Valle del Ebro para los años 2018 y 2019.	129
Figura V-16.	Distribución de los p-values de la prueba de Pettitt de las dobles cosechas de maíz y girasol en el Valle del Ebro para los años 2018 y 2019.....	130

ÍNDICE DE TABLAS

Tabla II-1.	Parcelas seleccionadas y características generales del cultivo.	24
Tabla III-1.	Número de adquisición datos con el espectro-radiómetro en cada fecha y transecto A y B (T-A y T-B) e información puntual (P) en las parcelas de estudio con cultivos de ciclo corto en 2018 (724 mediciones).....	32
Tabla III-2.	Número de adquisición datos con el espectro-radiómetro en cada fecha y transecto A y B (T-A y T-B) e información puntual (P) en las parcelas de estudio con maíz de ciclo largo en 2019 (552 mediciones).....	32
Tabla III-3.	Número de adquisición datos con el espectro-radiómetro en cada fecha y transecto A y B (T-A y T-B) e información puntual (P) en las parcelas de estudio con cultivos de ciclo corto en 2019 (599 mediciones).....	32
Tabla III-4.	Características técnicas del Sensor Sequoia y del Sensor Sunshine.....	34
Tabla III-5.	Vuelos realizados con UAV en cada una de las parcelas sobre cultivos de maíz y girasol de ciclo corto en 2019.....	38
Tabla III-6.	Resolución espectral y espacial para Sentinel 2A y 2B.	39
Tabla III-7.	Pares de medias de los sensores en el escenario1 para cada una de las de estudio en 2018.	46
Tabla III-8.	Pares de medias de los sensores incluidos en el escenario1 en cada una de las parcelas de maíz de ciclo largo en 2019.....	47
Tabla III-9.	Pares de medias de los sensores incluidos en escenario1 en cada una de las parcelas de maíz y girasol de ciclo corto en 2019.	47
Tabla III-10.	Pares de medidas de los sensores incluidos en el escenario2 en cada una de las parcelas de maíz y girasol de ciclo corto en 2019.....	48
Tabla III-11.	Pares de medias de los sensores incluidos en el escenario 3 (destacadas en verde) y el escenario 4 (todas) en cada una de las parcelas de maíz y girasol de ciclo corto en 2019.....	49
Tabla III-12.	Modelo de regresión lineal y estadísticos de intersección y pendiente para cada una de las bandas espectrales entre los sensores ASD y Sentinel 2 (n = 68).	55
Tabla III-13.	Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores ASD y Sentinel 2 (n = 68).	56
Tabla III-14.	Estadísticos de intersección (I) y pendiente (P) de los modelos de regresión lineal por cultivo y por etapa y sus diferencias para cada una de las bandas e IV entre los sensores ASD y Sentinel 2.....	60
Tabla III-15.	Estadísticos obtenidos del modelo de regresión lineal para cada una de las bandas espectrales entre los datos ASD y Sequoia (n=82).	62
Tabla III-16.	Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores ASD y Sequoia (n=82).	64

Tabla III-17.	Estadísticos de intersección (I) y pendiente (P) de los modelos de regresión lineal por cultivo y por etapa y sus diferencias para cada una de las bandas y de los IV entre los sensores ASD y Sequoia.....	66
Tabla III-18	Estadísticos obtenidos del modelo de regresión lineal para cada una de las bandas espectrales entre los datos Sentinel 2 y Sequoia (n=22).....	68
Tabla III-19.	Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores Sentinel 2 y Sequoia (n = 22).....	69
Tabla III-20.	Estadísticos de intersección (I) y pendiente (P) de los modelos de regresión lineal por cultivo y por etapa y sus diferencias para cada una de las bandas espectrales e IV entre los datos de Sentinel 2 y UAV en el píxel de medidas (n = 22).	72
Tabla III-21.	Estadísticos obtenidos del modelo de regresión lineal para cada una de las bandas espectrales entre los sensores MSI y Sequoia para todos los píxeles Sentinel incluidos en las parcelas (n=3240).....	77
Tabla III-22.	Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores MSI de Sentinel 2 y Sequoia para todos los píxeles Sentinel incluidos en las parcelas (n=3240).....	79
Tabla III-23.	Estadísticos de intersección (I) y pendiente (P) del modelo de regresión lineal por cultivo y etapas de cultivo para cada banda e IV entre los sensores MSI y Sequoia para todos los píxeles Sentinel incluidos en las parcelas.	82
Tabla IV-1.	Fechas de adquisición de fotografías con cámara RGB en cada una de las parcelas sobre cultivos de maíz y girasol en 2018 y 2019	91
Tabla IV-2.	Rangos espectrales utilizados de cada sensor.....	95
Tabla IV-3.	NDRre, NDVI y OSAVI derivados de las imágenes de Sequoia y MSI de Sentinel 2.....	95
Tabla IV-4.	Escenarios contemplados en la sustitución de imágenes Sentinel 2 (S2) por imágenes Sequoia (UAV). El número asociado (día juliano) a las imágenes Sequoia refiere a la imagen Sentinel 2 que sustituye.....	100
Tabla IV-5.	IED-referencia en días julianos.....	102
Tabla IV-6.	Determinación de IED por las diferentes pruebas e IED-referencia.	102
Tabla V-1.	Superficie declarada y número de parcelas seleccionadas por cultivos y por provincias para los años de estudio.....	119

I. Introducción

I.1 Antecedentes y justificación

I.1.1 Teledetección en agricultura

En los últimos años se ha avanzado sobremanera en la aplicación de las Tecnologías de la Información y la Comunicación en la agricultura y, en concreto, de las TIG (Tecnologías de la Información Geográfica), al tiempo que se han incrementado los recursos de teledetección disponibles: satelitales, aeroportados y terrestres. La teledetección ha permitido el desarrollo de diferentes alternativas metodológicas basadas en el uso de imágenes ópticas, siendo actualmente uno de los avances más significativos en este ámbito el uso de información capturada por drones o UAV (*Unmanned Aerial Vehicles*, UAV; Shahbazi et al., 2014).

La posibilidad de realizar cartografías y clasificaciones de cultivos de extensas zonas y hacer el seguimiento de las cubiertas vegetales son elementos que hacen de la teledetección una herramienta esencial en la monitorización de cultivos. Sin embargo, la monitorización del cultivo utilizando datos obtenidos mediante satélites sigue siendo un desafío técnico debido a la diversidad de sistemas de cultivo, variedades, prácticas de manejo y tamaños de las parcelas agrícolas (Song et al., 2017).

Se requiere información precisa para detectar las variaciones en las superficies agrícolas con el fin de implementar la estrategia de manejo más efectiva y realizar las prácticas agrícolas en consecuencia. Las técnicas y los datos de teledetección ya han demostrado ser eficaces para el monitoreo de cultivos. Estas técnicas generalmente se basan en la relación entre las propiedades ópticas de las plantas y los parámetros biofisiológicos (Chuvieco, 2010). Para caracterizar la vegetación, el primer programa espacial, ya en el año 1972, fue Landsat, con el primer satélite de la serie, ERTS-1, después renombrado como Landsat 1, que portaba a bordo, entre otros, el sensor MSS (*Multi-Spectral Scanner*, Bauer & Cipra, 1973); los rápidos avances en el procesamiento de imágenes propiciaron que en 1984 se incorporara, a bordo de Landsat 4, el sensor (TM, *Thematic Mapper*). Desde ese momento la obtención de datos por medio de la teledetección se ha convertido en indispensable (Panda et al., 2015).

Sin embargo, el ciclo de repetición de 16 días de las observaciones de Landsat 4 y posteriores no es a veces suficientemente adecuado para monitorear la vegetación, por lo que en ocasiones se utilizan datos capturados por sensores con mayor resolución temporal, como puede ser espectroradiómetro de imágenes de resolución moderada MODIS (*Moderate Resolution Imaging Spectroradiometer*), que resulta indicado para superficies extensas. En la actualidad se dispone de otros satélites, incluidos los de muy alta resolución y los nanosatélites, como los de la constelación RapidEye, WorldView-3 o la constelación de

satélites PlanetScope, que cuenta con alta resolución temporal y espacial, que han sido utilizados para realizar clasificaciones de pequeñas parcelas de cultivo con buenos resultados (Gerstmann et al., 2016; Skakun et al., 2021); sin embargo, tienen con frecuencia como inconveniente el alto costo de recopilación de datos.

Otros satélites que proporcionan imágenes con alta resolución espacial y temporal son los de la misión Sentinel-2 (ESA, 2016). Esta misión, desarrollada por la ESA dentro del programa Copernicus de la Comisión Europea, está compuesta por dos satélites idénticos: Sentinel 2A, lanzado en junio de 2015, y Sentinel 2B, lanzado en marzo de 2017. La información de estos satélites permite realizar la monitorización de cultivos con éxito, tal y como ponen en evidencia ya varios estudios (Campos-Taberner et al., 2019; Segarra et al., 2020; Sitokonstantinou et al., 2018).

Uno de los avances para monitorizar los cultivos a escala de explotación agrícola son los UAV, que pueden volar a baja altitud, incluso en días nublados, y obtener imágenes con una resolución espacial muy alta. Los vuelos se pueden realizar a conveniencia, haciéndolos coincidir con fases fenológicas específicas o después de un evento climático importante. Pueden llevar alojadas cámaras digitales, cámaras multispectrales, sensores hiperespectrales, cámaras termográficas y, en algunos casos, sensores LiDAR. Los datos de estos sensores se utilizan para detectar el estrés hídrico mediante imágenes térmicas (Zarco-Tejada et al., 2012), la detección temprana de malas hierbas (Peña et al., 2014) o el monitoreo de cultivos (Agüera Vega et al., 2015), mientras que los datos LiDAR aportan estimaciones de la altura de cultivo y la biomasa (Domingo et al., 2019; Zarco-Tejada et al., 2014),

No obstante, las aplicaciones operativas en agricultura mediante el empleo en UAV de sensores propiamente de teledetección son aún limitadas y complejas. Hay que tener en cuenta que las imágenes tienen diferentes características geométricas y radiométricas debido al movimiento y la estabilidad de la cámara alojada en el UAV. Por lo tanto, el procesamiento es complejo (Tsouros et al., 2019) y requiere realizar la calibración radiométrica, la corrección geométrica y la fusión de imágenes. En la actualidad, existen programas informáticos –como Pix4D, Agisost u OpenDroneMap, entre los más utilizados– que automatizan los procesos y facilitan la generación de imágenes, pero con frecuencia son cerrados y no permiten modificar los algoritmos de procesamiento que tienen implementados.

Para conseguir buenos resultados en la monitorización de cultivos es necesario considerar la fuente de imágenes a utilizar según el propósito que se persiga. La resolución espacial determina el tamaño de píxel más pequeño que se puede identificar; por lo tanto, a medida que aumenta la resolución espacial, el área de los píxeles disminuye y la homogeneidad del cultivo dentro del píxel aumenta. Mulla (2013) concluye que la estimación de biomasa y los rendimientos del cultivo requieren una mayor resolución espacial, de 1 y 3 m, en comparación a las aplicaciones de riego y fertilizantes, que sitúa entre 5 y 10 m; Fernández-Quintanilla et al. (2018) utilizan imágenes con una resolución espacial de entre 5 y 50 cm para cartografiar las malas hierbas. Además de la resolución espacial, la resolución

temporal es fundamental para observar la evolución de los patrones de los ciclos de los cultivos.

Diferentes estudios han demostrado su utilidad y viabilidad para la clasificación y cartografía de cultivos (Conrad et al., 2016; Martínez-Casasnovas et al., 2005; Yu & Shang, 2017; Zhong et al., 2014), el seguimiento fenológico (Boschetti et al., 2009; González-Gómez et al., 2018; Jiang et al., 2019; Ren et al., 2017; Sakamoto et al., 2005; Zhang et al., 2003), el estado y condición del cultivo (Cai et al., 2019; Chen et al., 2010; Clevers & Kooistra, 2012; Zarco-Tejada et al., 2018), el pronóstico del rendimiento (Ju et al., 2010; Skakun et al., 2021; You et al., 2017) o el monitoreo de los cultivos para verificar los subsidios agrícolas (Campos-Taberner et al., 2019; Diaz-Varela et al., 2014; Estrada et al., 2017; Schmedtmann & Campagnolo, 2015).

Se observa que los datos generados cada vez tienen mayor detalle temporal y espacial, lo que implica que el volumen de datos sea también mayor. Para lidiar con estas nuevas situaciones varias agencias ofrecen diversas plataformas para tratar los datos espaciales, como la plataforma Google Earth Engine, que incluye la posibilidad de compartir algoritmos y cadenas de procesamiento, integrar diferentes fuentes de datos y crear productos en servidores externos.

Teledetección y fenología del cultivo

La fenología define las etapas de desarrollo fisiológico del crecimiento de los cultivos desde la siembra hasta la cosecha y su relación con el tiempo y el clima (Piao et al., 2015). La información fenológica es relevante para comprender la respuesta de los ecosistemas al cambio climático (Chakraborty et al., 2018). Por otra parte, a escala local, en la agricultura de precisión, el monitoreo fenológico ofrece información importante para la toma de decisiones del manejo de cultivos, como el riego, la fertilización o la previsión del rendimiento (Bolton & Friedl, 2013; Kar & Verma, 2005; Lü et al., 2020).

La teledetección satelital proporciona observaciones frecuentes de las propiedades de la superficie terrestre que pueden caracterizar la fenología de los cultivos (Gao & Zhang, 2021). La dinámica fenológica derivada de datos procedentes de satélites se refiere a la fenología de la superficie terrestre (*Land Surface Phenology*, LSP). Las métricas de LSP más frecuentes se estiman normalmente como el día del año correspondiente al inicio, el final y el pico de la temporada.

En la literatura se constata la diversidad de sensores satelitales que se han empleado para detectar la dinámica de la vegetación y analizar la fenología. Se comenzó en 1981 con las observaciones satelitales diarias del radiómetro avanzado de muy alta resolución AVHRR-NOAA (Goward et al., 1985), que contaba con 5 bandas espectrales –rojo, infrarrojo cercano, infrarrojo medio y dos bandas en el infrarrojo térmico– y una resolución espacial en el nadir de 1,1 km. Este sensor cedió protagonismo al espectroradiómetro de imágenes de resolución moderada MODIS a bordo de los satélites Terra y Aqua (Boschetti et al., 2009; Cao et al., 2015; Sakamoto, 2018; Zhang et al., 2003), por su alta resolución temporal y su

resolución espacial máxima de 250 m en sus bandas 1 (rojo) y 2 (infrarrojo cercano). Sin embargo, 250 m sigue siendo una resolución demasiado grosera y solo es aplicable a escala regional o para grandes parcelas homogéneas, ya que en parcelas pequeñas genera problemas de píxeles mixtos. Para mejorar la resolución espacial se han fusionado imágenes de media resolución espacial y alta resolución temporal con imágenes de alta resolución espacial y baja resolución temporal; por ejemplo, imágenes de MODIS con imágenes de Landsat (Gao et al., 2017) o de SPOT-5 (Zeng et al., 2016), aunque estos métodos de fusión no satisfacen por completo y todavía presentan margen de mejora (Shi et al., 2022).

Actualmente, la misión Sentinel-2 ofrece una serie temporal sistemática y gratuita con un ciclo de repetición semanal mínimo de 5 días, lo que permite un seguimiento preciso del desarrollo del cultivo (Veloso et al., 2017). Además, la continuidad de imágenes Sentinel está garantizada hasta 2030 y la próxima generación de Sentinel (2C tiene previsto el lanzamiento en 2024) está planificada más allá de 2030, lo que permite garantizar un monitoreo ambiental a largo plazo. Con Sentinel 2 se ha abierto un gran potencial para estudios de fenología dada su resolución espacial y temporal; las bandas de borde rojo han sido consideradas beneficiosas en el estudio de la fenología en áreas urbanas (Granero-Belinchon et al., 2020). Además, Sentinel 2 tiene la capacidad de integrar imágenes de otros sensores compatibles (Misra et al., 2020).

Aunque cada vez hay mayor número de satélites con alta resolución espacial y temporal, los sensores ópticos siempre tienen el inconveniente asociado a la presencia de nubes. Para resolver este problema, las plataformas satelitales pueden combinarse con imágenes adquiridas con UAV (Maimaitijiang et al., 2020; Sagan et al., 2019; Zhao et al., 2019).

Durante años se ha estimado la fenología de los cultivos mediante series temporales de datos de teledetección. Las series temporales están compuestas generalmente por los índices de vegetación (IV), en lugar de utilizar directamente los datos de las bandas espectrales; su uso está muy consolidado en la literatura ya que integran dos o más bandas espectrales y, además, se ha puesto en evidencia que son mejores indicadores de las condiciones de la vegetación (Vrieling et al., 2018). Los IV más utilizados son NDVI, EVI, OSAVI, WDRVI o PPI, entre otros (Cao et al., 2015; Gao, Anderson, & Hively, 2020; Tian et al., 2021; Wu et al., 2014). El proceso para estimar la fenología normalmente incluye dos pasos fundamentales (Zeng et al., 2020): i) la aplicación de técnicas de suavizado y reconstrucción de la serie temporal y ii) la extracción de las métricas de la fenología de la vegetación.

En el primer paso se aplican técnicas que pueden realizarse mediante métodos empíricos, mediante ajustes de curvas o mediante la transformación de datos. En el primer caso se opera sobre una ventana temporal local dentro de la serie temporal basada en supuestos (Cao et al., 2018; Julien & Sobrino, 2010); en los métodos de ajustes de curvas se aplican funciones matemáticas para ajustar las curvas de series de tiempo del IV a una función específica (Cao et al., 2015; C. Wang et al., 2015; Zhang et al., 2003); en la transformación de datos se aplican funciones trigonométricas, siendo una de las transformaciones de datos más utilizada la transformada de Fourier (Sakamoto et al., 2005).

En el segundo paso, para extraer métricas de fenología de la vegetación, se pueden adoptar varios enfoques, siendo los más utilizados la aplicación de un umbral fijo o predefinido en los IV (White et al., 2014) o la detección de fechas clave, determinadas por el momento en el que se produce una tasa de cambio de la curvatura (Zhang et al., 2003). Estos métodos normalmente requieren tener datos del ciclo completo del cultivo, desde la siembra hasta la cosecha.

Recientemente se han desarrollado enfoques, dentro de la temporada, para cartografiar la emergencia de cultivos y el final de la etapa de senescencia sin necesidad de tener los datos del ciclo completo. Estas nuevas metodologías dentro de la temporada se centran en la detección de momentos específicas y están orientadas a las aplicaciones casi en tiempo real (Gao et al., 2021; Gao, Anderson, & Hively, 2020; Gao, Anderson, Daughtry, et al., 2020).

I.1.2 Retos de la digitalización en el marco de la Política Agrícola Común

Las prácticas agrícolas han cambiado a lo largo de los años, favoreciendo la biodiversidad y generando una amplia gama de paisajes agrícolas. Con el tiempo, las explotaciones se han intensificado y mecanizado, si bien las más pequeñas y tradicionalmente familiares se han quedado al margen y, en muchas ocasiones, han desaparecido, con consecuencias negativas para la biodiversidad (Comisión Europea, 2011).

La Estrategia de la Unión Europea sobre la biodiversidad señala que la integración en la Política Agrícola Común (PAC) de las necesidades de la biodiversidad ofrece buenas oportunidades para aumentar las sinergias y potenciar al máximo la coherencia entre los objetivos de la conservación de la biodiversidad y los de la agricultura (Comisión Europea, 2011). Es importante trabajar con los agricultores para apoyar e incentivar la transición a prácticas plenamente sostenibles, como la agricultura de precisión, agricultura ecológica, agroecología o agrosilvicultura, mediante la promoción de planes ecológicos y planes de pago basados en resultados (Comisión Europea, 2020).

En la reforma de la PAC de 2015 se promovió mejorar los procedimientos medioambientales de la agricultura comunitaria, haciendo obligatorias determinadas prácticas agrícolas beneficiosas para el clima y el medio ambiente a través del denominado "pago verde o greening". El pago verde tiene como fin proporcionar una remuneración a los agricultores por los bienes públicos que suministran mediante tres medidas: la protección de los pastos permanentes, incluidos los más sensibles desde el punto de vista medioambiental; la diversificación de cultivos; el mantenimiento de un porcentaje de las tierras cultivables como superficies de interés ecológico. A partir de la campaña 2015 estas medidas son obligatorias para los pagos directos.

Según el Fondo Español de Garantía Agraria (FEGA, 2020), la aplicación en España del pago verde ha generado, desde su implantación en 2015, una destacada evolución hacia una mayor diversificación de los cultivos, lo que ha favorecido importantes avances en términos de biodiversidad y mejora del suelo. De esta forma, las explotaciones que en 2014 tenían uno,

dos o tres tipos de cultivo representaban el 63% del total, cifra que se ha ido reduciendo progresivamente hasta 2019, en la que representan solo el 38%; por su parte, el número de explotaciones que tenían cuatro o más tipos de cultivo se ha incrementado desde el 37% en 2014 al 62% en 2019.

En la nueva PAC, promovida por el Consejo de la Unión Europea, que entrará en vigor a partir de 2023 se refuerzan los requisitos para asegurar una producción agraria respetuosa con el medio ambiente y que contribuya contra la lucha contra el cambio climático. Se transforma el pago verde que se incluyó en la reforma de la PAC de 2015, por una serie de eco-regímenes, que incluyen diversos requisitos que los beneficiarios de ayudas tienen que cumplir en relación con las prácticas agrícolas beneficiosas para el clima y el medio ambiente mediante “Buenas Condiciones Agrícolas y Medioambientales (BCAM)” (Ministerio de Agricultura, 2021).

Las administraciones públicas tienen la obligación de comprobar que se cumplen los requisitos de la condicionalidad, por lo que las autoridades europeas recomiendan encarecidamente técnicas de teledetección para hacer la monitorización. Como consecuencia, muchos estudios abordan los temas de identificación de cultivos y pastizales y el seguimiento de prácticas de gestión como cosecha, corte y rotación de cultivos basados en datos satelitales de los sensores Sentinel 1 y Sentinel 2 (Bargiel, 2017; d’Andrimont et al., 2020; Ottosen et al., 2019; Taravat et al., 2019; Veloso et al., 2017). En este sentido destacan los estudios del *Joint Research Centre* de la Comisión Europea, que facilitan la extracción de marcadores temporales a partir de los datos de las series temporales Sentinel 1 y Sentinel 2 para cuantificar los rasgos de la fenología y detectar eventos de gestión (Devos et al., 2017; Milenov et al., 2018; Milenov et al., 2018).

Con la revisión del Reglamento de Ejecución de la Comisión (Reglamento 2018/746 de 18 de mayo de 2018), las técnicas de teledetección se convirtieron en una fuente evidente de datos para el seguimiento agrícola. En la actualidad, la verificación de los cultivos se lleva a cabo mediante su monitorización, que es un procedimiento de observación periódica y sistemática de la tierra, basado fundamentalmente en la utilización de las imágenes de los satélites Sentinel del Programa Copernicus. Su objetivo es verificar la actividad declarada por el agricultor y la observada en la serie temporal de imágenes de satélite. Esta información puede ser completada por otras tecnologías como el uso de drones o fotografías geoetiquetadas y visitas de campo (FEGA, 2021).

I.1.3 Los regadíos en Aragón y las dobles cosechas

Los regadíos a lo largo del pasado siglo han sido una pieza clave en los procesos de las transformaciones agrarias, al posibilitar usos del suelo alternativos a los hasta entonces predominantes. Se ha incentivado la adopción de nuevas tecnologías que han supuesto un gran cambio de la agricultura tradicional a la agricultura moderna.

El gran paso de los regadíos aragoneses se da a partir de los años 50 del siglo XX. Así pues, en 1990 se regaban en Aragón unas 390.000 ha, distribuidas entre Canal Imperial y

Tauste, Canal de Bardenas, Riegos del Alto Aragón, Canal de Aragón y Cataluña, Bajo Gallego, Cuenca del Guadalupe, Cuenca del Jalón, Ribera del Cinca, otros riegos del Ebro y resto de pequeños regadíos (Bolea, 2003). En el año 2021 en Aragón la superficie regada es de 423.187 ha (ESYRCE, 2021). La superficie regada ha aumentado, en cambio, el uso del agua en el sector agrario tiene una marcada tendencia a la baja. El volumen de agua de riego utilizado en 1999 era de 2.836 hm³, pero en 2009 descendió a 2.301 hm³ y en 2018 se situó en 2.072 hm³ según las encuestas sobre el uso del agua en el sector agrario. Esta mejora en la utilización de los recursos hídricos es el resultado de las actuaciones llevadas a cabo para la modernización de regadíos. A partir del año 2001, con el Decreto 48/2001, de 27 de febrero del Gobierno de Aragón, mejoran las condiciones de las ayudas para la modernización de infraestructuras de regadíos existentes, así como la creación de nuevos regadíos. A esto se le unen las actuaciones del Plan Nacional de Regadíos (Real Decreto 329/2002, de 5 de abril), que dan lugar a la colaboración del gobierno central y el autonómico para implementar el plan, dando origen a un periodo de elevadas inversiones en el desarrollo de la política de regadíos (Sanagustín Sanz, 2017). Esto ha supuesto el cambio en los sistemas de riego, pasando en muchos casos a sistemas más eficientes y con demandas de agua menores.

No obstante lo anterior, el riego por gravedad sigue siendo en la actualidad el mayoritario, aunque ha descendido un 5,49% entre los años 2010 a 2019. En cambio, los sistemas de riego que requieren menor cantidad de agua han aumentado: el riego por aspersión con un 14,17% y el riego localizado con un 23,13% (Subsecretaría de Agricultura Pesca y Alimentación, 2020). La mejora en los sistemas de regadío permite ahorrar agua y mano de obra; muchas comunidades de regantes controlan los riegos de manera automática, constituyendo un método eficaz y más económico que los sistemas tradicionales (García Ruiz et al., 2003).

En las zonas donde los regadíos se han modernizado llevan asociada la concentración parcelaria con una mejora de la gestión para las comunidades de regantes, aumentando el tamaño medio de la explotación y, por tanto, reduciendo costes para el agricultor. Un ejemplo de situación de las parcelas en la actualidad se puede ver en la Figura I-1.

Además de los cambios en las superficies de las parcelas, también ha cambiado el tipo de cultivos. En la actualidad los cultivos leñosos como el almendro o melocotonero tienen una superficie importante en los regadíos, aunque la superficie es mayor en los cultivos extensivos como la cebada, el maíz, la alfalfa, el girasol o el arroz. Por otra parte, cada vez son más frecuentes las dobles cosechas para aumentar la rentabilidad de las parcelas; con las dobles cosechas se puede incrementar la producción entre un 15-20%.

En Aragón la superficie de segundas cosechas ha aumentado considerablemente; por ejemplo, en 2015 se cultivaron entre 30.000 y 35.000 ha de maíz, mientras que en el año 2020 esta superficie aumentó hasta las 45.471,65 ha (Gutiérrez López, 2022).

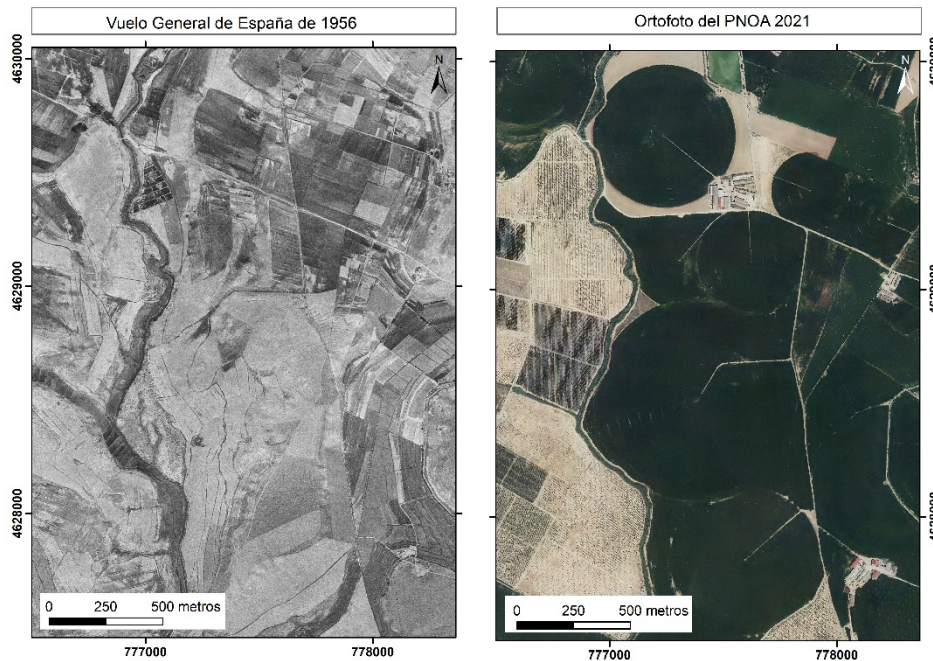


Figura I-1. Diferencia de las superficies de cultivo en los años 1956 y 2021 en una zona entre los municipios de Esplús y Tamarite de Litera (Huesca).

El maíz y girasol en las dobles cosechas

Dos de los cultivos que más se siembran en Aragón como segundos cultivos en dobles cosechas son el maíz y, en menor medida, el girasol. Para desarrollar esta tesis doctoral se han seleccionado ambos cultivos dada la importancia que tienen en las dobles cosechas en la Comunidad Autónoma de Aragón; además del interés por su representatividad, estos cultivos tienen patrones de cobertura de suelo muy diferentes, lo que ha permitido comparar los resultados obtenidos.

El maíz es uno de los cereales que más se produce y consume a nivel mundial. Se utiliza principalmente para fines alimentarios, además de para la producción de biocarburantes y para usos industriales. Su producción en 2020 fue de 1.162,35 millones de toneladas (Mt). Durante los últimos años se ha avanzado en la mejora genética de este cultivo, obteniéndose mejoras significativas en su adaptación a zonas más frías y en la obtención de híbridos muy productivos, junto con la resistencia a parásitos; ello ha propiciado que se haya convertido en una de las especies más cultivadas en el mundo. En la Unión Europea (27), la producción de maíz para la campaña 2020 fue de 67,85 Mt, comparativamente menor que la de los años 2018 y 2019, pero que ha aumentado con respecto al promedio de los últimos 5 años (FAOSTAT, 2021). En España es uno de los cereales más importantes junto con el trigo y la cebada, con una producción de 4,12 Mt (MAPA, 2021). Aragón es la segunda Comunidad Autónoma donde más maíz se produce de España, representando el 25% de la producción nacional (Figura I-2), con una producción en la campaña 2020/2021 cercana al millón de toneladas de grano.

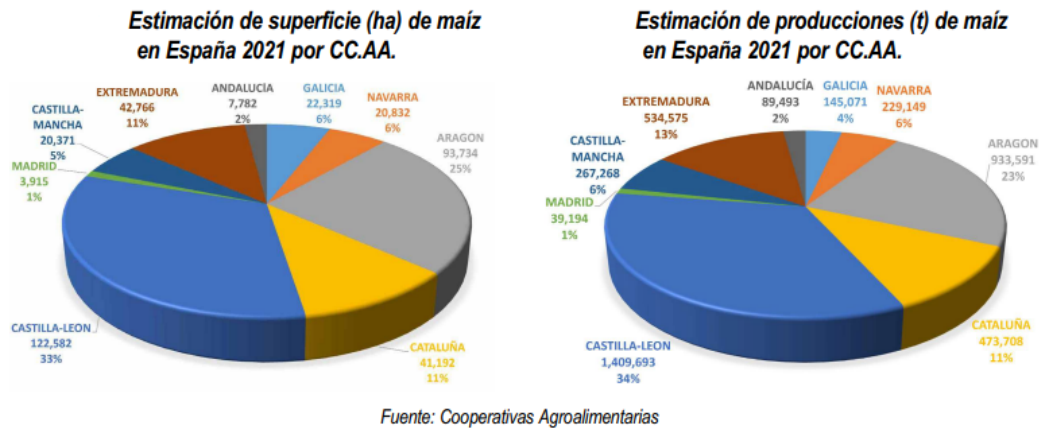


Figura I-2. Estimación de superficie (ha) y producciones (t) de maíz en España por Comunidades Autónomas en 2021. Extraído del informe de “Transferencia de resultados de la red de ensayos de maíz y girasol en Aragón. Campaña 2021” (Gutiérrez López, 2022).

El maíz representa en Aragón el 65% de la superficie de los cultivos extensivos de verano en el Valle del Ebro. En la campaña 2020 la superficie de maíz cultivada en Aragón fue de 85.420 ha (Figura I-3), es la cifra –junto con la campaña de 2019– más alta en los últimos 20 años, que suponen la recuperación del cultivo, ya que la última década había descendido notablemente. Esto se debe, en parte, a que en las últimas campañas está aumentando la superficie de maíz de segunda cosecha, que ya supone el 48,51% de la totalidad del maíz sembrado en Aragón, sobre todo en Huesca, provincia donde se siembra el 78% de la superficie total de maíz y el 87% del de segundas siembras tras otros cultivos (Gutiérrez & Aranda, 2021).




Figura I-3. Superficie de maíz en Aragón por provincias en desde 2014 a 2020. Fuente: Centro de Transferencia agroalimentaria (2022).

El girasol tiene menor superficie dedicada que el maíz, pero es una buena opción para el segundo cultivo en las dobles cosechas por su ciclo vegetativo más corto. Los usos

fundamentales de las semillas del girasol son para harina y aceite. La primera se utiliza para la industria de alimentos, ya que su contenido en proteína es alto y la hace atractiva para la alimentación del ganado. Por otro lado, el aceite de girasol es uno de los más demandados, ya que es uno de los que proveen mayores beneficios para la salud. Su producción en 2020 fue de 50,23 Mt. Al igual que con el maíz, durante los últimos años se ha investigado y van surgiendo nuevas variedades para hacer frente a plagas como el jopo, un patógeno parásito del girasol que muta con gran facilidad, constituyendo una amenaza constante, o para conseguir mejores calidades de aceite como el alto oleico (Gutiérrez & Aranda, 2021). Para el conjunto de la Unión Europea (27), la producción de girasol para la campaña 2020 fue de unos 9,1 Mt, algo inferior a la de los años 2018 y 2019 (FAOSTAT, 2021). En España la producción fue aproximadamente de 878,2 mil toneladas, se cultiva principalmente en Castilla y León, Andalucía y Castilla-La Mancha fundamentalmente en secano y en Aragón en menor medida y fundamentalmente en regadío. En Aragón el cultivo de girasol en la campaña 2020 ocupó una superficie menor que la de maíz, unas 14.000 ha (Figura I-4), con una producción de 20,32 mil toneladas; no obstante, es un cultivo importante en las rotaciones y alternativas tanto en secano como en regadío.

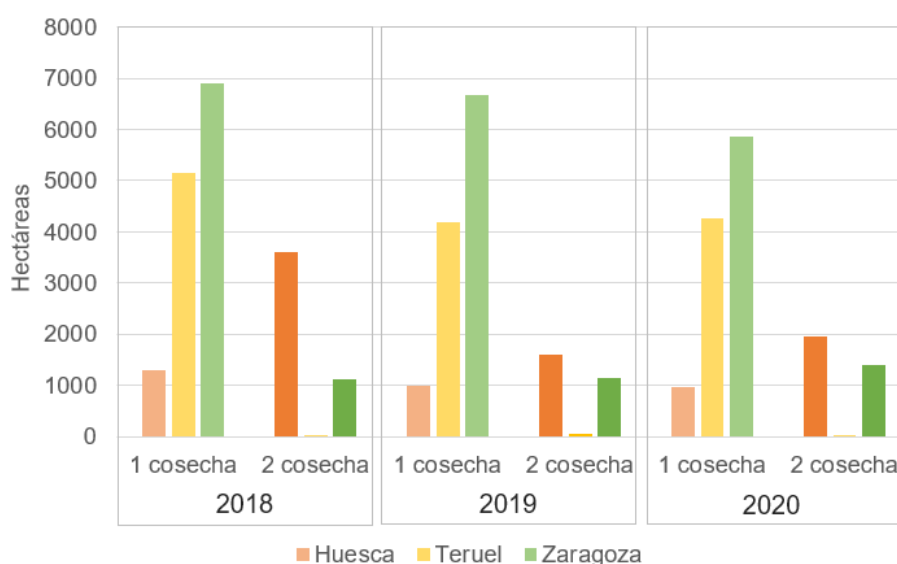


Figura I-4. Superficie de girasol en Aragón por provincias en 2018, 2019 y 2020. Fuente: Mur et al. (2021).

En Aragón, existen dificultades para verificar ciertos cultivos y ciertas operaciones de manejo en el control de los requerimientos de pago verde de las PAC, para lo que se sigue recurriendo a las visitas de campo. Una de estas dificultades se encuentra en la identificación temprana de la presencia de los segundos cultivos de la doble cosecha dentro del periodo de verificación fijado. En esta tesis doctoral se van a aportar soluciones operativas a la identificación temprana de la presencia de estos cultivos mediante series temporales de diferentes sensores.

I.2 Objetivos

El objetivo general de la tesis doctoral es la identificación temprana de la presencia y el desarrollo de cultivos de regadío mediante técnicas de teledetección, a partir de series temporales de datos de diferentes sensores, a diferentes escalas, para maíz y girasol. Para ello se utiliza información de campo registrada por cámara digital y espectrorradiómetro, imágenes aéreas con UAV y satelitales de Sentinel 2. La integración multiescala, desde la observación puntual, la parcela, hasta el regadío en Aragón se apoya en técnicas de modelado estadístico. Con todo ello se persigue aportar soluciones operativas a los requerimientos de la digitalización en agricultura.

Para responder a este objetivo general se definen los siguientes objetivos específicos:

Objetivo 1. Evaluación de la consistencia de los datos de reflectividad y de los índices de vegetación procedentes de los sensores Sequoia a bordo de un UAV y de MSI de Sentinel 2 para su aplicación operativa en agricultura.

Objetivo 2. Determinación temprana del inicio de la etapa de desarrollo de los cultivos de regadío a partir de series temporales de imágenes multiespectrales para segundas cosechas de maíz y girasol.

Objetivo 3. Identificación y análisis de la distribución espacial y del inicio de la etapa de desarrollo (IED) en parcelas comerciales de maíz y girasol de segunda cosecha en los regadíos de Aragón.

I.3 Estructura de la memoria

Esta tesis doctoral está estructurada en cinco capítulos: los dos primeros son introductorios (capítulos I y II), los tres siguientes son los capítulos de desarrollo, que dan respuesta a los objetivos planteados (capítulos III, IV y V), y un último capítulo de conclusiones y perspectivas de futuro (capítulo VI).

En el Capítulo I se describen, además de la estructura aquí presentada, el marco conceptual, la justificación de la investigación y los objetivos.

El Capítulo II presenta la zona de estudio y los cultivos analizados; además, se muestra, para el maíz y el girasol, su distribución, sus exigencias climáticas y edáficas, sus ciclos fenológicos y su caracterización espectral.

En el Capítulo III se desarrolla el objetivo 1, en el que se evalúa si la reflectividad a nivel superficial y los IV derivados desde los sensores Sequoia a bordo de un UAV y MSI de Sentinel 2A y 2B son lo suficientemente consistentes para proporcionar información útil para los actuales requerimientos de la digitalización en agricultura. Para ello se comparan los datos obtenidos con espectro-radiometría de campo con los datos de los sensores Sequoia y MSI de Sentinel 2A y 2B; también se relacionan los datos de Sequoia y MSI de Sentinel 2A y 2B.

En el Capítulo IV se desarrolla el objetivo 2, en el que se determina inicio de la etapa de desarrollo de los cultivos de regadío a partir de series temporales de imágenes

multiespectrales para segundas cosechas de maíz y girasol. Para lograr este objetivo, se aplica un nuevo enfoque basado en técnicas de detección del punto de cambio aplicadas a una serie temporal corta de índices de vegetación derivados de imágenes de Sentinel 2 y UAV. También se aplica una metodología más estandarizada, como es el ajuste de la serie temporal de varios IV utilizando una curva logística y calculando el punto de máxima curvatura. Ambas metodologías se comparan entre sí y con los datos obtenidos en el terreno.

En el Capítulo V se desarrolla el objetivo 3, en el que se identifica y analiza la distribución espacial y variabilidad del inicio de la etapa de desarrollo del maíz y del girasol de segundas cosechas en parcelas comerciales de regadío en Aragón. Para ello se aplica una técnica de detección de punto de cambio, la prueba de Pettit, y se estima la pendiente de Sen a la serie de NDVI de Sentinel 2. Por último, a través de la cartografía y varios análisis complementarios se ponen en relación el IED con la distribución espacial, con las características climáticas y con los cultivos precedentes.

Por último, en el Capítulo VI se extraen las conclusiones generales obtenidas de los trabajos anteriormente descritos y las líneas de trabajo que quedan abiertas para el futuro.

La tesis doctoral se acompaña de cinco anejos. En el primero se muestra un listado con las imágenes; en el segundo se incorporan las pruebas estadísticas y gráficos de los modelos de regresión lineal por cultivo y etapa del cultivo; en el tercero se incluye el recorte de las fotografías RGB cenitales y el resultado de su procesamiento en BreedPix; en el cuarto se muestran las imágenes procesadas obtenidas mediante UAV para cada fecha y parcela; en el quinto se presenta en una serie de mapas la distribución del IED y su significación para cada año y cultivo.

II. Cultivos y área de estudio

En este capítulo se describen las características de los cultivos objeto de estudio en términos de exigencias climáticas y edáficas para su desarrollo, su ciclo de cultivo y su respuesta espectral; además, se describen las zonas de estudio donde se localizan las parcelas comerciales utilizadas para la realización de esta tesis doctoral.

II.1 Características de los cultivos

Los cultivos seleccionados han sido maíz, cultivo muy relevante en el Valle del Ebro, y girasol. Son cultivos abundantes durante el verano en los regadíos de Aragón y suelen formar parte de las dobles cosechas, principalmente con la cebada como primer cultivo. Maíz y girasol son cultivos con una morfología vegetal distinta y, por tanto, una cobertura del suelo muy diferente.

II.1.1 Maíz

El maíz (*Zea mays* L.) pertenece a la subfamilia *Panicoideae*, dentro de la familia *Gramínea*, género *Zea*, especie *Zea mays*. Es uno de los cereales con mayor capacidad fotosintética, que deriva de su gran tamaño de planta, su elevada área foliar y su enorme capacidad productora de grano (Mateo Box et al., 2005). Generalmente requiere bastante incidencia de luz solar. Para que se produzca la germinación de la semilla la temperatura debe situarse entre 15°C y 20°C. El maíz puede soportar temperaturas mínimas de hasta 8°C; a partir de 30°C pueden aparecer problemas debido a la mala absorción de minerales y agua. En cuanto a las necesidades hídricas, son intensas 15 días antes y después de la floración masculina. El maíz se puede cultivar en todo tipo de suelos, prefieren los suelos ricos en elementos finos y materia orgánica, con un pH de tendencia ácida o ligeramente alcalina, con buena circulación del drenaje para no producir encharques que originen asfixia radicular (Infoagro, n.d.).

Ciclo vegetativo y respuesta espectral

El ciclo de desarrollo y estadios del maíz son diferentes según su variedad. La FAO clasifica los ciclos de maíz en 10 grupos, desde ciclo FAO 100 hasta ciclo FAO 1.000, según los días entre la nascencia y la maduración fisiológica (López Bellido, 1991). En esta tesis se estudia especialmente el maíz semiprecoz (FAO 400-500) que es aquel que necesita menos de 110 días desde la nascencia hasta la madurez fisiológica y se suelen sembrar como segundo cultivo en la doble cosecha en Aragón. No obstante, en el Capítulo III de esta tesis doctoral también se hace referencia el maíz de ciclo largo (FAO 700), que es el que presenta entre 125 y 130 días entre la nascencia hasta la madurez fisiológica.

Durante el ciclo del desarrollo del maíz se identifican varios estadios (Figura II-1). Según la descripción de Ritchie et al. (1986) se diferencia una fase vegetativa y una fase reproductiva.

Los estadios de la fase vegetativa se identifican con la letra V seguida del número de hojas que pueden distinguirse hasta el VT, que es el momento en el que todas las hojas de la planta han aparecido. Esta fase vegetativa engloba la germinación, emergencia y desarrollo vegetativo.

Los estadios de la fase reproductiva se identifican con la letra R, seguida de un número del 1 al 6 que refiere al desarrollo del grano de la mazorca. En esta fase reproductiva se produce la maduración. Tras la fecundación del grano comienza su engrosamiento, pasando por diferentes etapas: etapa de ampolla (R2), etapa de leche (R3), etapa de masa (R4), etapa de dentado (R5) y madurez fisiológica (R6) (Abendroth et al., 2011). En la Figura II-2 se presenta una serie de imágenes que muestran distintas etapas del ciclo vegetativo del maíz.

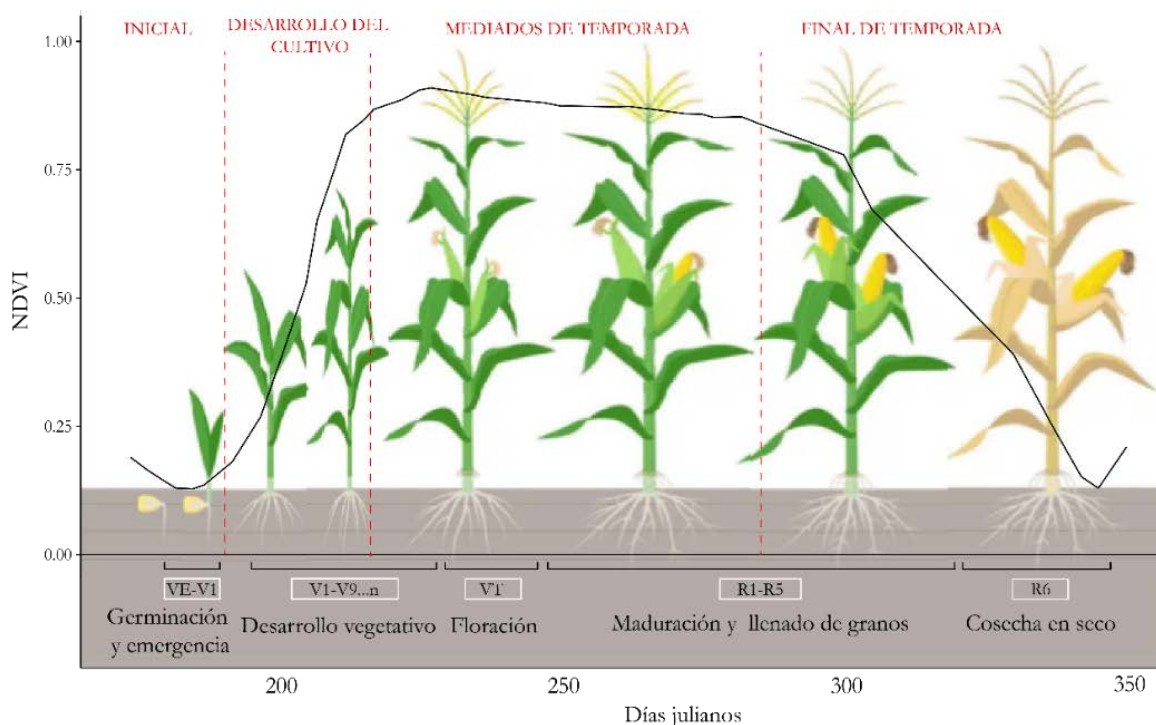


Figura II-1. Ciclo del crecimiento y desarrollo del maíz semiprecoz (FAO 400) de regadío en Almuédvar (Huesca) durante el año 2019. La curva muestra la evolución temporal del NDVI. Elaboración propia.



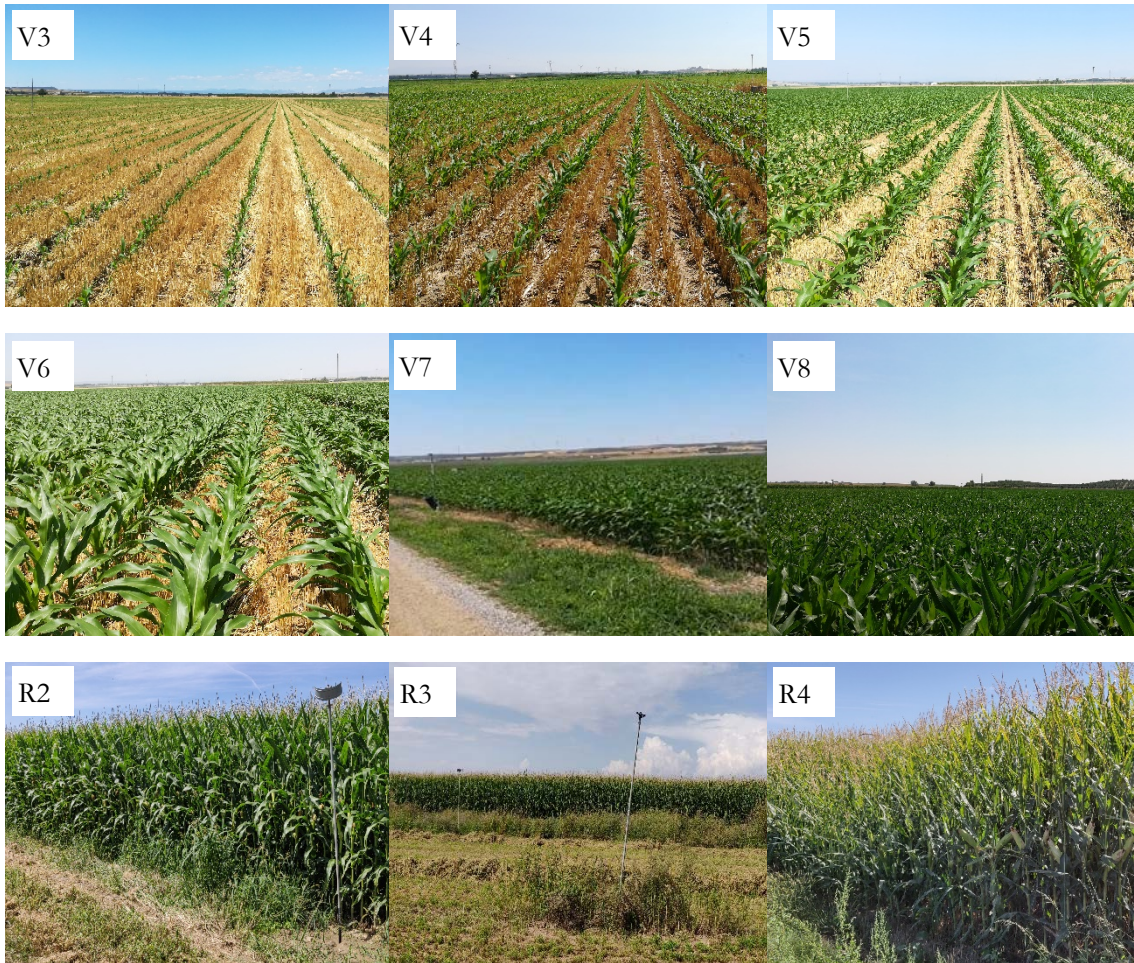


Figura II-2. Variabilidad de la cubierta vegetal del maíz en función de su ciclo.

La respuesta espectral del cultivo de maíz, como la de cualquier cultivo, varía en función de la morfología y estado de las hojas, su actividad fotosintética y su contenido en humedad y el estado fenológico. En la Figura II-3 se presenta la evolución de la respuesta espectral de la fase vegetativa de un maíz de ciclo corto (FAO 400), sembrado como segundo cultivo tras la cebada. Las regiones del espectro entre los 1350 nm y 1460 nm y entre 1790 y 1960 se interpolaron, ya que en estas ventanas espectrales la absorción del vapor de agua dificulta fuertemente la observación remota (Chuvieco, 2010); aunque se han incluido en el gráfico para dar continuidad a los datos, no se tendrán en cuenta en el análisis espectral que se presenta.

En la Figura II-3 se observa la variabilidad de la respuesta espectral en función del estadio en el que se encuentra. En los dos primeros –V1 y V2– el residuo de cebada es la cobertura dominante frente al cultivo (Figura II-2) y la respuesta espectral es muy elevada en las regiones del visible y del IC, debido al comportamiento altamente reflectivo del residuo, que se va atenuando a medida que aumenta la longitud de onda. En torno a los 670 nm, en el estadio V2 se empieza a intuir ligeramente una convexidad debido a la absorción por la clorofila.

A medida que avanza el ciclo del cultivo comienzan a hacerse más evidentes las características espectrales típicas de la vegetación. En el estadio V3 se comienza a apreciar

un pico de reflectividad, aproximadamente en 550 nm, causada por la menor absorción de los pigmentos foliares (clorofila, xantofila y carotenos), que se relaciona con la banda verde del espectro y que se ve también acentuado por la absorción de la clorofila que se observa en la longitud de onda aproximada de los 670 nm; esta última se relaciona con la banda del rojo del espectro, donde la curva de reflectividad se va haciendo más convexa a medida que se avanza en el ciclo. Se observa un orden correlativo: a mayor estadio más intensa es la absorción.

En el rango espectral del infrarrojo cercano se observan varios cambios conforme avanza el ciclo, las curvas espectrales cambian de línea en pendiente de sesgo positivo para convertirse en meseta, en la que se identifican varias bandas de absorción en función de contenido de agua de la planta. Así, a medida que la planta gana en vigor vegetal –y también lo hace en contenido de agua– se acusan las bandas de absorción que aparecen en las longitudes de onda de los 980 nm y 1240 nm. Aunque suelen seguir un orden –a mayor estadio, mayor intensidad de absorción– en los estadios que están próximos puede variar coyunturalmente la secuencia.

En el rango espectral del infrarrojo medio de onda corta las variaciones se observan dependiendo de la absorción de agua cuando la vegetación está viva y de los componentes químicos de las hojas cuando están secas (Ustin & Jacquemoud, 2020). La diferenciación entre estadios se observa fundamentalmente en torno a 2025 nm y 2100 nm. Esta variación es debida al componente de celulosa y lignina que tiene el residuo de cebada, que se traduce en un pico que se va atenuando a medida que el cultivo crece. El pico se observa hasta el estadio V5, tal y como refleja la Figura II-3; a partir del estadio V6, cuando las plantas de maíz cubren más del 60% de la parcela (Figura II-2), el pico provocado por el residuo de la cebada desaparece. En este rango espectral la diferenciación por estadios también es clara, a mayor estadio menor reflectividad, aunque la presencia de los efectos de la absorción por el agua en los espectros puede llevar a confusión entre estadios, tal y como se observa en la Figura II-3, donde el estadio V3 presenta valores más bajos que V4, debido a que en el momento en el que se tomó la medida en estadio de V3 el suelo estaba húmedo.

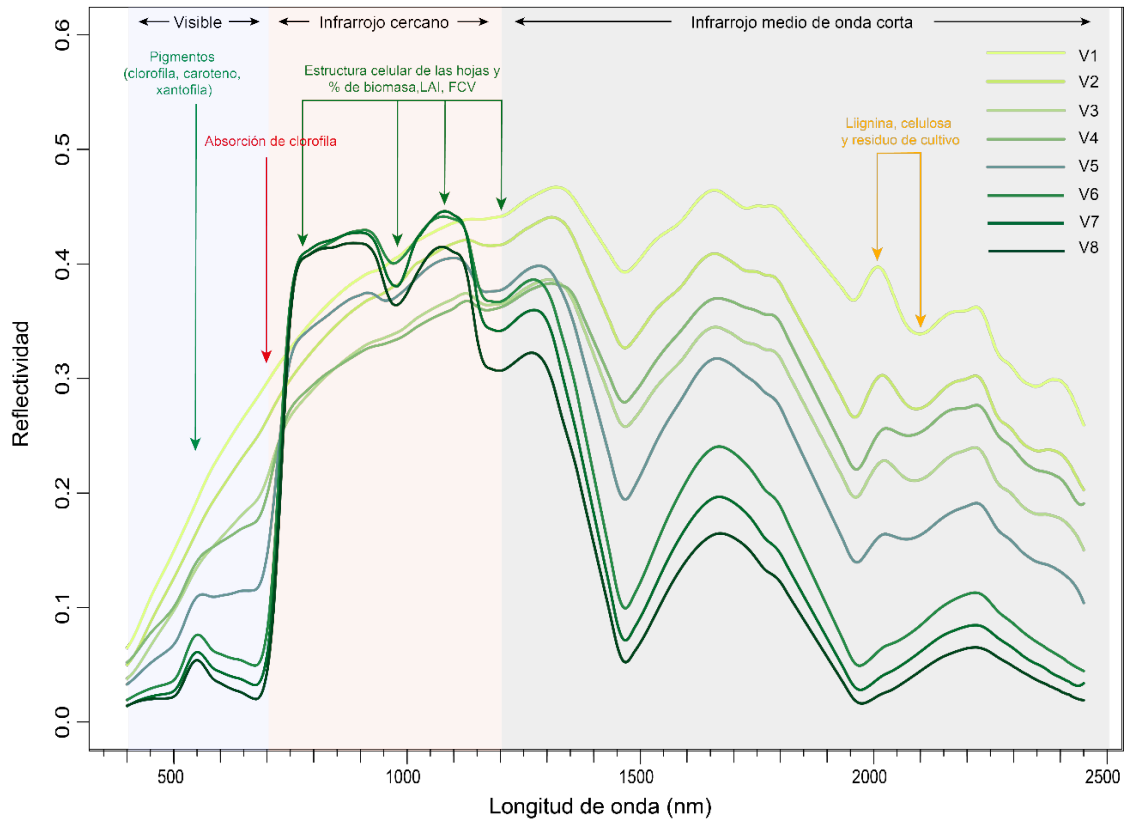


Figura II-3. Firmas espectrales del maíz según su estadio en la fase de desarrollo (V1-V8).
Elaboración propia.

II.1.2 Girasol

El girasol (*Helianthus annuus* L.) pertenece a la familia *Asteraceae*, genero *Helianthus*, especie *Helianthus annuus*. Es originario de las regiones templadas de América del Norte, aunque como cultivo está mundialmente extendido. Es una planta de gran porte que puede alcanzar los 2 m de altura. Para su óptimo desarrollo necesita un gran número de horas de insolación. Además, la temperatura es un factor importante en las primeras fases del cultivo; en la siembra, la temperatura idónea debe ser superior a 8-10°C y por debajo de 4°C no se produce la germinación. En condiciones de humedad y crecimiento normales, las mayores producciones se obtienen cuando las temperaturas en la fase de formación y llenado de semillas están comprendidas entre 18°C y 22°C (Mateo Box et al., 2005). En cuanto a las exigencias edáficas, el girasol no es un cultivo demasiado exigente en texturas de suelo y produce rendimientos aceptables sin demasiada fertilización; lo que resulta esencial es que el suelo sea profundo y tenga buen drenaje. El girasol prefiere suelos arcillo-arenosos, ricos en materia orgánica y permeables (Guerrero, 1999).

En regadío, además de como primera cosecha, también puede cultivarse como segunda cosecha tras un cultivo de invierno (cebada, colza, forrajes, etc.). En estas segundas cosechas, la siembra directa y los riegos por aspersión favorecen que el cultivo se implante en el menor tiempo posible tras la cosecha anterior. Cuanto antes se efectúe la siembra, mayor garantía hay de que la producción sea mayor. La producción en segundas cosechas es menor que en

la primera, pero sumada a la cosecha de invierno recolectada previamente supera ampliamente la producción de girasol de cosecha única (Pérez, 2016).

Ciclo vegetativo y respuesta espectral

Como ocurre con el maíz, el ciclo del desarrollo del girasol también se identifica en estadios. Uno de los métodos más utilizados es el de Schneiter & Miller, 1981. Este método diferencia entre la fase vegetativa y la fase reproductiva (Figura II-4). Los estadios de la fase vegetativa se inician con la letra V, seguida de un número par, en función del par de hojas que puede distinguirse hasta que aparece el botón floral. Esta fase engloba la germinación, la emergencia y el desarrollo de la etapa vegetativa.

Los estadios de la fase reproductiva se inician con la letra R, a la que sigue un número del 1 al 9. Se inicia con la aparición del botón floral, que abarca desde que aparece la inflorescencia (R1), hasta que la inflorescencia comienza a abrirse (R4). La siguiente etapa comprende desde que se produce la antesis de las flores tubuladas (R5) hasta que el receptáculo está completamente amarillo, pero las brácteas continúan verdes (R8). Por último, la etapa de madurez fisiológica se caracteriza porque las brácteas cambian a un color marrón (R9), concluyendo con la cosecha (MC). En la Figura II-5 se puede ver una serie de imágenes que muestran distintas etapas del ciclo vegetativo del girasol.

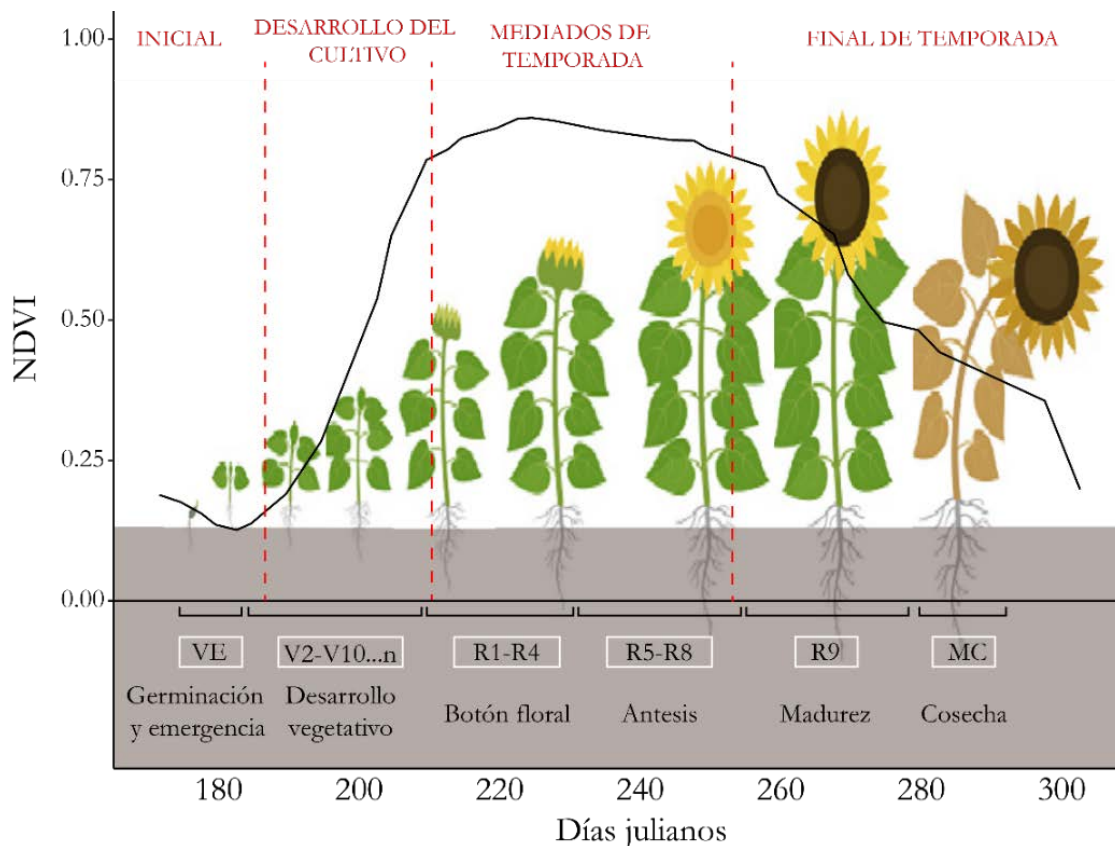


Figura II-4. Ciclo del crecimiento y desarrollo del girasol de ciclo corto de regadío en Almodévar (Huesca) durante el año 2019. La curva muestra la evolución temporal del NDVI. Elaboración propia.

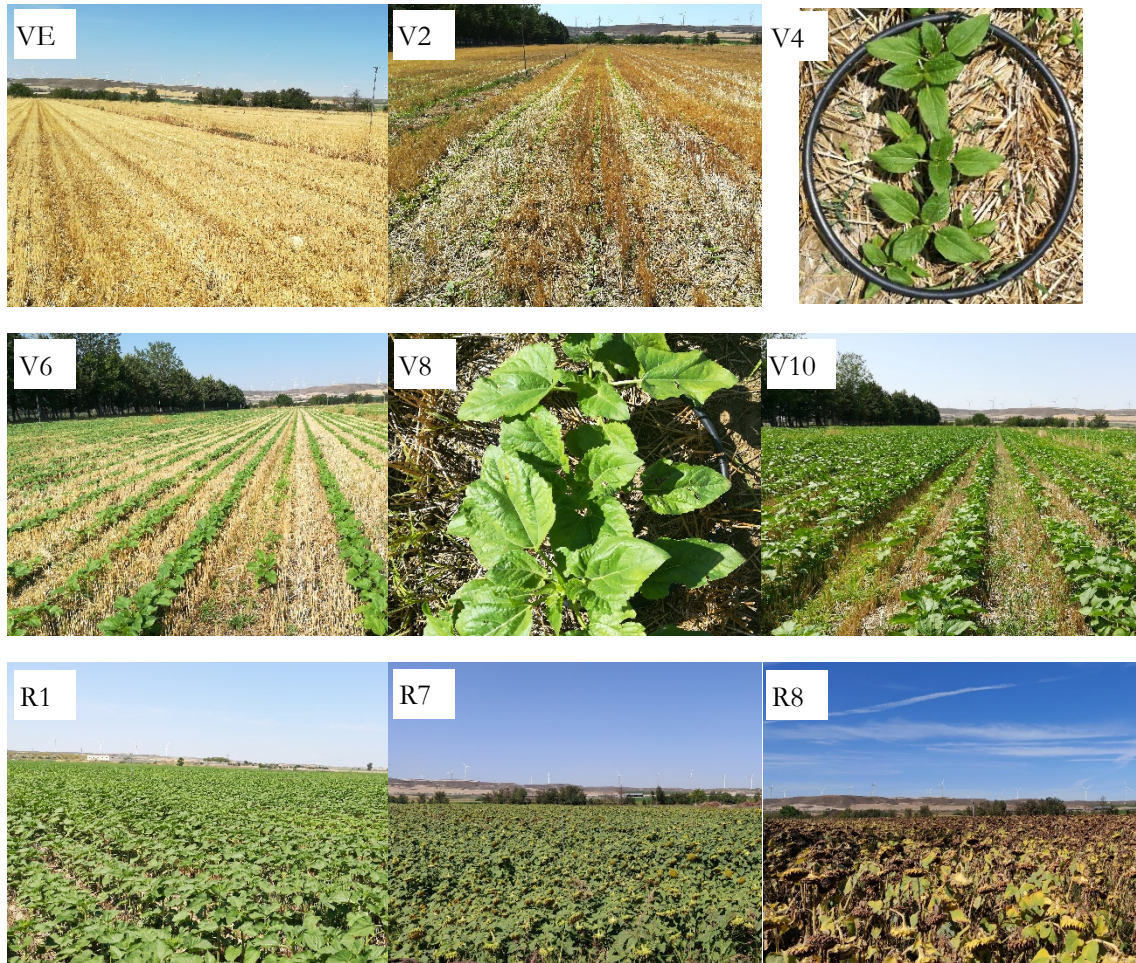


Figura II-5. Variabilidad de la cubierta vegetal del girasol en función de su ciclo.

En líneas generales la respuesta espectral del girasol es similar a la del maíz, aunque se puede observar alguna diferencia en un análisis detallado (Figura II-6). La respuesta espectral del girasol muestra cuatro situaciones diferenciadas: la primera incluye los estadios VE y V2, la segunda los estadios V4 y V6, la tercera los estadios V8 y V10 y, por último, el estadio R1. En los primeros estadios VE y V2, como en el maíz, el residuo de la cebada es la cobertura dominante (Figura II-5), que por su comportamiento reflectivo hace que en las regiones del visible e IC los valores de reflectividad sean altos; a medida que se incrementa la longitud de onda la reflectividad se va atenuando. También se observa en el rango espectral aproximado de los 670 nm, en el estadio V2 cómo se dibuja ligeramente la convexidad debida a la mayor absorción por la clorofila.

A medida que avanza el ciclo del cultivo, como para el maíz, empieza a hacerse más evidente el comportamiento espectral típico de la vegetación. En el estadio V4 comienza a destacar el pico de reflectividad situado aproximadamente en 550 nm, causado por la menor absorción de los pigmentos foliares; este pico se intensifica a medida que avanza el ciclo del cultivo. En la longitud de onda de los 670 nm, donde se produce la absorción por la clorofila, la curva de reflectividad se hace más cóncava a medida que avanza el ciclo, se observa un

orden correlativo igual que en el maíz: a mayor estadio mayor intensidad en la absorción, si bien los valores de reflectividad son algo más altos que en el maíz.

En el rango espectral del infrarrojo cercano se observan varios cambios conforme avanza el ciclo, tal y como ocurre en el maíz; las curvas espectrales varían desde línea en pendiente de sesgo positivo hasta convertirse en meseta, identificándose varias bandas de absorción en función de contenido de agua de la planta. Las bandas de absorción patentes en torno a 980 nm y 1240 nm no son tan pronunciadas como en el maíz; en esta región del espectro la diferenciación entre los estadios no es tan clara como en torno a 670 nm.

Como sucede con el maíz, en el rango espectral del infrarrojo medio de onda corta las variaciones se observan fundamentalmente en torno a los 2025 nm y los 2100 nm, debido al componente de celulosa y lignina que tiene el residuo de cebada. Pero, a diferencia de aquel cultivo, los valores en esta región del espectro son más altos, lo que se debe a que el girasol necesita menor cantidad de agua que el maíz y, por tanto, el aporte de agua de riego es menor. Además, el cubrimiento del suelo es menor que en el maíz (Figura II-5) y los rasgos espectrales en los 2025 nm y los 2100 nm se hacen visibles en todo el periodo de desarrollo del cultivo, dejándose de ver cuando el cultivo comienza en la fase de reproducción (R1). En este rango espectral la diferenciación por estadios también es clara: a mayor estadio menor reflectividad, aunque la presencia de los efectos de la absorción por el agua en los espectros puede puntualmente llevar a confusión entre estadios. Así, en la Figura II-6 se observa cómo el girasol en estadio V8 tiene valores más bajos de reflectividad en estadio V10, situación que está asociada a los riegos de la parcela antes de la toma de medidas.

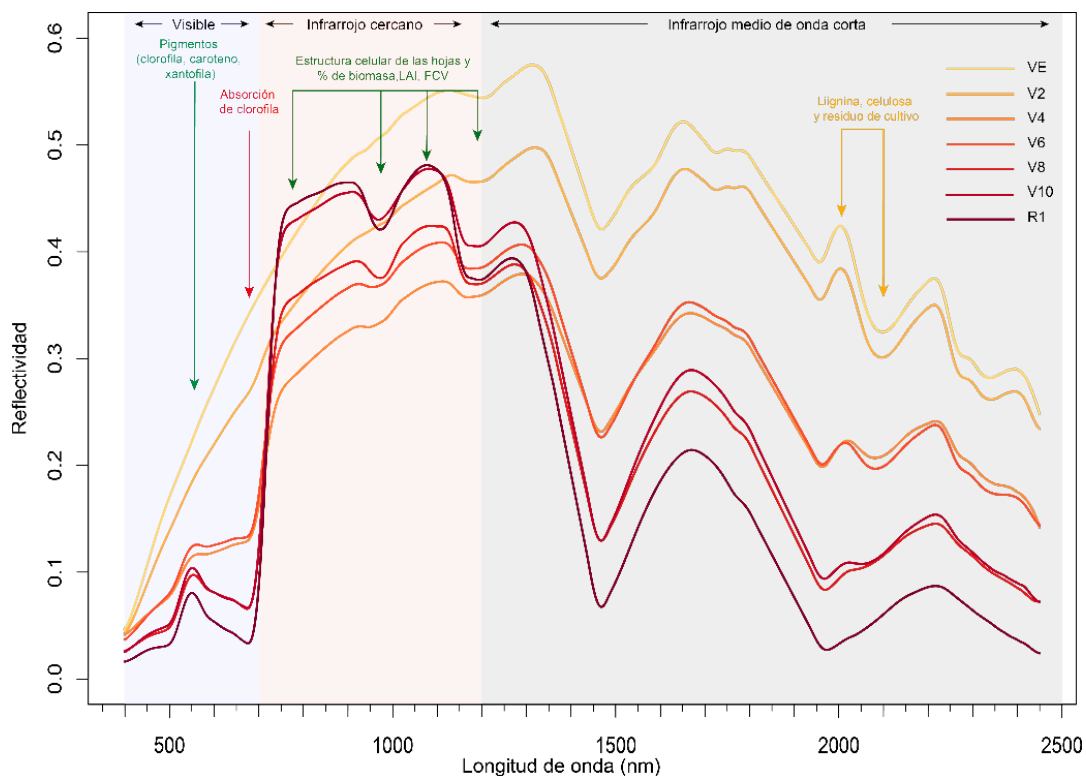


Figura II-6. Firmas espectrales del girasol según su estadio en la fase de desarrollo (VE-R1).
Elaboración propia.

El análisis visual de las características espectrales por estadios en el maíz y el girasol muestran que el rango espectral donde mejor se diferencian los estadios por cultivos es en torno a 670 nm. La diferenciación también se observa en la región del verde, pero las diferencias son menores. En las regiones del IC y infrarrojo medio de onda corta la influencia de la absorción por el agua provoca que los estadios no se diferencien de forma correlativa; además, en la región del infrarrojo media de onda corta, a pesar de observarse diferenciación, las medidas pueden estar demasiado influenciadas por las variaciones coyunturales de humedad de la parcela.

II.2 Área de estudio

En esta tesis doctoral se utilizan varias escalas de trabajo: una escala regional, localizada en el Valle del Ebro en Aragón en la que se distribuyen las parcelas que se utilizan en el Capítulo V; una escala a mayor detalle localizada en la Zona Regable de La Violada (ZRV), en la que se han seleccionado varias parcelas la mayor parte con doble cosecha y en las que, a su vez, variará la escala de trabajo en función del objetivo perseguido, de forma que se trabaja desde la observación puntual dentro de la parcela a la información por parcela completa. Estas parcelas se utilizan en los capítulos III y IV de la tesis doctoral.

II.2.1 Regadíos en el valle del Ebro en Aragón

Los grandes sistemas de regadío de la Depresión del Ebro se extienden por las llanuras de las Cinco Villas, la Violada, los Monegros septentrionales y La Litera. Desde principios del siglo XX se han ido construyendo las principales infraestructuras de regulación, conducción y aprovechamiento de aguas para transformar estas zonas llanas y áridas en nuevos regadíos. Son espacios amplios y, en cierto modo, desconectados de los cursos fluviales en los que los canales y acequias de riego constituyen elementos característicos del paisaje agrícola. La transformación en regadío de estas zonas supera el obstáculo de la aridez y favorece el aprovechamiento del amplio periodo vegetativo característico de la Depresión del Ebro, permitiendo que se realicen dos cosechas anuales (Frutos Mejías et al., 2008).

En la Depresión del Ebro también se encuentran superficies de regadíos tradicionales, que están más estrechamente vinculados a los cursos fluviales y su dinámica, como son los del Canal imperial, el Canal de Tauste, los del Bajo Gallego, los del Ebro medio o los del río Guadalope. Ocupan las franjas de las terrazas de los cauces adyacentes y, poco a poco, también están siendo modernizados, incorporando innovaciones tanto a nivel particular como de comunidad de regantes con el fin de mejorar las producciones y conseguir un uso más eficiente del agua de riego. De esta manera se hace también posible en ellos la práctica de las dobles cosechas.

En los principales sistemas de regadío de Aragón se ha seleccionado las parcelas con doble cosecha en los años 2018 y 2019 que se muestran en la Figura II-7

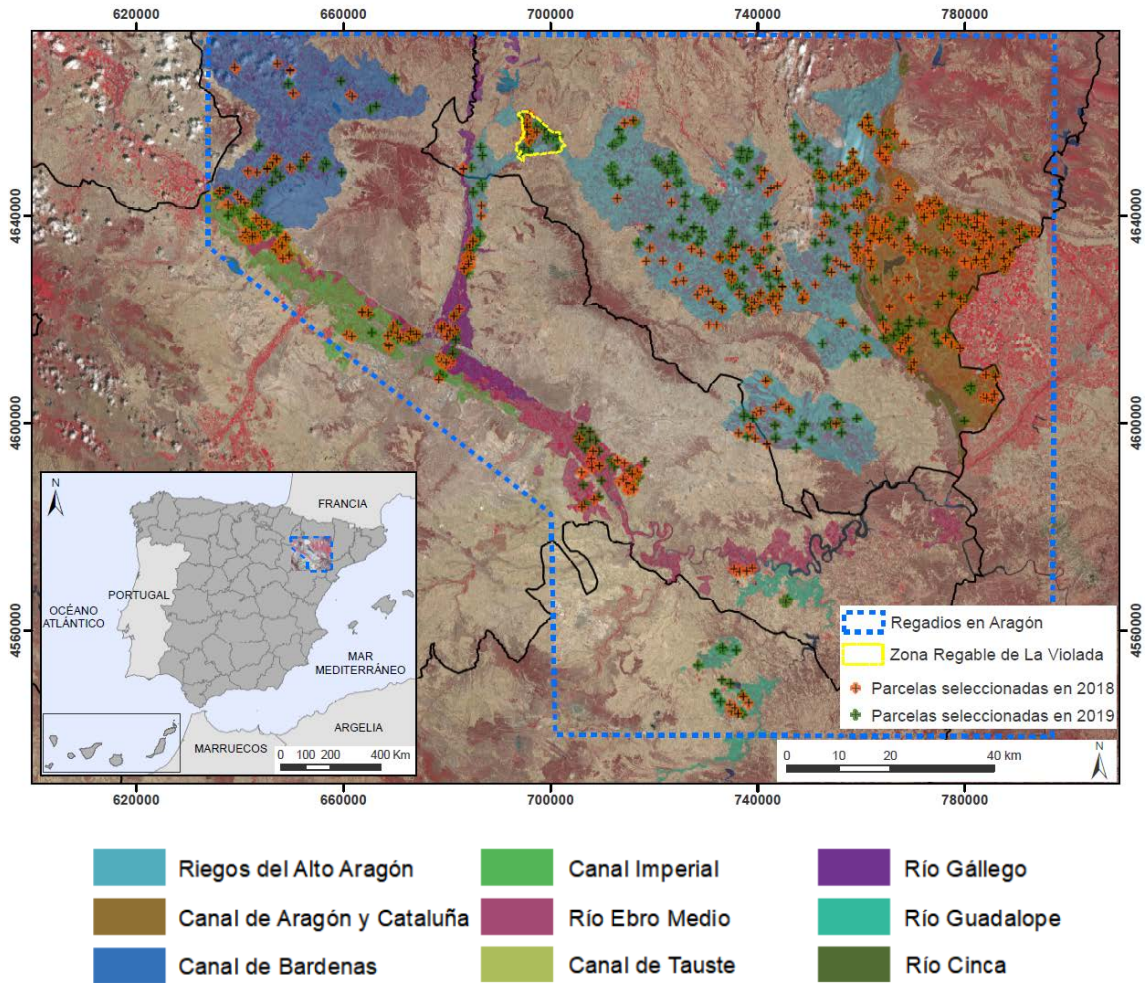


Figura II-7. Localización de las áreas de estudio. Imagen de Sentinel 2 de fecha 30 de julio de 2019 representada en falso color (IC, rojo y verde).

En las parcelas con doble cosecha el riego predominante es por aspersión, aunque en los regadíos cercanos a los cauces también se utiliza el riego por gravedad o “a manta”. Los cultivos mayoritarios son cebada, guisante, veza y raigrás como primer cultivo de invierno y maíz y girasol como segundo cultivo de verano (Figura II-8). Según las declaraciones PAC, la superficie con doble cosecha en 2018 fue de 33.407 ha y la de 2019 de 29.973 ha.

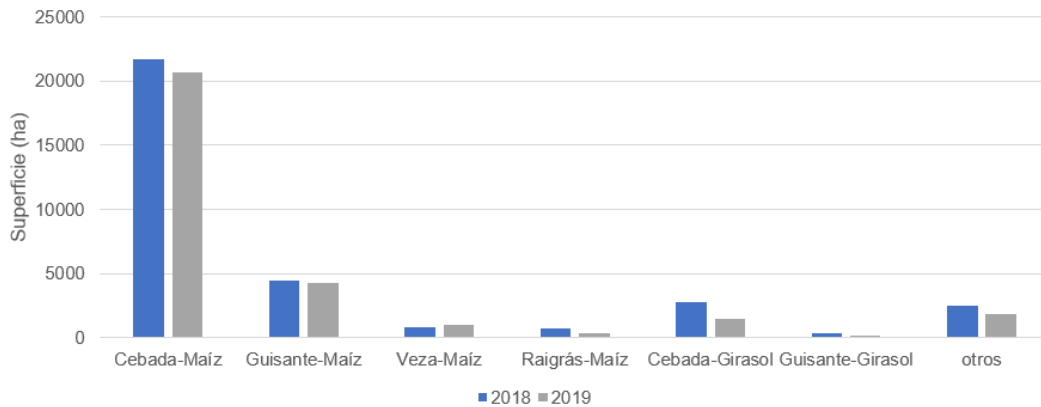


Figura II-8. Superficie declarada en la PAC con doble cosecha en Aragón. Fuente: Declaraciones PAC 2018 y 2019.

II.2.2 Zona Regable de La Violada

La Zona Regable de La Violada (ZRV), localizada en la parte central de los grandes sistemas de regadíos aragoneses, es una de las primeras áreas de la Comunidad Autónoma de Aragón en las que se implantaron cultivos de regadío (Figura II-9). Los intensos problemas de sequía desencadenaron la puesta en marcha del Plan de Riegos del Alto Aragón, cuyas obras se comenzaron a ejecutar en los años 50 del siglo XX y que han continuado expandiéndose hasta la actualidad. La ZRV se modernizó casi por completo en 2008-2009 (Jiménez-Aguirre et al., 2018), constituyendo una zona representativa de la modernización del regadío en Aragón. El 92% del área pasó de un sistema de riegos tradicionales a otro con riego por presión a la demanda con sistemas de telecontrol. Los cultivos predominantes son la cebada, el maíz y la alfalfa. Con la modernización del regadío se han ido implantando las doble cosecha, siendo en la actualidad una práctica habitual, combinando cultivos de invierno como la cebada o el guisante con cultivos de verano como el maíz o el girasol.

Dentro de la ZRV, con la colaboración de la Comunidad de Regantes de Almudévar y contando con el permiso de los agricultores para realizar las mediciones, se seleccionaron varias parcelas con doble cosecha. En la campaña de 2018 se seleccionaron 3 parcelas de girasol de ciclo corto (CC) y 4 de maíz de CC; en la campaña de 2019 fueron 3 parcelas de maíz de ciclo largo, 3 de maíz de CC y 2 de girasol de CC (Tabla III-1). La selección se realizó teniendo en cuenta las parcelas con estos cultivos durante los años de estudio y la operatividad para hacer las medidas. Así pues, se optó por seleccionar parcelas distribuidas a lo largo de un itinerario agrícola con el fin de facilitar el acceso y las mediciones con el espectrorradiómetro.




Figura II-9. Localización de la Zona Regable de La Violada y parcelas de estudio. Imagen de Sentinel 2 de fecha 30 de julio de 2019 representada en falso color IC, rojo y verde (RGB).

Tabla II-1. Parcelas seleccionadas y características generales del cultivo.

Año	Cultivo	Parcela	Hidrante	Variedad	Superficie (ha)	Densidad de siembra (plantas/ha)	Fecha de siembra	Rendimiento (kg/ha)
Ciclo corto 2018								
2018	maíz	A	208	DKC4796YG	7,47	88000	23/06/2018	12600
2018	maíz	B	227	DKC5032YG	19,91	94000	16/06/2018	13600
2018	maíz	C	267	DKC5032YG	7,40	90000	24/06/2018	12200
2018	maíz	D	289	DKC4746	3,25	90000	24/06/2018	12800
2018	girasol	E	217	8H288KLDM	7,30	90000	26/06/2018	2500
2018	girasol	F	226	8H288KLDM	10,72	100000	25/06/2018	2400
2018	girasol	G	258	8H288KLDM	15,45	90000	28/06/2018	3335
Ciclo largo 2019								
2019	maíz	A'	208	DKC6727	7,47	96000	19/04/2019	14086
2019	maíz	B'	227	DKC6980	19,91	96000	12/04/2019	14306
2019	maíz	G'	258	DKC6729	15,45	87000	14/04/2019	12300*
Ciclo corto 2019								
2019	maíz	H	206	DKC4696	3,34	88000	21/06/2019	12588
2019	maíz	I	284	DKC4696	10,50	88000	24/06/2019	12052
2019	maíz	D'	289	DKC5068	3,34	92000	26/06/2019	11880
2019	girasol	J	244	CARGUILL	6,68	85000	25/06/2019	2200
2019	girasol	K	247	CARGUILL	1,88	85000	25/06/2019	2200

* G' fue afectada por un viento fuerte el día 9/07/2019 con una valoración de pérdidas de producción de 1800 kg/ha.




Figura II-10. Fotografías de parcela de maíz con ciclo corto (G), ciclo largo (G'), de girasol (L) y de maíz de ciclo corto (H).

Las parcelas están sembradas a una distancia aproximada entre líneas de 0,73 m. La siembra se realizó con sembradoras de precisión para asegurar la perfecta distribución de las plantas. La densidad de siembra varía entre parcelas, como se observa en la Tabla III-1. En todas las parcelas de ciclo corto, excepto en la de maíz B de 2018, se realizó siembra directa tras el cultivo precedente, que fue cebada. En las parcelas de ciclo largo y la mencionada parcela B se sembró tras realizar laboreo. El riego en las parcelas es por aspersión, con un marco de 18x18 cm.

En la Figura II-10 se muestran algunas de las parcelas analizadas de maíz y girasol, representativas del área de estudio. En la parcela G' no se ha realizado siembra directa, en el resto sí y se observan los restos del cultivo precedente (cebada).

III. Comparación y evaluación de los datos obtenidos desde los sensores sequoia a bordo de un UAV y MSI de Sentinel 2 mediante espectro-radiometría de campo

En este Capítulo se desarrolla el objetivo 1 de la tesis doctoral. Concretamente, se evalúa si la reflectividad a nivel superficial y los índices de vegetación (IV) derivados de los sensores Sequoia a bordo de un UAV y MSI de Sentinel 2A y 2B son lo suficientemente consistentes para proporcionar información útil para los actuales requerimientos de digitalización en agricultura. Con este fin, se seleccionaron diferentes parcelas de maíz y girasol y se planificaron dos campañas de adquisición de datos durante los años 2018 y 2019. En la primera campaña, en 2018, se tomaron datos de espectro-radiometría de campo e imágenes de satélite; y en la segunda campaña, en 2019, además de tomar los datos de espectro-radiometría de campo e imágenes de satélite, se añadió la toma de datos con el sensor Sequoia a bordo de UAV.

La medición con espectro-radiómetro de campo es una valiosa fuente de información que sirve para evaluar los datos espaciales y aéreos. De forma habitual se utilizan los datos de espectro-radiometría de campo para validar de forma precisa los datos de los sensores espaciales (Milton et al., 2009; Sola et al., 2018; Vuolo et al., 2016). También se han utilizado en la validación datos de los sensores a bordo de UAV (Deng et al., 2018; Fawcett et al., 2020; Padró et al., 2018).

A diferencia de la mayoría de los estudios precedentes, que evalúan los datos para fechas concretas (Fawcett et al., 2020; Matese et al., 2015; Padró et al., 2018), en esta tesis doctoral se hace un seguimiento semanal y a medida que avanza el ciclo del cultivo quincenal. Se busca conocer en qué medida la variabilidad del ciclo del cultivo y el propio cultivo, según su estructura, pueden repercutir en la información radiométrica adquirida por los sensores utilizados. Para ello, se van a comparar los datos de espectro-radiometría de campo con los obtenidos con los sensores Sequoia y el sensor MSI de Sentinel 2. Así mismo se va a analizar la relación lineal entre los datos de reflectividad, así como de índices de vegetación obtenidos de estos dos sensores, con el fin de poder predecir valores de una variable en función de otra y poder cuantificar la diferencia entre un sensor y otro. Además, se va a comprobar si existen diferencias estadísticamente significativas entre la reflectividad registrada por ambos sensores.

III.1 Material y métodos

La información necesaria para el desarrollo de este capítulo de la tesis doctoral se obtuvo de 11 parcelas localizadas en la Zona Regable de La Violada. En la campaña de 2018 se seleccionaron 3 parcelas de girasol y 4 parcelas de maíz de ciclo corto (segunda cosecha); en la campaña de 2019 se seleccionaron 3 parcelas de maíz de ciclo largo, 3 parcelas de maíz de

ciclo corto y 2 parcelas de girasol de ciclo corto. La descripción detalla de los cultivos, de las parcelas de estudio y su localización se puede ver en el Capítulo II apartados II.2, II.3 y II.4.

La metodología propuesta consta de tres fases (Figura III-1): 1) preparación de las campañas de campo y obtención de datos para los años 2018 y 2019; 2) procesado de los datos para obtención de la reflectividad superficial de cada banda y generación de los índices de vegetación (IV); 3) comparación estadística de los tres sensores utilizados.

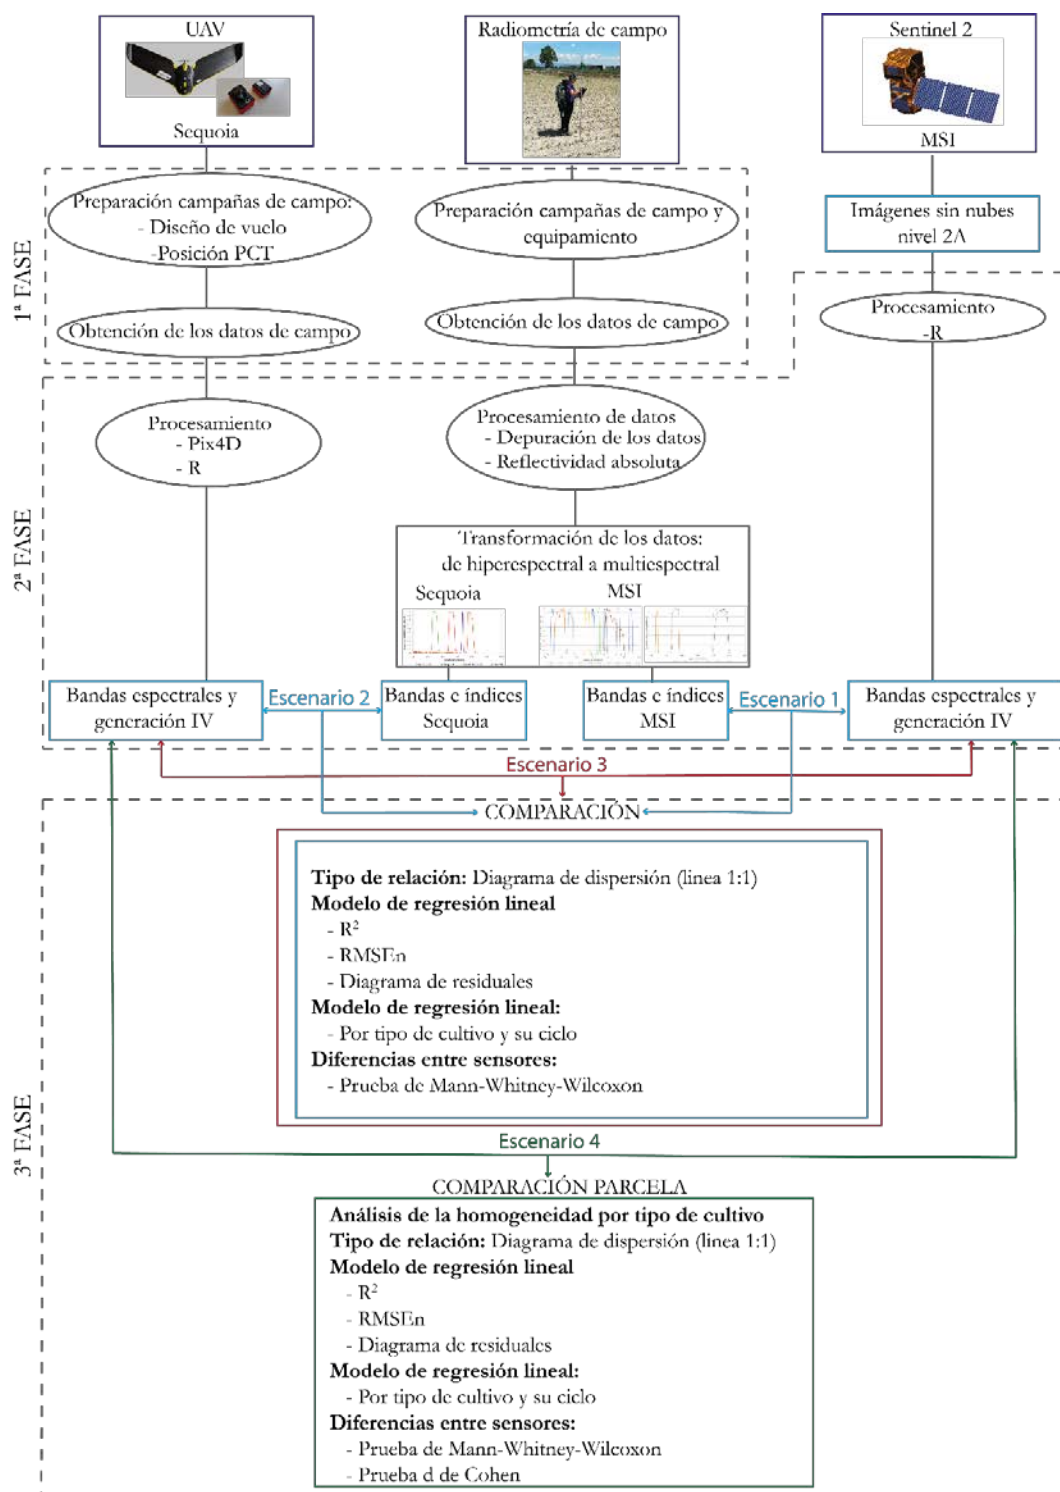


Figura III-1. Flujo de trabajo general para comparar y evaluar los sensores Sequoia a bordo de un UAV y MSI de Sentinel 2A y 2B.

Todos los procedimientos estadísticos y los gráficos presentados se desarrollaron utilizando diferentes paquetes del lenguaje de programación estadística R (R Core Team, 2020), que se van especificando en el texto conforme se utilizan.

III.1.1 Adquisición y preparación de datos

III.1.1.1 Temporalidad en la adquisición de datos

Momento de adquisición de los datos

Las medidas con el espectro-radiómetro se realizaron desde la siembra de los cultivos hasta el momento en que la altura de la planta no permitió el registro con el equipo radiométrico utilizado. Los vuelos con UAV se efectuaron desde la siembra hasta octubre, ya que posteriormente las condiciones meteorológicas (lluvia, viento principalmente) impidieron seguir con las mediciones. Este periodo abarca prácticamente el ciclo completo del girasol y hasta el estadio R4 del maíz.

Las visitas a campo se llevaron a cabo los días en los que las condiciones atmosféricas fueron óptimas para tomar las medidas radiométricas, días claros y sin nubes visibles, entre las 12:30 y las 15:30 hora local. La toma de medida se hizo teniendo en cuenta también el día de paso del satélite Sentinel 2 por la zona de estudio, para poder comparar las medidas en los días coincidentes. Los vuelos con UAV también se realizaron coincidiendo con el día de registro del satélite y además se sumó que las condiciones de viento fueran favorables, días con viento menor de 8 m/s. En la Figura III-2 se presentan las fechas de adquisición con cada instrumento.

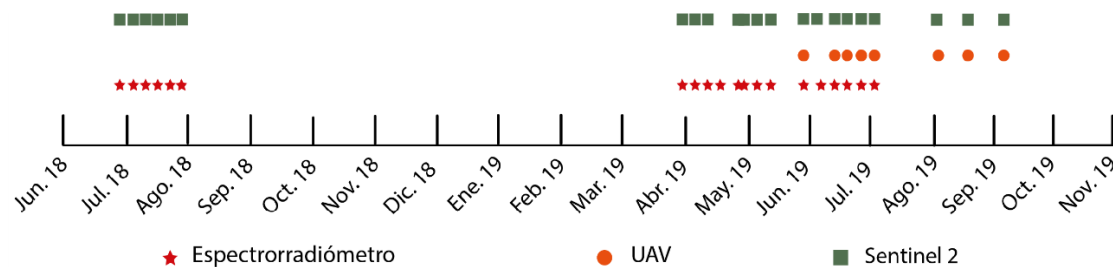


Figura III-2. Calendario de adquisición de datos con espectro-radiómetro, UAV y Sentinel 2 para los años 2018 y 2019.

Escala temporal adoptada

El ciclo vegetativo de los cultivos está estrechamente relacionado con la temperatura y, por lo tanto, la temperatura determina su desarrollo. Wang (1960) mostró que la duración de las etapas fenológicas de la vegetación está directamente relacionada con la temperatura.

En buena parte de los estudios de fenología de cultivos, el periodo de tiempo a menudo se presenta como Grados Día de Crecimiento (*Growing Degree Day*, GDD). Por lo tanto, los grados día acumulados desde el momento de la siembra (*Accumulated Growing Degree Day*, AGDD) es una variable que permite describir la evolución de la cubierta durante el ciclo del cultivo (González-Gómez et al., 2018). Esta escala temporal es la que se adopta en este Capítulo y permite la comparación de cultivos sembrados en diferentes fechas.

Los GDD se calculan restando la temperatura base (T_{base}) a la temperatura media del aire (T_{media}).

$$GDD = T_{media} - T_{base} \quad (III-1)$$

La T_{base} es la temperatura por debajo de la cual el desarrollo del cultivo no progresa. En el caso del girasol se consideró de 4°C y en el caso del maíz 8°C, valores utilizados por Malik & Dechmi (2019) para esta zona de estudio y también en el modelo AquaCrop (Versión 6.0 – 6.1) de simulación de crecimiento de los cultivos desarrollado por la FAO.

La T_{media} se calculó según el método de McMaster & Wilhelm (1997) (Ecuación (III-2)). En este método, previo al cálculo de la T_{media} , se compara la temperatura base con la temperatura superior. La $T_{superior}$ especifica la temperatura por encima de la cual el desarrollo del cultivo ya no aumenta con el incremento de la temperatura del aire. Tanto para el girasol como para el maíz esta temperatura se fijó en 30°C tal y como establece AquaCrop.

Las T_{max} y T_{min} se ajustan si caen por debajo de T_{base} o superan a $T_{superior}$ antes de T_{media} . La temperatura media viene dada por:

$$T_{media} = \frac{T_{max} + T_{min}}{2} \quad (III-2)$$

donde T_{max} es la temperatura máxima diaria del aire y T_{min} es la temperatura mínima diaria del aire.

Se aplican las siguientes normas:

- Si la $T_{max} > T_{superior}$ entonces $T_{max} = T_{superior}$
- Si la $T_{max} < T_{base}$ entonces $T_{max} = T_{base}$
- Si la $T_{min} > T_{superior}$ entonces $T_{min} = T_{superior}$
- Si la $T_{min} < T_{base}$ entonces $T_{min} = T_{base}$

Los datos meteorológicos utilizados para calcular los GDD se obtuvieron de la estación agrometeorológica de Tardienta (HU18), perteneciente a la Red de estaciones agrometeorológicas del Sistema de Información Agroclimática para el Regadío (SIAR, <https://eportal.mapa.gob.es/websiar/Inicio.aspx>).

III.1.1.2 Medidas de espectro-radiometría de campo

La espectro-radiometría de campo puede definirse como la técnica de medición de las interacciones entre la energía radiante con objetos in situ del medio ambiente (Montorio Llovería, 2014).

La espectro-radiometría de campo se convierte en el nexo entre la realidad y las medidas tomadas por sensores aéreos y satelitales. Por ello, se utiliza para el diseño y la calibración indirecta de estos sensores, para la corrección atmosférica (Milton et al., 2009; Sola et al., 2018), para establecer relaciones empíricas entre la reflectividad y parámetros biofísicos y estructurales de interés, como puede ser fracción de cobertura vegetal, índice de área foliar (LAI, *Leaf Area Index*), altura de cultivo (h), biomasa, evapotranspiración o fenología (Gilbert et al., 1996; González-Piqueras, 2006). Es por ello, que la radiometría resulta de especial interés en el seguimiento de cultivos.

Descripción y características del espectro-radiómetro de campo

Las medidas de la reflectividad se realizaron con el espectro-radiómetro portátil ASD FieldSpec®4 (Analytical Spectral Devices, Boulder, CO, USA). El espectrómetro registra con tres detectores separados visible/infrarrojo cercano (350-1000 nm), infrarrojo medio de onda corta 1 (1001-1800 nm) e infrarrojo medio de onda corta 2 (1801-2500 nm). El intervalo de muestreo espectral es de 1,4 nm para la región de 350-1000 nm y de 2 nm para la región espectral de 1001-2500 nm. La resolución espectral es de 3 nm para la región del visible y 10 nm para las regiones infrarrojo cercano e infrarrojo medio de onda corta (ASD, 2012). En el proceso de la medición, el software del dispositivo realiza la corrección de la señal eléctrica de referencia (corriente oscura) y remuestra los espectros a un intervalo de 1 nm en todas las regiones espectrales (Rosero-Vlasova et al., 2016).

Obtención de los datos de campo

La toma de datos de espectro-radiometría se realizaron de manera periódica una vez por semana, a una distancia de aproximadamente 50 m del límite de la parcela. En esta localización, el cultivo es totalmente homogéneo y se evitan los efectos de borde de parcela.

Para la recopilación de datos, el almacenamiento y la visualización de espectros se utilizó el software ASD RS³. Acorde con la recomendación del manual de ASD FieldSpec®4 (ASD, 2012) el software se configuró para promediar 10 espectros por cada escaneo de muestra, 25 promedios de blanco de referencia y 10 promedios de corriente oscura para reducir el ruido.

El instrumento se puso en marcha treinta minutos antes de empezar a realizar las mediciones, para permitir que los detectores internos alcancen sus temperaturas equivalentes (Mac Arthur, 2006). El sensor de fibra óptica del espectro-radiómetro con un campo de visión (*Field Of View*, FOV) de 25° se fijó en la pistola y esta a su vez en un sistema elevador (Figura III-3), que nos permitió medir en una posición nadir por encima del dosel de maíz y girasol a una altura aproximada de 165 cm del suelo. Así se consiguió ajustar el FOV a la superficie exacta que quería ser registrada, unos 73 cm, que es la distancia entre filas de cultivo. El sistema elevado permitió medir sin la utilización de extensiones de fibra óptica, evitando así el ruido que esto podía generar.

La radiancia medida por el sensor se transforma en energía reflejada, para lo que se emplea la radiación incidente obtenida midiendo con el mismo instrumento sobre el Spectralon®, un panel de color blanco de politetrafluoroetileno colocado sobre la superficie de la parcela (Figura III-4). Las medidas sobre la superficie de referencia se repiten regularmente –al comenzar la medición de cada parcela– durante todo el periodo de toma de datos para poder considerar equivalentes las condiciones atmosféricas y de elevación solar entre la medida de la referencia y la realizada sobre el cultivo.




Figura III-3. Medición de la reflectividad sobre maíz en estadio V2 con espectro-radiómetro portátil ASDFieldSpec4.

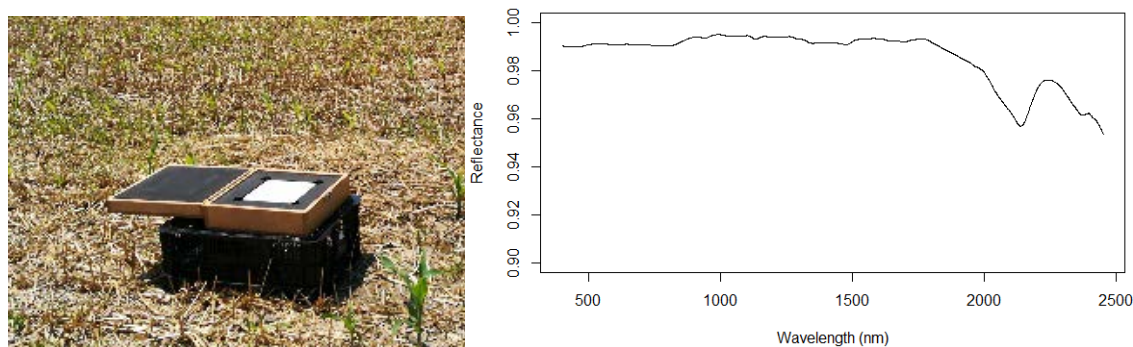


Figura III-4. Panel de referencia Spectralon® utilizado en las campañas de campo y ejemplo de su reflectividad.

Tal y como indican Milton et al. (1994), para mediciones repetidas se utiliza un soporte y un marco fijo. De este modo, se tomaron como se representa en la (Figura III-5) diez medidas caminando sobre la línea de cultivo (Transecto A) y otras diez medidas perpendiculares a la línea de cultivo (Transecto B) a un ritmo de aproximadamente de 0,75 m/s, alternado una medida sobre la línea y otra entre líneas del cultivo. Además, se realizaron tres medidas en tres puntos de la parcela, que se utilizarán en el Capítulo IV de esta tesis doctoral para obtener la función que relaciona la fracción de cobertura verde del cultivo con el índice derivado del dato radiométrico.

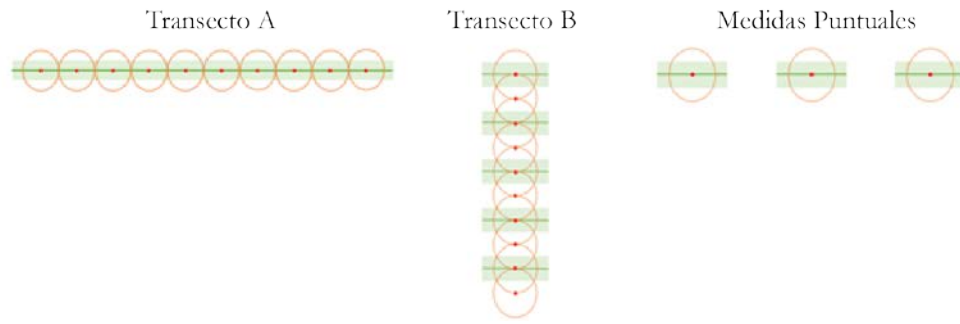


Figura III-5. Esquema de las medidas realizadas con el espectro-radiómetro de campo.

Las mediciones con el espectro-radiómetro han sido 1875: 724 en los cultivos de ciclo corto en 2018, 552 en el cultivo de ciclo largo en 2019 y 599 para los cultivos de ciclo corto en 2019 (véase Tabla III-1 a Tabla III-3). Algunas de las medidas se invalidaron porque la medición del panel referencia fue incorrecta y en otros casos hubo algún cambio de iluminación entre la medida del panel de referencia y los cultivos.

Tabla III-1. Número de adquisición datos con el espectro-radiómetro en cada fecha y transecto A y B (T-A y T-B) e información puntual (P) en las parcelas de estudio con cultivos de ciclo corto en 2018 (724 mediciones).

Parcela	27/06/2018			05/07/2018			10/07/2018			16/07/2018			23/07/2018			30/07/2018			Total
	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	
A	10*	10*		10	10	3	10	10	3	10	10	3	10	10	3				112
B	10	10		10*	10*	3*	10	10	3	10	10	3	10	10					109
C							10	10	3	10	10	3	10	10	3				69
D				10	10	3	10*	10*	3*	10	10	3	10	10	3				92
E				10	10	3	10	10	3	10	10	3	10	10	3	10	10	3	115
F	10*	10*		10	10	3	10	10	3	10	10	3	10	10	3	10	10	3	135
G							10*	10*	3*	10	10	3	10	10	3	10	10	3	92
Todas	30	30	0	50	50	15	70	70	21	70	70	21	70	70	18	30	30	9	724

* Medidas invalidadas

Tabla III-2. Número de adquisición datos con el espectro-radiómetro en cada fecha y transecto A y B (T-A y T-B) e información puntual (P) en las parcelas de estudio con maíz de ciclo largo en 2019 (552 mediciones).

Parcela	30/04/2019			06/05/2019			14/05/2019			21/05/2019			Total
	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	
A'	10	10	3	10	10	3	10	10	3	10	10	3	92
B'	10	10	3	10	10	3	10	10	3	10	10	3	92
G'	10	10	3	10	10	3	10	10	3	10	10	3	92
Parcela	29/05/2019			31/05/2019			04/06/2019			12/06/2019			Total
	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	
A'	10	10	3	10	10	3	10	10	3	10	10	3	92
B'	10	10	3	10	10	3	10	10	3	10	10	3	92
G'	10	10	3	10	10	3	10	10	3	10*	10*	3*	92
													552

* Medidas invalidadas

Tabla III-3. Número de adquisición datos con el espectro-radiómetro en cada fecha y transecto A y B (T-A y T-B) e información puntual (P) en las parcelas de estudio con cultivos de ciclo corto en 2019 (599 mediciones).

Parcela	28/06/2019			04/07/2019			10/07/2019			19/07/2019			25/07/2019			02/08/2019			Total
	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	
H				10	10	3	10	10	3	10	10	3	10	10	1	10*	10*		110
I	10*	10*		10	10	3	10	10	3	10	10	3	10	10	3	10	10		132
D'	10*	10*		10	10	3	10	10	3	10	10	3	10	10	3	10	10	3	135
J				10	10	3	10	10	3	10	10	1	10	10	3	10	10		110
K				10	10	3	10	10	3	10	10	3	10	10	3	10	10		112
Todas	20	20		50	50	15	50	50	15	50	50	13	50	50	13	50	50	3	599

* Medidas invalidadas

III.1.1.3 Imágenes UAV

Descripción del UAV y el sensor Sequoia

Las imágenes se obtuvieron con un UAV de ala fija [SenseFly eBee Classic](#) (Sensefly Ltd, 2014; Figura III-6). La estructura del eBee Classic es simple y ultraligera, puede cubrir grandes parcelas agrícolas (Mesas-Carrascosa et al., 2017) sin tener que realizar cambios de batería que aumentan los tiempos de adquisición de imágenes, ni disponer de un número mayor de baterías.




Figura III-6. UAV eBee Classic con el que se han realizado los vuelos (información obtenida (Sensefly Ltd, 2014).

El sensor instalado a bordo del eBee Classic fue Sequoia (Figura III-7). Es un sensor multiespectral diseñado para la agricultura. Cuenta con una excelente precisión, un tamaño y peso reducidos al máximo y una gran facilidad de uso (Parrot Sequoia, 2017). Sequoia incorpora 4 sensores monocromos, cada uno de los cuales recoge la información de una región del espectro; también, incorpora un sensor RGB. En la Tabla III-4 se especifican las características del sensor Sequoia. Además, para corregir los efectos de los pequeños cambios de iluminación que se dan durante el vuelo, junto con la cámara –aunque independiente a ésta– dispone de un sensor de iluminación “Sunshine” que registra las condiciones de iluminación y que se codifica dentro de los archivos de la imagen de la cámara multiespectral para la calibración radiométrica (Cowley et al., 2017).



Figura III-7. Cámara Sequoia y sensor Sunshine (información obtenida de Parrot Sequoia, 2017).

Tabla III-4. Características técnicas del Sensor Sequoia y del Sensor Sunshine.

Cámara multispectral	Resolución de la cámara	1.2 Mpx		
	Tamaño de la imagen	1280 x 960 píxeles		
	Obturador	Global Shutter		
	Distancia focal	3,98 mm		
	Bandas			
		Banda	Ancho de banda	
		Verde	550 nm	40 nm
		Rojo	660 nm	40 nm
		Borde del rojo	735 nm	10 nm
	Infrarrojo cercano	790 nm	40 nm	
Cámara RGB	Resolución de la cámara	16 Mpx		
	Tamaño de la imagen	4608 x 3456 píxeles		
	Obturador	Rolling Shutter		
	Distancia focal	4,88 mm		
Sensor sunshine	Dimensiones	47 mm x 39,6 mm x 18,5 mm		
	Peso	35 g		
	Sensores espectrales	Verde, Rojo, borde del rojo e infrarrojo cercano		
	Características adicionales	Global Positioning System (GPS) Unidad de Medición Inercial (IMU)		

La función de la respuesta espectral de los cuatro sensores monocromos (Figura III-8) del sensor Sequoia se obtuvo siguiendo la metodología de Fawcett et al. (2020) y las recomendaciones de los desarrolladores de Parrot (Fallet, 2017a).

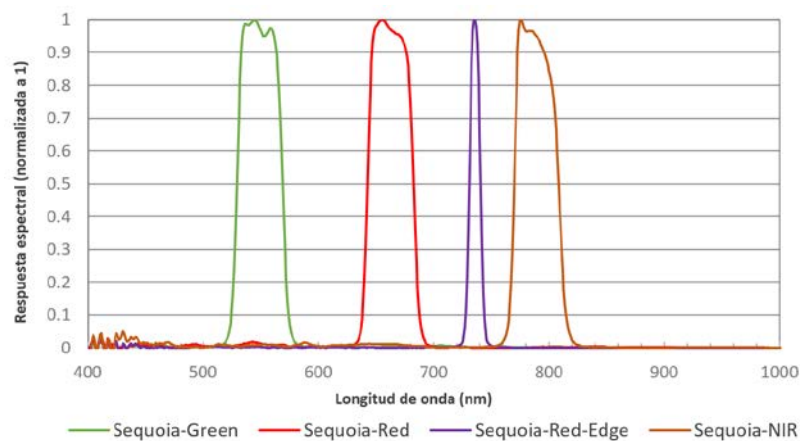


Figura III-8. Función de respuesta espectral de Sequoia.

Diseño del vuelo

La planificación y el control del vuelo se llevaron a cabo de manera automática con el software eMotion (SenseFly, CheseauxLausanne, Switzerland. Un ejemplo de esta planificación se muestra en la Figura III-9.

El software requiere como parámetros iniciales el área de estudio, la cámara que se va a utilizar, el tipo de altitud que se va a adoptar en el plan de vuelo, la resolución deseada del píxel (GSD) y la superposición de imágenes tanto lateral como longitudinal. En nuestro caso, la altitud fue *Above Elevation Data* (AED) que se define como la altitud aproximada sobre el suelo. Una vez se indican estos parámetros, el software calcula automáticamente el número de franjas para cubrir el área de estudio, la altura necesaria de vuelo, la velocidad de vuelo, el intervalo en el que se activa la cámara y la geometría interna de la cámara que se está utilizando. En el momento de cada adquisición, el sistema informático a bordo registra una marca de tiempo, la ubicación GPS, la altitud de vuelo y los ejes principales del vehículo (cabeceo, balanceo y guiñada); también intenta compensar los efectos del viento (Greenwood, 2015).

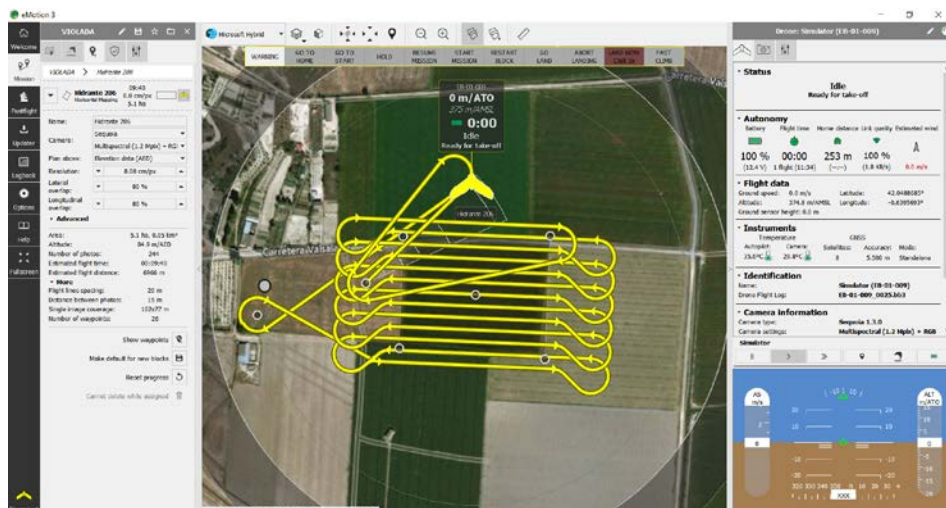


Figura III-9. Ejemplo de la planificación de uno de los vuelos en parcela H de la Zona de Riego de La Violada.

La planificación de los vuelos elegida tiene las siguientes características:

- Cámara: Sequoia multispectral (1,2 Mpix) + RGB
- Altitud utilizada: relativa al modelo de datos (AED)
- Resolución: 8 cm/px
- Solape lateral: 80%
- Solape longitudinal: 80%

Los vuelos se realizaron bajo control automático utilizando los planes de vuelo preprogramados. Para ello se necesita una antena de comunicación que será el enlace entre el UAV y el ordenador portátil. La distancia máxima de alcance son 3 km. Mediante el radio-módem que va conectado al ordenador se consultaron los datos sobre el plan de ruta, la

posición del UAV, la altitud de vuelo, la velocidad de vuelo, el tiempo de vuelo, el nivel de la batería y la calidad de la señal de control de radio, entre otros parámetros.

La misma planificación del primer vuelo inicial se utilizó para el resto de los vuelos realizados en la campaña agrícola durante 4 meses para el seguimiento de los cultivos (Figura III-2).

Adquisición de datos UAV

Una vez planificado el vuelo se pasa a la fase de la toma de datos. Para obtener imágenes perfectamente georreferenciadas se requiere el uso de puntos de control terrestre. La aeronave utilizada no lleva instalado el modo Real Time Kinematic (RTK) que permite mejorar la precisión en la localización hasta el grado de centímetros, así que fue necesario poner puntos de control distribuidos por las parcelas objeto de estudio.

Estos puntos de control terrestre (PCT) consistieron en un conjunto de rectángulos de tamaño 30×21 cm pintados de blanco y negro (Figura III-10). Se anclaron al suelo con un clavo de grandes dimensiones en el centro del rectángulo, justo en la intersección entre los recuadros negros y blanco. Los datos de posición de GNSS (*Global Navigation Satellite System*) para cada uno de los puntos de control se registraron en el centro del rectángulo utilizando un sistema de posicionamiento Leica VIVA®GS15 CS10. Desde Pix4D aconsejan que el tamaño de los puntos de control tenga entre cinco y diez veces las dimensiones de la resolución espacial de la imagen o que sea visible en las imágenes para reconocerlo durante las rutinas de procesamiento (Support pix4d, 2020). Se utilizaron los márgenes entre parcelas de cultivo para ubicar los PCT con un tamaño de aproximadamente cuatro veces las dimensiones de la resolución espacial. Sin embargo, en el primer procesamiento de imágenes se comprobó que el punto de control era visible en la imagen como aconseja Support pix4d. (2020), por lo que se dieron como válidos.

En fotogrametría una distribución tradicional es posicionar los puntos de control en las esquinas del área a medir (Ackermann, 1992). Sin embargo, el equipo de Pix4D y otros autores como Sanz-Ablanedo et al. (2018) proponen que los puntos de control deben distribuirse amplia y uniformemente por toda la parcela, particularmente hacia su periferia sin llegar a colocarse en los bordes del área, ya que solo serán visibles en algunas imágenes. Mesas-Carrascosa et al. (2015) experimentaron con 4 y con 5 puntos de control en un campo de trigo de 1,12 ha y el resultado fue que la precisión era mayor cuando colocaron 5 puntos de control.

En este estudio se decidió inicialmente incluir como mínimo 5 puntos de control por parcela tal y como recomienda Mesas-Carrascosa et al. (2015). Sin embargo, la densidad de siembra y el cultivo –maíz y girasol– hubiera cubierto a medida que avanza el ciclo del cultivo, el punto o puntos de control en el centro e interior de la parcela, por lo que en las parcelas más pequeñas se optó por poner únicamente 4 puntos de control en las cuatro esquinas y, en las más grandes, los puntos de control se distribuyeron por el perímetro de la parcela. En aquellos casos en los que fue posible incluir un punto visible en el centro de la parcela se hizo. En algún caso, también se hizo imposible localizar alguno de los puntos de control en

los bordes de las parcelas, así que se tomó como punto de control la arqueta de riego, al ser visible a lo largo de todo el ciclo del cultivo (Figura III-11).

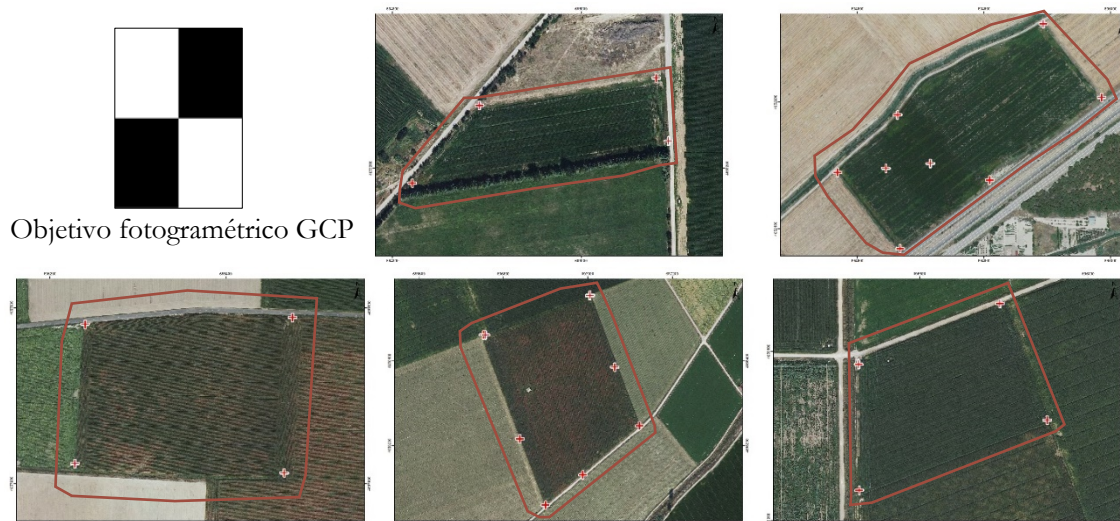


Figura III-10. Ubicaciones de los puntos de control para georreferenciación en las parcelas de estudio sobrevoladas con UAV.



Figura III-11. Ejemplo de punto de control rectangular (izquierda) y de punto de control en arqueta de riego (derecha) en imágenes RGB de UAV.

Antes de la adquisición de imágenes, se realizó una calibración radiométrica utilizando el panel de calibración (Figura III-12) que se proporciona junto con la cámara. El panel de calibración se situó horizontalmente en el suelo, en una zona despejada y a una distancia de la cámara de aproximadamente de 1 m, evitando sombras y reflejos de otros objetos.




Figura III-12. Imagen del panel para calibración de la cámara Sequoia.

Aunque en los vuelos a baja altitud los efectos atmosféricos son limitados, las sombras de las nubes y el ángulo solar pueden reducir la calidad de las imágenes (Zhang & Kovacs, 2012). Por ello, los vuelos se realizaron al mediodía solar, cuando el ángulo solar es mayor y

en días claros y sin demasiadas nubes. Los cambios de iluminación se corrigieron con los datos proporcionados por el sensor Sunshine a bordo del UAV.

Como se comentó anteriormente, los vuelos se realizaron de manera automática con un plan de vuelo programado, siendo un total de 38 (Tabla III-5) –dos de los vuelos se invalidaron porque se realizaron en una misma misión y la calibración radiométrica no se realizó correctamente–. La trayectoria de vuelo siguió un patrón de líneas paralelas que están conectadas a una serie de puntos de referencia. Esta ruta de vuelo se programó de manera que se capturasen suficientes imágenes y que el solape tanto longitudinal como latitudinal entre imágenes permitiera la identificación de puntos comunes entre imágenes durante la etapa de procesamiento para así poder generar con éxito el ortomosaico de toda el área de estudio.

Tabla III-5. Vuelos realizados con UAV en cada una de las parcelas sobre cultivos de maíz y girasol de ciclo corto en 2019.

Parcela	28/06/2019	10/07/2019	19/07/2019	25/07/2019	Total
H		X	X	X	3
I	X	X	X	X	4
D'	X	X	X	X	4
J	X*	X	X	X	4
K	X*	X	X	X	4
	02/08/2019	03/09/2019	18/09/2019	08/10/2019	
H	X	X	X	X	4
I	X	X	X	X	4
D'	X	X		X	4
J	X	X	X	X	4
	02/08/2019	03/09/2019	18/09/2019	08/10/2019	
K	X	X	X	X	4
Total					38

III.1.1.4 Imágenes de satélite Sentinel 2

Sentinel-2 es una misión de observación óptica de la Tierra de alta resolución desarrollada por la ESA dentro del programa Copernicus de la Comisión Europea (previamente conocido como *Global Monitoring for Environment and Security*, GMES). Es un sistema de dos satélites (A y B) en órbita heliosíncrona que, con el sensor MultiSpectral Instrument (MSI) que llevan a bordo, proporciona datos para el monitoreo operativo de la tierra, la respuesta de emergencias y los servicios de seguridad (Drusch et al., 2012). Las especificaciones tanto del sensor como del satélite se pueden consultar (ESA, 2016).


La resolución temporal de la misión Sentinel 2 es de 10 días, pasando a ser con los dos satélites Sentinel 2A y 2B de 5 días en el Ecuador y de 2-3 días en latitudes medias, debido a la superposición entre franjas de órbitas adyacentes. La resolución radiométrica del instrumento MSI es de 12 bits, lo que permite adquirir la imagen en un rango de 0 a 4095 valores potenciales de intensidad de luz. Captura información en 13 bandas espectrales (longitudes de onda), con diferentes resoluciones espaciales (Tabla III-6).

Tabla III-6. Resolución espectral y espacial para Sentinel 2A y 2B.

Bandas	Resolución espectral				Resolución espacial
	Sentinel 2A		Sentinel 2B		
	Longitud onda central (nm)	Ancho de banda	Longitud onda central (nm)	Ancho de banda	
1	442,7	21	442,3	21	60
2	492,4	66	492,1	66	10
3	559,8	36	559,0	36	10
4	664,6	31	665,0	31	10
5	704,1	15	703,8	16	20
6	740,5	15	739,1	15	20
7	782,8	20	779,7	20	20
8	832,8	106	833,0	106	10
8A	864,7	21	864,0	22	20
9	945,1	20	943,2	21	60
10	1373,5	31	1376,9	30	60
11	1613,7	91	1610,4	94	20
12	2202,4	175	2185,7	185	20

Datos Sentinel 2 utilizados

El programa Copernicus pone a disposición de los usuarios a través del centro de datos de acceso abierto (<https://scihub.copernicus.eu/dhus/#/home>) imágenes de sus satélites Sentinel 2 procesadas a dos niveles diferentes: el nivel-1C, que proporciona reflectividad ortorrectificada en la parte superior de la atmósfera (*Top-Of-Atmosphere*, TOA), y el nivel-2A que proporciona reflectividad ortorrectificada al nivel inferior de la atmósfera (*Bottom-Of-Atmosphere*, BOA). Para este estudio se utilizaron 21 imágenes nivel 2A de la tesela T30TXM (Anexo 1). Son ortoimágenes de 100x100 km² en proyección UTM/WGS84 y tienen un tamaño aproximado de 800 MB.



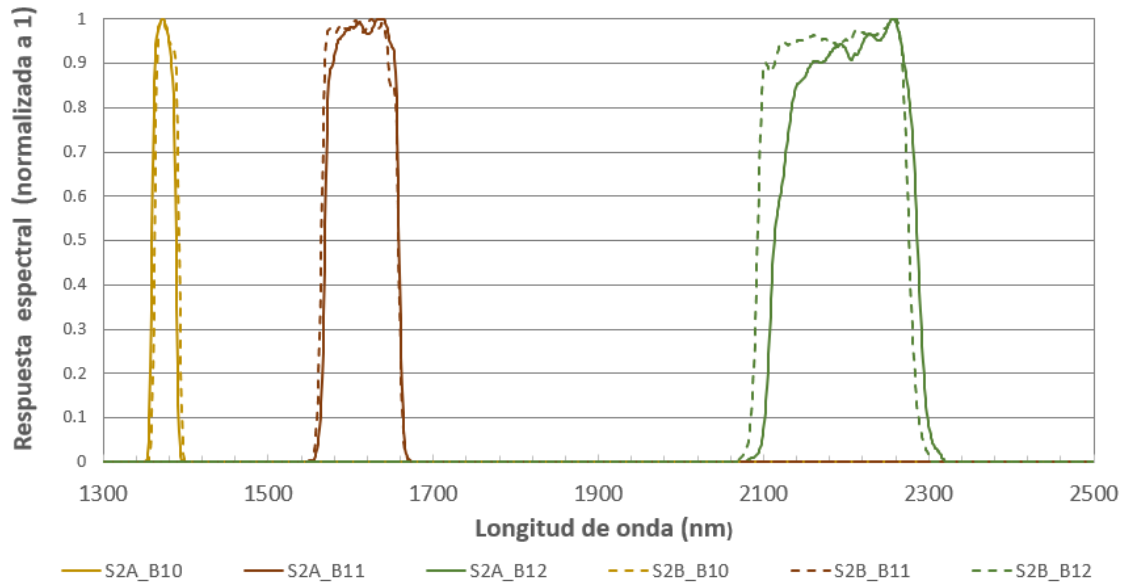


Figura III-13. Función de la respuesta espectral de los sensores MSI de Sentinel 2A y 2B.

III.1.2 Procesado de datos

III.1.2.1 Procesado de los datos hiperespectrales obtenidos con espectro-radiómetro

El procesamiento se realizó con el software ViewSpec™ Pro (Malvern Panalytical, 2014). Se generaron las medidas en reflectividad absoluta y se obtuvo un archivo de texto con todas ellas. Una primera visualización y análisis de los datos recopilados se llevó a cabo con el software Microsoft Office Excel –con el que se depuraron datos– y el paquete de R Hsdar (Lehnert et al., 2019), con el que se generó la información hiperespectral derivada de ellos. Además, los datos hiperespectrales se transformaron a las longitudes de onda de los sensores Sequoia y MSI aplicando el método de convolución en el software ENVI 4.7 (ENVI®, 2022) con la función de respuesta espectral (*Spectral Response Function*, SRF). Este método es muy utilizado, ya que proporciona alta precisión al tener en cuenta las características técnicas de los sensores simulados. La formulación aplicada fue la siguiente (Ecuación III-4)

$$\rho_{Ba} = \frac{\sum_{\lambda_1}^{\lambda_2} (\rho_i \times SRF_i)}{\sum_{\lambda_1}^{\lambda_2} SRF_i} \quad (\text{III-3})$$

donde ρ_{Ba} es el valor de la reflectividad en la banda simulada a ; ρ_i es la reflectividad del espectro-radiómetro en la banda i ; SRF_i es el valor de la función de respuesta espectral en la banda i , calculado por interpolación de los valores de SRF del sensor a las longitudes de onda del espectro-radiómetro de campo; λ_1 y λ_2 son las longitudes de onda inicial y final de la banda simulada.

III.1.2.2 Procesado de datos de UAV

El procesamiento de los datos se realizó en Pix4Dmapper (Pix4D SA, 2022). Para generar el ortomosaico multiespectral se utilizó la plantilla "Ag Multiespectral" de

Pix4Dmapper que define las propiedades de la cámara, el sistema de coordenadas y el sistema para importar las imágenes, aunque se cambiaron algunas opciones de procesamiento en la fase en la que se genera el modelo digital de superficie, el ortomosaico y los IV para mejorar la calidad de los resultados.

El procesamiento de Pix4Dmapper se basa en los algoritmos *Structure from Motion* (SfM), que generan automáticamente puntos clave y el emparejamiento de imágenes (Ruzgiene et al., 2015). Utilizar estos puntos es clave para encontrar coincidencias entre las imágenes. A partir de estas coincidencias iniciales, el software ejecuta una triangulación aérea automática y un ajuste de bloque de paquetes y los pasos de autocalibración de la cámara de forma iterativa hasta lograr una reconstrucción óptima (Fernández-Guisuraga et al., 2018). A continuación, genera una nube de puntos densificada para obtener un modelo digital de superficie altamente detallado que se utilizará para generar los mapas de reflectividad (Pla et al., 2019). La irradiancia solar se corrige con la información proporcionada por el sensor Sunshine, permitiendo normalizar las imágenes tomadas durante el vuelo y por tanto comparar imágenes tomadas en diferentes condiciones de iluminación. Pix4Dmapper aplica este proceso de calibración y corrección a cada imagen antes de realizar el ortomosaico de reflectividad final para cada banda espectral (Pla et al., 2019). Aunque el software Pix4Dmapper no permite interferir en el procesamiento para conseguir la reflectividad, el procedimiento de calibración radiométrica ha sido compartido por el fabricante y se detalla a continuación.

La relación entre la radiancia y el nivel digital (ND) depende de los parámetros de exposición (tiempo de exposición, apertura e ISO) utilizados para capturar la imagen. En el caso de Sequoia, esta relación ha sido caracterizada para cada banda por el fabricante utilizando la siguiente Ecuación III-5:

$$I = f^2 \frac{p - B}{A\varepsilon\gamma + C} \quad (\text{III-4})$$

donde I es la radiación del sensor, p es valor del píxel (ND), f es el número- f ($f = 2.2$), ε es el tiempo de exposición en segundos, γ es el ISO y A, B y C son coeficientes de calibración específicos de la cámara que modelan el comportamiento no lineal del sensor y que se encuentran en los datos de EXIF (Fallet, 2017b).

Una vez aplicadas estas correcciones, la radiancia en el sensor de cada píxel se convirtió en reflectividad utilizando el sensor de luz solar y una imagen objetivo de calibración. Los datos del sensor solar se convirtieron en irradiancia en unidades arbitrarias utilizando la siguiente Ecuación III-6:

$$I_{ss} = \frac{v}{g\tau} \quad (\text{III-5})$$

donde I_{ss} es irradiancia, v es el recuento registrado por el sensor *sunshine*, g es un factor de ganancia relativa (para normalizar todas las mediciones) y τ es el tiempo de integración (Bashir, 2017; Domenzain, 2017).

Para obtener la reflectividad se utilizó una imagen de un objetivo de reflectividad conocida; para calibrar la relación entre las mediciones en los dos sensores se aplicó la Ecuación III-7.

$$k = R_{obj} \frac{I_{SS}}{I} \quad (\text{III-6})$$

donde k es el coeficiente de calibración y R_{obj} la reflectividad objetivo.

Por ultimo, la reflectividad R para cada píxel en la imagen se calculó aplicando la Ecuación III-8.

$$R = k \frac{I}{I_{SS}} \quad (\text{III-7})$$

Los ortomosaicos de cada parcela y fecha de adquisición de datos se pueden consultar en el Anexo 4.

III.1.2.3 Obtención de los índices de vegetación

Los índices de vegetación (IV) son, además de la reflectividad, la variable escogida para el estudio pues se utilizan a menudo en el monitoreo de cultivos y suelen ser la información de base con la que se generan diferentes productos digitales muy útiles para aplicaciones en agricultura. Se obtienen a partir de los valores de la reflectividad de distintas longitudes de onda con el fin de extraer información relacionada con la vegetación minimizando la influencia de perturbaciones como las debidas al suelo y a las condiciones atmosféricas (Gilabert et al., 1997).

La mayoría de los IV combinan información contenida en dos longitudes de onda espectrales, la roja y la infrarroja cercana (IC). Estos índices tienen algunas limitaciones como la atenuación de la reflectividad en el IC cuando, por ejemplo, cambia la orientación de la hoja –de horizontal a vertical– en una determinada etapa del ciclo de crecimiento; o por la significativa contribución del suelo en la reflectividad del IC que supone, por ejemplo, una disminución en la reflectividad del IC cuando aumenta la humedad del suelo (Gitelson et al., 2002), entre otras. Por ello, se han desarrollado y se continúan desarrollando nuevos IV, probando diferentes regiones del espectro para tratar de evitar las limitaciones que se dan en el IC.

Ante la gran cantidad de IV existentes en la literatura se procedió a considerar qué regiones del espectro electromagnético eran las más idóneas para caracterizar la evolución de los cultivos con IV, teniendo en cuenta que fueran coincidentes con los rangos espectrales del sensor Sequoia y del sensor MSI de Sentinel 2, sensores con los que se obtendrán los índices. Para ello, se analizaron visualmente las firmas espectrales procedentes de las medidas realizadas con el espectro-radiómetro y se consideraron las siguientes regiones espectrales como las idóneas para confeccionar los IV:

- Reflectividad del verde (R_{VERDE}), utilizando la banda verde de Sequoia y la banda 3 de Sentinel 2.

- Reflectividad del rojo (R_{ROJO}), utilizando la banda roja de Sequoia y la banda 4 de Sentinel 2.
- Reflectividad del borde del rojo (R_{BR}), utilizando la banda del borde del rojo de Sequoia y la banda 6 de Sentinel 2.
- Reflectividad del infrarrojo cercano (R_{IC}), utilizando la banda del infrarrojo cercano de Sequoia y la banda 7 de Sentinel 2.

El cálculo de los índices se realizó, además de con los datos adquiridos con los sensores MSI de Sequoia y Sentinel 2A y 2B, con los datos de las medidas realizadas con el espectroradiómetro simulando estos dos sensores.

Los IV elegidos fueron 12 y corresponden a las siguientes cuatro categorías diferentes (3 índices por categoría): 1) índices basados en la diferencia normalizada, 2) índices basados en la diferencia normalizada utilizando la banda del borde del rojo, 3) índices ajustados a la reflectividad del suelo y, por último, 4) índices triangulares basados en las longitudes de onda del verde, rojo e infrarrojo cercano. En esta tesis doctoral no se ha diseñado ningún índice específicamente, pero sí se ha modificado levemente el rango espectral utilizado respecto a la formulación original para poder ajustarse a las longitudes de onda del sensor Sequoia.

Índices basados en la diferencia normalizada

El IV más conocido y ampliamente utilizado es el Índice de Vegetación de Diferencia Normalizada (NDVI, *Normalized Difference Vegetation Index*; Rouse et al., 1974), por eso se ha seleccionado. Se basa en el contraste entre la absorción máxima en el rojo debido a los pigmentos de clorofila y la máxima reflexión en el infrarrojo cercano producida por la estructura celular de la hoja (Ecuación III-9).

$$NDVI = \frac{(R_{IC} - R_{ROJO})}{(R_{IC} + R_{ROJO})} \quad (III-8)$$

A pesar de su uso intensivo, el NDVI es un índice que se satura en casos con cobertura vegetal densa y muestra una relación no lineal con parámetros biofísicos como el LAI. Por lo tanto, se han desarrollado otros IV como el Índice de Vegetación de Diferencia Renormalizada (RDVI, *Renormalized Difference Vegetation Index*; Roujean & Breon, 1995) con el fin de linealizar la relación con estos parámetros (Ecuación III-10), de ahí su elección.

$$RDVI = \frac{(R_{IC} - R_{ROJO})}{\sqrt{(R_{IC} + R_{ROJO})}} \quad (III-9)$$

Otra modificación del NDVI es el Índice de Vegetación de Diferencia Normalizada Verde (GNDVI, *Green Normalized Difference Vegetation Index*; Gitelson et al., 1996) cuya diferencia es el cambio de la banda roja por la verde (Ecuación III-11). El GNDVI es más sensible a la concentración de clorofila que el NDVI y presenta un punto de saturación más alto, por lo que es muy utilizado también en agricultura.

$$GNDVI = \frac{(R_{IC} - R_{VERDE})}{(R_{IC} + R_{VERDE})} \quad (III-10)$$

Índices basados en la diferencia normalizada utilizando la banda del borde del rojo

Existe una serie de IV que persigue predecir el contenido en clorofila con alta precisión y además ser consistentes a las variaciones de LAI, es decir, que no se saturan al aumentar el contenido de clorofila o LAI. El Índice de Relación Simple Modificada del Borde del rojo (MSRre, *Modified Simple Ratio Red-edge*; Wu et al., 2008) es uno de estos índices y utiliza la región del espectro de [705 nm, 750 nm] (Ecuación III-12). En este estudio se sustituyen estas regiones del espectro por [735 nm, 790 nm]. Este es uno de los IV que no se satura con valores altos tanto de LAI como de clorofila (Wu et al., 2008), por ello se incorpora al estudio.

$$\text{MSRre} = \frac{(R_{IC}/R_{BR}) - 1}{\sqrt{(R_{IC}/R_{BR}) + 1}} \quad (\text{III-11})$$

Otro de los índices más utilizados para relacionar el comportamiento espectral entre la reflectividad y contenido de clorofila es el Índice de Clorofila del Borde del rojo (CIre, *Red-edge chlorophyll Index*; Gitelson et al., 2005; Ecuación III-13). Además, este IV también tiene una alta sensibilidad con el LAI (Qiao et al., 2020)

$$\text{CIre} = \frac{R_{IC}}{R_{BR}} - 1 \quad (\text{III-12})$$

Uno de los índices indicados para estimar la FCV es el Índice de Diferencia Normalizada del Rojo-Borde del rojo (NDRre, *Normalized Difference Red-edge Index*), denominado VI₇₀₀ por Gitelson et al. (2002). Este IV relaciona la región espectral de los 700 nm con la región de absorción del rojo (Ecuación III-14). En este estudio se modificó la región de los 700 nm introduciendo en su lugar la región de 735 nm coincidente con la banda del bode del rojo del sensor Sequoia.

$$\text{NDRre} = \frac{(R_{BR} - R_{ROJO})}{(R_{BR} + R_{ROJO})} \quad (\text{III-13})$$

Índices ajustados a la reflectividad del suelo

Se han desarrollado IV ajustados al suelo que minimizan la influencia del suelo y tienen en cuenta sus propiedades. El principal IV de este tipo es el Índice de Vegetación Ajustado al Suelo (SAVI, *Soil-Adjusted Vegetation Index*; Huete, 1988) que incluye un factor L de ajuste de suelo (Ecuación III-15).

El factor L es función de la densidad de la vegetación y varía de 0 hasta infinito. Su determinación requiere un conocimiento previo de la cantidad de vegetación. Su autor recomienda tomar un valor de L=1 para densidades de vegetación baja, L=0,5 para densidades intermedias y L=0,25 para densidades altas. Sin embargo, recomienda usar un parámetro L=0,5 cuando se aplique sobre imágenes satelitales donde existen parcelas con distintas densidades de vegetación o cuando se toman medidas en campo siguiendo un muestreo aleatorio en parcelas heterogéneas, donde se puede medir sobre puntos con diferente densidad de vegetación. En este estudio se usó el valor de L=0,5.

$$\text{SAVI} = \frac{(1 + L)(R_{IC} - R_{ROJO})}{(R_{IC} - R_{ROJO} + L)} \quad (\text{III-14})$$

Intentando mejorar el índice SAVI con respecto a las diferencias de suelo, se desarrolló el Índice de Vegetación Ajustado al Suelo Modificado (MSAVI, *Modified Soil Adjusted Vegetation Index*; Qi et al., 1994; Ecuación III-16). Este IV se ve menos afectado por las variaciones de los parámetros del dosel de la vegetación y de las propiedades del suelo (Broge & Leblanc, 2001).

$$\text{MSAVI} = 0,5[2R_{\text{IC}} + 1 - \sqrt{(2R_{\text{IC}} + 1)^2 - 8(R_{\text{IC}} - R_{\text{ROJO}})}] \quad (\text{III-15})$$

Otro de los IV propuestos es el Índice de Vegetación Ajustado al Suelo Optimizado (OSAVI, *Optimized Soil Adjusted Vegetation Index*; Rondeaux et al., 1996; Ecuación III-17). En este caso, el factor L de ajuste de suelo es sustituido por 0,16. A diferencia de los índices SAVI y MSAVI, que presentan cierta sensibilidad al suelo para valores bajos de vegetación, el índice OSAVI presenta buen comportamiento en todo el ciclo del cultivo (Gilbert et al., 1997).

$$\text{OSAVI} = \frac{(1 + 0,16)(R_{\text{IC}} - R_{\text{ROJO}})}{(R_{\text{IC}} + R_{\text{ROJO}} + 0,16)} \quad (\text{III-16})$$

Índices triangulares basados en las longitudes de onda del verde, rojo e infrarrojo cercano

El Índice Triangular de Vegetación (TVI, *Triangular Vegetation Index*; Broge & Leblanc, 2001) está destinado a caracterizar la energía radiante absorbida por los pigmentos de las hojas en términos de la diferencia relativa entre reflectividad en la banda roja e infrarrojo cercano en conjunción con la magnitud de la reflectividad en la región de la banda del verde (Ecuación III-18). Se basa en el área del triángulo formado por el pico en la banda del verde, el hombro del infrarrojo cercano y la absorción o reflectividad mínima en la banda del rojo. El área aumentará como resultado del aumento de la concentración de clorofila (absorción en la banda roja y menor absorción en la banda verde) y la abundancia de tejido foliar (aumento de la reflectividad en la banda del infrarrojo cercano).

$$\text{TVI} = [120(R_{750} - R_{\text{VERDE}}) - 200((R_{\text{ROJO}} - R_{\text{VERDE}}))] \quad (\text{III-17})$$

El TVI se intentó mejorar para obtener un IV que fuera menos sensibles a los efectos de la clorofila, más sensible a las variaciones verdes de LAI y más resistente a los efectos del suelo y la atmósfera, desarrollando los Índices Modificados Triangulares de Vegetación MTVI1 y MTVI2 (*Modified Triangular Vegetation Index-1 y 2*, Haboudane et al., 2004; Ecuaciones III-19 y III-20), respectivamente.

$$\text{MTVI1} = 1.2[1.2(R_{\text{IC}} - R_{\text{VERDE}}) - 2.5(R_{\text{ROJO}} - R_{\text{VERDE}})] \quad (\text{III-18})$$

$$\text{MTVI2} = \frac{1.5[1.2(R_{\text{IC}} - R_{\text{VERDE}}) - 2.5(R_{\text{ROJO}} - R_{\text{VERDE}})]}{\sqrt{(2R_{\text{IC}} + 1)^2 - (6R_{\text{IC}} - 5\sqrt{R_{\text{ROJO}}}) - 0.5}} \quad (\text{III-19})$$

III.1.3 Comparación de la reflectividad y de los índices de vegetación

Los cuatro escenarios de comparación que se plantean en este Capítulo son:

- Escenario 1: espectro-radiómetro –datos tratados y simulados al sensor MSI de Sentinel 2– vs. MSI de Sentinel 2.
- Escenario 2: espectro-radiómetro –datos tratados y simulados al sensor Sequoia– vs. Sequoia.
- Escenario 3: Sequoia vs. MSI de Sentinel 2, para la zona de las parcelas con medidas con espectro-radiómetro.
- Escenario 4: Sequoia vs. MSI de Sentinel 2, para las parcelas.

Para realizar estas comparaciones, las medidas de la reflectividad de los diferentes sensores y de los IV se transformaron a resoluciones espectrales y espaciales comunes, tal y como se detalla más adelante.

Para los escenarios 1-3 se realizó una comparación con los datos obtenidos desde la siembra del cultivo hasta que la altura de la planta permitió la medida con el radiómetro manualmente. En el escenario 4, que engloba todos los píxeles de las parcelas de estudio, la comparación se realizó para el girasol desde la siembra del cultivo hasta el fin del ciclo y para el maíz, desde la siembra hasta que las condiciones meteorológicas impidieron seguir con la toma de datos (principios de octubre) con el UAV.

III.1.3.1 Comparación de espectro-radiometría de campo con Sentinel 2

Para comparar los valores de la reflectividad y de los IV de Sentinel 2 con los valores de espectro-radiometría de campo, los valores obtenidos por el espectro-radiómetro se transformaron a Sentinel 2 con la función de la respuesta espectral del sensor MSI de Sentinel 2A y 2B (Figura III-13), tal y como se indica en el apartado III.1.2.1.

La comparación en este escenario se realizó calculando el promedio de las 10 mediciones del Transecto B (Figura III-5) y el píxel de Sentinel 2 de 20 m. La comparación se realizó correlacionando banda por banda e índice por índice los datos de espectro-radiometría con los datos del sensor MSI de Sentinel 2. En la Figura III-14 se presentan las fuentes con las que se comparan ambos sensores. En total se dispuso de 68 pares de medidas que se detallan de la Tabla III-7 a la Tabla III-9.

Tabla III-7. Pares de medias de los sensores en el escenario1 para cada una de las de estudio en 2018.

Parcela	27/06/2018	05/07/2018	10/07/2018	16/07/2018	23/07/2018	30/07/2018	Total
A		X	X	X	X		4
B	X		X	X	X		4
C			X	X	X		3
D		X		X	X		3
E		X	X	X	X	X	5
F		X	X	X	X	X	5
G				X	X	X	3
Total	1	4	5	7	7	3	27

Tabla III-8. Pares de medias de los sensores incluidos en el escenario1 en cada una de las parcelas de maíz de ciclo largo en 2019.

Parcela	30/04/2019	06/05/2019	14/05/2019	29/05/2019	31/05/2019	12/06/2019	Total
A'	X	X	X	X	X	X	6
B'	X	X	X	X	X	X	6
G'	X	X	X	X	X		5
Total	3	3	3	3	3	3	17

Tabla III-9. Pares de medias de los sensores incluidos en escenario1 en cada una de las parcelas de maíz y girasol de ciclo corto en 2019.

Parcela	04/07/2019	10/07/2019	19/07/2019	25/07/2019	02/08/2019	Total
H	X	X	X	X		4
I	X	X	X	X	X	5
D'	X	X	X	X	X	5
J	X	X	X	X	X	5
K	X	X	X	X	X	5
Total	5	5	5	5	3	24

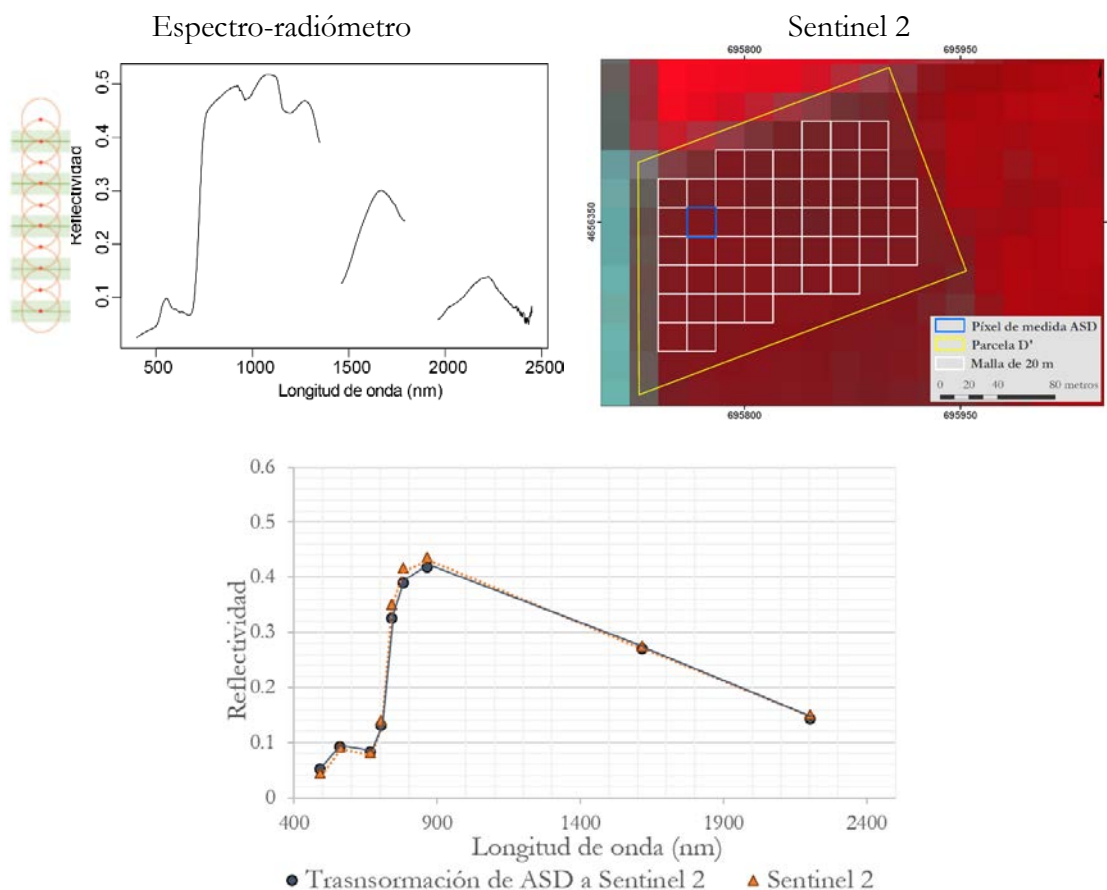


Figura III-14. Comparación de las medidas de espectro-radiómetro de campo con el píxel de Sentinel 2. Imagen de falso color RGB (IC, Rojo y Verde) de MSI de Sentinel 2 del 2/08/2019.

III.1.3.2 Comparación de espectro-radiometría de campo con UAV

En este caso los valores de Sequoia se transformaron con la función de la respuesta espectral del sensor Sequoia (Figura III-8). El esquema de cómo se realizó la comparación entre ambos sensores se puede ver en la Figura III-15.

Para esta comparación se utilizaron la media del transecto A y del transecto B y las tres medidas puntuales para cada parcela y fecha, por lo que normalmente habrá 5 comparaciones por parcela y fecha, a excepción de las fechas últimas donde no se tomó medida puntual. Se dispuso de 82 pares de medidas que se detallan en de la Tabla III-10.

Tabla III-10. Pares de medidas de los sensores incluidos en el escenario2 en cada una de las parcelas de maíz y girasol de ciclo corto en 2019.

Parcelas	10/07/2019			19/07/2019			25/07/2019			02/08/2019			Total
	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	T-A	T-B	P	
H	1	1	3	1	1	3	1	1	1				13
I	1	1	3	1	1	3	1	1	3	1	1		17
J	1	1	3	1	1	3	1	1	3	1	1	3	20
K	1	1	3	1	1	1	1	1	3	1	1		15
L	1	1	3	1	1	3	1	1	3	1	1		17
Totales	5	5	15	5	5	13	5	5	13	4	4	3	82

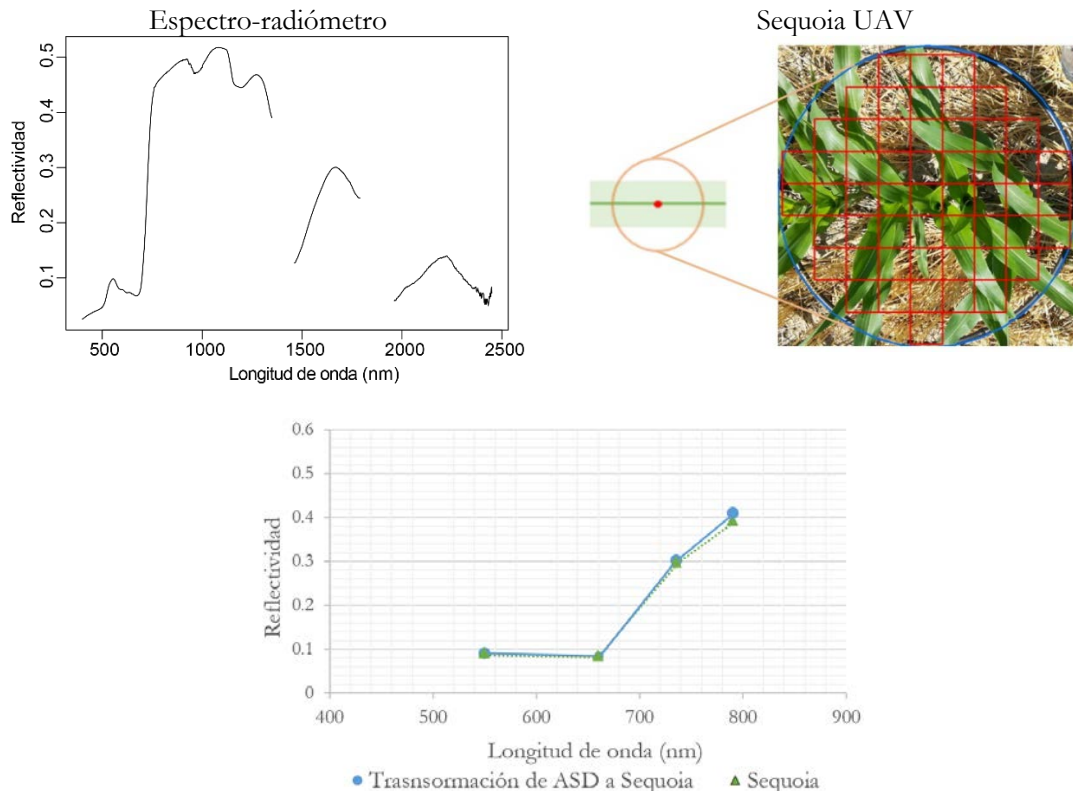


Figura III-15. Comparación de la medida puntual de espectro-radiómetro de campo con el promedio de píxeles de Sequoia.

La superficie registrada en las medidas puntuales tiene aproximadamente un diámetro de 73 cm, lo que equivale a unos 50-55 píxeles de Sequoia. Para relacionar las medidas de Sequoia con las medidas con el espectro-radiómetro se realizó un promedio del valor de todos los píxeles de Sequoia equivalentes al diámetro medido con el espectro-radiómetro. En

el caso de los transectos, se relacionan el promedio de las 10 medidas realizadas por transecto con el espectro-radiómetro con el promedio de los píxeles equivalentes al área del transecto, que es de unos 2,75 m². Esta superficie equivale a unos 360-370 píxeles de Sequoia aproximadamente.

III.1.3.3 Comparación de Sentinel 2 con UAV

Para realizar la comparación entre estos productos que tienen diferente tamaño de píxel, la cuadrícula de Sequoia se adaptó a la cuadrícula MSI de Sentinel 2 de 20 m. Cada píxel de Sentinel equivale a 62500 píxeles de Sequoia. Se calculó el promedio de píxeles de Sequoia por área de píxel Sentinel de 20 (Figura III-16).

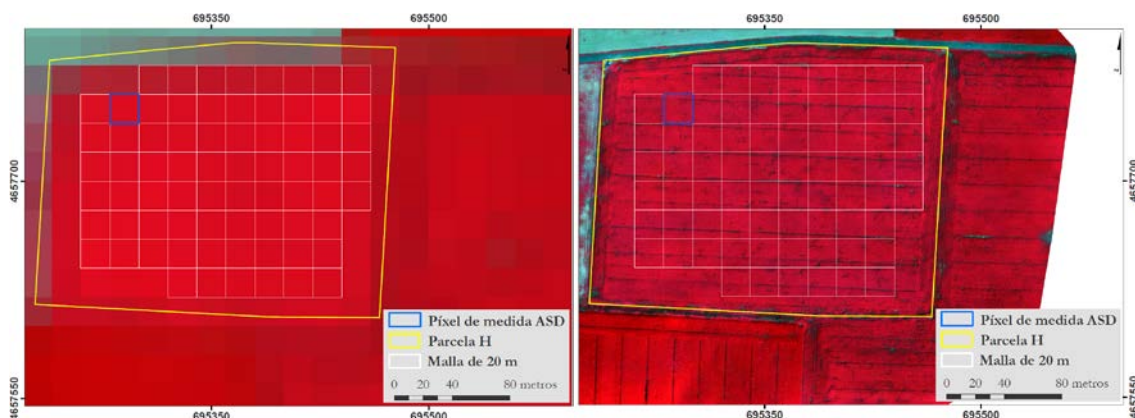


Figura III-16. Imágenes en falso color RGB (IC, Rojo y Verde) de MSI Sentinel 2 (izquierda) y de Sequoia (derecha) de 02/08/2019.

La comparativa se realizó para dos conjuntos de datos. El primero de ellos corresponde con el escenario 3, en el que la comparativa se hizo con el píxel en el que se realizaron las medidas con radiometría desde la siembra hasta la fecha en la que se pudo medir con radiómetro. El segundo corresponde con el escenario 4, en el que la comparativa se hizo con todos los píxeles que se encuentran dentro de las parcelas y en todas las fechas de adquisición de imágenes.

Para el escenario 3 se dispuso de 22 pares de medias, sombreadas en verde en la Tabla III-11 y para el escenario 4 se dispuso de 36 vuelos coincidentes con Sentinel 2, resultando para cada parcela un número de pares de medidas distintas en función del número de píxeles de cada una. En total se contó con 3240 pares de medidas.

Tabla III-11. Pares de medias de los sensores incluidos en el escenario 3 (destacadas en verde) y el escenario 4 (todas) en cada una de las parcelas de maíz y girasol de ciclo corto en 2019.

Parcelas	28/06/2019	10/07/2019	19/07/2019	25/07/2019	02/08/2019	Total
H		X	X	X	X	4
I	X	X	X	X	X	5
J	X	X	X	X	X	5
K		X	X	X	X	4
L		X	X	X	X	4
	03/09/2019	18/09/2019	08/10/2019	Escenario3		22
H	X	X	X			3
I	X	X	X			3
J	X		X			2
K	X	X	X			3

Parcelas	28/06/2019	10/07/2019	19/07/2019	25/07/2019	02/08/2019	Total
L	X	X	X			4
	Escenario 4					36

Las longitudes de onda del sensor Sequoia están en las regiones del espectro electromagnético del verde, rojo, borde del rojo e infrarrojo cercano, pero tienen diferentes superposiciones espectrales a las longitudes de onda correspondientes del sensor MSI de Sentinel 2A y 2B (Figura III-17). Por tanto, además de remuestrear la resolución espacial, también se comprobó qué superposiciones espectrales tienen mayor similitud. La banda del verde de Sequoia se relacionó con la banda 3 de MSI; ambas tienen un ancho similar, pero hay que tener en cuenta que la banda de MSI se desplaza aproximadamente 20 nm a longitudes de onda más cortas. La banda del rojo de Sequoia se relaciona con la banda 4 de MSI; en este caso, el ancho de Sequoia es mayor al de MSI, excediendo unos 10 nm a banda más corta y unos 5 nm a banda más larga. La banda del borde del rojo de Sequoia se relacionó con la banda 6 de MSI, siendo el ancho de banda de Sequoia menor y, además, estando desplazado unos 4 nm a longitudes de onda más bajas. La banda del infrarrojo cercano de Sequoia se relaciona con la banda 7 de MSI; en este caso, la banda de Sequoia tiene casi el doble de rango espectral.

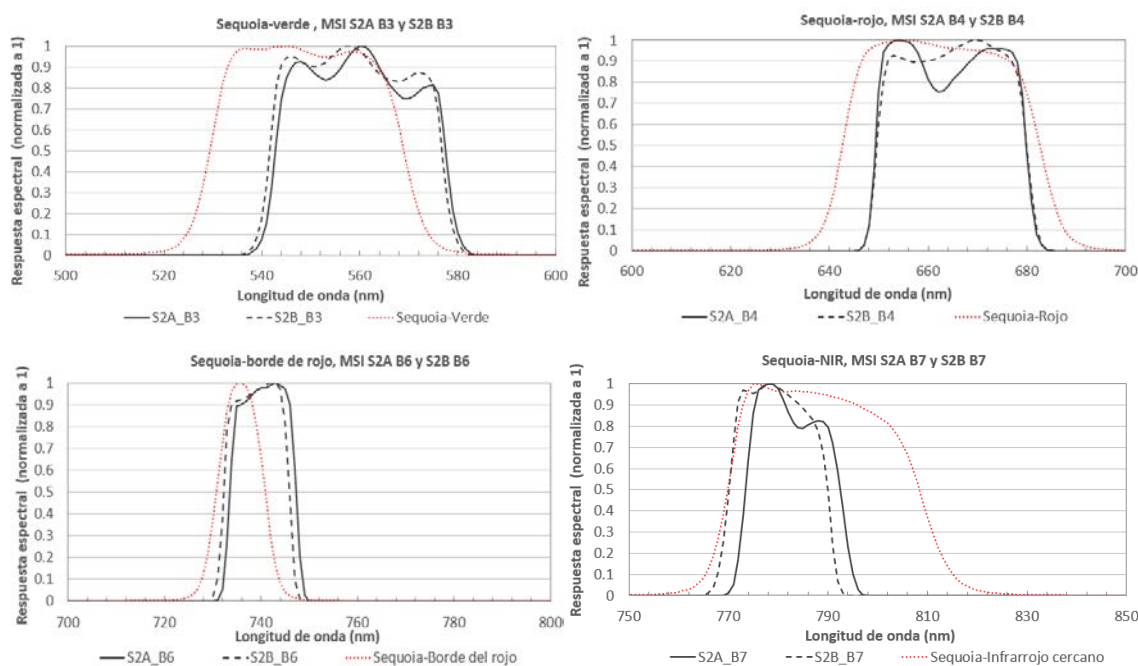


Figura III-17. Función de la respuesta espectral del sensor Sequoia y las homólogas del sensor MSI de los satélites Sentinel 2A y 2B.

En el resto de la tesis doctoral, las longitudes de onda de Sequoia se denominarán con las longitudes de onda de MSI de Sentinel 2 que se relacionan, es decir, la banda verde de Sequoia se denominará B3, la banda roja de Sequoia se denominará B4, la banda del borde del rojo de Sequoia se denominará B6 y, por último, la banda del infrarrojo cercano de Sequoia se denominará B7.

III.1.4 Análisis estadístico

Con este análisis estadístico se pretende, por un lado, medir la fuerza de la relación lineal entre dos sensores y, por otro, ver cómo se relacionan estos sensores con el fin, ya no solo

de poder predecir valores de una variable en función de otra variable, sino de poder cuantificar la diferencia entre un sensor y otro.

Los gráficos y los análisis estadísticos se desarrollarán utilizando el lenguaje de programación estadística R (R Core Team, 2020). Para la manipulación y tratamiento de los datos se utiliza el paquete *dplyr*, para ajustar los modelos lineales y extraer coeficientes de determinación y residuales el paquete *stats*, la prueba de d de Cohen con el paquete *psych*, la prueba de Mann-Whitney-Wilcoxon se aplicó utilizando el paquete *ggpubr* y con *ggplot2* se generaron los gráficos.

El análisis estadístico se realizó para los cuatro escenarios planteados. Se detallan a continuación los modelos y estadísticos elegidos para el análisis.

Relación entre sensores - Modelo de regresión lineal simple

La forma directa para ver el tipo de relación existente entre dos variables cuantitativas es a través de un diagrama de dispersión. La nube de puntos muestra el tipo de relación entre las dos variables representadas (Pardo Merino & Ruiz Díaz, 2005) y la distribución de los puntos respecto a la línea 1.1 indica la dispersión de los datos y la tendencia.

Dadas las características de la nube de puntos, se optó por el modelo regresión lineal simple (Ecuación III-21) para describir la tendencia y analizar la relación entre variables (sensores).

$$Y = \beta_0 + \beta_1 X + e \quad (\text{III-20})$$

donde β_1 es la pendiente de la recta que representa el incremento que experimenta el valor de Y por cada unidad que se incrementa el valor de X ; β_0 es la ordenada en la intersección, es decir, el valor de Y cuando X vale 0; e es el error aleatorio. Este último representa la diferencia entre el valor ajustado por la recta y el valor real. Recoge el efecto de todas aquellas variables que influyen en Y pero que no se incluyen en el modelo como predictores. Al error aleatorio también se le conoce como residuo.

El residual en la observación e_i es la diferencia entre el valor observado de la variable dependiente (Y_i) y el valor estimado de esa variable (\hat{Y}_i).

Los residuales se normalizaron (Ecuación III-22) para que tanto los valores de las longitudes de onda como los índices, que están medidos en diferentes escalas, aporten la misma contribución al análisis. De este modo se transformaron a escalas comparables con el mismo rango.

$$rn_i = \frac{e_i}{(e_{i_{max}} - e_{i_{min}})} \quad (\text{III-21})$$

donde rn_i es el residuo normalizado, e_i es el residual, $e_{i_{max}}$ es el valor máximo del residual de la variable, $e_{i_{min}}$ es el valor mínimo del residual de la variable.

El análisis de regresión debe respetar una serie de condiciones subyacentes que debe darse para garantizar la validez del modelo. Si el cumplimiento de estas suposiciones no se produce con una cierta precisión, la validez de las deducciones hechas a partir de la regresión

disminuye, aunque la ecuación de regresión conserva su valor como descriptor de la relación existente entre dichas variables (Ebdon, 1982). Las condiciones son la normalidad, homocedasticidad e independencia de los residuos que se evaluaron visualmente mediante los gráficos de dispersión de dichos residuos y con la aplicación de las siguientes pruebas estadísticas:

- Para determinar la normalidad se aplicó la prueba de Kolmogorov-Smirnov (K-S; Lilliefors, 1969) y Shapiro Wilks (S-W; Shapiro & Wilk, 1965) siendo esta última más adecuada que la primera para muestras pequeñas ($n < 30$). La prueba permite establecer si los datos siguen una distribución normal (hipótesis nula H_0) o no siguen una distribución normal (hipótesis alternativa H_1). Se fijó como un valor de probabilidad inferiores a 0,05 para rechazar H_0 , aceptando la H_1 .
- La prueba de Breusch-Pagan (B-P; Breusch & Pagan, 1979) determina la homocedasticidad. La prueba establece como H_0 que la homocedasticidad está presente (los residuos se distribuyen con la misma varianza) y como H_1 que no existe homocedasticidad, es decir que los residuos no se distribuyen con la misma varianza. Igual que en la prueba anterior si la probabilidad es inferior de 0,05 se acepta la H_1 y rechazar la H_0 .
- El estadístico de Durbin-Watson (D-W; Durbin & Watson, 1950) permite conocer la condición de independencia entre residuos. Este estadístico oscila entre valores de 0 y 4, de forma que cuando D-W es igual a 2 los residuos son completamente independientes. En este estudio se ha utilizado el rango de 1 a 3 para aceptar de forma general que los residuos son independientes.

Para valorar el poder explicativo del modelo de regresión se utilizó el coeficiente de determinación R^2 (Ecuación III-23).

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (\text{III-22})$$

donde R^2 es el coeficiente de determinación, Y_i es el valor real para la observación i , \bar{Y} es la media de los valores reales, \hat{Y}_i es el valor pronosticado para la observación i .

El R^2 es una medida estandarizada que adopta valores de 0 a 1, siendo mayor el poder explicativo del modelo de regresión cuanto más alto sea.

Para valorar globalmente la exactitud del modelo se optó por el error cuadrático medio (*root-mean-square error*, RMSE, (Ecuación III-24), estadístico muy empleado por distintos autores en la comparación entre sensores (Chastain et al., 2019; Padró et al., 2018; Sola et al., 2018) en su formulación normalizada, RMSE normalizado (RMSEn, Ecuación III-25; Yue et al., 2019), para hacer que las magnitudes de error sean comparables entre los valores de las diferentes longitudes de onda y los índices propuestos.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (\text{III-23})$$

donde Y_i es el valor real para la observación i , \hat{Y}_i es el valor pronosticado para la observación i y n es el número de casos.

$$RMSE_n = \frac{RMSE}{\bar{Y}} \times 100 \quad (III-24)$$

donde $RMSE_n$ es el error cuadrático medio normalizado, $RMSE$ es el error cuadrático y \bar{Y} es la media de los valores reales.

Además, se utilizó el estadístico F (Ecuación III-26), sobre el que se aplica la prueba de significación ($p < 0,05$) para contrastar la hipótesis, que la variación explicada por el modelo es mayor que la variación explicada por su media (Pardo Merino & Ruiz Díaz, 2005).

$$F = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 / p}{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 / (n - p - 1)} \quad (III-25)$$

donde F es el estadístico F, \hat{Y}_i es el valor pronosticado para la observación i , \bar{Y} es la media de los valores reales, Y_i es el valor real para la observación i , p es el número de variables independientes y n es el número de casos.

Diferencias entre sensores

Para observar las diferencias entre sensores y la dispersión de los datos se realizó un primer análisis mediante un diagrama de cajas. Se aplicó la prueba no paramétrica de U de Mann-Whitney, también llamada de Mann-Whitney-Wilcoxon, que identifica la diferencia entre poblaciones con respecto a sus medianas o medias, sin asumir que siguen una distribución normal y es relativamente insensible a la falta de homogeneidad de la varianza de los datos de la muestra (Yue & Wang, 2002). La hipótesis nula (H_0) es que no existen diferencias estadísticamente significativas entre las medias de los dos sensores con los que se han obtenido los datos. La hipótesis alternativa (H_1) es que existen diferencias significativas entre las medias de los dos sensores con los que se han obtenido los datos. Se fijan valores de probabilidad inferiores a 0,05 para rechazar H_0 , aceptando la hipótesis alternativa H_1 .

La estadística de prueba $U = \min(U_1, U_2)$ de Mann-Whitney escoge el valor mínimo de las Ecuaciones III-28 y III-29.

$$U_1 = n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - R_1 \quad (III-26)$$

$$U_2 = n_1 n_2 + \frac{n_2(n_2 + 1)}{2} - R_2 \quad (III-27)$$

donde U_1 es el número total de observaciones de un sensor a, que preceden a las observaciones del sensor b, y U_2 es el recuento total de las observaciones de b que preceden al sensor a, n_1 y n_2 son los tamaños de la muestra del sensor a y b, respectivamente, y R_1 y R_2 son el sumatorio de los rangos de las muestras del sensor a y b, respectivamente.

Como ya se ha indicado, cuando se realiza la diferenciación entre sensores con todos los píxeles Sentinel 2 incluidos en las parcelas y todas las fechas el tamaño de la muestra es de 3240 pares de muestras. En este caso, los resultados de las pruebas estadísticas se evaluaron

mediante la prueba d de Cohen (Ecuación III-30), que indica la diferencia estandarizada entre dos medias y es independiente del tamaño de la muestra. Por lo tanto, se prefiere a las pruebas de significación estadística tradicionales, que para muestras muy grandes producen resultados estadísticamente significativos (Ameztegui et al., 2015)

$$d = \frac{\mu_1 - \mu_2}{\sigma} \quad (\text{III-28})$$

donde d es el índice que indica la diferencia estandarizada entre dos medias, μ_1 y μ_2 son los valores medios de las poblaciones y σ la desviación estándar de cualquier población (ya que se supone que son iguales).

En función de la prueba d de Cohen (1988), consideramos un tamaño del efecto pequeño cuando $d < 0,2$, moderado cuando $d \approx 0,5$ y grande cuando $d > 0,8$.

Homogeneidad por el cultivo y su estadio con el sensor Sequoia

En el caso del escenario 4 se evaluó la homogeneidad de los cultivos utilizando la información espectral recogida por Sequoia en función del píxel Sentinel 2 y calculando la desviación estándar de las longitudes de onda e IV por estadio. Este análisis se realizó con el objetivo de valorar el impacto de la variabilidad de la reflectividad en los análisis estadísticos realizados anteriormente. El análisis de la desviación estándar por estadio se llevó a cabo mediante varios diagramas de cajas. Los estadios del maíz y de girasol siguen diferente codificación (Ritchie et al., 1986; Schneiter & Miller, 1981), por lo que los gráficos para el análisis de homogeneidad se elaboraron en función del cultivo y de la variable a analizar (bandas o IV).

III.2 Resultados

Los resultados del modelo lineal (referido en este apartado como modelo lineal general) y la comprobación de las condiciones que deben darse para garantizar la validez del modelo han derivado en la realización de modelos de regresión lineal por cultivo y por etapa del cultivo. Las regresiones lineales por cultivo y por etapa del cultivo, así como los resultados de las pruebas estadísticas K-S, S-W, P-B y D-W, pueden consultarse en el Anexo 2. En la presentación de los resultados las regiones espectrales evaluadas se referirán con la equivalencia a la banda del sensor MSI de Sentinel 2 (Apartado III.1.3.3).

III.2.1 Comparación de espectro-radiometría de campo con Sentinel 2

En la Figura III-18 se muestran los gráficos de dispersión y distribución de la reflectividad de cada banda para los pares de puntos de la muestra respecto a la línea 1:1. Las ecuaciones de la regresión lineal y estadísticos obtenidos para cada banda pueden encontrarse en la Tabla III-12.

Para todas las bandas los puntos se distribuyen en torno a la línea 1:1, próximos a ella. La línea de la ecuación de regresión prácticamente coincide con la línea 1:1, lo que indica que la función de ajuste es casi perfecta.

Las bandas del visible, B2, B3 y B4, junto con la banda del borde del rojo B5, muestran que la relación lineal entre los sensores es muy alta, con R^2 iguales o mayores a 0,95 (Tabla III-12), con intersección en 0 y con pendientes superiores a 0,95 excepto para B3 que es de 0,93. Esto indica que los datos de la reflectividad de Sentinel 2 y los datos recogidos con el espectro-radiómetro para estas longitudes de onda son similares y que apenas hay diferencias entre sensores.

En las bandas del borde del rojo e infrarrojo cercano, B6, B7 y B8A, la relación lineal, si bien es alta, con valores de coeficientes de determinación R^2 en torno a 0,8, es menor que para las bandas del visible y borde del rojo B5. La intersección sigue siendo cercana al origen de 0 y la pendiente se aleja algo más de 1 que en las longitudes de onda del visible (Tabla III-12). En estas bandas se observa una ligera sobreestimación de Sentinel 2 hasta la reflectividad de 0,4 igualándose los valores para reflectividades superiores, tal y como se puede ver en la Figura III-18.

Por último, en las bandas del infrarrojo cercano de onda corta B11 y B12 (*Shortwave-infrared* SWIR), el comportamiento es similar a las bandas del visible, mostrando una relación muy alta entre sensores, con coeficientes de determinación R^2 elevados y con valores cercanos a la intersección. En cuanto a la pendiente los valores son ligeramente menores que en el visible (ver Tabla III-12).

Tabla III-12. Modelo de regresión lineal y estadísticos de intersección y pendiente para cada una de las bandas espectrales entre los sensores ASD y Sentinel 2 (n = 68).

Banda	Intersección	Pendiente	R^2	RMSEn (%)
B2	0	0,96	0,95***	11,4
B3	0,01	0,93	0,95***	9,3
B4	0,01	0,98	0,97***	10,4
B5	0,01	0,99	0,95***	9,8
B6	0,05	0,88	0,81***	8,9
B7	0,05	0,88	0,81***	9,1
B8A	0,06	0,86	0,79***	8,8
B11	0,05	0,88	0,93***	7,5
B12	0,03	0,90	0,96***	9,0

*** nivel de significación $p < 0,001$

En relación con la exactitud del modelo general, las bandas presentan errores inferiores al 12% (Tabla III-12), siendo el mayor RMSEn de 11,4% para la banda azul (B2) y el menor, 7,5%, el de la banda del SWIR1 (B11). El resto de las bandas presentan errores entre 8,8% y 10,4%.

En cuanto a los IV, los pares de puntos también se distribuyen en torno a la línea 1:1, próximos a ella; el ajuste es todavía mejor que para las bandas. La relación lineal es casi perfecta, con valores de coeficiente de determinación R^2 muy elevados, iguales o superiores a 0,95 (ver Figura III-19), excepto para los índices MSRre y CIre con R^2 de 0,9. La mayoría de los IV tiene un intersección positiva con valores muy cercanos a 0, tal y como se puede

ver en la Tabla III-13. Los valores de las pendientes están en torno a 1, lo que es indicativo de que las diferencias entre sensores son muy pequeñas.

Los RMSEn son generalmente mayores en los IV que en las bandas, tal y como se puede ver en Tabla III-13. El RMSEn más alto se observa en los índices triangulares basados en las bandas del verde, rojo e infrarrojo con valores entre 28% del TVI y 18,2% del MTVI1 y a continuación en los índices en los que intervienen una banda del borde del rojo (B6) y la banda del infrarrojo cercano (B7), con valores de 16,4% el MSRre y 16,9% el CIre. El resto de los IV tienen RMSEn entre 10% y 14%, siendo el GNDVI el IV con menor RMSEn, un 6%.

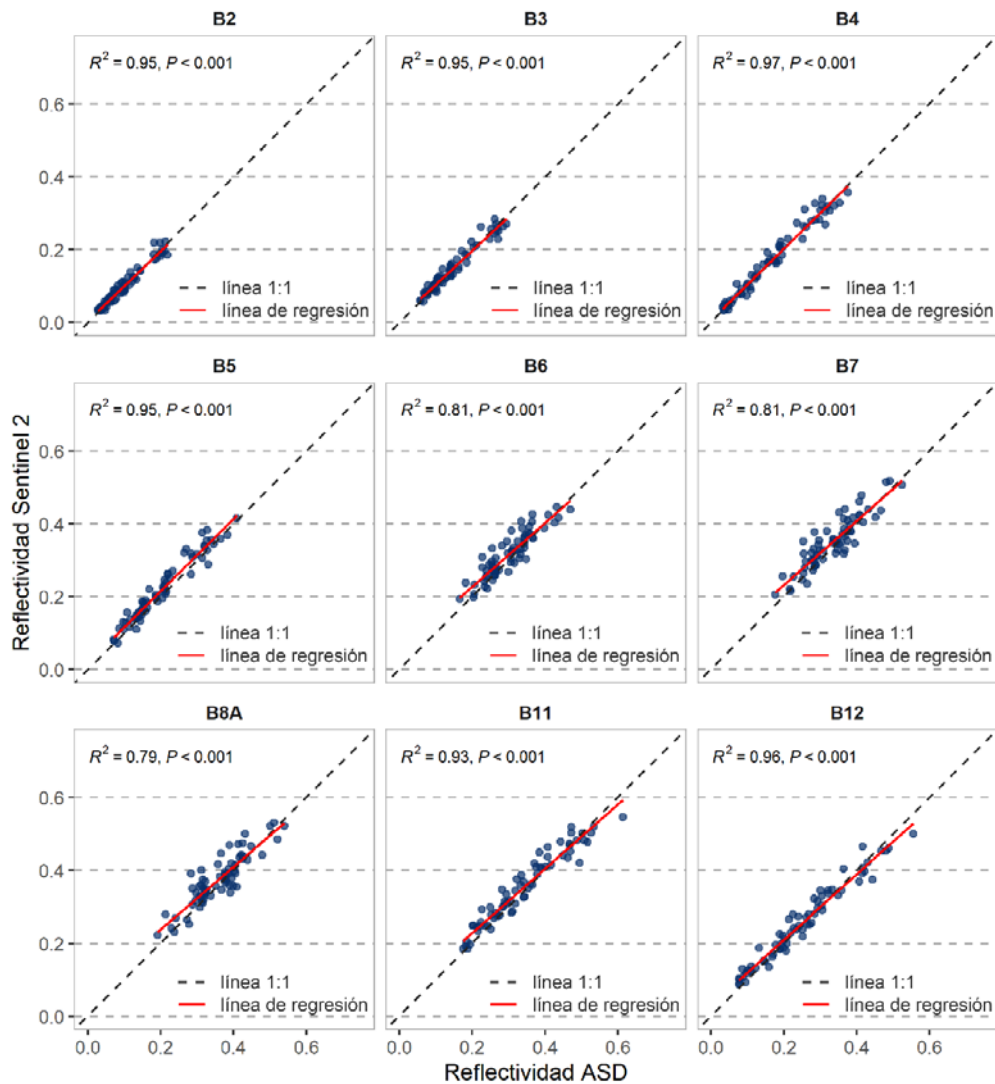


Figura III-18. Diagrama de dispersión de la reflectividad en cada banda espectral entre las medidas de ASD y Sentinel 2 (n=68).

Tabla III-13. Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores ASD y Sentinel 2 (n = 68).

Índice	Intersección	Pendiente	R ²	RMSEn (%)
NDVI	0,01	1,00	0,98***	9,9
RDVI	0	0,95	0,97***	11,9
GNDVI	0,02	0,98	0,98***	6,0

Índice	Intersección	Pendiente	R ²	RMSEn (%)
MSRre	0	0,93	0.90***	16.4
CIre	0,01	0,92	0.90***	16.9
NDRre	0.01	0,99	0.98***	12.7
SAVI	0,01	0,95	0,97***	12,1
MSAVI	0,01	1,01	0,96***	14,3
OSAVI	0,01	1,00	0,97***	10,8
MTVI1	0,01	1,04	0,95***	18,2
MTVI2	0,01	1,01	0,96***	20,6
TVI	0,02	1,05	0,96***	28,0

*** nivel de significación p<0,001

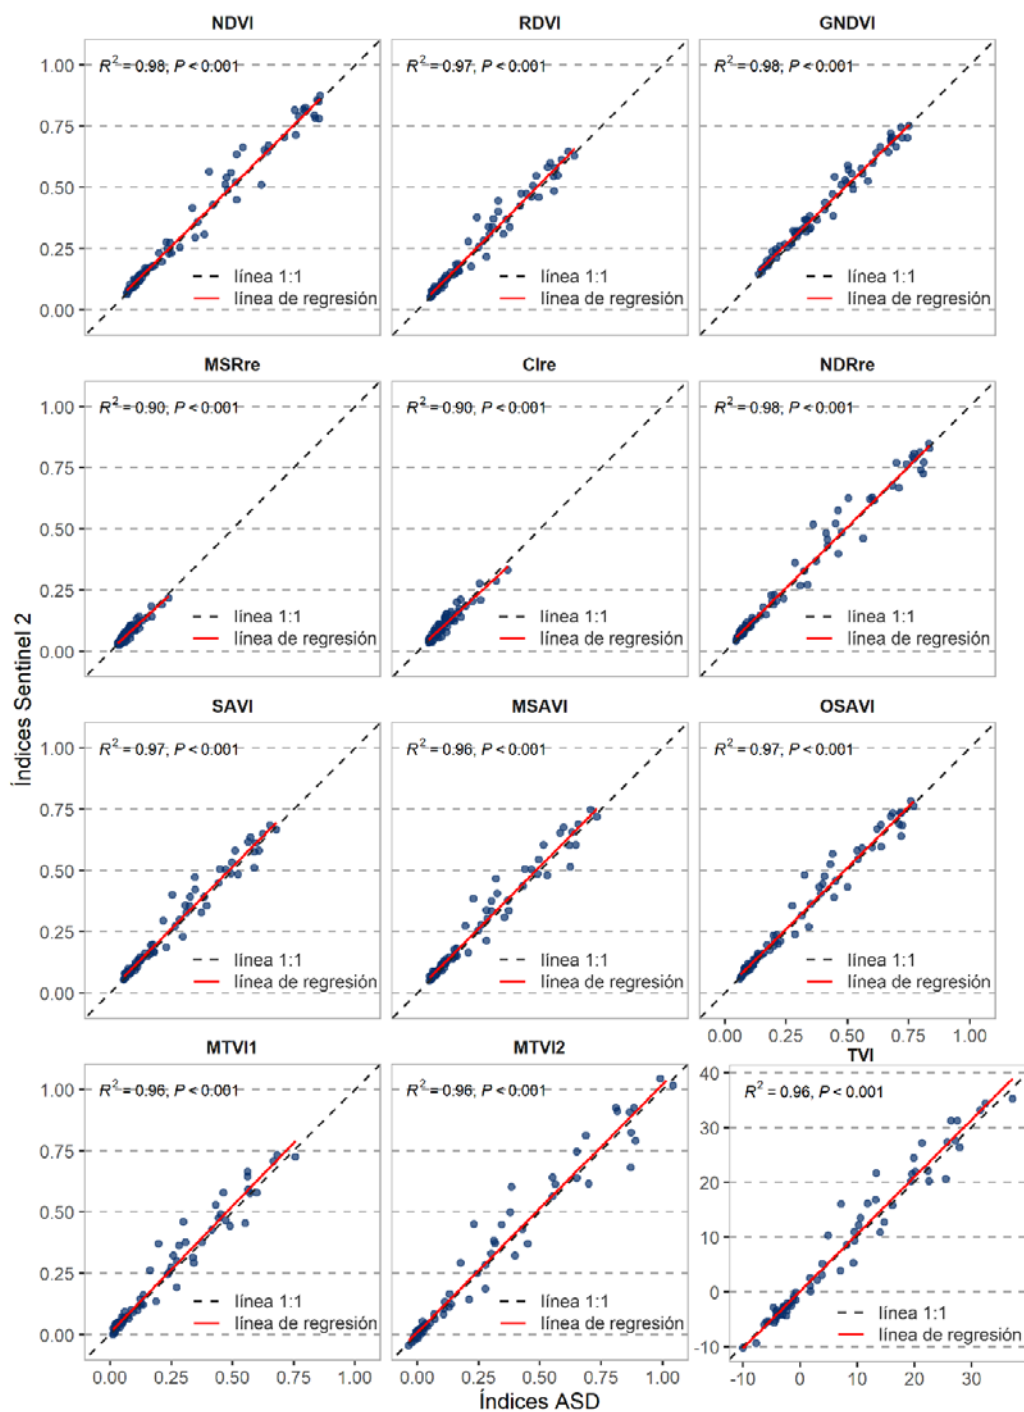


Figura III-19. Diagrama de dispersión de cada IV obtenidos con ASD y Sentinel 2 (n=68).

En la Figura III-20, donde se representan los residuos normalizados (rn), se pueden observar diferencias en función del cultivo. En la B6, B7 y B8A los rn de maíz se localizan cercanos a 0, mientras que los de girasol están algo más dispersos y mayoritariamente por encima de 0. El cultivo del maíz tiene un porte y una estructura foliar diferente a la del girasol, por lo que el cubrimiento del suelo y la aparición de sombras es menor, dando lugar a mayores similitudes entre las medidas de campo y de satélite. El resultado de la prueba de normalidad de los residuos en la B7 y B8A muestra unos niveles de significancia $p < 0,05$ que indican la falta de normalidad en la distribución de los residuos; no es así, en cambio, en el resto de las bandas. En cuanto a la dispersión temporal, en las bandas B2, B3, B4, B5 se observa cómo al comienzo del ciclo, hasta los 400 AGDD, los rn están más dispersos que en el resto del ciclo, mostrando cierta heterocedasticidad, que se corroboró con los resultados obtenidos de la prueba de Breusch-Pagan (Anexo 2) con valores de significación $p < 0,05$ e indica que para estas bandas la varianza de los errores no es constante en todas las observaciones. En las bandas no se observa autocorrelación en los residuales (Anexo 2).

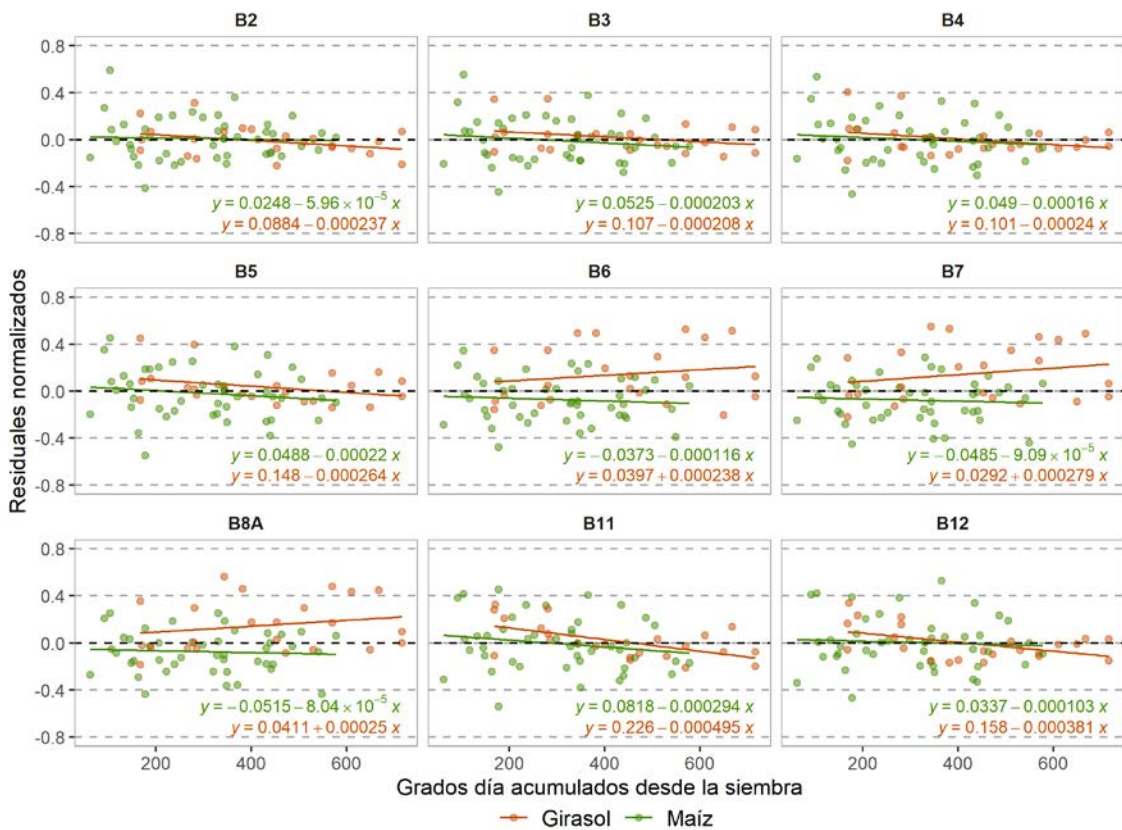


Figura III-20. Gráficos de residuos estandarizados en las bandas obtenidos al aplicar el modelo lineal en función de los AGDD y líneas de tendencia.

En la Figura III-21, donde se representan los rn de los IV, se aprecia una ligera diferencia en función del cultivo, con valores del girasol sistemáticamente por encima del maíz. Sin embargo, las diferencias son más holgadas en función del ciclo del cultivo. Se observa cómo los rn al comienzo del ciclo de ambos cultivos se encuentran cercanos al 0 y, a medida que avanza el ciclo, a partir de 400 AGDD se alejan de 0, indicando que la varianza de los errores no es constante en todas las observaciones. En esta primera fase del cultivo, donde domina el factor suelo, el registro es muy homogéneo; por tanto, los datos de espectro-radiometría y

de satélite son similares. A medida que avanza el ciclo del cultivo el valor residual aumenta y difiere más entre radiometría y Sentinel 2 debido al aumento de la vegetación, la proyección de sombras y la rugosidad del terreno. Además, los resultados de las pruebas de Breusch-Pagan indican heterocedasticidad, con p values $< 0,05$.




Figura III-21. Gráficos de residuos estandarizados en los IV obtenidos al aplicar el modelo lineal en función de los AGDD y líneas de tendencia.

Las diferencias en los r_n y los resultados de las pruebas aplicadas para garantizar la validez del modelo llevaron a considerar dos aproximaciones para el análisis de los datos. Por un lado, según el cultivo –girasol y maíz– y por otro según el ciclo de cultivo, primera etapa (E-1) –hasta 400 AGDD– y segunda etapa (E-2) –>400 AGDD–.

Los resultados de los modelos de regresión lineal para cada cultivo son similares al modelo de regresión lineal general, con R^2 muy altos, intersecciones cercanas a 0 y pendientes cercanas a 1 (Anexo 2). En el caso de los modelos de regresión lineal por etapas del cultivo el ajuste es algo menor que en la regresión lineal general, pero aun así sigue siendo alto (Tabla III-14). En ambos modelos, al igual que en el modelo general, la relación lineal en las bandas

B6, B7 y B8A es más baja que en el resto de las bandas y entre los índices son el MSRre y CIre los que tienen valores más bajos de coeficiente de determinación (Anexo 2).

Cuando aplicamos los estadísticos para comprobar que se garantiza la validez del modelo, los resultados indican que para el modelo según cultivo existe falta de normalidad en los residuos para ambos cultivos en la mayor parte de los IV y también en las bandas B4, B6, B7 y B8A. Además, la prueba de heterocedasticidad en los IV en el modelo del maíz y en las bandas B3, B4, B5 y B11 en el modelo del girasol indica que la varianza de los errores no es constante con respecto a la variable respuesta con p values $< 0,05$. Las pruebas también se han aplicado para los modelos por etapas del ciclo y los resultados indican que en la primera etapa la varianza de los errores sigue sin ser constante, no así en la segunda etapa. En la primera etapa se hicieron las mediciones en parcelas sembradas después del laboreo y en parcelas con siembra directa, por lo que se volvieron a dividir los datos en estas dos categorías para comprobar si las prácticas de siembra influían en el modelo lineal (Anexo 2).

En la Tabla III-14 se observan las intersecciones y pendientes resultantes de aplicar el modelo de regresión lineal para cada cultivo y cada etapa del cultivo, así como las diferencias que existen entre las variables de cada modelo. Las mayores diferencias se observan en los IV entre la primera y la segunda etapa y en las bandas B7 y B8A; esto mismo se veía tanto en los gráficos de residuales (Figura III-21) como en los resultados obtenidos de las pruebas estadísticas (Anexo 2) que garantizan la validez del modelo.

Tabla III-14. Estadísticos de intersección (I) y pendiente (P) de los modelos de regresión lineal por cultivo y por etapa y sus diferencias para cada una de las bandas e IV entre los sensores ASD y Sentinel 2.

Banda/ índice	Modelo lineal según cultivo						Modelo lineal según etapa del cultivo					
	Maíz		Girasol		Diferencias (Maíz-Girasol)		E-1		E-2		Diferencias (E1-E2)	
	I	P	I	P	I	P	I	P	I	P	I	P
B2	0,01	0,94	0,00	1,00	0,01	-0,06	0,01	0,92	0,00	0,92	0,01	0,01
B3	0,01	0,92	0,01	0,98	0,00	-0,05	0,02	0,90	0,01	0,89	0,01	0,01
B4	0,01	0,96	0,00	1,03	0,01	-0,08	0,02	0,93	0,00	0,97	0,01	-0,03
B5	0,02	0,97	0,01	1,06	0,01	-0,09	0,03	0,95	0,02	0,96	0,01	-0,02
B6	0,06	0,83	0,09	0,80	-0,04	0,03	0,06	0,83	0,04	0,93	0,02	-0,09
B7	0,07	0,81	0,09	0,84	-0,02	-0,04	0,08	0,80	0,05	0,92	0,03	-0,13
B8A	0,08	0,79	0,12	0,78	-0,04	0,01	0,09	0,79	0,05	0,91	0,03	-0,12
B11	0,06	0,85	0,03	0,97	0,04	-0,12	0,10	0,78	0,06	0,82	0,04	-0,04
B12	0,04	0,88	0,01	0,98	0,02	-0,10	0,05	0,84	0,04	0,81	0,01	0,03
NDVI	0,01	0,96	0,02	1,00	-0,01	-0,03	-0,01	1,11	0,03	0,96	-0,04	0,15
RDVI	0,01	0,96	0,02	1,02	-0,01	-0,06	-0,01	1,18	0,03	0,97	-0,03	0,21
GNDVI	0,03	0,95	0,03	0,98	0,00	-0,03	0,00	1,06	0,04	0,95	-0,04	0,11
MSRre	0,00	0,92	-0,01	1,15	0,01	-0,24	-0,01	1,23	0,01	0,88	-0,02	0,35
CIre	0,01	0,91	-0,01	1,15	0,02	-0,24	-0,02	1,23	0,01	0,88	-0,03	0,35
NDRre	0,01	0,96	0,02	1,00	-0,01	-0,03	0,00	1,12	0,04	0,95	-0,04	0,17
SAVI	0,01	0,96	0,02	1,02	-0,01	-0,06	-0,01	1,18	0,03	0,97	-0,04	0,21
MSAVI	0,01	0,95	0,03	1,02	-0,01	-0,07	-0,01	1,22	0,03	0,97	-0,05	0,26
OSAVI	0,01	0,96	0,02	1,01	-0,01	-0,05	-0,01	1,15	0,03	0,96	-0,04	0,19

Banda/ índice	Modelo lineal según cultivo						Modelo lineal según etapa del cultivo					
	Maíz		Girasol		Diferencias (Maíz-Girasol)		E-1		E-2		Diferencias (E1-E2)	
	I	P	I	P	I	P	I	P	I	P	I	P
MTVI1	0,01	0,97	0,03	1,02	-0,03	-0,05	-0,01	1,23	0,03	0,99	-0,03	0,24
MTVI2	0,01	0,95	0,00	1,02	0,00	-0,07	0,00	1,22	0,04	0,96	-0,05	0,26
TVI	-0,18	0,99	1,10	1,05	-1,28	-0,06	0,27	1,16	1,14	0,99	-0,87	0,17

En sombreado rosa se identifican las mayores diferencias entre modelos (Etapa primera E-1, Etapa segunda E-2).

De acuerdo con la prueba no paramétrica de Mann-Whitney-Wilcoxon, que no exige asumir la distribución normal de la muestra y es relativamente insensible a la falta de homogeneidad de la varianza de los datos de la muestra, no existen diferencias estadísticamente significativas al 95% ($p > 0,05$) entre las mediciones del espectro-radiómetro y Sentinel 2 para ninguna de las bandas ni IV (Figura III-22).

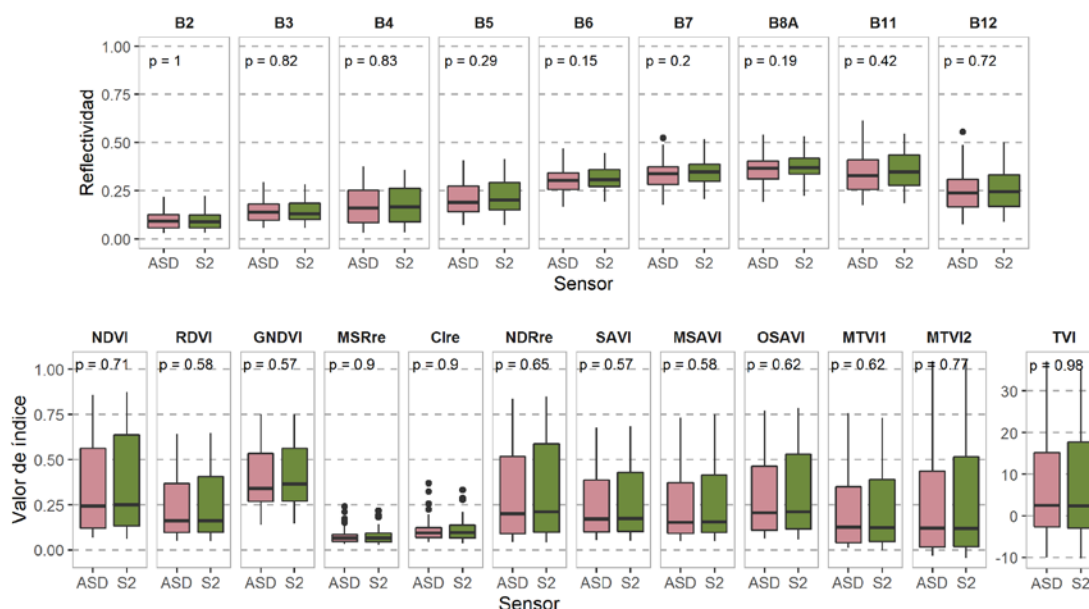


Figura III-22. Diagramas de cajas de los valores de reflectividad en cada banda espectral y de los valores de los IV para ambos sensores ASD y Sentinel 2 ($n=68$). Umbral de significación según test Wilcoxon $p < 0,05$.

III.2.2 Comparación de espectro-radiometría de campo y UAV

Al igual que en el escenario 1, en el escenario 2, tanto para las diferentes bandas como los IV analizados, los pares de puntos de la muestra se distribuyen en torno a la línea 1:1, próximos a ella. Sin embargo, la línea de la ecuación de regresión no se aproxima tanto a la línea 1:1.

Las bandas del visible (B3 y B4) muestran una relación lineal muy alta con coeficientes de determinación por encima de 0,94 (Figura III-23) y pendientes cercanas a 1 (Tabla III-15). Las diferencias entre las reflectividades de ambos sensores son mínimas. En el caso de la B6 y B7 la relación es alta, aunque menor que en el visible, el intercepto es positivo y mayor que en el visible, y las pendientes están más alejadas de la situación ideal 1, lo que sugiere una mayor diferencia entre los datos de ASD y Sequoia. En el borde del rojo, B6, se observa una

ligera subestimación de los datos del sensor Sequoia a partir de la reflectividad de 0,3 (Figura III-23). En el infrarrojo, B7, las diferencias entre reflectividad Sequoia y espectro-radiómetro se observan en todo el ciclo pasando Sequoia de sobreestimar a subestimar la reflectividad a partir de la reflectividad de 0,45.

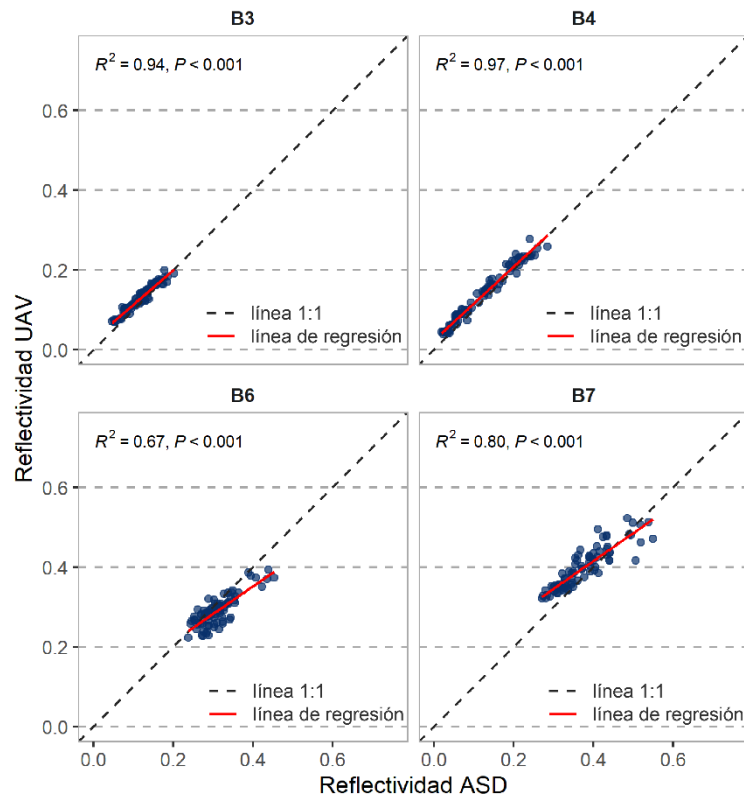


Figura III-23. Diagrama de dispersión de cada banda espectral. (n=82).

En general, los RMSEn son bajos, entre 6,3% y 9,4%, siendo la B4 la que mayor error tiene y la B7 la que menor (Tabla III-15).

Tabla III-15. Estadísticos obtenidos del modelo de regresión lineal para cada una de las bandas espectrales entre los datos ASD y Sequoia (n=82).

Banda	Intersección	Pendiente	R ²	RMSEn (%)
B3	0,03	0,86	0,94***	7,0
B4	0,02	0,93	0,97***	9,4
B6	0,07	0,69	0,67***	7,1
B7	0,13	0,70	0,8***	6,3

*** nivel de significación p<0,001

En el caso de los IV la relación es casi perfecta, tal y como muestran los gráficos de dispersión de la Figura III-24; los R² tienen valores superiores a 0,93. Además, la mayor parte de los IV tienen una intersección en origen positiva y muy cercana a 0, con unas pendientes entre 0,8 y 0,9 (Tabla III-16). La excepción son los índices MSRre y CIre que, aunque presentan un R² de 0,93, tienen una pendiente muy elevada, de 1,45 y 1,59 respectivamente, lo que indica que existe una diferenciación holgada entre los datos de ASD y Sequoia. La mayor parte de los IV están sobrestimados con el sensor Sequoia hasta los valores de 0,4 a 0,45 aproximadamente, a partir de ahí se produce una subestimación. En los índices GNDVI

y MTVI 2 el punto de cambio de sobreestimación a subestimación se presenta en valores 0,55 y 0,35 respectivamente. En los índices MSRre, CIre y NDRre las diferencias aumentan a medida que lo hace el vigor vegetal, si bien en sentidos diferentes según el índice, MSRre y CIre tiende a sobreestimar y NDRre a subestimar.

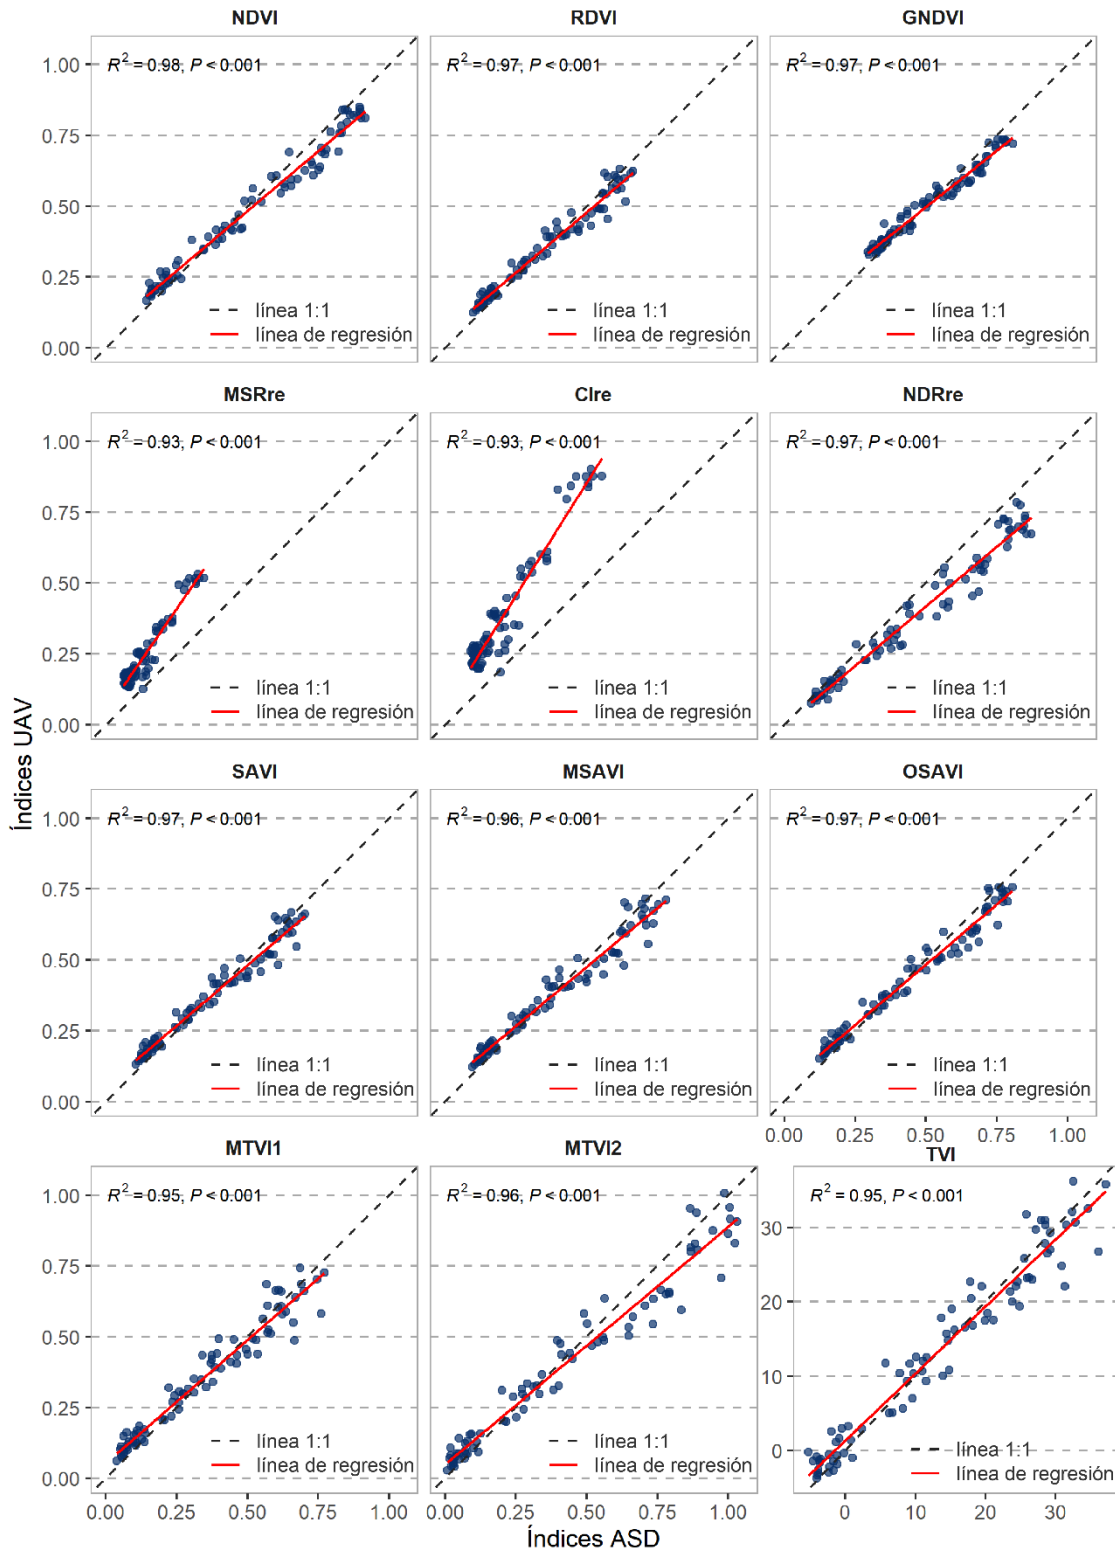


Figura III-24. Diagrama de dispersión de cada IV. Valores de índice producto de la reflectividad medida por ASD en el eje X contra valores de índice producto de la reflectividad medida por Sequoia en el eje Y (n=82).

Los valores de RMSEn para los IV son similares a los de las bandas, como se puede ver en la Tabla III-16, a excepción de los índices triangulares basados en las bandas del verde, rojo e infrarrojo cercano, cuyos valores se encuentran entre 20% el TVI y 13,2% el MTVI1. En contraposición, los índices GNDVI y NDVI presentan los valores más bajos, 4,2% y 6,4% respectivamente. Para el resto de los IV el error se sitúa entre el 7% y 9,4%.

Tabla III-16. Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores ASD y Sequoia (n=82).

Índice	Intersección	Pendiente	R ²	RMSEn (%)
NDVI	0,06	0,84	0,98***	6,4
RDVI	0,05	0,85	0,97***	8,1
GNDVI	0,01	0,80	0,97***	4,2
MSRre	0,05	1,45	0,93***	22,9
CIre	0,06	1,59	0,93***	25,7
NDRre	0,00	0,84	0,97***	8,8
SAVI	0,05	0,85	0,97***	8,1
MSAVI	0,06	0,83	0,96***	9,4
OSAVI	0,06	0,85	0,97***	7,0
MTVI1	0,05	0,87	0,95***	13,2
MTVI2	0,05	0,83	0,96***	13,3
TVI	1,32	0,90	0,95***	20,0

*** nivel de significación $p < 0,001$

El análisis de los r_n revela que éstos no se distribuyen de la misma forma, confirmando la heterocedasticidad (Figura III-25). En las bandas B3 y B6 los residuos se distribuyen de forma diferente según el cultivo. En las bandas B4 y B7 también se observan diferencias según su ciclo (Figura III-25); en la B4 la dispersión de los residuos es mayor al comienzo del ciclo y en la B7 al contrario. Las pruebas estadísticas confirman estas diferencias observadas en todas las bandas a excepción de la B6, donde, a pesar de apreciarse diferencias entre cultivos, los residuales están distribuidos de forma aleatoria, por tanto, el valor de la prueba de significación de B-P es $> 0,05$. Además, en la B6 se muestra una clara tendencia descendente, sobre todo en el maíz, que denota autocorrelación de los residuales. Este resultado se corrobora con la prueba de D-W, que ofrece un valor de 0,52 y en la B7 un valor de 0,86 (Anexo 2).

En cuanto a los IV la distribución que vemos en la Figura III-26 por cultivos es similar en todos los IV a excepción de MSRre, CIre y NDRre, donde los r_n del maíz se mantienen estables sobre la línea de 0, mientras que en el girasol se observa un cambio de tendencia en los r_n , de positivo a negativos. En la distribución de los r_n en cuanto al ciclo de los cultivos se da la misma situación que en el escenario 1. Los r_n , menos dispersos hasta los 400 AGDD, aumentan la dispersión a partir de ese momento. La prueba de B-P indica que la mayoría de los IV tienen un nivel de significación $p < 0,05$, por lo que la heterocedasticidad está presente. En vista de estos resultados, y al igual que en el escenario 1, los datos se agruparon por etapas de cultivo E-1 –hasta 400 AGDD–, E-2 \rightarrow 400 AGDD– y según el cultivo –girasol y maíz–.

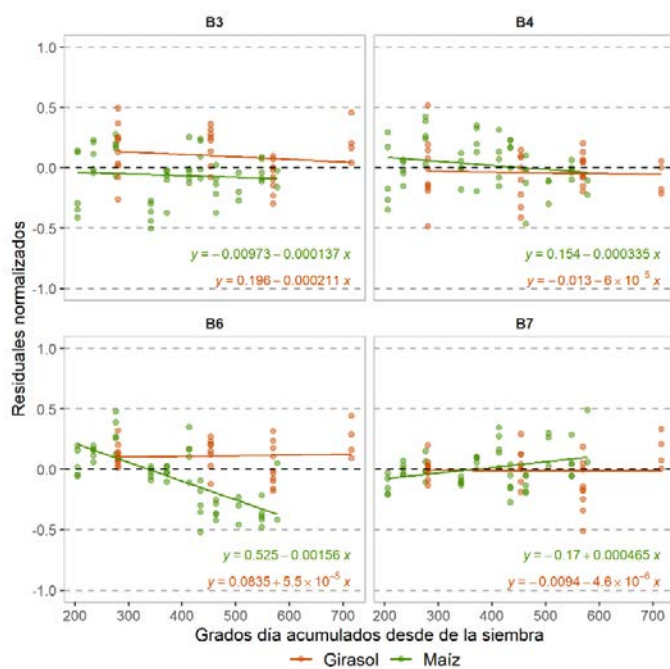


Figura III-25. Gráficos de residuos estandarizados de las bandas obtenidos al aplicar el modelo lineal en función de los AGDD.

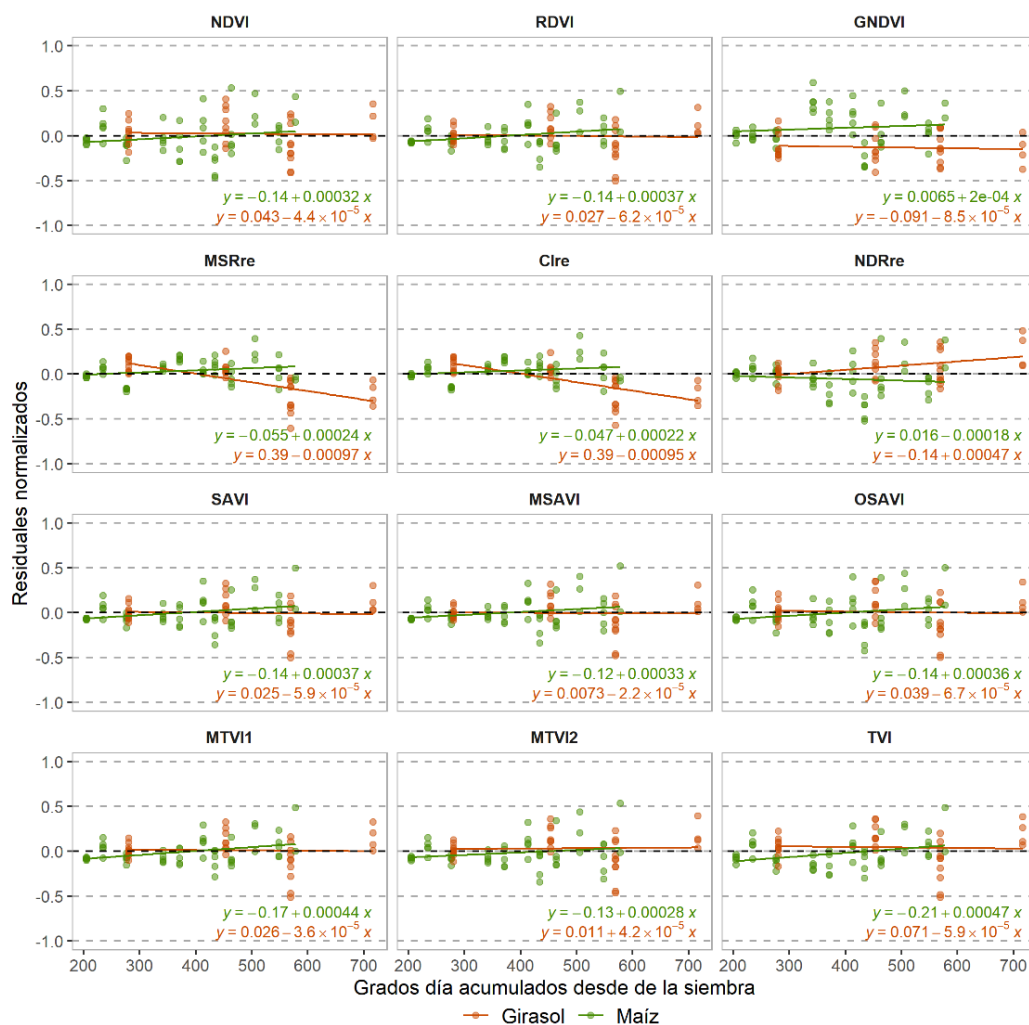


Figura III-26. Gráficos de residuos estandarizados de los IV obtenidos al aplicar el modelo lineal en función de los AGDD.

Los modelos de regresión lineal por cultivos aplicados a las bandas (Anexo 2) son similares al modelo general en todas las bandas a excepción de la B6, donde la diferencia entre los datos de ASD y Sequoia se acentúa mucho más en el maíz, presenta un R^2 con un valor mucho más bajo (0,19) y una pendiente alejada de 1 (0,39) (Tabla III-17). Además, la prueba de B-P sigue indicando heterocedasticidad en las bandas B3 y B4 en maíz y en B6 y B7 en girasol. Cuando se aplica el modelo lineal por etapas del cultivo, el coeficiente de determinación disminuye ligeramente con respecto al modelo lineal general, pero las condiciones que garantizan la validez del modelo se cumplen.

Los modelos de regresión lineal por cultivos aplicados a los IV muestran diferencias, fundamentalmente, para el MSRre y CIre (Tabla III-17) en el cultivo del girasol con un R^2 de 0,32 que evidencia la poca relación entre los sensores (Anexo 2). Las pruebas K-S y B-P indican que en la mayoría de los IV existe heterocedasticidad y, además, en el maíz hay falta de normalidad en los índices RDVI, SAVI, MSAVI, MTVI1 y MTVI2. En los modelos de regresión lineal por etapas de cultivo, los resultados son similares a los obtenidos con las bandas, con relaciones entre sensores algo más bajas. En la primera etapa los R^2 se sitúan en torno a 0,94; en cambio, en la segunda etapa son algo más bajos y oscilan entre 0,83 en TVI y MTVI1 y 0,94 en GNDVI. Los índices MSRre y CIre tienen una relación entre sensores mucho más baja que el resto de IV; en la primera etapa los R^2 son 0,68 y 0,69 respectivamente. Aunque los modelos de regresión lineal por etapa de cultivo ofrecen unas relaciones entre sensores algo más bajas en relación con el modelo lineal general, sí cumplen las condiciones que garantizan la validez del modelo.

Tabla III-17. Estadísticos de intersección (I) y pendiente (P) de los modelos de regresión lineal por cultivo y por etapa y sus diferencias para cada una de las bandas y de los IV entre los sensores ASD y Sequoia.

Banda/ índice	Modelo lineal según cultivo						Modelo lineal según etapa del cultivo					
	Maíz		Girasol		Diferencias (Maíz-Girasol)		Etapa 1 E-1		Etapa 2 E-2		Diferencias (E1-E2)	
	I	P	I	P	I	P	I	P	I	P	I	P
B3	0.03	0.84	0.03	0.86	0.00	-0.02	0.03	0.87	0.02	0.90	0.00	-0.03
B4	0.02	0.94	0.02	0.91	0.00	0.03	0.06	0.77	0.02	0.89	0.03	-0.12
B6	0.16	0.40	0.10	0.64	0.06	-0.24	0.13	0.54	0.03	0.82	0.10	-0.28
B7	0.11	0.77	0.16	0.63	-0.05	0.14	0.10	0.80	0.17	0.63	-0.07	0.17
NDVI	0.05	0.86	0.07	0.83	-0.02	0.03	0.08	0.77	0.08	0.82	0.00	-0.05
RDVI	0.05	0.87	0.07	0.82	-0.02	0.05	0.06	0.80	0.08	0.81	-0.02	-0.01
GNDVI	0.11	0.79	0.09	0.79	0.02	0.00	0.05	0.94	0.07	0.84	-0.02	0.10
MSRre	0.05	1.50	0.13	0.47	-0.08	1.03	0.03	1.70	0.03	1.50	0.01	0.20
CIre	0.06	1.60	0.20	0.50	-0.14	1.10	0.04	1.90	0.02	1.70	0.02	0.20
NDRre	0.00	0.81	-0.01	0.88	0.01	-0.07	0.03	0.67	0.02	0.82	0.01	-0.15
SAVI	0.05	0.88	0.07	0.82	-0.02	0.06	0.06	0.80	0.08	0.81	-0.02	-0.01
MSAVI	0.05	0.85	0.07	0.80	-0.02	0.05	0.06	0.80	0.09	0.79	-0.03	0.01
OSAVI	0.05	0.87	0.07	0.83	-0.02	0.04	0.07	0.78	0.08	0.82	-0.01	-0.04
TVI	0.38	0.95	2.80	0.85	-2.42	0.10	0.82	0.72	4.40	0.79	-3.58	-0.07
MTVI1	0.04	0.91	0.08	0.82	-0.04	0.09	0.06	0.78	0.11	0.77	-0.05	0.01
MTVI2	0.03	0.87	0.08	0.78	-0.05	0.09	0.05	0.74	0.12	0.74	-0.07	0.00

En sombreado rosa se identifican las mayores diferencias entre modelos.

Según el test de Wilcoxon (ver Figura III-27) en las bandas del visible no existen diferencias estadísticamente significativas al 95% ($p > 0,05$) entre las mediciones del espectroradiómetro y las de Sequoia en UAV. Sin embargo, en las bandas del borde del rojo e infrarrojo cercano sí que existen diferencias estadísticamente significativas.

En la mayoría de los IV no se presentan diferencias estadísticamente significativas si se obtienen con ASD o con Sequoia. La excepción son los índices MSRre y Clre, así como el índice NDRre que sí presenta diferencias significativas, aunque está muy cerca de no tener diferencias estadísticamente significativas (Figura III-27).

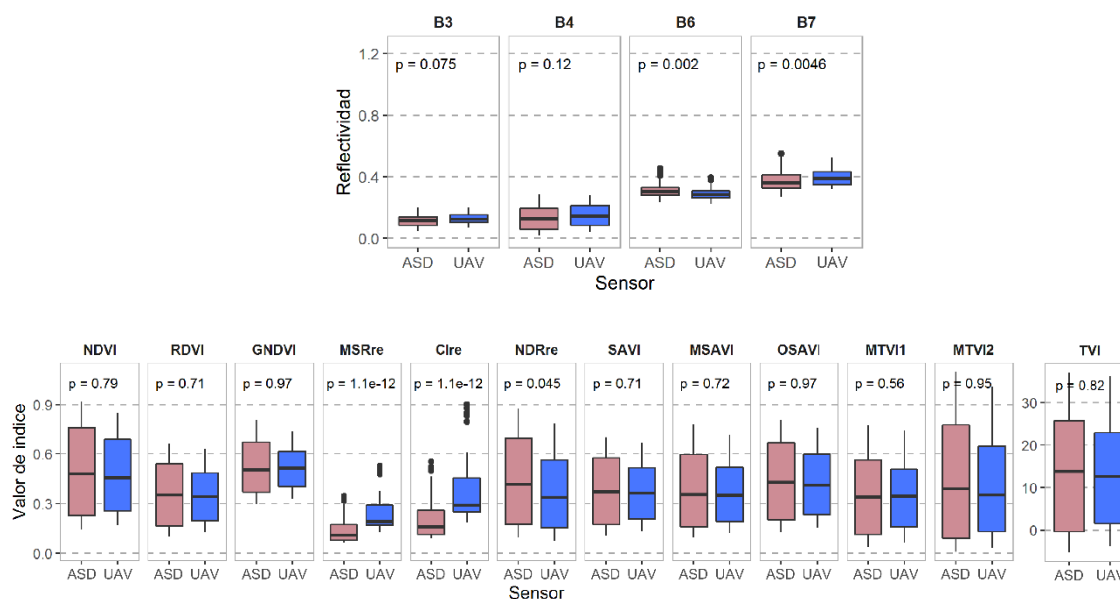


Figura III-27. Diagrama de caja de los valores de reflectividad en cada banda espectral y valores de los IV para ambos sensores ASD y Sequoia y resultados del test de Wilcoxon ($n=82$).

III.2.3 Comparación de Sentinel 2 y UAV

Como ocurre en las comparaciones anteriores, para este escenario 3 la relación lineal entre ambos sensores es muy alta en el caso de las bandas del visible (Figura III-28), con coeficientes de determinación por encima de 0,93 y unas pendientes cercanas a 1 (Tabla III-18). Las diferencias entre las reflectividades de ambos sensores son mínimas, sobrestimado Sequoia hasta la reflectividad de 0,12, cuando comienza a subestimar. En el caso de la banda del infrarrojo cercano la relación es alta, aunque menor que en el visible y las pendientes más alejadas de la situación ideal 1, lo que sugiere una mayor diferencia entre los datos de Sentinel 2 y Sequoia. En las bandas B6 y B7 las diferencias aumentan a medida que lo hace el vigor vegetal, aunque en sentidos diferentes: el primero tiende a subestimar los datos del sensor Sequoia y el segundo a sobreestimar.

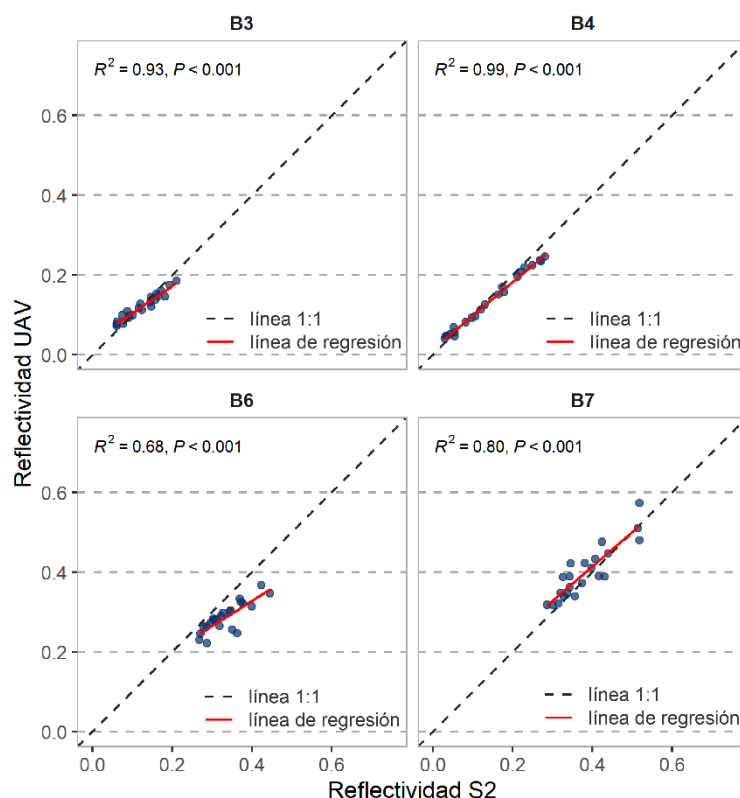


Figura III-28. Diagrama de dispersión de la reflectividad en cada banda espectral entre medidas Sentinel 2 y UAV (n=22).

Los valores de RMSEn indican una buena exactitud del modelo (Tabla III-18). En general, los errores son bajos para todas las bandas con valores entre 4,4% y 7,5%, siendo la banda del rojo la que menor error presenta y la banda del infrarrojo cercano la que mayor.

Tabla III-18. Estadísticos obtenidos del modelo de regresión lineal para cada una de las bandas espectrales entre los datos Sentinel 2 y Sequoia (n=22).

Banda	Intersección	Pendiente	R ²	RMSEn (%)
B3	0,04	0,68	0,93***	6,7
B4	0,01	0,84	0,99***	4,4
B6	0,08	0,63	0,68***	6,2
B7	0,07	0,86	0,80***	7,5

*** nivel de significación p<0,001

Para los IV, como ocurre en el escenario 2, en la mayor parte de ellos la relación es casi perfecta con R2 superiores a 0,96, a excepción de MSRre Y CIre, cuya relación es más baja con R2 0,8 (Figura III-29). Los IV tienen una intersección en origen positiva y las pendientes valores cercanos a 1, exceptuando MSRre y CIre, cuya pendiente es de 1,88 y 2,13 respectivamente (Tabla III-19), lo que indica diferencia entre los datos de Sentinel 2 y UAV. Como ocurría en el escenario 2, los índices NDVI, MSAVI, OSAVI y MTVI 2 tienden a sobreestimar el sensor Sequoia hasta valores de 0,60 0,7 aproximadamente y a partir de ahí comienzan a subestimar. En los índices RDVI, SAVI, MTVI 1 y TVI los valores de Sequoia sobrestiman en los valores más bajos, pero a medida que aumenta el valor del IV, los datos se ajustan a la línea 1:1. En MSRre, CIre y NDRre las diferencias aumentan a medida que lo hace el vigor vegetal, sobrestimando en MSRre y CIre y subestimando en NDRre.

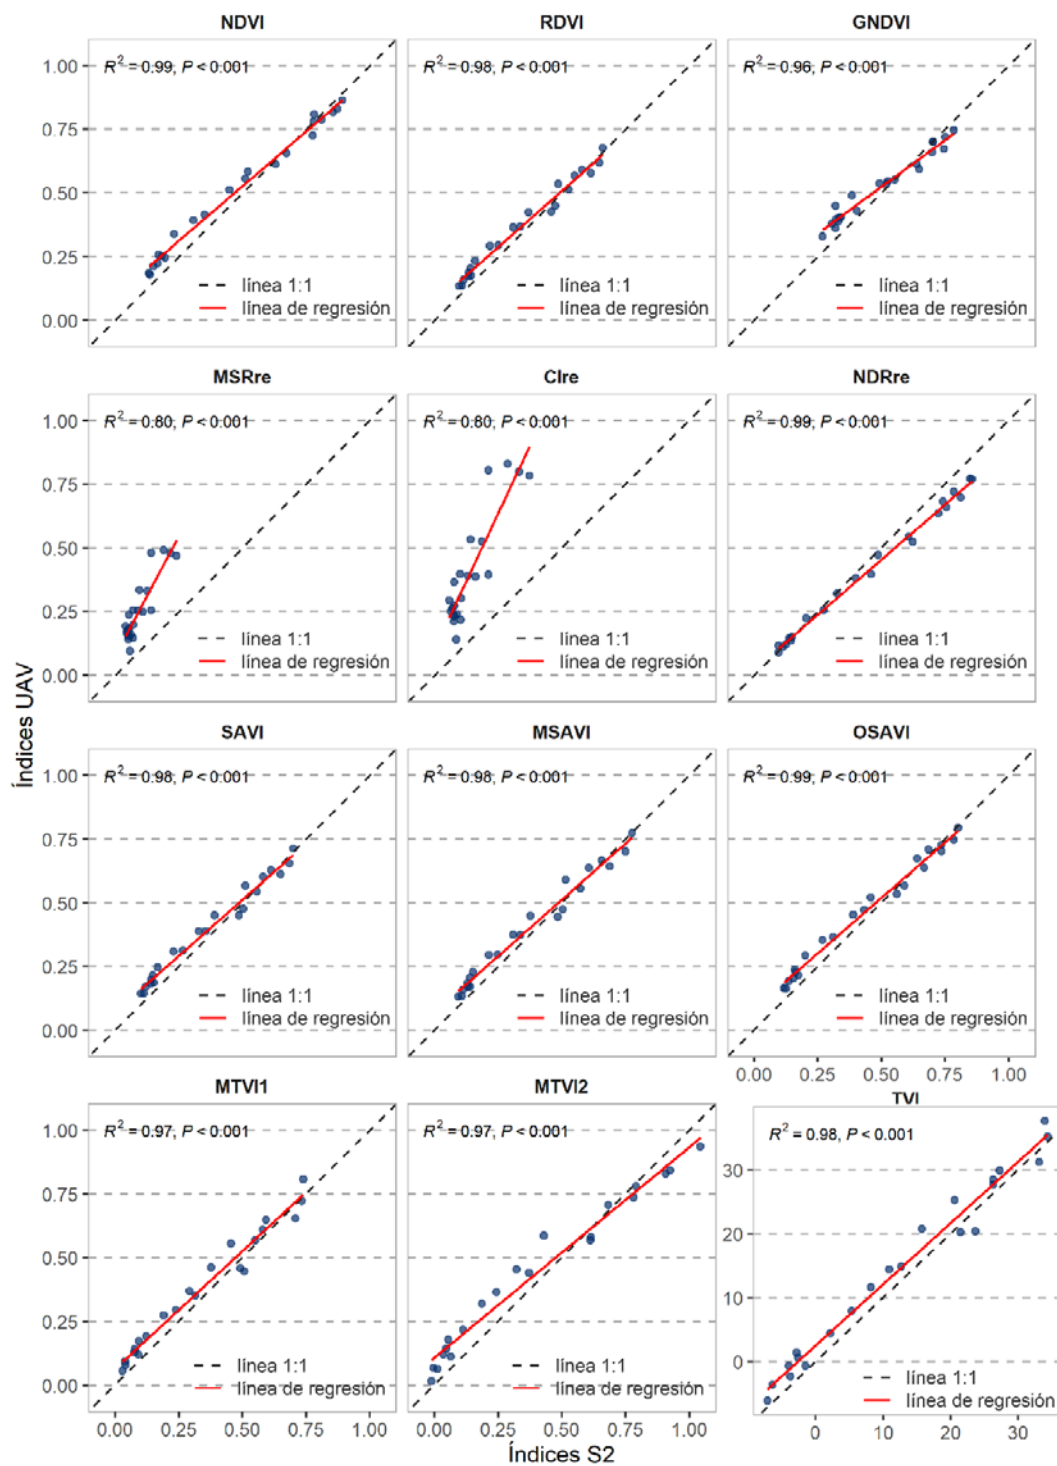


Figura III-29. Diagrama de dispersión de cada IV entre medidas Sentinel 2 y UAV (n=22).

Los RMSEn basados en la diferencia normalizada, NDRre y los índices ajustados al suelo son bajos, como se puede ver en la Tabla III-19. En los índices triangulares el RMSEn es algo más elevado, con valores entre 11,6% y 15,6% y, por último, el error en MSRre y CIre, índices que utilizan la banda B6 y B7, es muy elevado, con valores de 57,3% y 67,5%.

Tabla III-19. Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores Sentinel 2 y Sequoia (n = 22).

Índice	Intersección	Pendiente	R ²	RMSEn (%)
NDVI	0,10	0,86	0,99***	5,2
RDVI	0,07	0,88	0,98***	7,1
GNDVI	0,16	0,73	0,96***	4,9
MSRre	0,08	1,88	0,80***	57,3
CIre	0,10	2,13	0,80***	67,5
NDRre	0,02	0,86	0,99***	4,0
SAVI	0,07	0,88	0,98***	7,1
MSAVI	0,07	0,88	0,98***	8,3
OSAVI	0,08	0,87	0,99***	5,8
MTVI1	0,06	0,93	0,97***	11,9
MTVI2	0,11	0,83	0,98***	11,6
TVI	2,57	0,96	0,98***	15,6

*** indica un nivel de significación $p < 0,001$

Los r_n en las bandas tienen una distribución aleatoria (Figura III-30), similar a la del escenario 2. En las bandas B3, B6 y B7 los residuos se distribuyen de forma diferente según el cultivo. Además, al inicio del ciclo, los valores tienen poca dispersión en las bandas B6 y B7, que aumenta a medida que avanza el ciclo. En el momento del ciclo donde se da la mayor dispersión se obtienen valores negativos r_n en la banda B6 y valores positivos en la banda B7. Tras aplicar las pruebas estadísticas para comprobar las condiciones del modelo de regresión lineal, se observa homocedasticidad en la banda B6, con valores de P-B de 0,002.

En el caso r_n de los IV se observan dos tendencias según el cultivo y el ciclo del cultivo. Para el maíz en el comienzo del ciclo los r_n son cercanos a 0 o negativos y se convierten en positivos un poco antes de los 400 AGDD. En el girasol es al contrario, con r_n positivos al inicio del ciclo y a medida que este avanza pasan a ser negativos. Esto ocurre en todos los IV a excepción del NDRre. A pesar de observar estas tendencias se aplicaron las pruebas estadísticas para comprobar el modelo y únicamente se observa falta de normalidad en el índice MTVI1.

Los modelos de regresión lineal por cultivos aplicados a las bandas (Anexo 2) son similares al modelo lineal general para todas las bandas a excepción de la B6 como ocurría con el escenario 2. La diferencia entre sensores se acentúa mucho más en el maíz, con un R² de 0,27 y una pendiente con valor de 0,14. En el girasol la pendiente también se aleja de 1 tanto en la banda B6 como en la B7 (Tabla III-20). Las condiciones que garantizan la validez del modelo por cultivo y etapas del cultivo se cumplen en todos los casos (Anexo 2).

Los modelos de regresión lineal por cultivos aplicados a los IV muestran diferencias en varios casos (Tabla III-20). Los sensores Sequoia y MSI se relacionan mejor cuando se trata del maíz. En girasol, tanto coeficientes de determinación como pendientes presentan valores más bajos. En cuanto a las etapas, las diferencias también se observan en todos los IV, a excepción de GNVI y NDRre. En general, los sensores se relacionan mejor en la primera etapa que en la segunda. Se aplicaron las pruebas que garantizan la validez del modelo y a pesar de las diferencias observadas en la Tabla III-20 se cumplen en todos IV, lo que puede deberse al reducido tamaño de la muestra.

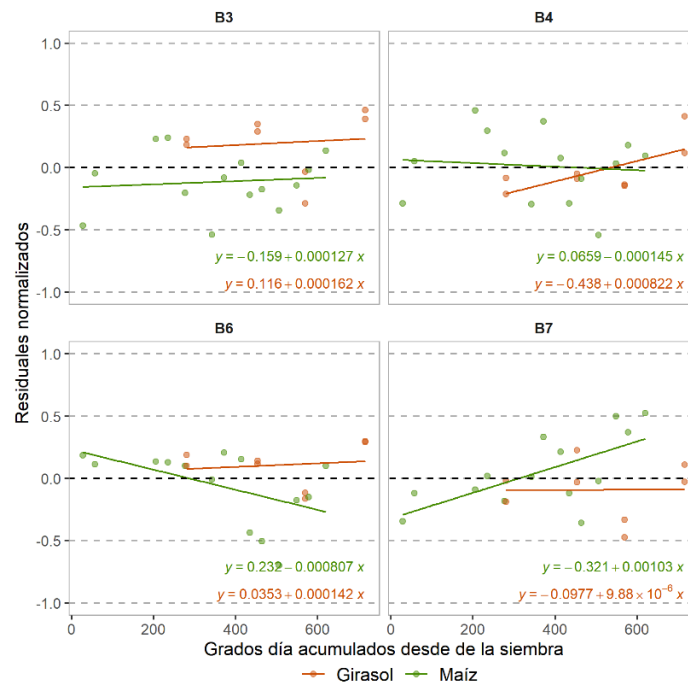


Figura III-30. Gráficos de residuos estandarizados de las bandas obtenidos al aplicar el modelo de regresión lineal en función de los AGDD.




Figura III-31. Gráficos de residuos estandarizados de los IV obtenidos al aplicar el modelo de regresión lineal en función de los AGDD.

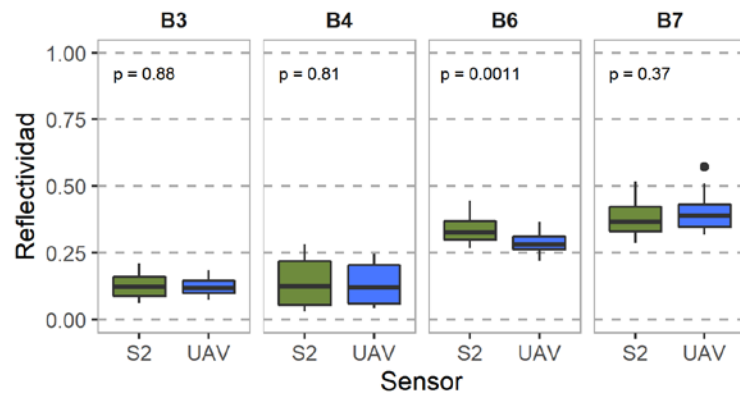
Tabla III-20. Estadísticos de intersección (I) y pendiente (P) de los modelos de regresión lineal por cultivo y por etapa y sus diferencias para cada una de las bandas espectrales e IV entre los datos de Sentinel 2 y UAV en el píxel de medidas (n = 22).

Banda/ índice	Modelo lineal según cultivo						Modelo lineal según etapa del cultivo					
	Maíz		Girasol		Diferencias (Maíz-Girasol)		E-1		E-2		Diferencias (E1-E2)	
	I	P	I	P	I	P	I	P	I	P	I	P
B3	0.03	0.67	0.05	0.66	-0.01	0.01	0.04	0.66	0.04	0.61	0.00	0.05
B4	0.01	0.86	0.02	0.81	-0.01	0.05	0.02	0.84	0.01	0.86	0.00	-0.02
B6	0.14	0.27	0.12	0.52	0.02	-0.25	0.06	0.71	0.04	0.71	0.02	0.00
B7	0.02	1.00	0.12	0.72	-0.11	0.28	0.05	0.90	0.12	0.75	-0.07	0.15
NDVI	0.09	0.88	0.11	0.82	-0.02	0.06	0.06	1.00	0.15	0.79	-0.09	0.21
RDVI	0.06	0.93	0.08	0.82	-0.03	0.11	0.04	1.00	0.10	0.82	-0.06	0.18
GNDVI	0.16	0.75	0.15	0.71	0.01	0.04	0.16	0.72	0.21	0.66	-0.05	0.06
MSRre	0.08	1.90	0.13	1.00	-0.05	0.90	0.15	0.32	0.11	1.70	0.04	-1.38
CIre	0.11	2.20	0.19	1.10	-0.08	1.10	0.22	0.41	0.16	1.90	0.06	-1.49
NDRre	0.02	0.85	0.03	0.87	0.00	-0.02	0.01	0.96	0.01	0.88	0.00	0.08
SAVI	0.06	0.93	0.09	0.82	-0.03	0.11	0.04	1.00	0.10	0.82	-0.06	0.18
MSAVI	0.06	0.94	0.09	0.82	-0.03	0.12	0.03	1.10	0.11	0.82	-0.08	0.28
OSAVI	0.08	0.90	0.10	0.82	-0.02	0.08	0.05	1.00	0.12	0.81	-0.07	0.19
TVI	2.10	1.00	3.90	0.87	-1.80	0.13	2.80	1.10	3.10	0.93	-0.30	0.17
MTVI1	0.05	1.00	0.09	0.83	-0.04	0.17	0.04	1.10	0.09	0.87	-0.05	0.23
MTVI2	0.11	0.84	0.15	0.77	-0.04	0.07	0.07	1.20	0.19	0.71	-0.12	0.49

En sombreado rosa se identifican las mayores diferencias entre modelos. (Etapa primera E-1, Etapa segunda E-2).

Los resultados de los diagramas de cajas y el valor de la significación el test de Wilcoxon nos indican que en las bandas del visible e infrarrojo cercano no existen diferencias estadísticamente significativas entre los datos de Sentinel 2 y Sequoia con $p > 0,05$ (Figura III-32); sin embargo, en la banda del borde del rojo sí que existen diferencias estadísticamente significativas entre los datos de Sentinel 2 y Sequoia con $p < 0,05$.

La mayoría de los IV no presentan diferencias estadísticamente significativas con $p > 0,05$. Para MSRre y CIre sí que existen diferencias estadísticamente significativas entre los datos de Sentinel 2 y Sequoia al 95% de nivel de confianza.






Figura III-32. Diagrama de caja de los valores de reflectividad en cada banda espectral y valores de los IV para ambos sensores Sentinel 2 y Sequoia.

III.2.4 Comparación de sensores en el escenario 4

A diferencia de los escenarios 1 a 3, donde la comparación se hace hasta los estadios V8 en maíz y R1 en girasol (hasta que se puede medir manualmente con el radiómetro), en el escenario 4 se hace hasta el estadio R4 para maíz y R8 para girasol.

III.2.4.1 Homogeneidad de la información espectral de Sequoia por cultivo y estadio

Antes de realizar el análisis comparativo entre la reflectividad y los IV obtenidos con MSI y Sequoia a bordo de UAV, se evaluó la homogeneidad por cultivo de la información espectral recogida por Sequoia con el objetivo de valorar la variabilidad de la reflectividad por banda e IV.

En general, en todas las bandas e IV el maíz presenta menores desviaciones estándar y datos más homogéneos (menor rango en las desviaciones de un mismo estadio) que el girasol (Figura III-33 y Figura III-34). Para el cultivo del girasol la variabilidad es mayor al comienzo del ciclo en las regiones del visible (B3 y B4), para ir descendiendo conforme avanza el desarrollo del cultivo y se inicia la fase reproductiva (estadio R). Al final de esta fase reproductiva, estadios R7 y R8, la variabilidad vuelve a ascender, pero sin superar el error estándar 0,025. En las longitudes del borde del rojo e infrarrojo cercano (B6 y B7) la variabilidad se mantiene más o menos estable desde V2 a R5, mientras que en los dos últimos estadios con datos, R7 y R8, aumenta, si bien en la banda B7 la variabilidad es algo mayor en las fases finales del ciclo. El aumento de la variabilidad en estas últimas fases del ciclo es debido a que el girasol comienza a secarse, por lo que encontramos plantas secas o muy secas y otras plantas con algo de verdor aún. La respuesta espectral difiere de unas a otras, lo que supone mayor variabilidad debido al grado y proporción de plantas secas. Además, al secarse la planta cubre menos el suelo, influyendo este en la respuesta espectral.

En el cultivo del maíz las regiones del visible tienen un comportamiento similar en las bandas B3 y B4. Al comienzo del ciclo del cultivo, hasta V5, es cuando mayor variabilidad se observa, comenzando a disminuir hasta la fase reproductiva donde se mantiene estable. En el borde del rojo (B6) la variabilidad se mantiene más o menos estable hasta la fase reproductiva, cuando comienza a aumentar. En el infrarrojo cercano (B7) la desviación aumenta desde V6, con mayor rango en la fase reproductiva que en el borde del rojo. El aumento de la variabilidad en el inicio de la fase reproductiva (hasta R4) se debe

principalmente a la aparición de la inflorescencia masculina (penacho) y de la inflorescencia femenina (mazorca) que no se producen a la vez en todas las parcelas.

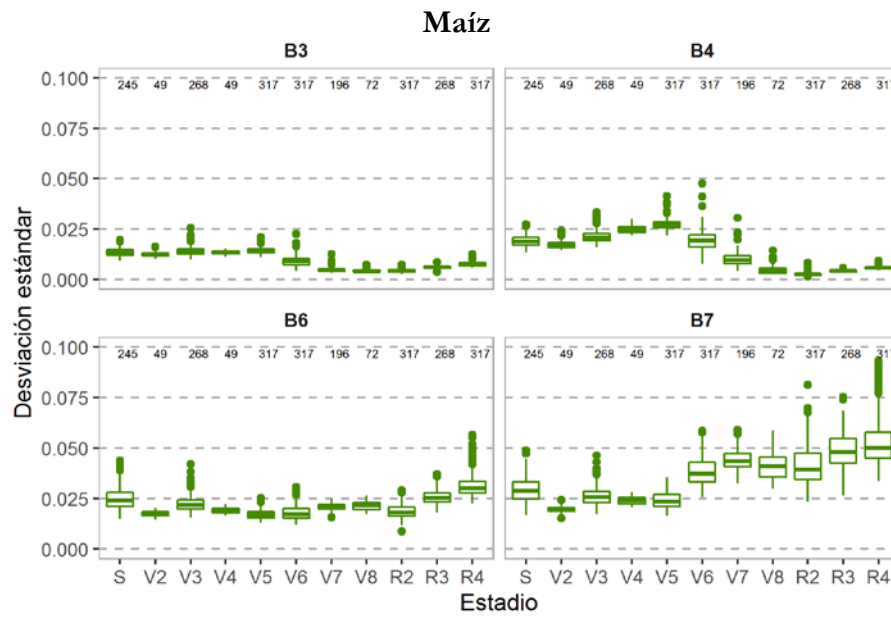


Figura III-33. Desviación estándar de los valores de reflectividad obtenidos por Sequoia en función de los píxeles Sentinel 2 en los diferentes estadios del cultivo de maíz. El valor anotado en la parte superior de los gráficos refiere al número de muestras.

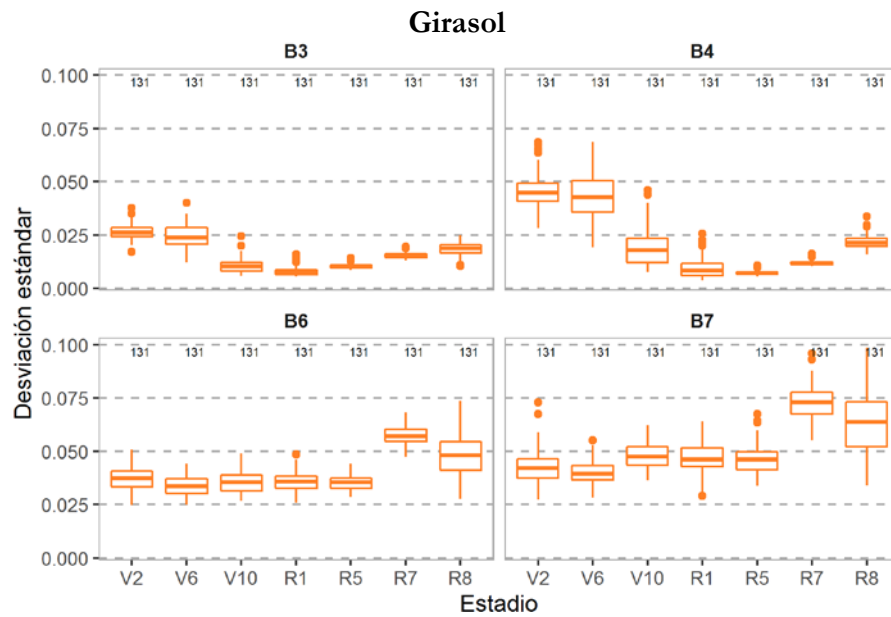


Figura III-34. Desviación estándar de los valores de reflectividad obtenidos por Sequoia en función de los píxeles Sentinel 2 en los diferentes estadios del cultivo de girasol. El valor anotado en la parte superior de los gráficos refiere al número de muestras.

En cuanto al análisis de la variabilidad de los IV (Figura III-35 a y b), en el caso del girasol la tendencia es similar en todos los IV a excepción de MSRre y CIre, donde las desviaciones son estables para todo en ciclo con un rango algo mayor para CIre.

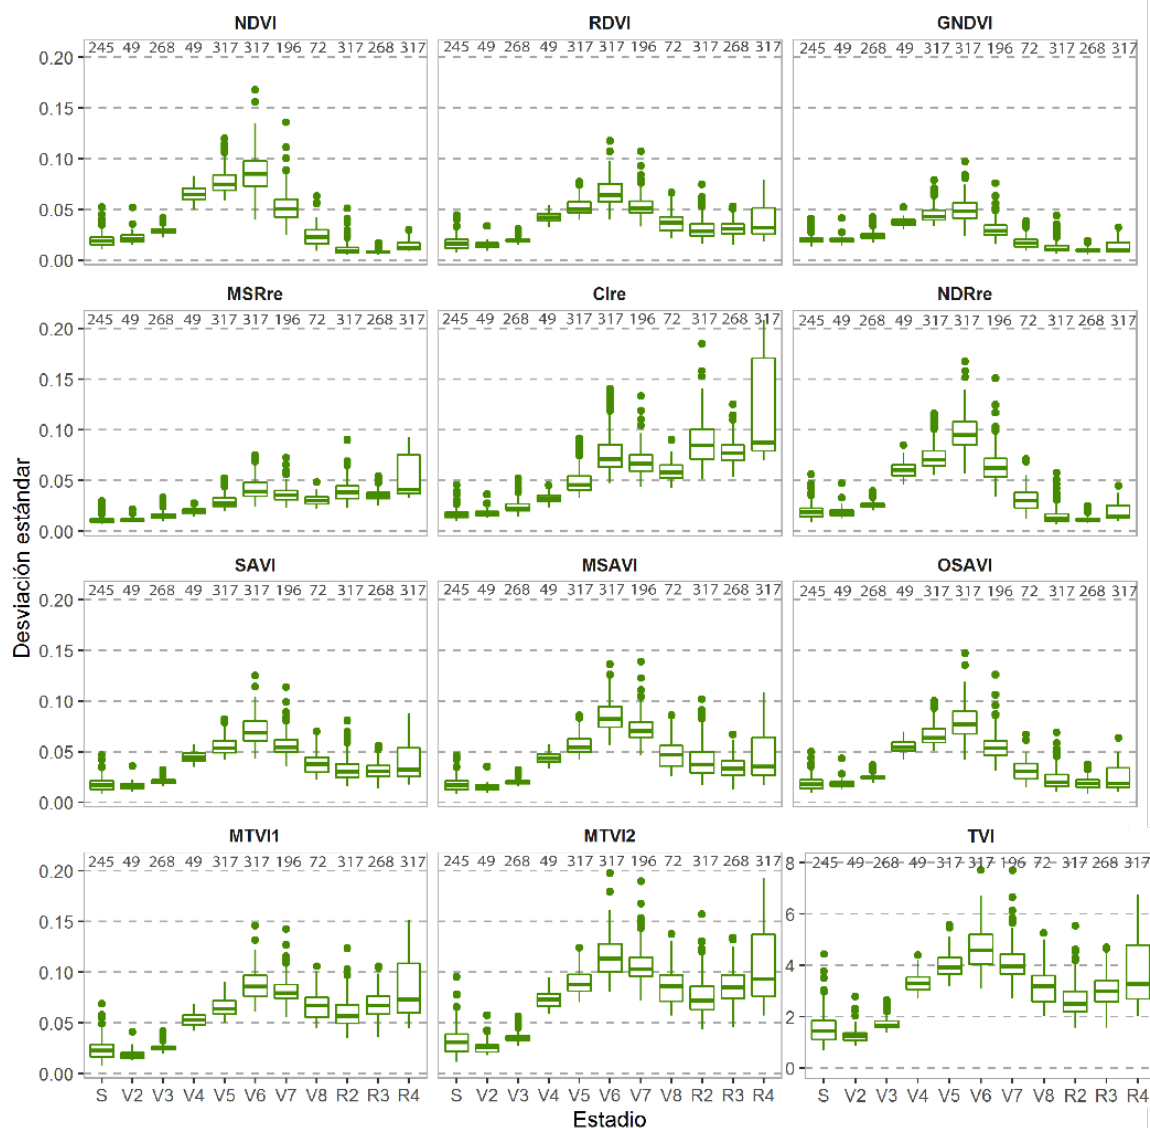


Figura III-35a. Desviación estándar de los IV obtenidos a partir de Sequoia en función del píxel Sentinel 2 en los diferentes estadios del cultivo para maíz. El valor anotado en la parte superior de los gráficos refiere al número de muestras.

En el resto de los IV la tendencia es de aumento de la desviación desde V2 hasta V6, para luego decrecer hasta la fase reproductiva y aumentar en R7 y R8. La respuesta espectral al comienzo del ciclo del cultivo se debe fundamentalmente al rastrojo de cebada. A medida que el cultivo comienza a crecer desde el estadio V2 se observan la superficie del suelo, el rastrojo de cebada, la aparición de malas hierbas, la cobertura del cultivo y sus sombras. Cuando el cultivo alcanza el estadio R5, la superficie registrada por el sensor corresponde fundamentalmente con el cultivo, ya que este alcanza una cobertura vegetal mayor del 90%. A partir de R6 las flores liguladas pierden turgencia y comienzan a marchitarse, dejando ver plantas con diferentes tonalidades entre amarillo-marrón y se comienza a ver de nuevo parte de suelo.

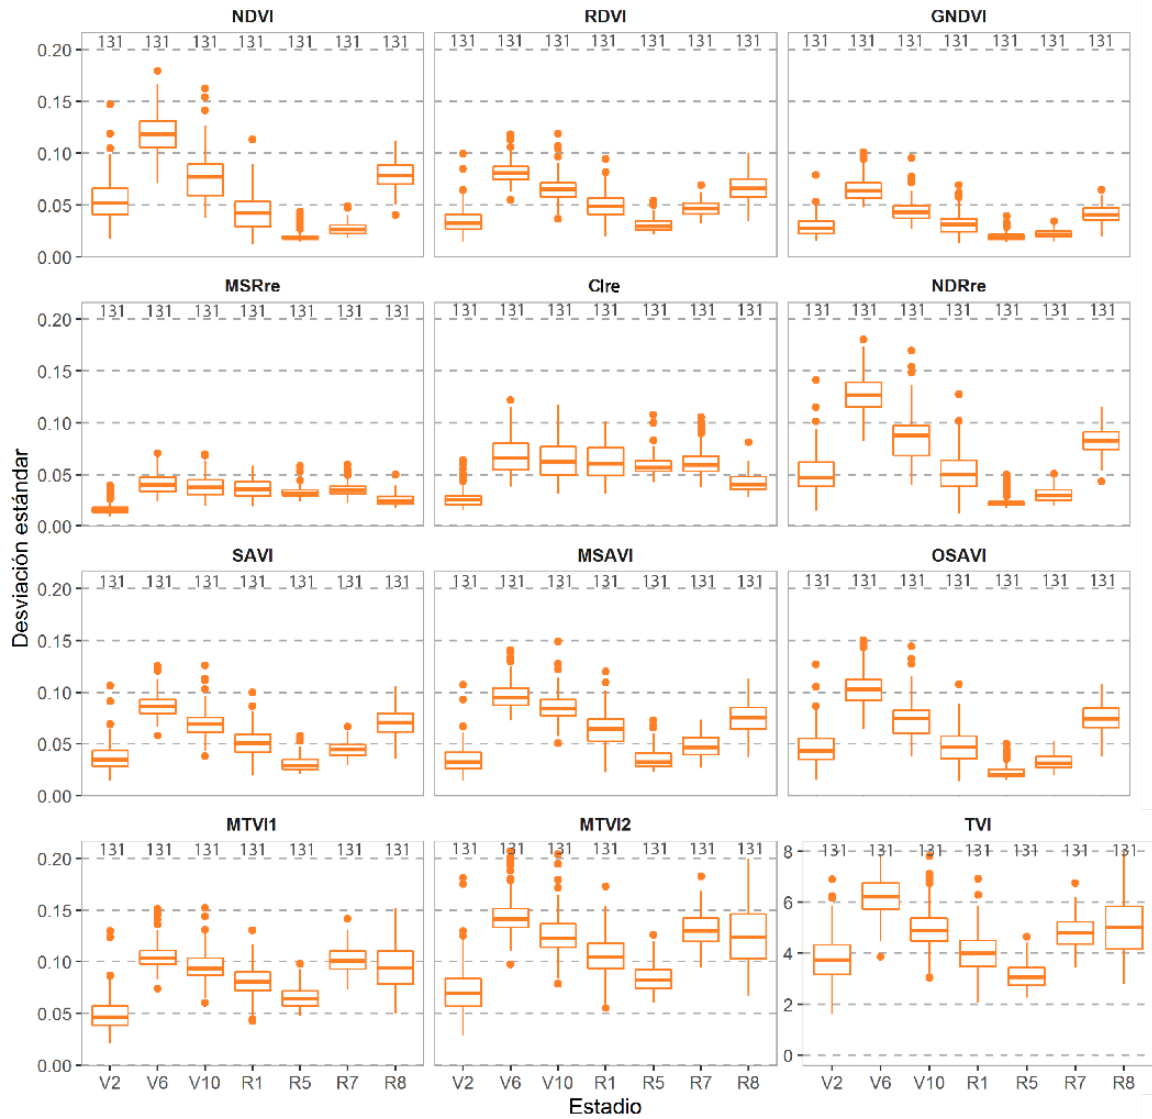


Figura III-36b. Desviación estándar de los IV obtenidos a partir de Sequoia en función del píxel Sentinel 2 en los diferentes estadios del cultivo para girasol. El valor anotado en la parte superior de los gráficos refiere al número de muestras.

En el maíz sucede lo mismo que en el girasol y los índices tienen una tendencia similar, a excepción de MSRre y CIre. La variabilidad en los primeros estadios (S, V2 y V3) es baja, aumenta en V4 hasta V6, donde se encuentra el máximo valor, y va descendiendo hasta R2-R3 y en R4 vuelve a aumentar. La variabilidad que se ha observado puede explicarse por los momentos fenológicos del cultivo. Como se observa en el apartado II.3 del Capítulo II, la variabilidad en la superficie de la parcela en los primeros estadios (S, V2 y V3) es baja y se registra principalmente la respuesta espectral del rastrojo de la cebada. A medida que avanza el ciclo, en los estadios V4, V5 y V6 aumenta la variabilidad debida a la cobertura parcial del cultivo (desde un 30% aproximadamente en V4 al 70% aproximadamente en V6). Esta cobertura parcial hace que las sombras que produce el cultivo también sean captadas por el sensor, así como la superficie de suelo y el rastrojo de cebada. A partir de V7 el tamaño y el porte del cultivo hacen que la cobertura del suelo sea mayor descendiendo la variabilidad en la superficie. En R4, una vez producida la maduración y llenado de grano y comienzo del

final de temporada, el tallo y las hojas inferiores comienzan a marchitarse, adquiriendo un color amarillento, aumentando de nuevo la desviación estándar y la variabilidad.

III.2.4.2 Comparación de Sentinel 2 y UAV

Como se puede apreciar en la Figura III-36, la relación lineal entre los sensores en las bandas del visible es alta para la B3 y muy alta en la B4. La pendiente en la B3 tiene valores más bajos de 1 y en cambio es cercana a 1 en la B4 (Tabla III-21). En estas bandas las diferencias entre las medidas de reflectividad de ambos sensores son mínimas, sobre todo en la B4. En la B3 son algo mayores, sobrestimando Sequoia la reflectividad hasta 0,12 y subestimándola a partir de este valor de reflectividad. En el caso de las bandas del borde del rojo y el infrarrojo cercano, la correlación es moderada y alta, respectivamente, y los coeficientes de determinación R^2 tienen valores 0,58 y 0,79. En estas bandas la intersección en el origen se aleja de 0 y las pendientes se alejan de 1. Todo ello indica que existen diferencias entre las medidas de reflectividad de ambos sensores, que parece que aumentan con la respuesta espectral, pasando de subestimar a sobreestimar a partir de una reflectividad de 0,2 en la B6, mientras en la B7 únicamente se sobreestima (Figura III-36). Los resultados, como cabía esperar, son similares a los del escenario 3.

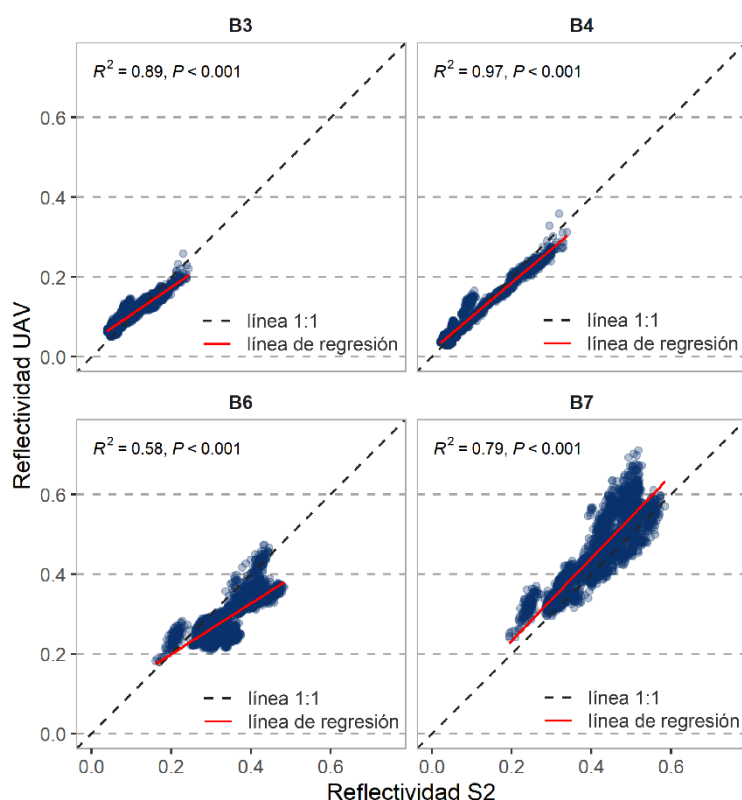


Figura III-37. Diagrama de dispersión de la reflectividad en cada banda espectral para todos los píxeles Sentinel de las parcelas entre medidas de MSI y UAV (n=3240).

Los valores de RMSEn (Tabla III-21) nos indican una buena exactitud del modelo, entre 9% y 11,4%.

Tabla III-21. Estadísticos obtenidos del modelo de regresión lineal para cada una de las bandas espectrales entre los sensores MSI y Sequoia para todos los píxeles Sentinel incluidos en las parcelas (n=3240).

Índice	Intersección	Pendiente	R ²	RMSEn (%)
B3	0,04	0,68	0,89***	11,0
B4	0,02	0,85	0,97***	11,4
B6	0,07	0,64	0,58***	9,0
B7	0,03	1,04	0,79***	10,5

*** indica un nivel de significación $p < 0,001$

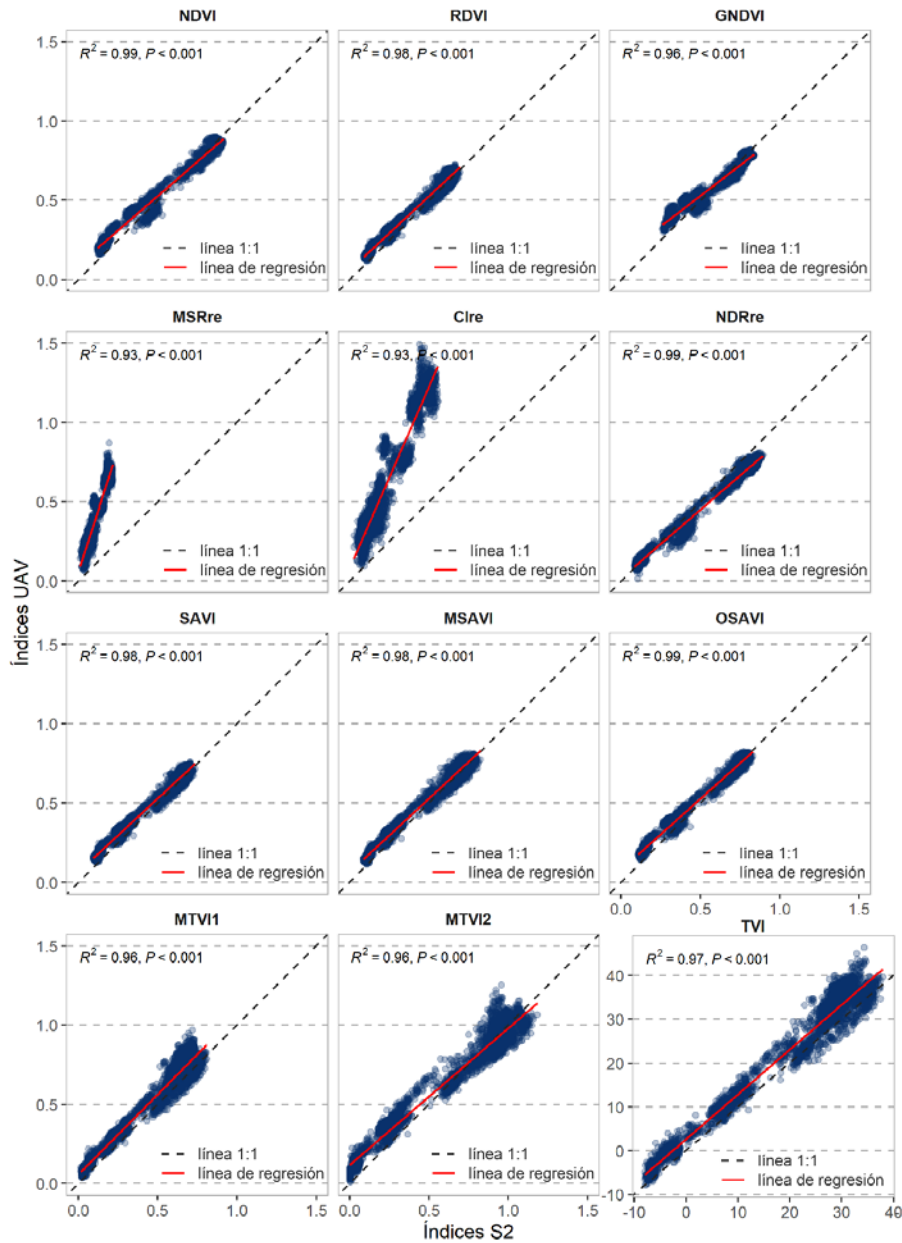


Figura III-38. Diagrama de dispersión de los IV para todos los píxeles Sentinel de las parcelas entre medidas de MSI y UAV (n=3240).

Para los IV, los resultados concuerdan con los obtenidos en el escenario 3 a excepción de MSRre y CIre, para el resto de IV la relación es casi perfecta con coeficientes de determinación R^2 superiores a 0,96. La intersección en origen es positiva y muy cercana a 0. Las pendientes tienen valores entre 0,77 y 1,02, siendo GNDVI el índice que tiene la pendiente más atenuada. En el caso de los índices MSRre y CIre la relación es algo menor, aunque sigue siendo muy alta (R^2 de 0,93). Las pendientes en ambos índices, de 1,95 y 2,29 respectivamente, evidencian la diferencia de los valores entre los sensores.

Se observa que el sensor Sequoia tiende a sobreestimar los índices NDVI y MTVI2 hasta valores próximos a 0,8 y 0,95 respectivamente y a partir de ahí se subestiman. En los índices RDVI, SAVI, MSAVI, OSAVI, MTVI 1 y TVI Sequoia sobrestima en los valores bajos del índice, pero, a medida que aumenta el valor, los datos se ajustan a la línea 1:1. En GNDVI el punto de cambio de sobreestimación a subestimación se ubica en los valores 0,6. En los índices MSRre, CIre y NDRre las diferencias aumentan a medida que lo hace el vigor vegetal, si bien en sentidos diferentes: en el MSRre y CIre tiende a sobreestimar y en el NDRre a subestimar, como ocurre en el escenario 3.

Los RMSEn de los índices basados en la diferencia normalizada son bajos, a éstos se les suman también NDRre y los índices ajustados a la línea de suelo, como se puede ver en la Tabla III-22. El RMSEn en los índices triangulares es algo más elevado que en los basados en la diferencia normalizada, con valores entre 8,06% y 14%. Por último, los RMSEn en los índices que utilizan la banda del rojo, excluyendo el NDRre, son los más elevados con valores de 27,6% y 41,1%.

Tabla III-22. Estadísticos obtenidos del modelo de regresión lineal para cada uno de los IV entre los sensores MSI de Sentinel 2 y Sequoia para todos los píxeles Sentinel incluidos en las parcelas (n=3240).

Índice	Intersección	Pendiente	R ²	RMSEn (%)
NDVI	0,09	0,87	0,99***	4,9
RDVI	0,06	0,93	0,98***	6,7
GNDVI	0,14	0,77	0,96***	4,7
MSRre	0,06	1,95	0,93***	27,6
CIre	0,08	2,29	0,93***	41,1
NDRre	0,02	0,86	0,99***	4,9
SAVI	0,06	0,93	0,98***	6,4
MSAVI	0,07	0,93	0,98***	7,1
OSAVI	0,08	0,90	0,99***	4,9
MTVI1	0,06	1,01	0,96***	12,4
MTVI2	0,10	0,88	0,97***	8,1
TVI	2,62	1,02	0,97***	14,0

*** indica un nivel de significación $p < 0,001$

En la Figura III-38, donde se representan los rn mediante gráficos de dispersión, se puede observar una diferenciación en función del cultivo y su ciclo. En el girasol, las bandas B3, B4 y B6 presentan rn superiores a los del maíz, al contrario en la banda B7. En cuanto al ciclo de cultivo, al inicio los rn se sitúan en torno al 0 o incluso por debajo, como en la B7; en cambio, a partir de los 1500 AGDD están siempre por encima de cero. En el maíz para las bandas B3 y B4 los rn se distribuyen de forma similar en todo el ciclo y muy cercanos a 0. En la B6 los valores son positivos en la primera parte del ciclo de cultivo y a partir de los 400 AGDD son negativos y más dispersos a medida que avanza el ciclo. En la B7 ocurre lo contrario, los valores de rn son negativos al inicio del ciclo y a media que avanza hay más dispersión y los valores son positivos. Las pruebas estadísticas confirman estas diferencias (Anexo 2), falta de normalidad en los rn de todas las bandas y, además, heterocedasticidad en las B6 y B7. Sin embargo, no se observa autocorrelación en los residuales.

En los IV también se observa esta diferenciación de los rn (Figura III-39). Hasta alrededor de los 400 a 500 AGDD los rn se distribuyen en torno a 0 y no hay diferencias notables por cultivo. Es a partir de ese periodo del ciclo cuando se observan las diferencias según el cultivo. Los rn del maíz se sitúan sistemáticamente por encima de los del girasol. Además, los del maíz presentan una tendencia ascendente a medida que avanza el ciclo, excepto en los IV en los que interviene la banda del borde del rojo, en los que los rn se mantienen estables y cercanos a la línea de 0. Los rn del girasol tienen una tendencia descendente a excepción de los índices triangulares basados en las bandas del verde, rojo e infrarrojo cercano. Para testar las diferencias que observamos en Figura III-39, como en los escenarios anteriores, se han aplicado las pruebas estadísticas que garantizan la validez del modelo y el resultado indica que no existe autocorrelación de los residuos; por contra, en gran parte de los IV existe heterocedasticidad. Los índices basados en la diferencia normalizada, SAVI, MSAVI y MTVI2 muestran falta de normalidad en los datos.

La distribución de los rn lleva a dividir los datos, por un lado, según el cultivo –girasol y maíz– y, por otro, según el ciclo de cultivo en primera etapa –hasta 400 AGDD–, segunda etapa –>400 AGDD– y, para este escenario 4, tercera etapa para el girasol –>1500 AGDD– que se corresponde con su fase de senescencia.

Los modelos de regresión lineal por cultivos aplicados a las bandas (Anexo 2) son similares al modelo general en las bandas B3 y B4. En la B6 la diferencia entre los datos de Sentinel 2 y Sequoia se acentúa mucho más en el maíz, con un R^2 muy bajo (0,04) y una pendiente muy alejada de 1 (0,15; Tabla III-23); en la B7 la reflectividad en maíz se sitúa por encima del modelo general y en girasol por debajo, dejando patente la diferencia entre ambos cultivos. Además, las pruebas estadísticas indican heterocedasticidad y falta de normalidad en las bandas B6 y B7 y falta de normalidad en la B4. Cuando se aplica el modelo lineal por etapas del cultivo los estadísticos tienen el mismo patrón que el modelo lineal general, aunque los coeficientes de determinación son ligeramente más bajos. La homocedasticidad se cumple en todas las bandas en las diferentes etapas, a excepción de la B7 en la E-2 y E-3. Con respecto a la normalidad, se cumple en todas las bandas de la E-3, en la E-1 en las bandas B3, B4 y B6, y en la E-2 únicamente se cumple en la B3. La independencia de los residuales se cumple en todas las situaciones.

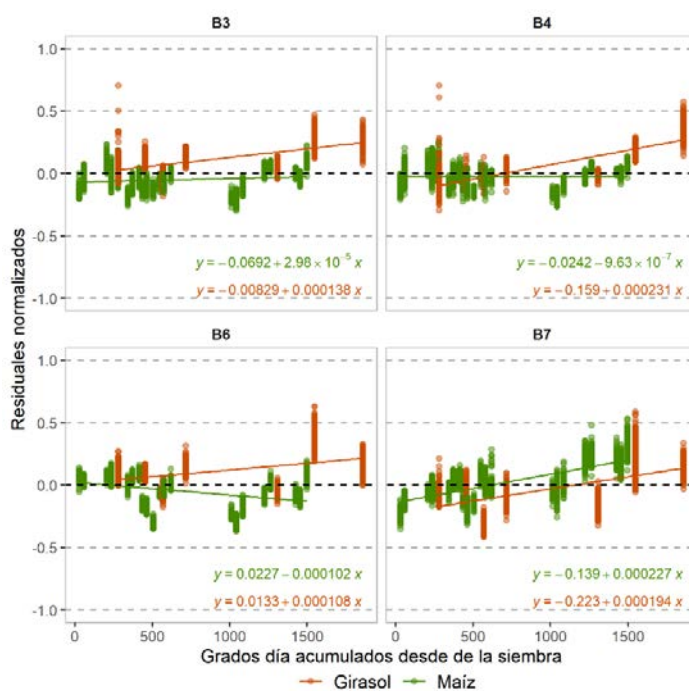


Figura III-39. Gráficos de dispersión de residuos estandarizados de las bandas obtenidos al aplicar el modelo de regresión lineal para los píxeles Sentinel de todas las parcelas en función de los AGDD.

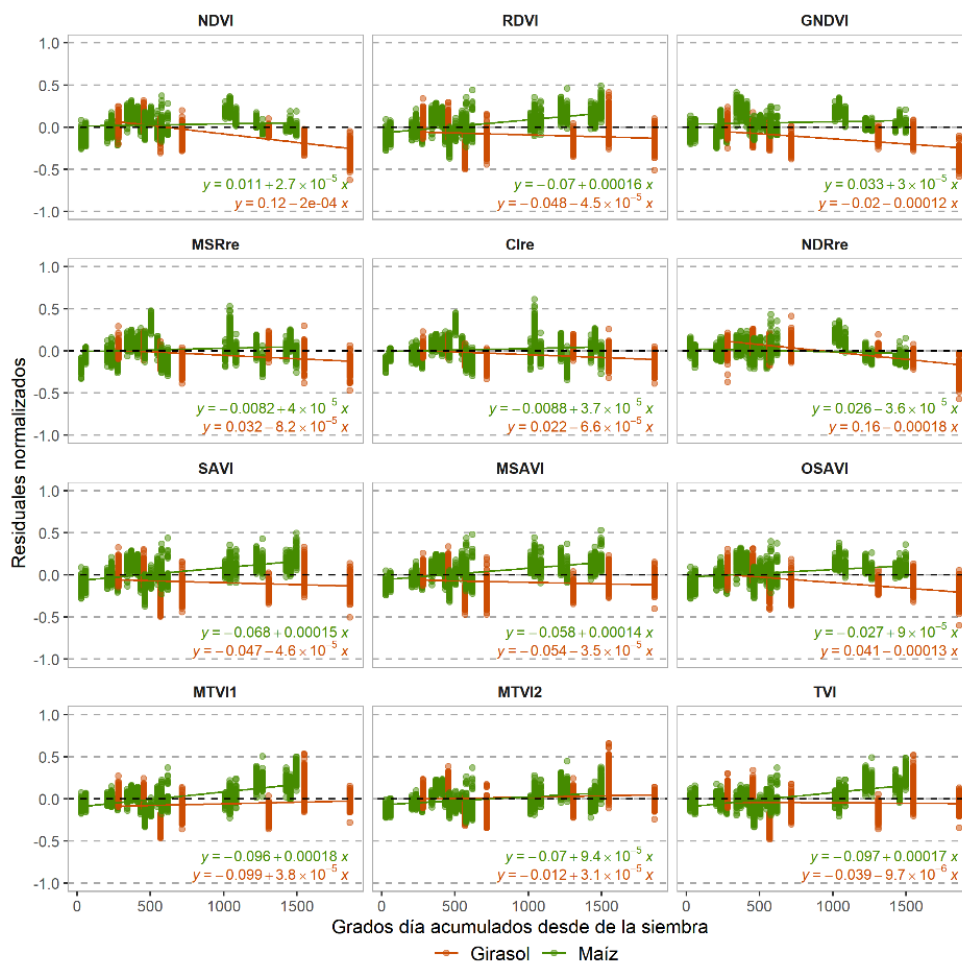


Figura III-40. Gráficos de dispersión de residuos estandarizados de los IV obtenidos al aplicar el modelo de regresión lineal para los píxeles Sentinel de todas las parcelas en función de los AGDD.

Los modelos de regresión lineal por cultivos aplicados a los IV muestran diferencias notables en el girasol en los índices MSRre y CIre (Tabla III-23), con R^2 de 0,52 y 0,51 respectivamente; la pendiente en el maíz alcanza un valor de 3,1 evidenciado la ausencia de relación entre los sensores (Anexo 2). En los modelos de regresión lineal por etapas de cultivo aplicados a los IV se constatan diferencias entre etapas (Tabla III-23), aunque los R^2 siguen siendo altos en todos los casos, con valores superiores a 0,95, a excepción de los índices MSRre y CIre en la primera y en la segunda etapa, llegando a un mínimo de 0,08 en la primera (Anexo 2).

Las pruebas de K-S y B-P y D-W y los resultados indicaron que en la mayoría de los IV por cultivo existe heterocedasticidad; además en el maíz hay falta de normalidad en los índices NDVI, GNDVI, CIre, NDRre, TVI, MTVI1 y MTVI2. En cambio, los resultados de las pruebas por etapas de cultivo indican que en la E-1 en todos los IV existe homocedasticidad y normalidad de los r_n , a excepción de los índices MSRre y CIre; en la E-2 existe falta de homocedasticidad en los índices GNDVI, TVI, MTVI1 y MTVI2 y falta de normalidad en la mayor parte de ellos; por último, en la E-3 existe heterocedasticidad en los índices NDRre, TVI, MTVI1 y MTVI2 y todos los IV tienen normalidad en los residuos. La independencia de los residuales se cumple en todos los IV en cada cultivo y en cada etapa del cultivo.

Tabla III-23. Estadísticos de intersección (I) y pendiente (P) del modelo de regresión lineal por cultivo y etapas de cultivo para cada banda e IV entre los sensores MSI y Sequoia para todos los píxeles Sentinel incluidos en las parcelas.


Banda/ índice	Modelo lineal según cultivo					
	Maíz		Girasol		Diferencias	
	I	P	I	P	I	P
B3	0,034	0,680	0,056	0,620	-0,022	0,060
B4	0,012	0,860	0,028	0,800	-0,016	0,060
B6	0,220	0,150	0,130	0,550	0,090	-0,400
B7	0,042	1,200	0,110	0,820	-0,068	0,380
NDVI	0,095	0,880	0,094	0,840	0,001	0,040
RDVI	0,056	0,960	0,074	0,870	-0,018	0,090
GNDVI	0,150	0,770	0,130	0,740	0,020	0,030
MSRre	0,064	3,100	0,110	1,900	-0,046	1,200
CIre	0,120	2,100	0,170	1,400	-0,050	0,700
NDRre	0,022	0,860	0,001	0,890	0,021	-0,030
SAVI	0,060	0,960	0,080	0,860	-0,020	0,100
MSAVI	0,059	0,960	0,085	0,850	-0,026	0,110
OSAVI	0,077	0,910	0,088	0,850	-0,011	0,060
TVI	2,300	1,100	3,600	0,940	-1,300	0,160
MTVI1	0,047	1,100	0,085	0,910	-0,038	0,190
MTVI2	0,110	0,850	0,140	0,810	-0,030	0,040

Banda/ índice	Modelo lineal según cultivo											
	E-1		E-2		E-3		Diferencias					
	I	P	I	P	I	P	E-1/E-2		E-2/E-3		E-1/E-3	
	I	P	I	P	I	P	I	P	I	P	I	P
B3	0,012	0,830	0,021	0,840	0,014	1,200	-0,009	-0,010	0,007	-0,360	-0,002	-0,370
B4	0,021	0,830	0,011	0,860	0,001	1,400	0,010	-0,030	0,010	-0,540	0,020	-0,570
B6	0,056	0,730	0,010	0,770	0,061	0,690	0,046	-0,040	-0,051	0,080	-0,005	0,040
B7	0,068	0,870	0,072	0,880	0,110	0,950	-0,004	-0,010	-0,038	-0,070	-0,042	-0,080
NDVI	0,043	1,100	0,140	0,820	0,068	1,000	-0,097	0,280	0,072	-0,180	-0,025	0,100
RDVI	0,023	1,200	0,081	0,870	0,004	1,100	-0,058	0,330	0,077	-0,230	0,019	0,100
GNDVI	0,014	1,200	0,110	0,820	0,046	1,000	-0,096	0,380	0,064	-0,180	-0,032	0,200
MSRre	0,100	1,800	0,076	3,000	0,015	3,400	0,024	-1,200	0,061	-0,400	0,085	-1,600
CIre	0,150	1,400	0,160	1,900	0,040	2,400	-0,010	-0,500	0,120	-0,500	0,110	-1,000
NDRre	0,004	0,980	0,027	0,870	-0,099	0,990	-0,023	0,110	0,126	-0,120	0,103	-0,010
SAVI	0,025	1,200	0,087	0,870	0,014	1,000	-0,062	0,330	0,073	-0,130	0,011	0,200
MSAVI	0,017	1,300	0,093	0,870	0,035	0,990	-0,076	0,430	0,058	-0,120	-0,018	0,310
OSAVI	0,034	1,200	0,110	0,850	-0,018	1,000	-0,076	0,350	0,128	-0,150	0,052	0,200
TVI	2,700	1,100	3,900	0,930	1,800	1,100	-1,200	0,170	2,100	-0,170	0,900	0,000
MTVI1	0,044	1,200	0,082	0,920	0,053	1,100	-0,038	0,280	0,029	-0,180	-0,009	0,100
MTVI2	0,075	1,300	0,200	0,720	0,070	0,960	-0,125	0,580	0,130	-0,240	0,005	0,340

En sombreado rosa se identifican las mayores diferencias entre modelos. (Etapa primera E-1, Etapa segunda E-2, Etapa tercera E-3).

El test de Wilcoxon indica que existen diferencias estadísticamente significativas entre los datos de MSI de Sentinel 2 y Sequoia para todas las bandas y todos los IV. Sin embargo, si observamos los diagramas de cajas, estas diferencias en las bandas del visible no parece que existan, así como tampoco en la mayor parte de los IV. Por lo que estos resultados, que son estadísticamente significativos de forma sistemática, parece que están vinculados al tamaño de la muestra, que en este caso es de 3240 observaciones.

Los resultados de la prueba d de Cohen (Figura III-40) revelan un efecto pequeño en las bandas del visible (B3 y B4), no existiendo diferencias entre los sensores. Sin embargo, en la banda del borde del rojo (B6) el efecto es grande; es decir, hay diferencias holgadas, siendo mayores los valores de MSI respecto a los de Sequoia. En la banda del infrarrojo cercano (B7) el efecto es moderado; aunque también existen diferencias entre sensores, no son tan elevadas como en la banda B6. En la mayor parte de los IV el efecto es pequeño, no observándose diferencias entre sensores, a excepción de los índices MSRre y CIre, donde el efecto es grande, de modo que sí existen diferencias entre los datos de MSI y Sequoia.






Figura III-41. Diagrama de caja y prueba d de Cohen de los valores de reflectividad en cada banda espectral y valores de los IV para ambos sensores, MSI de Sentinel 2 y Sequoia (n=3240).

III.3 Discusión

Para monitorear y detectar las variaciones en las superficies agrícolas con sensores o combinación de sensores es importante y se requiere la consistencia de los datos. Sentinel 2, satélite de observación de la Tierra (EO) de última generación de la Agencia Espacial Europea (ESA), ofrece resoluciones espectrales, espaciales y temporales apropiadas para hacer el seguimiento de los cultivos agrícolas. Pero, en ocasiones, según el momento del ciclo del cultivo o cuando se necesita mayor resolución espacial, su precisión resulta insuficiente; por ello, el uso de UAV constituye una oportunidad adecuada. Así, la combinación de datos de imágenes Sentinel 2 con datos adquiridos desde UAV se convierte en una buena opción para resolver estos problemas.

En este Capítulo de la tesis doctoral se han comparado los datos registrados por MSI de Sentinel 2 y Sequoia a bordo de UAV con medidas de espectro-radiómetro en campo para los cultivos de maíz y girasol. Los resultados muestran que, en general, hay buena relación entre sensores, pero las condiciones que deben darse para garantizar la validez del modelo de regresión lineal entre estos sensores no siempre ocurren. Se van a discutir los resultados del modelo, aunque no cumplan las condiciones para garantizar su validez, porque, como indica Ebdon (1982), la regresión sigue conservando su valor como descriptor de la relación existente entre dichas variables y en este Capítulo se busca analizar la relación que existe entre sensores y la consistencia de los datos que ofrecen. Además, se valoran también los resultados con pruebas no paramétricas que no exigen una distribución normal y son relativamente insensible a la falta de homogeneidad de la varianza de la muestra. Todas las consideraciones que se presentan deberán tenerse en cuenta cuando se utilicen series temporales de datos de reflectividad o IV para distintas aplicaciones.

Los resultados de la comparativa entre ASD y Sentinel 2 muestran que la relación entre ambos sensores es muy alta. Los modelos de regresión lineal que relacionan ASD con Sentinel son muy similares y muestran buena concordancia entre ambos sensores tanto para las bandas como para los IV (Tabla III-12 y Tabla III-13). Hay que resaltar que para la segunda banda del borde del rojo (B6) y las dos bandas del infrarrojo cercano (B7 y B8A) la concordancia es algo menor. Es probable que esto se relacione con la existencia de franjas de absorción por el vapor de agua en este rango espectral (Chuvienco, 2010), que pueden estar afectando de modo diferente a los registros satelitales y a los proximales por el menor espesor atmosférico involucrado en la observación con UAV.

En estudios anteriores, Voulo *et al.* (2016) también localizan las mayores diferencias entre espectro-radiómetro y datos de Sentinel 2 en la banda del infrarrojo cercano. Sola *et al.* (2018) comparan diferentes métodos de calibración radiométrica para datos de Sentinel 2 con espectro-radiometría de campo; en la comparación sobre vegetación (matorrales y pastos) encuentran también diferencias más acusadas en las regiones del borde del rojo e infrarrojo cercano, aunque para todas las bandas hay una ligera sobreestimación de Sentinel 2. Cuando se comparan datos procedentes de Sentinel 2 con otros satélites, como por ejemplo Landsat 7 y 8 (Chastain *et al.*, 2019; Zhang *et al.*, 2018) o WorldView-3 (Pancorbo *et al.*, 2021), también se producen diferencias entre bandas, siendo igualmente la región del infrarrojo cercano la que ofrece mayores diferencias. Los IV generalmente tienen mayor concordancia que las bandas. Diferentes estudios que se centran en la comparación de NDVI entre sensores (Lange *et al.*, 2017; Zhang *et al.*, 2018), obtienen al igual que en esta tesis doctoral, muy buena concordancia entre ellos. En este Capítulo, además de la buena concordancia con el NDVI, se muestra la también buena observada para el resto de IV estudiados.

Las diferencias que se dan entre estos dos sensores se hacen más patentes a medida que el cultivo va creciendo, como ilustran las Figuras III-33 a III-35, debido a una cobertura más heterogénea durante la etapa de desarrollo. La menor resolución espacial del registro con satélite frente al espectro-radiómetro supone una mayor repercusión de esta heterogeneidad en la reflectividad que proporciona. Las pequeñas diferencias que se observan corresponden con las etapas de V6 a V10 en girasol y de V4 a V6 en maíz, etapas en las que ambos cultivos se están desarrollando y los sensores captan la mayor variabilidad de los elementos presentes: el propio cultivo, la proyección de sus sombras, la rugosidad del terreno o presencia de malas hierbas. A pesar de las ligeras diferencias mostradas, la relación de ASD y Sentinel 2 es muy alta y esto se constata con el test de Wilcoxon, cuyos resultados muestran que no hay diferencias estadísticamente significativas entre los datos de ASD y Sentinel 2 para las bandas y los IV.

Los modelos de regresión lineal según el cultivo presentan valores similares a los del modelo lineal general y siguen sin cumplir las condiciones de validez del modelo. Los modelos según la etapa del ciclo del cultivo cumplen las condiciones de validez para la segunda etapa y para las bandas en la etapa primera, pero no para los IV. Finalmente, se aplicó el modelo considerando los datos de la primera etapa del cultivo y su manejo en la siembra y entonces sí se cumplieron las condiciones de validez exigidas. Así pues, cuando se apliquen series temporales de reflectividad de IV de Sentinel 2 se deberá tener en cuenta el manejo en la siembra de la parcela, según esté sembrada de una forma u otra, y la etapa del ciclo del cultivo, ya que el comportamiento es diferente según la fase del ciclo. Se deberán generar modelos lineales independientes si se quieren hacer inferencias a partir de los modelos de regresión.

Por otra parte, en cuanto a la comparación de ASD con Sequoia (UAV), los resultados indican que, generalmente, la relación de sensores es muy alta, tanto para las bandas como para los IV (Tabla III-15 y Tabla III-16). En la B6 el sensor Sequoia subestima sistemáticamente los datos, mientras que para la B7 la relación es buena, aunque no tanto

como para las bandas de visible. No obstante, aunque el ajuste en la B7 es bueno, tanto pendiente como intersección se alejan de la situación ideal; además, la significación derivada del test de Wilcoxon indica que en estas bandas (B6 y B7) existen diferencias estadísticamente significativas entre los sensores. Las diferencias se pueden relacionar con un rango espectral estrecho –sobre todo en la B6– y la consiguiente sensibilidad a los cambios de la vegetación. Además, las medidas se han tomado sobre cultivos en continuo cambio y también hay que añadir el registro de las sombras y la rugosidad del terreno, que es diferente para un sensor a bordo de UAV que para el registro a pie de campo. Los resultados obtenidos en esta tesis doctoral son similares a otros estudios previos que también utilizan Sequoia, como Fawcett et al. (2020), que observan buena consistencia de las bandas del visible. En cambio, en la B6 de Sequoia se subestiman sistemáticamente los datos, observándose las mayores diferencias entre sensores. En la B7 la relación entre sensores es buena pero no tanto como en el visible. Los resultados obtenidos también concuerdan con los presentados por Stow et al. (2019), que evidencian que las bandas del visible principalmente la banda del rojo, son más precisas que las bandas del infrarrojo cercano y del borde del rojo, siendo esta última en la que obtienen menor precisión. Estudios que no utilizan el sensor Sequoia, como el de Padró et al. (2018), que se valen de la cámara multispectral MicaSense RedEdge, señalan que la reflectividad de las bandas del visible se ajusta mejor a la reflectividad adquirida con espectroradiómetro que la banda del infrarrojo próximo. Cao et al. (2019), que realizaron su estudio con el sensor MultiSpec 4C en laboratorio, reduciendo así la incertidumbre en las medidas, concluyen en sus resultados que las bandas del visible arrojan mayor acuerdo con los datos de espectroradiometría, mientras que el ajuste es peor para las bandas del borde del rojo y del infrarrojo cercano, tal y como ocurre en las comparativas realizadas en este Capítulo de la tesis doctoral.

Por todo lo expuesto, las diferencias observadas, además de estar relacionadas con las condiciones inherentes a la toma de datos en campo, pueden estar motivadas también por la incertidumbre de la función de la respuesta espectral (SFR) y el remuestreo espectral del sensor Sequoia. Tal y como explican Fawcett et al. (2020), la SFR aproximada del sensor Sequoia para la banda del borde del rojo, derivado de la información del fabricante sobre la transmisión del filtro y la SFR, puede ser insuficiente. Las diferencias detectadas entre Sequoia y ASD son destacables respecto a las que se suele dar en las calibraciones de sensores, sobre todo en la región del borde del rojo, por lo que el sensor Sequoia tiene margen de mejora en el ajuste de esta banda.

Otra excepción se da en la comparativa de los índices MSR_{re} y CI_{re}, ya que los resultados muestran una pendiente y una intersección alejadas de la situación ideal. Fawcett et al. (2020) también evalúan el índice CI_{re} y los resultados son muy parecidos a los de este Capítulo. El RMSE_n en estos IV es elevado (Tabla III-16) y el resultado de la significación del test de Wilcoxon (Figura III-27) muestra que existen diferencias significativas entre sensores. Los valores en el sensor Sequoia sobreestiman muy por encima los obtenidos con ASD. Revill et al. (2020) atribuyen estas diferencias de valores del CI_{re} entre sensores a la heterogeneidad de la superficie de medida y al momento fenológico del cultivo. Pero el hecho de que en la comparativa del escenario 1 no existan estas diferencias induce a pensar que se

deba a la falta de precisión y consistencia de las bandas que se utilizan para formar estos IV. Por el contrario, la consistencia es muy alta para el resto de los IV que combinan una de estas bandas (B6 y B7) con otras del visible. Así, la introducción de una banda del visible para formar un IV ofrece buen nivel de consistencia, aunque se utilice una banda menos precisa, como puede ser la B6 o la B7.

En el escenario 2 al aplicar el modelo de regresión lineal según el cultivo el resultado fue similar al del escenario 1. Por lo que se realizó otra fragmentación de datos, según la etapa del ciclo del cultivo, y en este caso las condiciones de validez del modelo se cumplen para ambas etapas con alguna excepción. En el TVI, MTVI y MTVI2 sigue extendiendo heterocedasticidad en la etapa segunda y falta de normalidad en el MTVI 1 en la etapa primera. Además, sigue habiendo autocorrelación de los residuos en la primera etapa en la B6 y en los índices MSRre y CIre, y en la segunda etapa en estos mismos IV. Por lo que, cuando se apliquen series temporales con datos de Sequoia, se deberá tener en cuenta la etapa del ciclo del cultivo; además, se deberán utilizar con cautela las bandas B6 y B7 y los índices MSRre, CIre, TVI, MTVI y MTVI2).

Los resultados para los escenarios 3 y 4 son similares a los del escenario 2, tanto para la comparativa que se hizo con los datos de un único píxel Sentinel 2 como para la comparativa que se hizo para todos los datos píxeles de Sentinel 2 incluidos en las parcelas de estudio. Al igual que para los anteriores escenarios, los resultados muestran generalmente buen ajuste y consistencia de datos en todas las bandas e IV, aunque con las mismas excepciones que en el escenario 2, en la banda B6 y los IV MSRre y CIre. La diferencia con el escenario 2 se da en la B7, que en el escenario 3 al aplicar la prueba de Wilcoxon muestra que no existen diferencias significativas entre sensores. También en el escenario 4, el efecto del tamaño que describe la *d* de Cohen entre sensores es moderado, a diferencia del escenario 2 donde sí existían diferencias estadísticamente significativas entre los sensores. Los resultados del escenario 3 y 4 son similares a los de Fawcett et al. (2020) en la comparación que realizan entre el sensor Sequoia y el sensor aeroportado HyPlant dual-channel module, donde las bandas del visible (B3 y B4) muestran coeficientes de determinación muy altos a diferencia de la B6 que muestra un coeficiente de determinación medio y la B7 alto. Padró et al. (2018) comparan datos del sensor MicaSense RedEdge obtenidos con UAV frente a datos de Sentinel 2 y los resultados siguen el mismo patrón que los de este Capítulo, con errores cuadráticos medios bajos en las bandas del visible y superiores en la banda del IC. En cambio, Lu et al. (2020) analizan las diferencias entre los sensores Sequoia y DJI Phantom 4 y la consistencia de los valores espectrales entre los dos sensores es muy alta en todas las bandas, incluso en las del borde del rojo e infrarrojo cercano, aunque es en esta última donde peores resultados obtienen; en cuanto a los IV, como en nuestro estudio, la relación encontrada por estos autores es también muy alta, con coeficientes de determinación mayores de 0,95.

Los resultados con menor concordancia entre sensores en los escenarios 3 y 4 muestran lo discutido en el escenario 2. La SFR de Sequoia difiere de la SFR de MSI de Sentinel 2 (apartado 4.1.2), fundamentalmente en las regiones del borde del rojo y del infrarrojo cercano, siendo peor la relación en estas bandas. En la actualidad ya existen sensores como MAIA que tienen bandas equivalentes a Sentinel 2. Como indican Revill et al. (2019), la

utilización de este sensor reducirá los efectos derivados del distinto rango espectral de cada banda en aplicaciones que combinan ambos sensores.

Las condiciones de validez del modelo lineal general en el escenario 3 se cumplen prácticamente en todos los casos, mientras que en el escenario 4 y los modelos para cada cultivo se cumplen únicamente para la banda B3 y los índices RDVI, SAVI y MSAVI. En cambio, si los modelos se hacen para las tres etapas de cultivo establecidas, se cumplen las condiciones en el modelo de la primera etapa en todas las bandas e IV, a excepción de MSRre y CIre; el modelo de la etapa segunda solo en la B3 y en los índices MSRre y CIre; por último, en la tercera etapa se cumplen las condiciones en todos los casos a excepción de B7 e IV SAVI, TVI, MTVI y MTVI2.

Como se ha podido observar en algún caso, aun generando los modelos para cada cultivo o etapa se siguen sin cumplir las condiciones que garantizan su validez, por ello se podría considerar utilizar transformaciones de las variables o modelar la heterogeneidad encontrada con modelos generalizados mixtos, incluyendo factores fijos y aleatorios. Como explican García-Mozo et al. (2015), el modelo lineal mixto es la técnica más adecuada para estudiar fenómenos que presentan interacciones tanto fijas como aleatorias.

La consistencia de los datos MSI de Sentinel 2 y Sequoia es grande a tenor de los resultados obtenidos, a excepción de para las bandas B6 y B7 y los índices MSRre y CIre para Sequoia. Por tanto, las series temporales de estos dos sensores pueden utilizarse con garantías para la identificación del inicio de la etapa de desarrollo con las excepciones señaladas.

Es destacable la fuerte relación que existe tanto para las bandas del visible como para los IV de MSI de Sentinel 2 y Sequoia, lo que denota el potencial para integrar estos datos de Sequoia en una serie temporal con datos de Sentinel 2, tanto para adaptarlos como alternativa de trabajo para obtener mayores resoluciones espaciales, como para integrar mediciones adicionales en determinadas fases del ciclo en el monitoreo de los cultivos.

Los resultados obtenidos revelan que los índices NDVI, NDRre y OSAVI son los que mejor consistencia tienen entre MSI y Sequoia, aspecto a tener en cuenta cuando se vaya a trabajar con series temporales que combinen datos de estos dos sensores. Además, los modelos lineales en la primera etapa del ciclo de maíz y del girasol indican que se cumplen las condiciones que garantizan el modelo de regresión lineal entre ambos sensores y, por lo tanto, puede utilizarse una combinación de datos de ambos sensores para el propósito de esta tesis doctoral, la detección del inicio de la etapa de desarrollo de estos cultivos.

IV. Determinación temprana del IED de maíz y girasol de segunda cosecha con series temporales de imágenes de Sentinel 2 y UAV

En este Capítulo se aborda el objetivo 2 de la tesis, determinar de forma temprana el inicio de la etapa de desarrollo de los cultivos de regadío a partir de series temporales de imágenes multiespectrales para segundas cosechas de maíz y girasol

Para muchos de los modelos de crecimiento de cultivos o modelos de determinación de sus necesidades hídricas es preciso conocer el momento de inicio del crecimiento (Bandaru et al., 2020), que suele considerarse o bien la fecha de siembra o la de emergencia del cultivo. Esta fecha no siempre se tiene, optando por determinarla a partir del momento del inicio de la etapa de desarrollo del cultivo (Liu et al., 2018). Además, el hacerlo de forma temprana resulta de utilidad para las labores de control asociadas a la PAC, como indicador de que la parcela está cultivada, ya que es necesario disponer de esta información lo antes posible para evitar retrasos en las inspecciones de las declaraciones.

Las fechas de siembra dependen de las condiciones del campo y de las prácticas de los agricultores; a veces, si se produce una fase prolongada de sequía o una fase de periodos más húmedos, los agricultores pueden variar el momento de la siembra, llegando incluso a cambiar de cultivo o dejar la parcela sin cultivar. Por lo tanto, el inicio de la etapa de desarrollo (IED) de los cultivos, termino adoptado por la FAO 56 (Allen et al., 2006) que comienza cuando el cultivo cubre aproximadamente un 10% del suelo, está determinado tanto por factores ambientales como por las operaciones de manejo de cada agricultor.

La teledetección satelital proporciona observaciones frecuentes de las propiedades de la superficie terrestre que pueden caracterizar la fenología de los cultivos, generalmente esta caracterización se estima a partir de series temporales. Aunque actualmente existen satélites como Sentinel 2, con alta resolución temporal y resolución espacial adecuada, que pueden ofrecer esta información, la frecuente cobertura de nubes en algunos momentos del ciclo del cultivo sigue siendo el principal inconveniente para tener datos con la frecuencia necesaria. Para evitar estas situaciones y completar la serie de datos se pueden incluir imágenes adquiridas con UAV. En el Capítulo III se ha constatado que la combinación de IV derivados de MSI de Sentinel 2 y de Sequoia (UAV) presenta buen nivel de consistencia, por lo que la combinación de los datos MSI de Sentinel 2 y Sequoia en series temporales puede ser una buena opción para determinar de forma más ajustada la fecha de IED.

Para abordar el objetivo II se va a desarrollar y validar una metodología para detección temprana de IED utilizando la serie temporal de Sentinel 2, analizando la falta de datos (cubrimiento por nubes) en la determinación de IED y las aportaciones en la determinación de IED cuando se incorporan datos Sequoia a la serie temporal Sentinel 2. La metodología de detección de IED se basará en una técnica de detección de punto de cambio elegida tras

seleccionar y comparar varias de estas técnicas. Además, se comparará la metodología desarrollada con la clásica, basada en el ajuste logístico de los datos y el cálculo del punto de máxima curvatura.

IV.1 Material y métodos

Para este estudio se utilizaron las parcelas de la Zona Regable de La Violada (ZRV, Huesca) A, C, D, E, F y G cultivadas en 2018 y D', H, I, J y K en 2019 que se describen en el Apartado II.4 del Capítulo II. Corresponden a parcelas con maíz y girasol de segunda cosecha sembradas sin laboreo, es decir, mediante siembra directa después de cosechar la cebada. La siembra se realizó normalmente a finales de junio, produciéndose la emergencia del cultivo, como promedio, aproximadamente dos semanas después de la siembra.

El flujo de trabajo seguido para el desarrollo de este capítulo de la tesis consta de tres fases (Figura IV 4): 1) obtención del día juliano con el 10% de FCV de las parcelas mediante fotografías RGB cenitales; 2) determinación del IED en las series de IV por medio de las técnicas de detección de punto de cambio y el método estándar de ajuste logístico y punto de máxima curvatura; 3) incorporación de imágenes obtenidas por medio de UAV en la serie temporal de datos y su efecto en la determinación de IED.

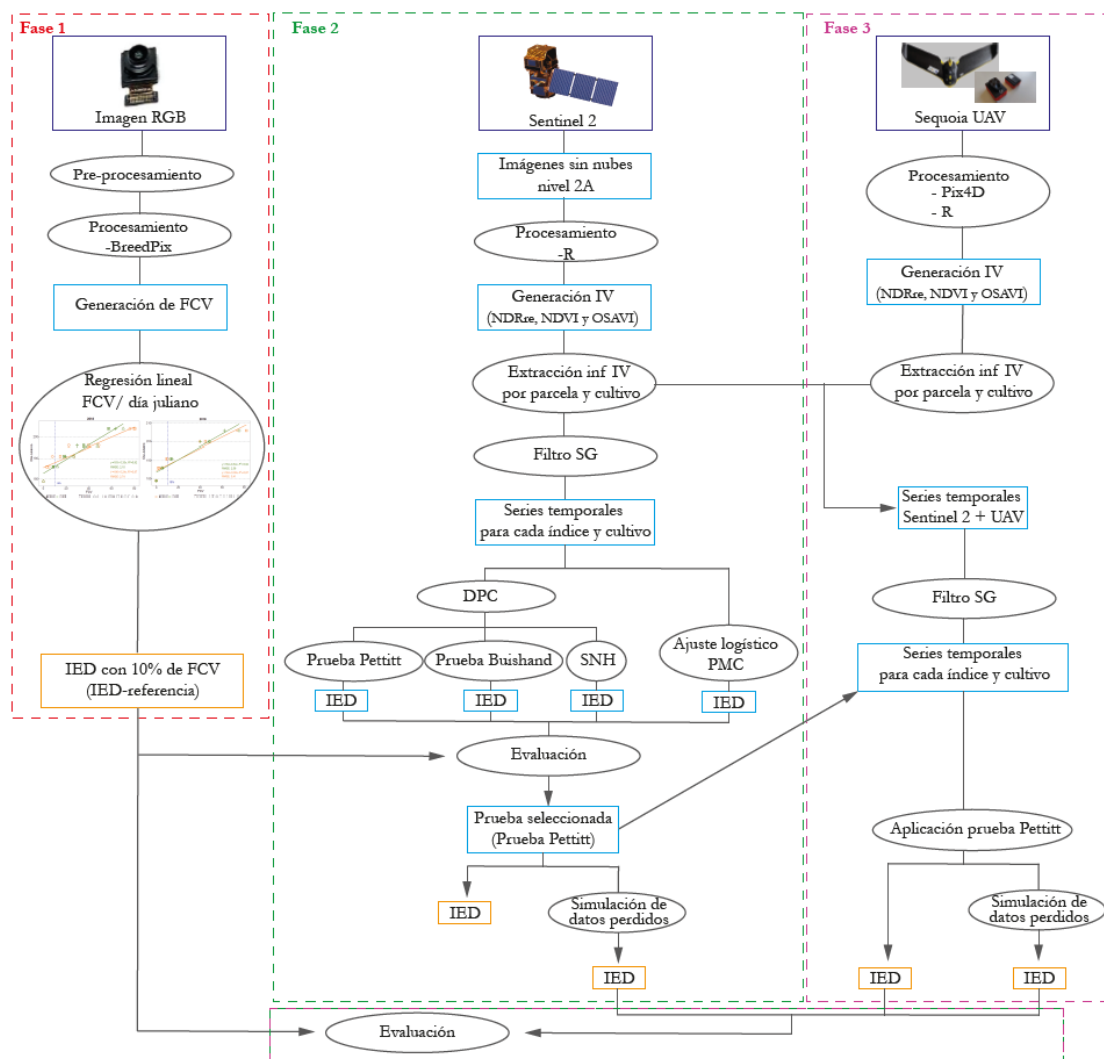


Figura IV-1. Flujo de trabajo general para determinar el IED.

Todos los procedimientos estadísticos y los gráficos presentados se desarrollaron utilizando diferentes paquetes del lenguaje de programación estadística R (R Core Team, 2020), que se van especificando en el documento conforme se utilizan.

IV.1.1 Temporalidad de datos

IV.1.1.1 Selección de la ventana temporal óptima para detección de IED

Tras revisar varios estudios llevados a cabo en la ZRV por parte del Centro de Investigación y Tecnología Agroalimentaria de Aragón (Malik, 2019), el periodo óptimo para la detección del IED en maíz y girasol de doble cosecha mediante series de imágenes multitemporales se sitúa entre la primera y la segunda semana de julio, concretamente entre los días julianos 186 y 192.

El nuevo enfoque que se propone en este capítulo para determinar el IED —la técnica de detección de punto de cambio (DPC)— requiere datos durante las primeras etapas de crecimiento, periodo que se muestra en la Figura IV-2 sombreado en verde, que abarca desde la siembra hasta V4-V5 para maíz y hasta V6 para girasol. En cambio, cuando se aplica el método de ajuste logístico y punto de máxima curvatura (AjLog_PMC), los datos necesarios van desde la siembra del cultivo hasta que este adquiere el máximo desarrollo vegetativo.

Los periodos de cada año en los que se realizaron las salidas de campo (toma de fotografía RGB) corresponden a los estadios V1 a V6 en maíz y VE a V8 en girasol. Las fechas concretas de captura de fotografías se pueden consultar en la Tabla IV-1; los días exactos en los que se obtuvieron datos de vuelo con Sequoia se pueden consultar en el Capítulo III y los de Sentinel 2 en el Anexo 1. El primer día de toma de fotografías RGB, tanto el maíz como el girasol estaban recién sembrados y la cobertura de estos cultivos era inexistente; por ello, la cobertura es nula.




Figura IV-2. Momentos de realización de las fotografías RGB en campo, obtención de datos de Sentinel 2 y de UAV. El área sombreada en verde corresponde con el periodo en el que se necesitan datos para calcular el IED mediante el método DPC.

Tabla IV-1. Fechas de adquisición de fotografías con cámara RGB en cada una de las parcelas sobre cultivos de maíz y girasol en 2018 y 2019.

Año	Parcela	Cultivo	28/06/2019	05/07/2019	10/07/2019	15/07/2019	23/07/2019
2018	A	Maíz	X	X	X	X	X
	C	Maíz			X	X	X
	D	Maíz		X	X	X	X
	E	Girasol		X	X	X	X
	F	Girasol	X	X	X	X	X

Año	Parcela	Cultivo	28/06/2019	05/07/2019	10/07/2019	15/07/2019	23/07/2019
	G	Girasol			X	X	X

Año	Parcela	Cultivo	28/06/2019	05/07/2019	10/07/2019	18/07/2019	25/07/2019
2019	H	Maíz		X	X	X	
	I	Maíz	X	X	X	X	X
	D'	Maíz	X	X		X	X
	J	Girasol	X	X	X	X	X
	K	Girasol	X	X	X	X	X

IV.1.1.2 Escala temporal

Para determinar la fecha del IED de los cultivos se han considerado tres escalas temporales: los días julianos (J), los días después de la siembra (*Growing Degree Day*, GDD) y los grados día acumulados después de la siembra (*Accumulated Growing Degree Day*, AGDD). En una primera aproximación se recurrió a utilizar los GDD o los AGDD (escalas descritas en el Apartado III.3.1.1 del Capítulo III), ya que están estrechamente relacionados con el ciclo vegetativo de los cultivos y la duración de las etapas fenológicas está directamente relacionada con la temperatura (Wang, 1960). Sin embargo, el origen de ambas escalas temporales se produce en el momento de la siembra, dato que no siempre se conoce, sobre todo cuando se trata de áreas extensas de estudio donde la variabilidad de fechas de siembra puede ser mayor. Por ello, se optó por la escala de los días julianos.

IV.1.2 Adquisición y procesamiento de fotografías RGB

En la ZRV el maíz de segunda cosecha se siembra generalmente en torno al 20 de junio, con una variabilidad de una semana, y el girasol de segunda cosecha suele sembrarse unos días después del maíz, hacia finales de junio. Las fechas de siembra en las parcelas de estudio fueron similares en los dos años, 2018 y 2019 (Tabla II.3.1 del Capítulo II).

De acuerdo con esto, las fotografías se realizaron durante 10 jornadas de campo distribuidas en el periodo inicial de desarrollo del cultivo, desde finales de junio hasta final de julio, en los dos años de estudio, tal y como se puede ver en la Tabla IV-1.

En cada parcela se seleccionaron 3 zonas donde se identificó visualmente en el campo que el cultivo era representativo del conjunto de la parcela. Con una cámara Huawei WAS-LX1A se tomó una fotografía RGB sobre una superficie delimitada por un aro de 73 cm de diámetro (correspondiente con la distancia entre filas de cultivo) colocado en las zonas elegidas (Figura IV-3). La cámara estaba a unos 120 cm del suelo, para asegurar recoger toda la superficie abarcada por el aro, en un plano cenital y enfocando el centro de cada circunferencia. Tanto la velocidad de obturación como la apertura se dejaron automáticas y las imágenes se tomaron sin flash. El tamaño de la imagen fue de 3968×2240 píxeles y se guardaron en formato JPEG.

Maíz



Girasol



Figura IV-3. Fotografía original (izquierda) e imagen recortada ajustada al área de muestreo para extraer la información de FCV.

Se realizó un recorte de las imágenes ajustado a la circunferencia definida por el aro (Figura IV-3) y posteriormente se analizaron las imágenes resultantes con el software de acceso libre BreedPix 0.2 (Casadesús et al., 2005). Este software clasifica los píxeles de la imagen según su tono (Hue, en representación de la imagen HSI) y cuantifica la proporción de píxeles de la imagen que son verdes (GA, *Green Area*) y muy verdes (GGA, *Greener Area*). Tanto GA como GGA describen la cantidad de biomasa verde en la imagen (Figura IV-4), si bien el segundo excluye los píxeles de color verde amarillento y, en nuestro caso, los píxeles con más brillo, por lo que se optó por utilizar el GA. El GA indica el porcentaje de píxeles de la imagen cuyo tono está entre 60° y 120° de la totalidad, mientras que el GGA muestra el porcentaje de píxeles con tono entre 80° y 120° (Casadesús et al., 2005; Casadesús & Villegas, 2014). La FCV de cada parcela se estimó como el promedio de las tres medidas de GA realizadas en cada parcela, ya que en los primeros estadios del cultivo la GA está estrechamente relacionada con la cobertura del suelo. El resultado del procesamiento de las imágenes se puede consultar en el Anexo 3.

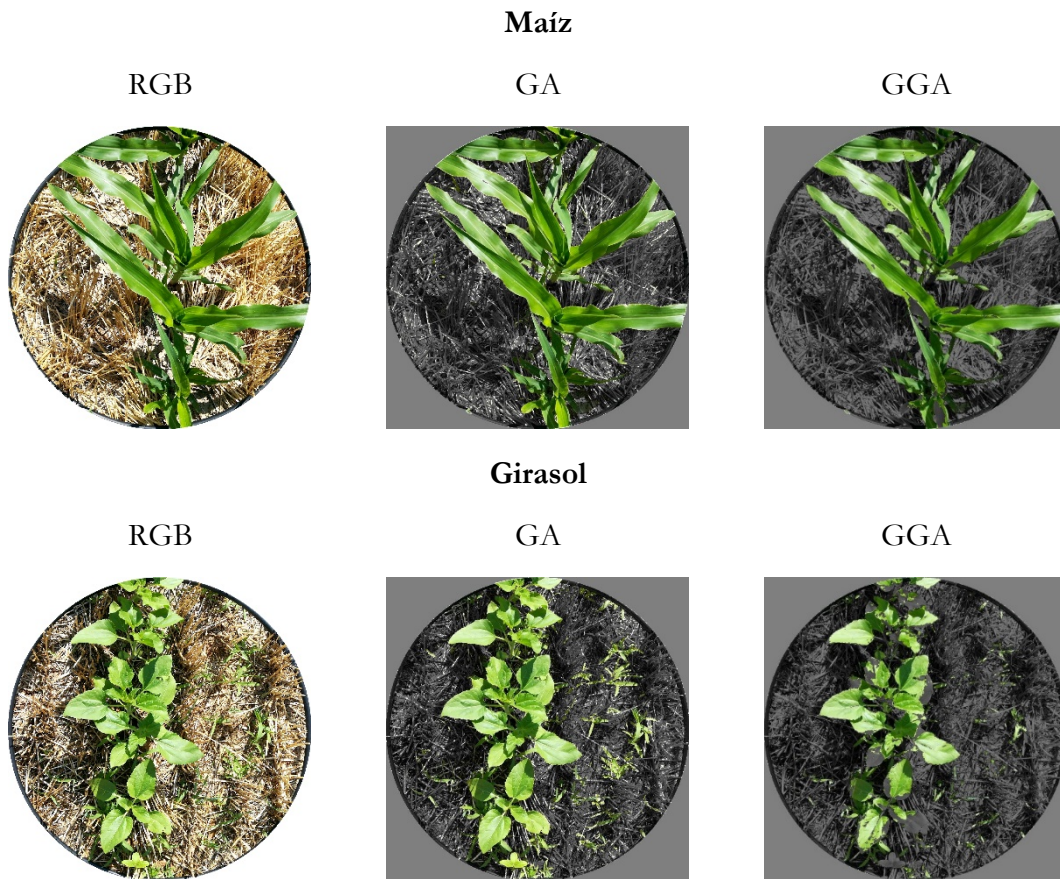


Figura IV-4. Estimación de la FCV: imagen utilizada (RGB), imagen de área verde (GA) e imagen del área más verde (GGA) tratadas con BreedPix.

IV.1.3 Recopilación y procesamiento de los datos de detección remota

IV.1.3.1 Imágenes multiespectrales

En este apartado se utilizan imágenes de tres vuelos adquiridas con UAV e imágenes Sentinel 2, 16 del año 2018 y 19 del 2019. De los tres vuelos con UAV, el primero se realizó coincidiendo aproximadamente con el día de siembra, el segundo con el momento del IED y el tercero una semana después del IED (Figura IV-2).

Las imágenes se obtuvieron con un UAV de ala fija SenseFly eBee Classic al que se le había instalado el sensor Sequoia. La planificación y el control del vuelo se llevaron a cabo con el software eMotion. Los vuelos se realizaron en condiciones atmosféricas óptimas, días con viento menor de 8 m/s y sin demasiadas nubes visibles. En todo caso, el UAV dispone de un sensor de iluminación “Sunshine” que permite calibrar los valores adquiridos. La captura se realizó al mediodía solar, cuando el ángulo solar es más alto, minimizando así las sombras de la vegetación. La altitud del vuelo fue de 100 m aproximadamente, lo que permite obtener una resolución espacial de 8 cm. Las imágenes se adquirieron con un 80% de superposición, tanto lateral como longitudinal. Para la calibración radiométrica se utilizó el objetivo de calibración del sensor Sequoia y para la georreferenciación de la imagen se pusieron entre 4 y 8 puntos de control, según la dimensión de cada parcela. Los datos extraídos de las imágenes fueron procesados con el software Pix4Dmapper. Los detalles

sobre las características completas del UAV y del sensor, así como el diseño de vuelo, la adquisición de los datos y su procesado están descritos en el Apartado 3.1.3 del Capítulo III.

Las imágenes Sentinel 2 se obtuvieron de los dos satélites, A y B, de la misión Copernicus. Una descripción más completa de Sentinel 2 se incluye en el Apartado 3.1.4 del Capítulo III. El producto que se utilizó fue el nivel 2^a, que proporciona imágenes de reflectancia corregidas atmosféricamente, es decir, en las que se excluyen los efectos de la atmósfera sobre la luz reflejada por la superficie de la Tierra que llega al sensor. Las imágenes se descargaron del Copernicus [Open Access Hub](#) de la Agencia Espacial Europea (ESA).

La ZRV y, por tanto, las parcelas de estudio se encuentran en un área de superposición de dos franjas adyacentes de paso del satélite Sentinel 2, lo que permite disponer de mayor frecuencia de imágenes. Durante la temporada de crecimiento de 2018 se adquirieron imágenes cada 2 y 3 días en el mejor de los casos y cada 5 en el peor. Sin embargo, en la temporada de 2019 hay más situaciones con imagen cada 5 días, cuya repercusión en la detección del IED será objeto de análisis.

IV.1.3.2 Índices de vegetación

Los IV seleccionados para la determinación del IED fueron el NDRre, NDVI y OSAVI. Estos índices, además de estar entre los más utilizados en la literatura, sobre todo NDVI y OSAVI, han sido los que mejor relación mostraron entre los sensores MSI de Sentinel 2 y Sequoia en el Capítulo III. La serie de datos que se utiliza para determinar el IED corresponde con los de la primera etapa de desarrollo del cultivo, hasta los 400 AGDD. Como se ha comprobado en el apartado III.2.4 del Capítulo III, el modelo de regresión lineal entre ambos sensores para esta etapa y los tres índices seleccionados cumple con las condiciones de normalidad, homocedasticidad y autocorrelación de los residuos que garantizan la validez del este modelo de regresión. Aunque ya se han descrito en ese Capítulo III, se retoma ahora su formulación para agilizar la comprensión del presente. En la Tabla IV-2 se muestra el rango espectral utilizado de cada sensor para que en la formulación de los IV (Tabla IV-3) sean coincidentes los rangos espectrales de Sequoia y MSI de Sentinel 2.

Tabla IV-2. Rangos espectrales utilizados de cada sensor.

Rango espectral	Sequoia	MSI de Sentinel 2
Reflectividad del rojo (R_{VERDE})	banda verde	banda 3
Reflectividad del rojo (R_{ROJO})	banda roja	banda 4
Reflectividad del borde del rojo (R_{BR})	banda del borde del rojo	banda 6
Reflectividad del infrarrojo cercano (R_{IC})	banda del infrarrojo cercano	banda 7

Tabla IV-3. NDRre, NDVI y OSAVI derivados de las imágenes de Sequoia y MSI de Sentinel 2.

Índice vegetación	Fórmula	Referencia
Índice de Vegetación de Diferencia Normalizada del Rojo-Borde del rojo (NDRre)	$NDRre = \frac{(R_{BR} - R_{ROJO})}{(R_{BR} + R_{ROJO})}$	(Gitelson et al., 2002)
Índice de Vegetación de Diferencia Normalizada (NDVI)	$NDVI = \frac{(R_{IC} - R_{ROJO})}{(R_{IC} + R_{ROJO})}$	(Rouse et al., 1974)
Índice de Vegetación Ajustado al Suelo Optimizado (OSAVI)	$OSAVI = \frac{(1 + 0,16)(R_{IC} - R_{ROJO})}{(R_{IC} + R_{ROJO} + 0,16)}$	(Rondeaux et al., 1996)

IV.1.4 Determinación del Inicio de la Etapa de Desarrollo (IED)

IV.1.4.1 IED a partir de fotografías RGB y la fracción de cobertura vegetal

Con los datos de FCV obtenidos en los muestreos de campo se realizó un primer análisis exploratorio mediante gráficos de dispersión, lo que permitió determinar la relación entre la FCV y los días julianos. Se utilizaron técnicas de regresión lineal para analizar la relación existente entre la escala temporal y la FCV. Para valorar la exactitud de la precisión del modelo se utilizaron el coeficiente de determinación (R^2) y el error cuadrático medio (RMSE). El 10% de la FCV será el IED de referencia (Fase 1 en la Figura IV-1) con el que evaluarán las otras metodologías de obtención de IED (Fase 2 en la Figura IV-1). Para su cálculo se aplicaron las ecuaciones resultantes de la regresión lineal entre FCV y los días julianos.

IV.1.4.2 IED a partir de imágenes Sentinel 2 y la técnica de detección del punto de cambio

La técnica de detección de puntos de cambio tiene como objetivo identificar los momentos en los que cambia la distribución de probabilidad de una serie temporal (Jiménez-Ruano et al., 2017). Para detectar el IED se aplicaron tres pruebas de detección de punto de cambio ampliamente utilizadas en la literatura (Elzeiny et al., 2019; Jaiswal et al., 2015; Martínez et al., 2010): la prueba de Pettitt, la prueba de Rangos de Buishand y la prueba de homogeneidad normal estándar (Fase 2 en la Figura IV-1). En el contexto de la detección de las etapas fenológicas del ciclo anual de cultivos agrícolas, estas pruebas no han sido previamente utilizadas; son pruebas que se utilizan a menudo para el análisis de series hidrológicas y climáticas.

La serie temporal de IV se formó con todas las parcelas para cada cultivo, a partir de los datos promedio de cada parcela y fecha. Los datos se ordenaron consecutivamente teniendo en cuenta los AGDD, dando lugar a una serie temporal a la que se le aplicaron las técnicas de detección de punto de cambio. Previamente a la aplicación de las técnicas de detección de cambio, con el objetivo de eliminar ruido y suavizar los datos de la serie, se aplicó el filtro Savitzky-Golay (SG). Los parámetros utilizados en el filtro SG fueron un polinomio de orden 3 y la longitud del filtro de 5 (es un filtro poco marcado, ya que en una exploración inicial se observó que los datos no presentaban grandes picos).

Prueba de Pettitt

La prueba de Pettitt es un método no paramétrico que se aplica habitualmente para detectar un único punto de cambio en series hidrológicas o climáticas con datos continuos (Pettitt, 1979) y permite comprobar si hay un cambio en la tendencia central de una serie temporal. Pone a prueba la hipótesis nula, “ningún cambio”, frente a la alternativa “existe un punto de cambio”. El estadístico no paramétrico en el que se basa la prueba (Ryberg et al., 2020; Verstraeten et al., 2006) se define como (Ecuaciones IV-1 y IV-2) :

$$\hat{U} = \max |U_k| \quad (IV-1)$$

donde

$$U_k = \left(2 \sum_{i=1}^k r_i \right) - k(n+1) \quad k = 1, 2, 3, \dots, n \quad (IV-2)$$

donde r_i es la clasificación (ranking) en la serie temporal, n es la longitud de la serie temporal.

El punto de cambio probable \hat{U} se encuentra ubicado donde U_k tiene su máximo valor absoluto, siempre que el estadístico sea significativo y la probabilidad de significación de \hat{U} $p \leq 0,05$. Esta probabilidad se calcula según la Ecuación (IV-3):

$$p = 2 \exp \left(\frac{-6\hat{U}^2}{n^3 + n^2} \right) \quad (IV-3)$$

En raras ocasiones la prueba de Pettitt devuelve dos puntos de cambio debido a empates en los datos; en estos casos se optó por el primer punto de cambio, de acuerdo con Ryberg et al. (2020).

La prueba de Pettitt sí se ha utilizado en el contexto de la determinación de los puntos de cambios en las tendencias de parámetros fenológicos en cultivos, pero para una serie de años (Chakraborty et al., 2018).

Prueba de Rangos de Buishand

En las series aleatorias, la desviación de la media se distribuirá a ambos lados de la media de la serie, cuando la series es homogénea sin ningun punto de cambio. En esto se basa la prueba de Rangos de Buishand (Buishand, 1982), que se como (Ecuación (IV-4)):

$$Rb = \frac{\max S_k - \min S_k}{\sigma} \quad (IV-4)$$

La suma parcial ajustada (S_k), que es la desviación acumulativa de la media para la k^{th} observación de una serie $x_1, x_2, x_3, \dots, x_k, \dots, x_n$ con media (\bar{x}) puede calcularse utilizando la Ecuación (IV-5):

$$S_k = \sum_{i=1}^k (x_i - \hat{x}) \quad (IV-5)$$

El valor p para determinar la significación de la prueba se estima con una simulación de Monte Carlo utilizando m réplicas.

Prueba de Homogeneidad Normal Estándar (*Standard Normal Homogeneity test*, SNHT)

Por último, se aplicó la prueba de homogeneidad normal estándar (Alexandersson, 1986). Esta prueba se utiliza para detectar si hay o no cambio en la serie de datos en los promedios para los períodos anterior y siguiente al que se analiza. Si la diferencia entre los promedios alcanza un valor crítico se deduce que existe cambio (hipótesis igual a la de la prueba Rangos de Buishand). La ventaja de esta prueba es que tiene la capacidad de deducir el punto de cambio al principio o al final de la serie de datos.

La prueba estadística se calcula mediante las Ecuaciones (IV-6) y (IV-7):

$$T_k = kz_1^2 + (n - k)z_2^2 \quad (\text{IV-6})$$

donde z_1 y z_2 son computadas como:

$$z_1 = \frac{1}{k} \sum_{i=1}^k \frac{x_i - \bar{x}}{\sigma x} \quad z_2 = \frac{1}{n - k} \sum_{i=k+1}^n \frac{x_i - \bar{x}}{\sigma x} \quad (\text{IV-7})$$

donde, \bar{x} y σx son la media y la desviación estándar de la serie; el día k puede considerarse como punto de cambio y consiste en una ruptura donde el valor de T_k alcanza el valor máximo.

El valor p de significación se estima igual que en la prueba anterior, con una simulación de Monte Carlo utilizando m réplicas.

Todos estos análisis estadísticos se realizaron con el paquete *trend* en R (Pohlert, 2020).

La evaluación de la precisión del IED obtenido mediante las técnicas de detección de punto de cambio de los IV NDRre, NDVI y OSAVI de la serie Sentinel 2 se realizó observando las diferencias con el IED-referencia.

IV.1.4.3 IED a partir de imágenes Sentinel 2 y el ajuste logístico

El método de ajuste logístico ha sido utilizado ampliamente para la detección del *green-up* (Cao et al., 2015; Wang et al., 2015, 2017). Generalmente se aplica la función logística y se calcula la tasa máxima de cambio de curvatura, siguiendo la metodología de Zhang et al. (2003). En esta tesis se optó por un ajuste logístico y se extrajo el punto de máxima curvatura utilizando el método de la distancia perpendicular.

La función no lineal del modelo logístico de cuatro parámetros (Ecuación (IV-8)) se calculó sobre la base de la parametrización realizada por el paquete R de dosis-respuesta *drc* (Ritz et al., 2015):

$$f(x) = c + \frac{d - c}{1 + e^{b(x-e)}} \quad (\text{IV-8})$$

donde x es el tiempo, $f(x)$ es el valor del IV en el momento de x , d es la meseta de la curva, que indica el mayor valor de IV, c es el valor más bajo de IV, b y e son parámetros de ajuste (b es la pendiente de la curva y e es el punto de inflexión entre c y d).

Una vez obtenida la curva, el siguiente paso fue determinar el punto de inflexión de la misma aplicando el método de la distancia perpendicular, tal y como se describe en Rodrigo Da Silva & Paiva de Lima (2017). Para ello, en primer lugar, se traza una línea tangente, $h(x) = b_0 \pm b_1x$, a lo largo de la función subyacente $f(x)$ que conecta sus límites (x, y) , como se puede ver en la Figura IV-6. Luego se busca el punto de máxima curvatura x_i donde la distancia a la línea tangente, $d_i = \left\{ (x_i - x_j)^2 + [f(x_i) - h(x_j)]^2 \right\}^{1/2}$ es mayor, tal y como se puede ver en la Figura IV-5.




Figura IV-5. Gráficos de los resultados de la función maxcurv con el método de la distancia perpendicular.




Figura IV-6. Gráfico del método de las distancias perpendiculares.

Para aplicar el método de la distancia perpendicular se utilizó la función maxcurv dentro del paquete *soilphysics* de R (Rodrigo Da Silva & Paiva de Lima, 2017).

La comparación de IED-AjLog_PMC con el IED obtenido al aplicar las técnicas de detección de puntos de cambio se realizó observando las diferencias con el IED-referencia.

IV.1.4.4 IED a partir de imágenes Sentinel 2 y la prueba de Pettitt simulando datos perdidos.

Como se pondrá de manifiesto a presentar los resultados, la prueba que menor diferencia obtiene al compararla con el IED-referencia fue la prueba de Pettitt. Por tanto, esta fue la prueba elegida para proceder a comprobar cómo afectaría a la predicción de IED la carencia de algunas imágenes. Para ello se simularon datos perdidos en la serie temporal (falta de imágenes) que podrían haberse generado de forma natural por nubosidad u otras causas. La eliminación de las imágenes no se realizó de forma aleatoria, sino que se eliminaron de forma correlativa una, dos y hasta tres imágenes seguidas durante el periodo establecido en el que se puede producir el IED, tal y como se puede ver en la Figura IV-7.




Figura IV-7. Ejemplo de datos perdidos generados (-) cuando se comienza con la imagen de los días julianos 174 y 184.

Los resultados se evaluaron con el mismo procedimiento que en los apartados anteriores, observando las diferencias con el IED-referencia.

IV.1.4.5 IED a partir de la combinación de imágenes Sentinel 2 y UAV aplicando la prueba de Pettitt

Se comprobó también cómo se vería afectada la predicción de IED cuando al combinar datos de Sentinel 2 y UAV (Fase 3 en la Figura IV-1). Para ello, las tres imágenes de Sequoia obtenidas mediante UAV sustituyeron en la serie temporal a las imágenes Sentinel 2 de ese mismo día. La incorporación de imágenes de UAV en la serie de datos de Sentinel 2 da lugar a varios escenarios a analizar para maíz y girasol, tal y como se puede ver en la Tabla IV-4, aunque para girasol no se generaron todos los escenarios, ya que la imagen de UAV correspondiente al día 179 no se pudo procesar correctamente. Para evaluar los resultados con la incorporación de las imágenes de Sequoia se realizó el mismo procedimiento anterior, eliminando fechas y comparando los resultados con el IED-Referencia.

Tabla IV-4. Escenarios contemplados en la sustitución de imágenes Sentinel 2 (S2) por imágenes Sequoia (UAV). El número asociado (día juliano) a las imágenes Sequoia refiere a la imagen Sentinel 2 que sustituye.

Escenario	Denominación	Imágenes
Escenario 1	E1 S2	Solo imágenes de S2
Escenario 2	E2 S2 + Sequoia (179)	Serie S2 con Sequoia 179
Escenario 3	E3 S2 + Sequoia (191)	Serie S2 con Sequoia 191
Escenario 4	E4 S2 + Sequoia (199)	Serie S2 con Sequoia 199
Escenario 5	E5 S2 + Sequoia (179+191)	Serie S2 con Sequoia 179 y 191
Escenario 6	E6 S2 + Sequoia (179+199)	Serie S2 con Sequoia 179 y 199
Escenario 7	E7 S2 + Sequoia (191+199)	Serie S2 con Sequoia 191 y 199
Escenario 8	E8 S2 + Sequoia (179+191+199)	Serie S2 con Sequoia 179, 191 y 199

IV.2 Resultados

En el presente Capítulo se determinó primero el IED de referencia al 10% de FCV. A continuación, se aplicaron a las series temporales de los tres IV elegidos la prueba de Pettitt, la prueba de Rangos de Buishand, la prueba de homogeneidad normal estándar como pruebas del método de punto de cambio y una prueba más estandarizada, como es la prueba

de ajuste logístico y punto de máxima curvatura. Se seleccionó la prueba que ofrece el IED más próximo al IED-referencia. Finalmente, con la prueba seleccionada se evaluó cómo afectaba a la predicción del IED la falta de imágenes o la introducción de nuevas imágenes de otro sensor. Los resultados obtenidos se describen a continuación.

IV.2.1 Determinación de la FCV e IED de referencia

En la Figura IV-8 se presentan las relaciones lineales entre la escala temporal y las FCV, el coeficiente de determinación de (R^2) y el error medio cuadrático (RMSE). Se ha comprobado que cumple con las condiciones de normalidad, homocedasticidad y autocorrelación de los residuos que garantizan la validez de este modelo de regresión. Tanto para maíz como para girasol se obtienen en los dos años de estudio altos R^2 y bajos RMSE, siendo algo mejores para el maíz.

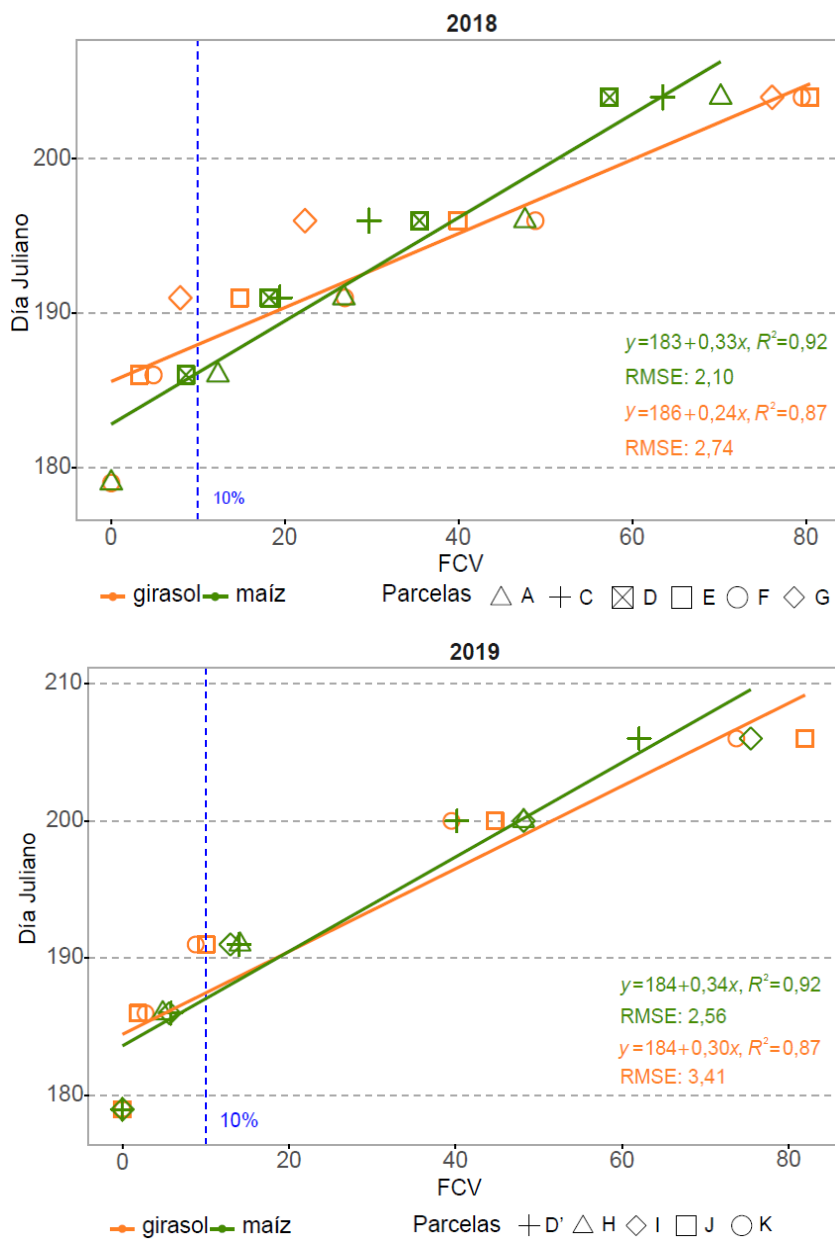


Figura IV-8. Relación entre el día juliano y la FCV estimada en campo para los cultivos de girasol y maíz.

El resultado del momento temporal cuando la FCV es del 10% o momento del IED-referencia se produce en el girasol uno o dos días después del maíz (Tabla IV-5). Las diferencias entre los dos años de estudio y entre cultivos son mínimas y se deben principalmente al manejo de las parcelas y al momento de siembra de los cultivos.

El IED en los dos cultivos estudiados se encuentra, para el área de estudio, entre los días julianos 186 y 188, unos 12 días después de la siembra (el día de siembra se puede consultar en la Tabla III.1 del capítulo II). El del girasol se produce 1 o 2 días después del maíz. El estadio en el que se produce el IED es V2 para girasol y entre V2 y V3 para maíz.

Tabla IV-5. IED-referencia en días julianos.

	Girasol 2018	Maíz 2018	Girasol 2019	Maíz 2019
IED-referencia	188	186	188	187

IV.2.2 Determinación de IED con la serie temporal de Sentinel 2

Los resultados del IED determinado con cada prueba DPC para las series temporales de los tres IV se presentan en la Tabla IV-6. De todas las pruebas realizadas, el IED obtenido con la prueba de Pettitt es el que más se acerca al IED-referencia. El IV OSAVI en 2019 se diferencia de los otros dos empleados al determinar el IED unos días después que ellos, es el que más difiere del IED-referencia. La prueba de Rangos de Buishand también ofrece IEDs cercanos al IED-referencia, tan solo separados 3 días de este. La excepción es el maíz en 2019, que dista 4 días del IED-referencia. Con esta prueba todos los índices coinciden en la fecha de IED que determinan. El SNHT es el que presenta las mayores diferencias con el IED-referencia, va de 5 días para el maíz de 2018 a 9 días para el maíz en 2019, lo que supone no detectar el IED hasta que el maíz está en estadio V4. En el girasol también se observan diferencias holgadas, con el IED-referencia en ambos años 8 días, lo que hace que el IED se detecte entre los estadios V4 y V6. También con esta prueba, el IED coincide en los distintos índices. Por último, la prueba de ajuste logístico ofrece mejores resultados para el girasol que para el maíz, las diferencias con el IED-referencia en girasol son de 2 días para 2018 y 4 días para 2019 y para el maíz son de 7 días para ambos años; el índice OSAVI determina el IED, en este caso, 1 día después que los otros dos índices.

En general, los IED obtenidos para el año 2018 se ajustan más al IED-referencia. Esto es debido a que en el momento en el que se produce el IED la recurrencia de imágenes es de 2 a 3 días. En cambio, en 2019, en el momento de IED hay una imagen de satélite menos, produciéndose un periodo sin imágenes de 5 días.

Tabla IV-6. Determinación de IED por las diferentes pruebas e IED-referencia.

	Girasol 2018			Girasol 2019		
	NDRre	NDVI	OSAVI	NDRre	NDVI	OSAVI
Pettitt	189	189	189	186	186	191
Buishand	191	191	191	191	191	191
SNHT	196	196	196	196	196	196
Ajlog-PMC	190	190	191	192	192	193
IDE-referencia	188			188		

	Maíz 2018			Maíz 2019		
	NDRre	NDVI	OSAVI	NDRre	NDVI	OSAVI
Pettitt	186	186	186	186	186	191
Buishand	189	189	189	191	191	191
SNHT	191	191	191	196	196	196
Ajlog-PMC	193	193	193	194	194	194
IDE-referencia	186			187		

IV.2.3 Determinación de IED con la serie temporal de Sentinel 2 y la prueba de Pettitt simulando datos perdidos.

Para interpretar los resultados y observar el efecto de la falta de imágenes en la determinación del IED se presentan varios gráficos como el de la Figura IV-9. Las celdas con sombreado gris son el resultado de la diferencia entre el momento del IED y el momento de IED-referencia cuando se eliminan las imágenes. Así, cuando la generación de datos perdidos comienza con la falta de imagen del día 174, el resultado se muestra en la celda X₁; cuando faltan dos imágenes correlativas –174 y 176– el resultado aparece en la celda X₂; por último, cuando se eliminan tres imágenes –174, 176 y 179– el resultado se muestra en la celda X₃. El mismo proceso se lleva a cabo para todas las imágenes entre los días julianos 174 y 199. La celda 0 corresponde al IED obtenido cuando no se simulan datos perdidos

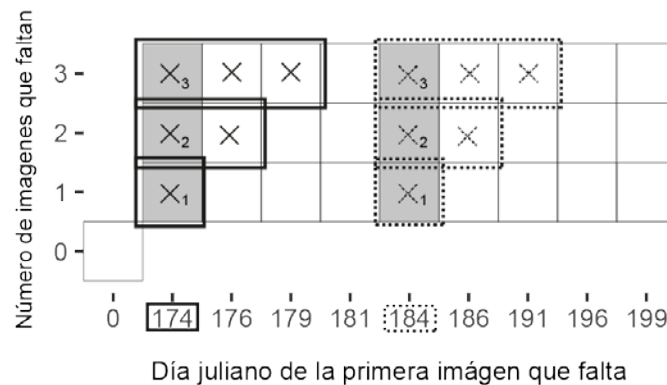


Figura IV-9. Ejemplo de los resultados obtenidos cuando las primeras imágenes que faltan son las de los días julianos 174 y 184.

En la Figura IV-10 se observan los resultados al aplicar la prueba de Pettitt en la serie temporal de datos disponible para los cultivos de maíz y girasol en los dos años de estudio añadiendo datos perdidos. Como ya se ha señalado, las imágenes en la zona de estudio tienen una recurrencia de 2 a 3 días si las condiciones atmosféricas son óptimas (no hay nubes), aunque estas condiciones óptimas pocas veces suceden, por lo que se generan vacíos o huecos temporales de imágenes. En los años de estudio se produjeron, en el peor de los casos, periodos de cinco días sin imágenes. En 2018 un periodo sin imágenes de 5 días sucede tan solo una vez del día juliano 191 al 196; en cambio, en 2019 este periodo de imágenes cada 5 días sucede 2 veces, del día juliano 186 al 191 y del día 191 al 196.

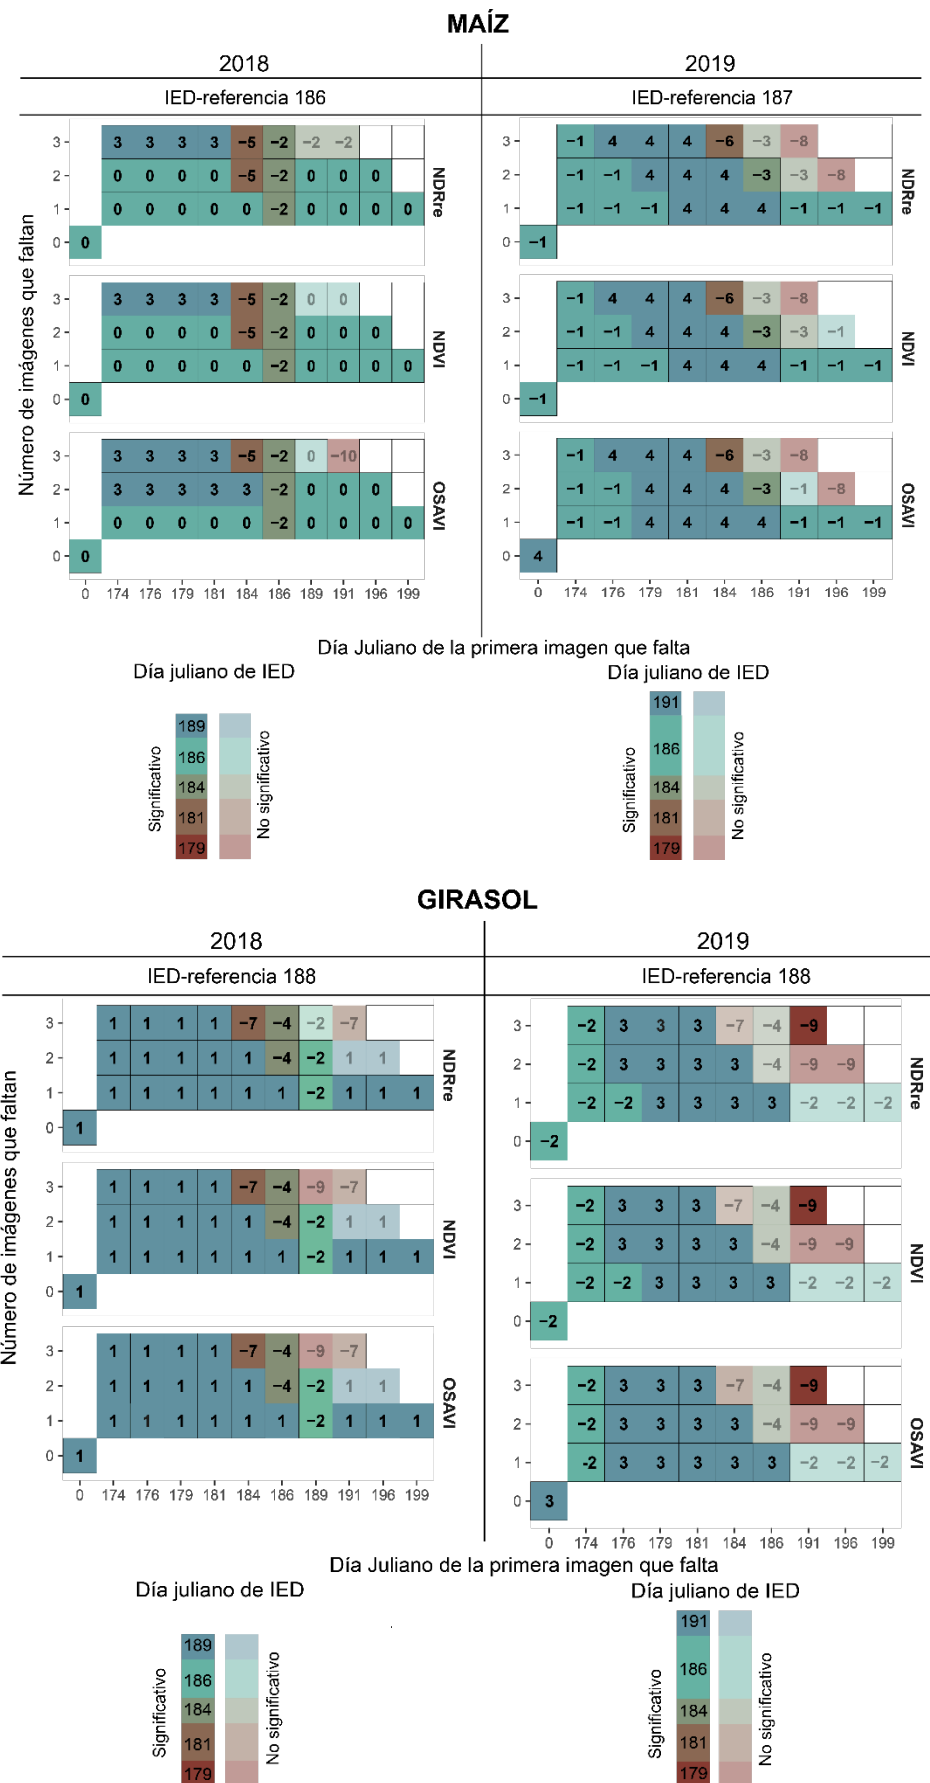


Figura IV-10. Diferencias del IED determinado para maíz y girasol mediante el método de Pettitt respecto al IDE-referencia para los tres índices de estudio derivados de MSI de Sentinel 2. Nivel de significación $p < 0,05$.

Los resultados muestran que, en 2018, cuando se elimina una imagen, el IED obtenido no difiere o varía solo en un día respecto al IED-referencia. Sin embargo, si la imagen eliminada corresponde con el momento en que se produce el IED, entonces sí se aprecian diferencias entre el IED estimado con la prueba de Pettitt y el IED-Referencia. Esto se aprecia claramente cuando se elimina la imagen del día juliano 186 en maíz, imagen que corresponde con el día del IED-referencia, y cuando se elimina la imagen 189 en girasol. El IED se determina entonces con 2 días de adelanto. Cuando el número de días sin datos es mayor, es decir, cuando se eliminan 2 y 3 imágenes consecutivas, los resultados varían en función de cuándo se produce la falta de imágenes. Si está cercana a la siembra, no afecta o afecta poco en la determinación del IED; en cambio, cuando las imágenes eliminadas se localizan cercanas al momento de IED, la fecha determinada se adelanta notablemente respecto a la IED de referencia, hasta 7 días, lo cual supondría que el IED se encontrase en la etapa fenológica del cultivo de emergencia, tan solo 5 días después de la siembra, no respondiendo a la realidad. En estas situaciones, por tanto, el resultado obtenido no es fiable. Cuando las imágenes descartadas son posteriores al IED, los resultados son no significativos, con intervalo de confianza es menor de 95%, por lo que la predicción del IED no es estadísticamente significativa.

En 2019 la eliminación de imágenes produce los mismos efectos que en 2018. Como ya se ha señalado, en 2019 la periodicidad de las imágenes no siempre es de 2 o 3 días. En el año 2018 se disponía de la imagen 189, en cambio, en 2019 no la hay, siendo la siguiente imagen disponible la del día juliano 191, lo que conlleva una diferencia mayor entre el IED obtenido y el IED-referencia. Las diferencias entre localizar el IED 1 día antes del IED-referencia suponen que el IED se dé cuando el maíz está en estadio V2; si la diferencia con el IED-referencia es de 4 días después el maíz está en estadio V3. En el caso del girasol, los valores son similares al maíz, el IED se estima sobre los días julianos 186 y 191, en este caso el girasol se encuentra en estadio VE y V2, respectivamente.

Los tres índices considerados se comportan de forma similar, si bien, en el año 2019 para ambos cultivos, OSAVI proporciona resultados ligeramente más distantes del IED-referencia con toda la serie de datos.

IV.2.4 Determinación de IED con la serie temporal de Sentinel 2 - UAV aplicando la prueba de Pettitt

Los resultados que se presentan corresponden a los escenarios descritos en el apartado IV.1.4.5. Los IED obtenidos para maíz y girasol con las series de datos de los tres índices se muestran en las Figura IV-11 y Figura IV-15.

En el maíz, cuando se utiliza el índice NDRre, los IED obtenidos al sustituir los datos de Sentinel 2 por los datos de UAV son muy similares a los obtenidos con la serie Sentinel 2 (escenario E1 S2). Únicamente se observa una pequeña diferencia cuando no hay datos perdidos en los escenarios 5 y 8.

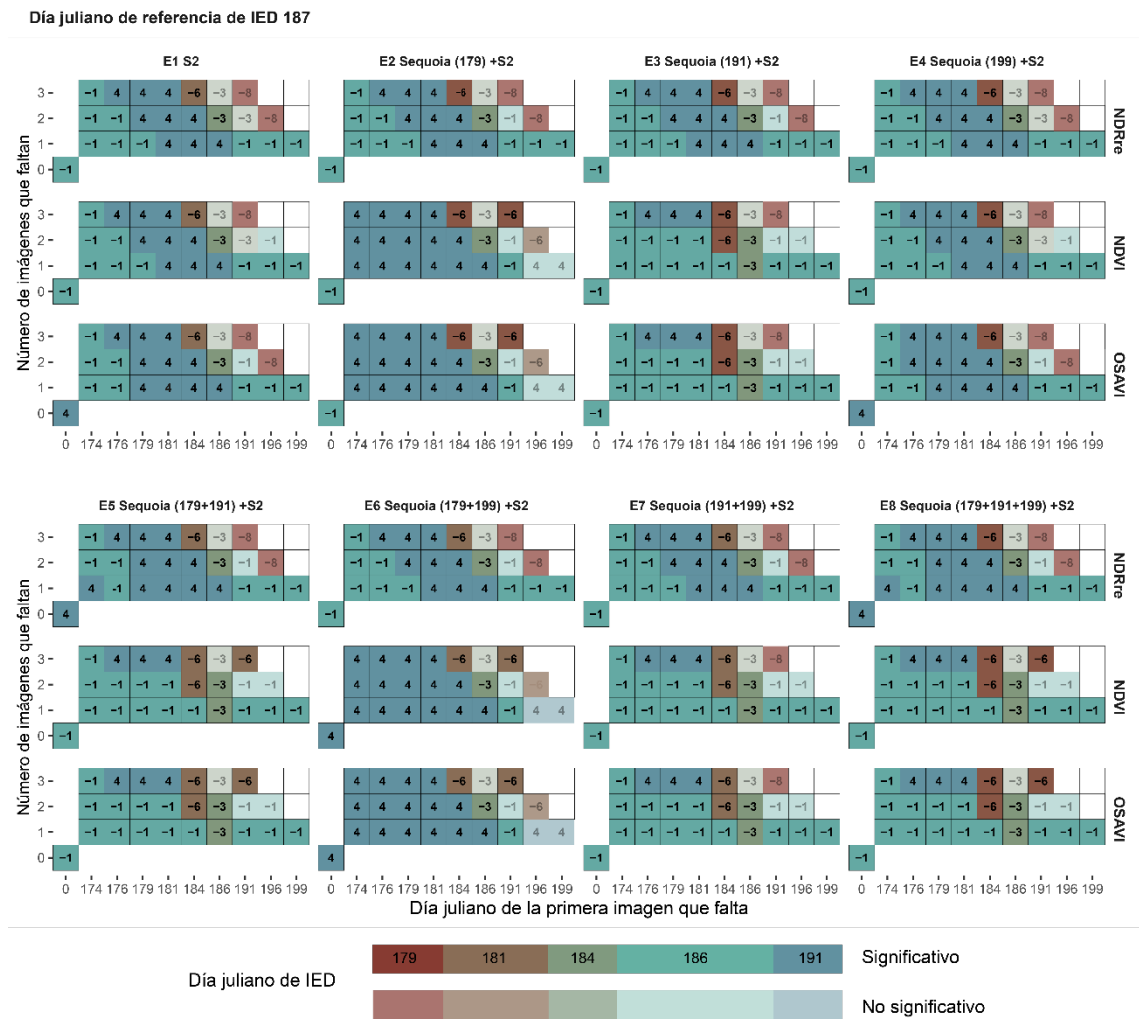


Figura IV-11. Diferencias del IED determinado para maíz mediante la prueba de Pettitt respecto al IED-referencia para los tres índices de estudio derivados de MSI de Sentinel y Sequoia en 2019 (serie temporal en días julianos). Nivel de significación $p < 0,05$.

Los IEDs con la serie temporal NDVI son iguales al IED-referencia únicamente para el escenario 4, es decir, cuando se incorpora la imagen de Sequoia del día juliano 199. En cambio, en el resto de los escenarios se observa alguna diferencia. A continuación, se exponen algunos ejemplos de estas diferencias haciendo referencia a las posibles causas en la discusión (Figura IV-12, Figura IV-13, Figura IV-14).

En el escenario 2, en el que se sustituye la imagen del día juliano 179, que corresponde a la primera parte de la serie temporal de datos antes del momento de IED, el IED se retrasa 4 días respecto al IED-referencia (Figura IV-12). Como se ha señalado en el Capítulo III, los valores de NDVI son sistemáticamente más altos en Sequoia que en MSI. Esto hace que, al sustituir esta imagen del día 179, el sumatorio de la clasificación de los datos de la serie (Ecuación IV-2) al comienzo de la serie aumenta y por tanto el IED se produzca más tarde en el escenario 2, escenario donde se incluyen los datos de UAV, respecto a cuando se produce en el escenario 1.




Figura IV-12. Diferencias en la serie temporal NDVI e IED del maíz entre el Escenario 1 (serie de datos de MSI de Sentinel 2) y Escenario 2 (serie en la que se sustituyen datos de MSI por datos de Sequoia).

En el escenario 3 sucede lo contrario debido a que el momento en el que se sustituye la imagen de MSI por la de Sequoia es en la parte final de la serie temporal de datos. En este caso la imagen sustituida es del día juliano 191 y el sumatorio de la clasificación aumenta en la parte final de la serie de datos de NDVI, haciendo que se determine antes el IED, por lo que el IED aparece antes en el escenario 3 que en el 1 (Figura IV-13).




Figura IV-13. Diferencias en la serie temporal NDVI e IED del maíz entre el Escenario 1 (serie de datos de MSI de Sentinel 2) y Escenario 3 (serie en la que se sustituyen datos de MSI por datos de Sequoia).

El índice OSAVI se comporta de forma similar al NDVI. En el escenario 4 no se observan diferencias, en cambio sí se producen en el resto de los escenarios. Se muestra como ejemplo el escenario 7 donde se sustituyen las imágenes Sentinel 2 de los días julianos 191 y 199 por las de Sequoia (Figura IV-14). Corresponde con un periodo sin imágenes de 10 días entre los julianos 181 y 191, que es cuando mayores diferencias se dan en la

determinación del IED respecto al escenario 1. Como el sensor Sequoia genera valores de OSAVI más elevados que MSI, el sumatorio de la clasificación aumenta en esta parte final de la serie temporal, después del punto de ruptura; por tanto, el IED se determina antes en el escenario 3 que en el escenario 1.

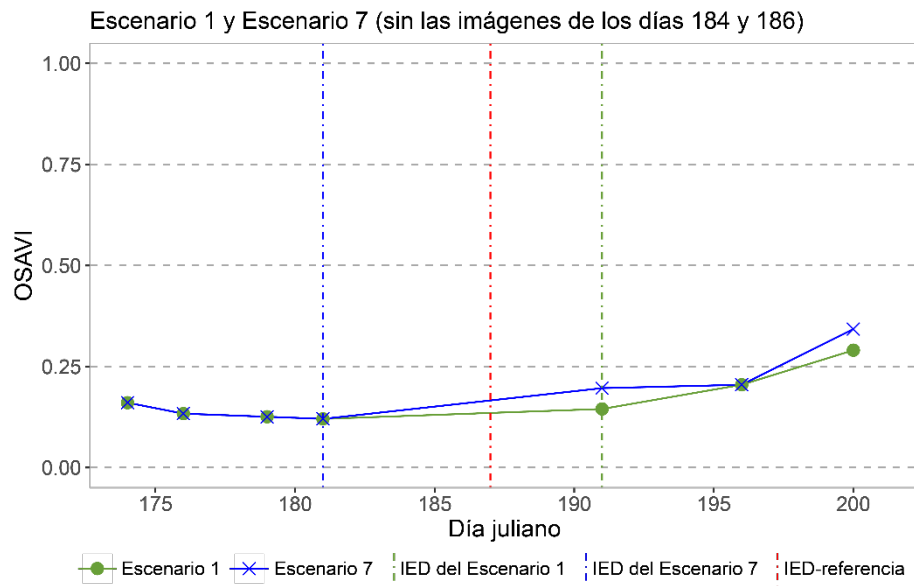


Figura IV-14. Diferencias en la serie temporal OSAVI e IED del maíz entre el Escenario 1 (serie de datos de MSI de Sentinel 2) y Escenario 7 (serie en la que se sustituyen datos de MSI por datos de Sequoia).

Los resultados de determinación del IED de 2019 en girasol, presentados en la Figura IV-15, se comportan de forma similar a los obtenidos para el maíz. Al utilizar la serie temporal del índice NDRre no se constatan diferencias entre el escenario 1 con el resto de los escenarios. En cambio, como sucedía con el maíz, tanto NDVI como OSAVI manifiestan diferencias en los escenarios 3 y 7 (Figura IV-16).

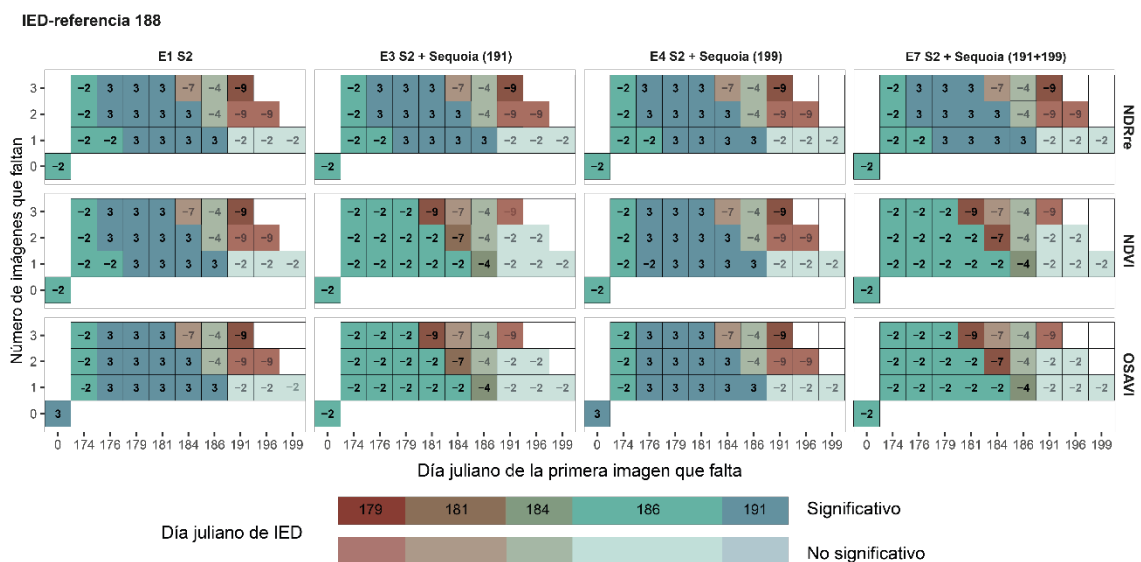


Figura IV-15. Diferencias del IED determinado para girasol mediante el método DPC y los datos de campo para los tres índices de estudio derivados de MSI de Sentinel y Sequoia en 2019 (serie temporal en días julianos). Nivel de significación $p < 0,05$.

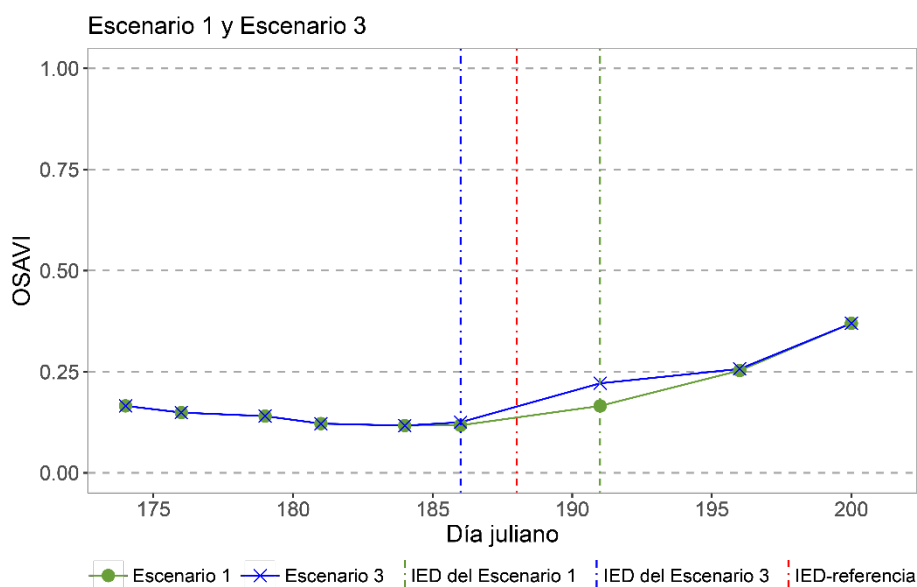


Figura IV-16. Diferencias en la serie temporal OSaVI e IED del girasol entre la serie de datos de Sentinel 2 y la serie en la que se incorporan datos de Sequoia.

En general, si los datos de Sequoia se incorporan al comienzo de la serie y antes de que se produzca el IED, este se determina más tarde que cuando únicamente se construye la serie temporal con datos de Sentinel 2. En cambio, si los datos se sustituyen en la parte final de la serie temporal, tras producirse el IED, este se determinará días antes.

IV.3 Discusión

La mayoría de los estudios fenológicos se centran en la detección de etapas fenológicas de manera retroactiva (Cao et al., 2015; Gao et al., 2017; Zhang et al., 2003, 2020). Estos enfoques suelen utilizar métodos de ajuste de curvas o de umbral, que necesitan una serie larga de datos de IV –incluido el valor máximo de IV– para construir la función de ajuste confiable. Existen también programas informáticos como TIMESAT (Jönsson & Eklundh, 2004) o DATimeS (Belda et al., 2020) que analizan y reconstruyen la serie temporal y extraen los parámetros estacionales relacionados con las temporadas de crecimiento. Pero normalmente necesitan el ciclo completo del cultivo con imágenes de satélite para encontrar la información estacional confiable (Belda et al., 2020; Jönsson & Eklundh, 2004). Además, en estos estudios previos, el *green-up* para maíz se detecta de 2 a 4 semanas después de la emergencia, cuando el cultivo se encuentra en estadio V3.

Actualmente, se están incorporando estudios fenológicos centrados en la detección de la fenología en tiempo real. Liu et al. (2018) integran la fenología climatológica y las observaciones de dos años de observaciones satelitales; simulan el crecimiento de cultivo utilizando un modelo logístico e identifican las etapas LSP utilizando la tasa de cambio de la curvatura. Gao et al. (2020) utilizan el algoritmo WISE, que es un enfoque similar a la metodología realizada en este estudio; en primer lugar, se suaviza la serie de datos y en segundo lugar se buscan las fechas de transición dentro de la serie temporal. En ambos enfoques no son necesarias las imágenes del ciclo completo del cultivo, sino que se pueden llevar a cabo con las imágenes que cubran las primeras etapas del crecimiento.

La metodología desarrollada en este capítulo utiliza el filtro SG y una prueba de detección de punto de cambio para encontrar la fecha de transición. Tanto SG como las pruebas de detección de punto de cambio ensayadas no necesitan una serie temporal larga que cubran el ciclo completo del cultivo, pudiéndose utilizar para detectar el IED una serie de datos de únicamente las primeras etapas de crecimiento.

Los resultados obtenidos muestran que, de las tres pruebas de detección de punto de cambio, la prueba de Pettitt es la que ofrece un IED más cercano al IED-referencia. La prueba de Rangos de Buishand ofrece sistemáticamente IED posteriores a los obtenidos con la prueba de Pettitt y algo más alejados del IED-referencia. SNHT es la prueba de detección de cambio que peores resultados ofrece, dando, al igual que la prueba de Rangos de Buishand, IED posteriores al de referencia. De las tres pruebas, la de Pettitt es sensible al IV utilizado en la serie de datos. Los IED con las pruebas de Pettitt y de Rangos de Buishand son en general parecidos o mejoran la determinación del IED obtenido con AjLog_PMC. El método del AjLog_PMC ofrece resultados similares a los detectados por estudios previos que aplican estas metodologías más estandarizadas, detectando el IED cuando el cultivo se encuentra en V3. Este método, al igual que la prueba de Pettitt, ofrece IED diferentes según la serie temporal del índice que se utiliza.

Los resultados varían según el IV que se utiliza para generar la serie temporal. NDVI y NDRre ofrecen IED similares y más aproximados al IED-referencia, mientras que OSAVI retrasa la detección del IED.

A la vista de los resultados obtenidos, la opción que se propone para determinar el IED es la prueba de Pettitt aplicada a una serie temporal de datos de NDVI o NDRre. Con esta metodología se consigue determinar el IED para los cultivos de segunda cosecha en la ZRV con una FCV del 10%, entre 10 y 15 días después de la siembra para girasol –cuando está en estadio V2 y V4– y entre 11 y 16 días después de la siembra para maíz, cuando está entre los estadios V2 y V3. Gao et al. (2020), con el enfoque WISE, determinan el *green-up* de 4 a 5 días después de la emergencia de cultivo, en estadio VE-V1 para maíz y VE-VC para soja. La diferencia con el trabajo que aquí se presenta es que el enfoque WISE lo hace sobre cultivos sin una cobertura anterior; en cambio, en este trabajo se ha aplicado la metodología propuesta en cultivos sobre rastrojo de cebada (cultivo anterior) y los restos de vegetación de cebada repercuten en la observación del nuevo cultivo, detectando el IED en estadio más avanzado, V2-V3, que cuando lo detectan Gao et al. (2020). La metodología propuesta por Liu et al. (2018) da como resultado diferentes pronósticos para las fases del *green-up*. Estos autores concluyen que la simulación de *green-up* “medio”, que es la fase del cultivo cuando se encuentra en la mitad de la etapa de desarrollo, es el mejor relacionado con las fechas de siembra y emergencia de los cultivos, por lo que estos autores consideran la fecha de *green-up* “medio” un identificador eficaz para determinar de las fechas de siembra y emergencia. Una diferencia fundamental con la propuesta de esta tesis es que utilizan series temporales de datos construidas a partir de imágenes del satélite VIIRS cuya resolución espacial mejor es de 371 m, lo que limita su aplicación según la escala de trabajo. Además, el proceso metodológico que utilizan es complejo y dependiente de situaciones climáticas de años

anteriores. La metodología que se presenta en esta tesis, a pesar de que el IED se obtiene alrededor de dos semanas después de que se produzca, la resolución de las imágenes Sentinel 2 permite estimar el IED a escala de parcelas; además, la metodología aplicada es sencilla, fácil de automatizar y reproducible.

El impacto de los datos perdidos en la serie temporal en la determinación de IED varía en función de la duración del periodo sin imágenes y del momento del ciclo en el que se produce. Como se ha podido comprobar en el análisis realizado, los resultados son dependientes del número de datos utilizados, es decir del número de imágenes satelitales. Si el periodo sin imágenes se produce cerca de la siembra, la determinación del IED mediante la prueba de Pettitt no se ve afectada. En cambio, cuando el lapso sin imágenes se encuentra cercano al IED, los resultados se alteran, adelantándose notablemente la determinación de la fecha de IED. Si el periodo sin imágenes es posterior al IED y faltan más de dos imágenes consecutivas, los resultados no son significativos a un intervalo de confianza del 95%. Así, los IED estimados para el año 2018 se ajustan más a los de referencia debido principalmente a que la recurrencia de imágenes en el momento en el que se produjo el IED fue de 2 a 3 días. En cambio, para 2019, en el momento del IED se dispone de una imagen de satélite menos, por lo que el periodo sin imágenes es de 5 días. La carencia de datos en el momento en el que se produce el IED o en momentos posteriores no permite reflejar el momento real del IED, estimándose con anterioridad este momento. Esto mismo ocurre en el trabajo de Pan et al. (2021), donde la falta de imágenes en el punto de inflexión de la serie de tiempo de la combinación de índices NDVI y LSWI hace que no se pueda determinar el momento del crecimiento de los cultivos con exactitud.

Por tanto, la metodología propuesta en este capítulo requiere para tener un resultado fiable (más/menos 2 días de error) disponer de imágenes al menos cada 2 o 3 días en el periodo anterior y posterior a producirse el IED.

Ha quedado patente que la determinación del IED de forma temprana depende de la calidad y cantidad de las imágenes satelitales. La presencia de nubes puede durar consecutivamente varios días, lo que reduce en gran medida la disponibilidad de datos y la precisión de la determinación del IED. Para solventar este problema se puede aumentar el número de imágenes combinando las procedentes de satélite con otras obtenidas mediante UAV y así superar los problemas ocasionados por la presencia de nubes. En estudios anteriores, Kowalski et al. (2020) y Pan et al. (2021) comprobaron cómo la combinación de varios sensores aumenta el número de observaciones y hace más confiables los resultados. Para combinar datos de múltiples sensores tiene que garantizarse una consistencia en los datos (Gao et al., 2010), como se ha constatado en el Capítulo III, donde se ha puesto de manifiesto que la consistencia entre los IV obtenidos de MSI de Sentinel 2 y de Sequoia tienen una alta correlación. Las series temporales en las que se han sustituido datos del sensor MSI de Sentinel 2 por Sequoia han arrojado resultados confiables, sobre todo cuando se utiliza el índice NDRre. Los resultados del Capítulo III sugieren que la relación entre sensores Sequoia y MSI de Sentinel 2 es mejor al comienzo del ciclo del cultivo; es por ello que la determinación del IED —que se produce en los primeros días del ciclo— utilizando la serie de

datos de NDRre combinada de MSI de Sentinel 2 y Sequoia genera resultados similares a los de la serie de datos de MSI de Sentinel 2.

Esto abre la posibilidad de completar con un vuelo UAV la serie temporal de datos de Sentinel 2, especialmente en los momentos críticos cercanos al IED, cuando han pasado más de tres días con nubosidad y las previsiones meteorológicas indican persistencia de nubes y el paso del satélite ha coincidido o coincidirá con estos eventos nubosos. La limitación que presenta frente a de Sentinel 2 es que solo será aplicable a escala de parcela o explotación ya que los vuelos con UAV dependen en gran medida de la duración de la batería. Para zonas más extensas se puede plantear la adquisición de imágenes con vuelos UAV en diferentes localizaciones con variabilidad fenológica y extender el resultado a otras áreas con fenologías similares. Para ello se precisará conocer la zonificación de fenológica en el área que se quiere aplicar, aspecto que se abordará en el siguiente capítulo.

Finalmente, indicar que esta metodología se ha aplicado en una zona donde la recurrencia de imágenes es de 2 a 3 días, pero habría que probar en un futuro en otras zonas donde el lapso temporal entre imágenes es mayor, con recurrencia de 5 días, ya que se ha observado que cuando los huecos entre imágenes son más amplios, como ocurre en el año 2019, los resultados se ven alterados.

V. Distribución del IED en parcelas comerciales de maíz y girasol de segunda cosecha del Valle del Ebro en Aragón

En este Capítulo V se aborda el objetivo III de la tesis, la identificación y el análisis de la distribución espacial del inicio de la etapa de desarrollo en parcelas comerciales de maíz y girasol de segunda cosecha en los regadíos de Aragón. Se persigue aportar una metodología e información para la monitorización de cultivos de la PAC en relación con la condicionalidad reforzada, concretamente con las prácticas del *Greening* en el marco de las Buenas Condiciones Agrarias y Medioambientales, BCAM 7 “Rotación en tierras de cultivo excepto en cultivos bajo agua” (Ministerio de Agricultura, 2021). El Real Decreto 1172/2015 incluye que el periodo en el que se llevará a cabo por parte de la Administración la verificación del número de cultivos y su superficie (porcentaje que ocupan) será entre los meses de mayo y julio. No obstante, indica también que las Comunidades Autónomas podrán ajustar dicho periodo teniendo en cuenta sus condiciones agroclimáticas propias. Para cumplir con la BCAM 7 en cuanto a la diversificación de cultivos, el cultivo declarado –con el que se persigue la diversificación– debe permanecer mayoritariamente en ese periodo; con "mayoritariamente" se entiende al menos la mitad del período.

En cultivos extensivos de invierno y verano la fecha de siembra y el ciclo fenológico permite en Aragón hacer la monitorización con las imágenes de satélite y obtener los resultados de forma temprana. Pero en el caso de las dobles cosechas, el segundo cultivo no se siembra hasta después de cosechar el cultivo de invierno, por lo que los resultados de la monitorización del cultivo de segunda cosecha se retrasan (comunicación personal de los técnicos del Gobierno de Aragón, 15 de febrero de 2017, 4 de julio de 2017 y 18 de abril de 2022).

Como se ha constatado en el Capítulo IV, la prueba de Pettitt es útil para determinar de forma temprana y con bastante exactitud el momento IED de los cultivos. Por ello, en el presente Capítulo se va a aplicar a una serie de parcelas localizadas en los regadíos del Valle del Ebro en Aragón con fecha de siembra desconocida, por lo que se debe establecer el periodo de la serie temporal de datos a considerar para su aplicación. En Aragón, las segundas cosechas de maíz y girasol se siembran entre mediados y final de junio (Gutiérrez López, 2022; Gutiérrez & Aranda, 2020, 2021; Mur et al., 2021), aunque en alguna explotación se puede llegar a sembrar hasta la primera semana de julio. En función de ello se va a considerar el periodo entre el 13 de junio y el 31 de julio para la serie temporal de datos.

Las variaciones regionales del momento del IED responden a factores relacionados con el propio cultivo (especie, variedad, fecha de siembra, manejo, etc.), con la climatología de cada zona y con las condiciones meteorológicas propias de cada campaña agrícola. Estos factores deben tenerse en cuenta a la hora de determinar el IED y analizar su ocurrencia en el territorio estudiado. En Aragón las dobles cosechas son variadas, combinándose distintos

cultivos. La fecha de siembra del maíz y girasol en la doble cosecha dependerá de cuál sea el cultivo que la precede, ya que cada cultivo presenta diferentes ciclos, variando el momento de su cosecha o recolección. Además, la diversidad climática de Aragón será otro factor a considerar, así como las condiciones meteorológicas específicas de cada uno de los dos años de estudio, 2018 y 2019.

V.1 Material y métodos

El flujo de trabajo propuesto para el desarrollo de este Capítulo de la tesis doctoral se muestra en la Figura V-1. En la primera fase se realiza el tratamiento de la información temática y espacial –declaraciones PAC y SIGPAC– con la que se seleccionan las parcelas con segundas cosechas de maíz y girasol. En la segunda fase se obtiene de las imágenes de satélite la serie temporal de IV para cada parcela. Por último, se determina el IED aplicando la prueba de Pettitt. El área de estudio en la que se va a desarrollar esta parte de la tesis corresponde a los principales regadíos de la Cuenca del Ebro en Aragón (apartado II.2.1 del Capítulo II).

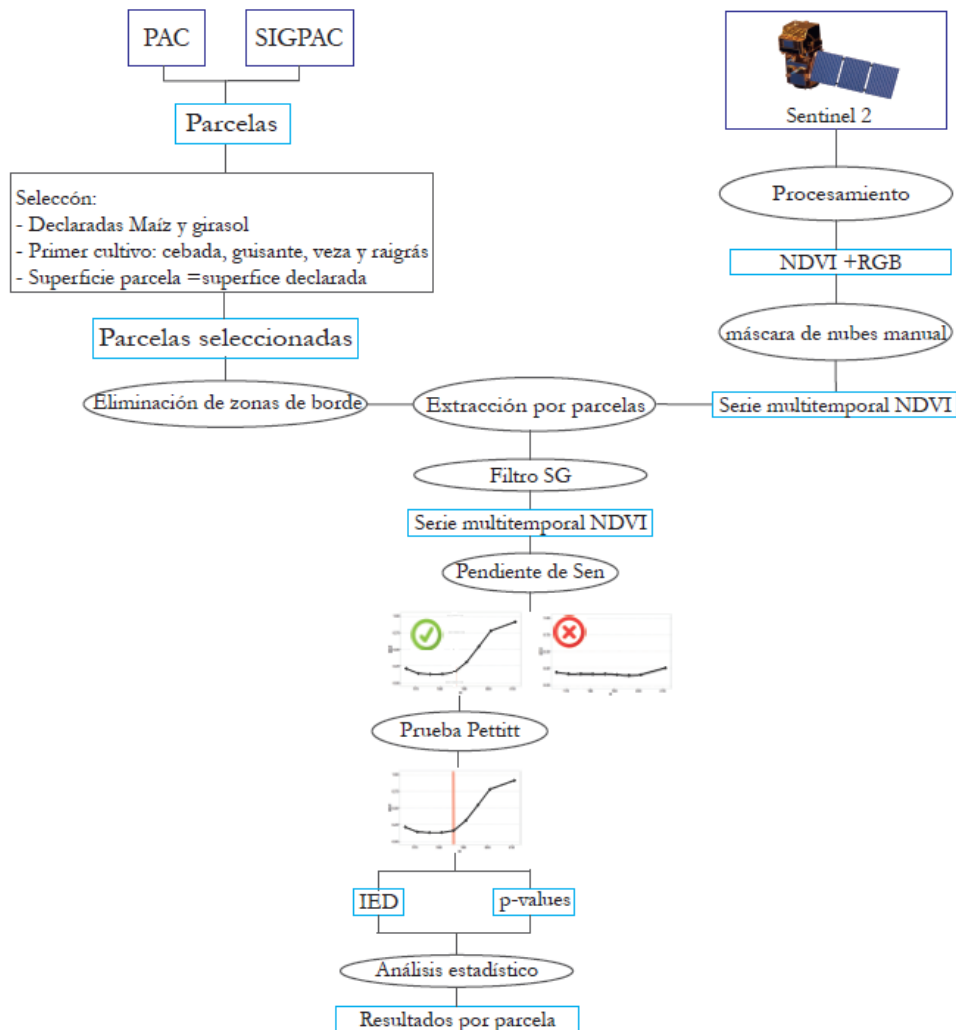


Figura V-1. Flujo de trabajo general de la metodología para determinar y analizar el IED del maíz y del girasol en el Valle del Ebro en Aragón.

V.1.1 Selección de parcelas con doble cosecha

Las dobles cosechas objeto de estudio en este Capítulo corresponden con las compuestas por un primer cultivo de cebada, guisantes, veza o raigrás seguido de maíz y girasol, siendo éstas las más representativas en el área de estudio de acuerdo con las declaraciones PAC 2018-2019. Para elegir una muestra de parcelas con estas dobles cosechas se utilizó la información facilitada por el Gobierno de Aragón de los cultivos declarados en la PAC de los años 2018 y 2019. Se seleccionaron diferentes parcelas declaradas con dos cosechas anuales y cuyo segundo cultivo fuera maíz o girasol. La localización de estas parcelas se puede consultar en el Apartado II.3 del Capítulo II. Para poder representar espacialmente esta información se utilizó como base cartográfica el parcelario del SIGPAC, también facilitado por el Gobierno de Aragón, a la que se asoció la información sobre cultivos declarados por los agricultores.

Los pasos y criterios seguidos en la selección de parcelas con doble cosecha de maíz y de girasol fueron: 1) selección de los recintos cuyo cultivo declarado (producto declarado) corresponde con maíz o con girasol; 2) selección de aquellos recintos en los que la superficie declarada como maíz o girasol es toda la superficie del recinto, ya que a veces se pueden encontrar recintos con varios productos declarados que podrían conducir a errores (Figura V-2); 3) selección de los píxeles que se encuentran en el interior de la parcela, sin considerar los píxeles que interceptan con el borde para evitar confusiones de píxeles mixtos

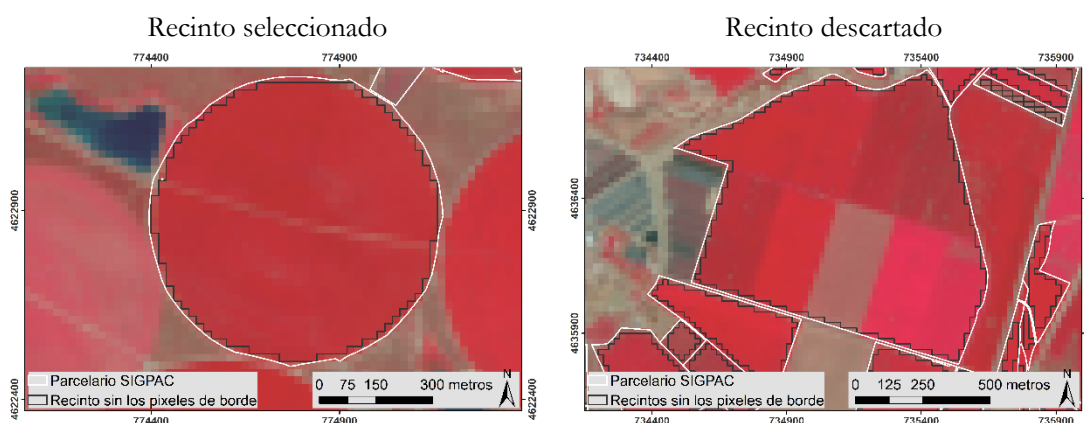


Figura V-2. Visualización en imagen Sentinel 2 (RGB:7-4-3) de los recintos SIGPAC seleccionados y descartados según tengan uno o más cultivos declarados.

V.1.2 Procesamiento de imágenes de Sentinel 2

Las imágenes que se utilizaron en este Capítulo han sido el producto nivel 2A de la misión Copernicus Sentinel 2 (descripción más completa en el apartado 3.1.4 del Capítulo III). El área de estudio se incluye en las teselas TXM, TYM y TYL. La serie temporal de imágenes varía de unas parcelas a otras según su localización por el solape de pasadas de Sentinel 2 (Figura V-3). Se obtuvieron un total de 67 imágenes: 29 para la tesela TXM, 19 para la tesela TYM y 19 para la tesela TYL. En la Figura V-4 se presenta la distribución temporal de las imágenes.

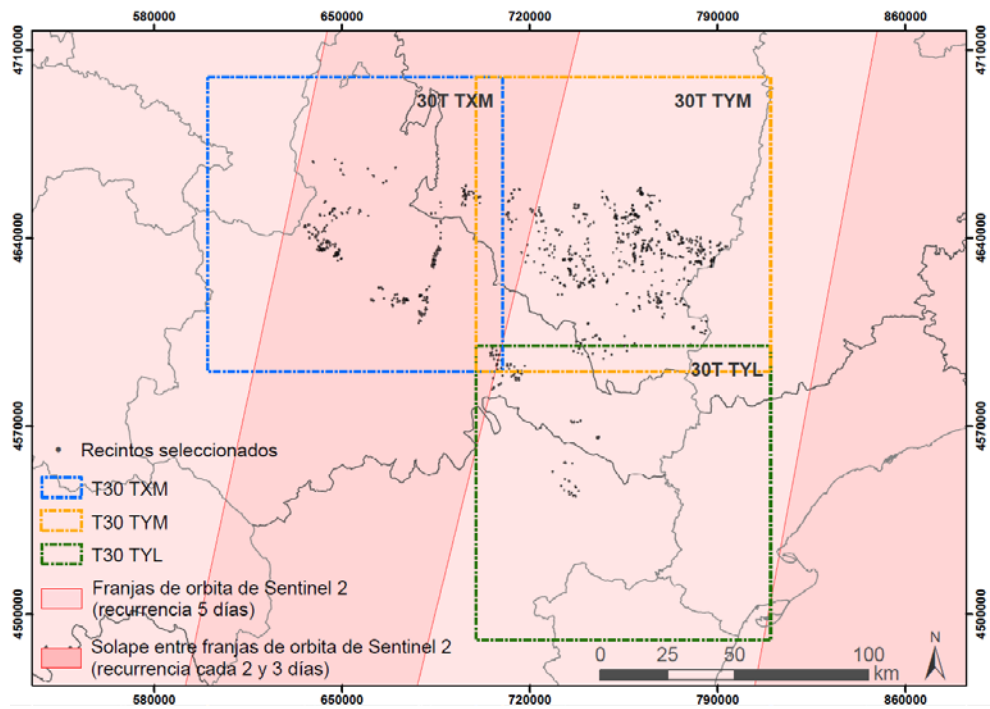


Figura V-3. Órbitas de paso de Sentinel 2 y teselas utilizadas.




Figura V-4. Fecha de adquisición de Sentinel 2 y porcentaje de píxeles sin nubes sobre las parcelas de estudio para los años 2018 y 2019.

Las tareas de procesamiento para la construcción de la colección de imágenes de la serie temporal se realizaron en la plataforma Google Earth Engine (GEE). Como ya se ha señalado previamente, las imágenes se obtuvieron para los años 2018 y 2019 en el periodo comprendido entre el 13 de junio y el 31 de julio. Se aplicó una máscara de nubes utilizando la banda de máscara de bits QA60, que contiene la información sobre nubes, y se calculó el NDVI para cada imagen. Sin embargo, esta información solo permite enmascarar las nubes opacas, por lo que no se eliminaron áreas de la imagen donde seguía observándose algún cirro, neblina y sombras de las nubes (Figura V-5). Por ello, se decidió ampliar la máscara de forma manual mediante un análisis visual, ya que si en la serie temporal de NDVI se incluyen observaciones afectadas por nubes, cirros, neblina y sombras pueden provocar

incertidumbres adicionales en la estimación de IED (Forkel et al., 2013). Esta ampliación de máscara de nubes se realizó de forma manual con [ArcMap 10.7.1](#) (ESRI, 2019)




Figura V-5. Mascara de nubes: a) Imagen Sentinel 2 (RGB 4-3-2); b) máscara de bits QA60 (color salmón) sobre NDVI; c) ampliación de la máscara de nubes realizada manualmente.

V.1.3 Datos meteorológicos

El desarrollo de los cultivos depende de la temperatura, las horas de sol o las precipitaciones en diferentes periodos de su ciclo. Por tanto, la variabilidad del clima puede explicar las variaciones en el ciclo los de cultivos (Iizumi & Ramankutty, 2015). Por tanto, las variaciones en el ciclo del cultivo de un año pueden ser explicadas por eventos meteorológicos. Por ello se recogió información sobre temperatura y precipitación para analizar su variación en Aragón y la relación con el momento en que se produce el IED.

Se consultaron las categorías sintéticas de temperatura y precipitación de España para cada año de estudio en los documentos “Calendario Meteorológico 2019 y 2020 Información meteorológica y climatológica de España” (de Cara et al., 2018, 2019).

Además, se elaboraron una serie de climogramas a escala mensual a partir de los datos de varias estaciones meteorológicas distribuidas por el área de estudio (Figura V-6), pertenecientes a la Red de estaciones agrometeorológicas del Sistema de Información Agroclimática para el Regadío (SIAR, <https://portal.mapa.gob.es/websiar/Inicio.aspx>).

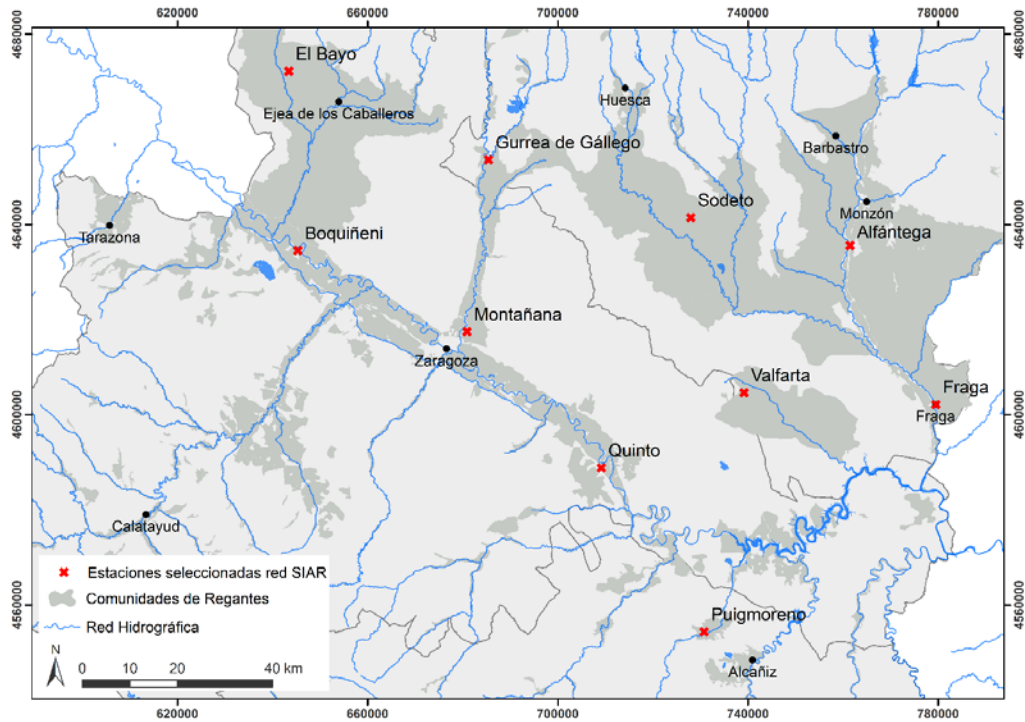


Figura V-6. Localización de las estaciones agrometeorológicas del Sistema de Información Agroclimática para el Regadío (SIAR).

V.1.4 Detección del IED

Para la detección del IED se generó la serie temporal de datos NDVI procedentes de imágenes Sentinel 2, IV que, como se comprobó en el Capítulo IV, ofrece buenos resultados en la detección del IED. A la serie temporal se le aplicó el filtro SG, tal y como se detalla en la metodología descrita en el apartado IV.1.5.2 del Capítulo IV.

Como los agricultores realizan la declaración de la PAC en los meses de febrero a abril y la siembra de los segundos cultivos generalmente se realiza en junio, según meteorología y el mercado, pueden decidir a última hora no realizar la segunda cosecha. Para detectar estas situaciones se aplicó la pendiente de Sen (Sen, 1968), que se calcula con la siguiente Ecuación (V-1):

$$d_k = \text{mediana} \frac{x_j - x_i}{j - i}, \quad j > i \quad (\text{V-1})$$

donde d es la pendiente, x_i y x_j son los valores en los momentos j e i , respectivamente.

Esta prueba ha sido ampliamente utilizada en el análisis de datos climatológicos (Malede et al., 2022; Samy et al., 2019; Yang et al., 2013), porque es menos sensible a la no-normalidad de la distribución y se ve menos afectada por valores extremos o atípicos en la serie. Un valor positivo de la pendiente de Sen indica una tendencia creciente y un valor negativo indica una tendencia decreciente en la serie temporal y, por tanto, que no hay nuevo cultivo y la parcela es descartada del estudio.

La detección del IED se realizó con la prueba de punto de cambio de Pettitt. Su descripción se puede encontrar en el Apartado IV.3.2.1 del Capítulo IV. El intervalo de confianza fijado para la prueba de Pettitt se estableció en 90% ($p\text{-value} > 0,1$). Si el estadístico de la prueba estimado es inferior al intervalo de confianza del 90% no se puede rechazar la hipótesis nula de que no hay cambio en la serie de datos y, por lo tanto, se considera que no existe cambio estadísticamente significativo para el nivel de confianza fijado. Para analizar la variación de los p- values se utiliza el valor de la mediana de todos los píxeles de la parcela, se generan diagramas de cajas y cartografía de su distribución en la zona de estudio.

Finalmente, los IED obtenidos para cada parcela se cartografían a partir de la moda de todos los valores de la parcela.

V.2 Resultados

V.2.1 Dobles cosechas y su distribución

En los regadíos de Aragón cada vez es más frecuente la incorporación de las dobles cosechas, como ponen de manifiesto las Figuras I 3 y I 4 del Capítulo I. Las parcelas seleccionadas para el desarrollo de este capítulo fueron 807 en 2018, que suponen un total de 2226 ha, y 1030 en 2019 que suponen un total de 3332 ha (Tabla V-1). La superficie media de las parcelas seleccionadas en 2018 es de 2,76 ha y de 3,23 ha para 2019, aunque hay parcelas de todos los tamaños, desde la mayor de 84,62 ha a la más pequeña con 0,11 ha.

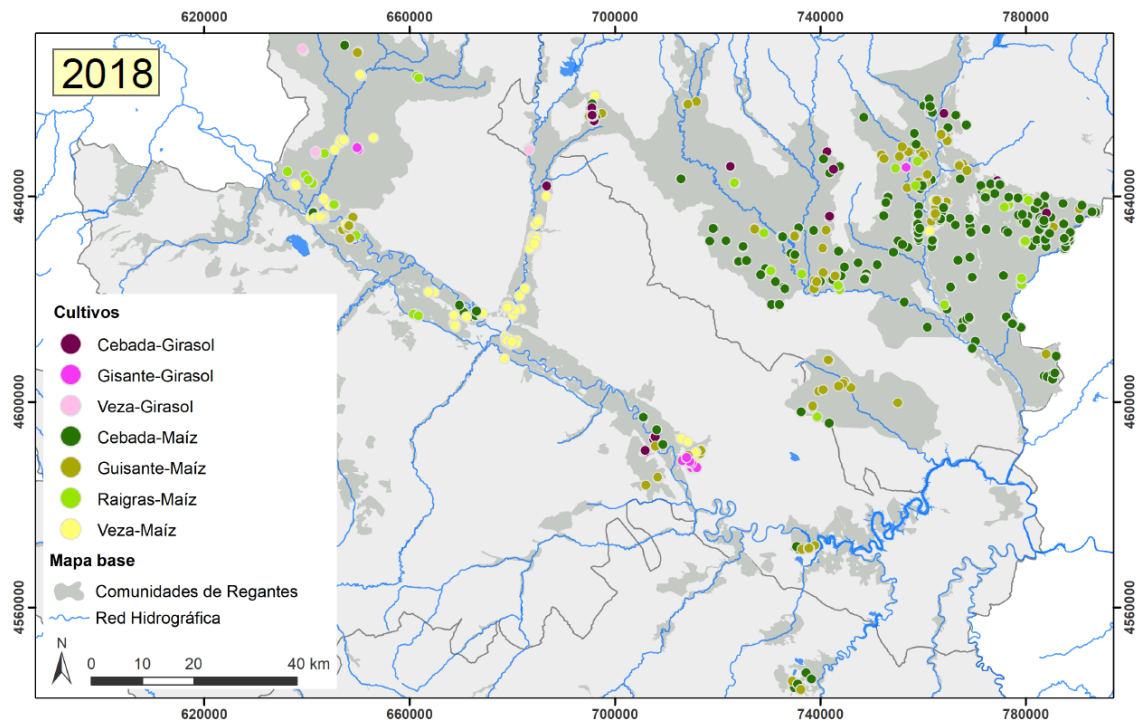
Tabla V-1. Superficie declarada y número de parcelas seleccionadas por cultivos y por provincias para los años de estudio.

2018								
Cultivo	Huesca		Teruel		Zaragoza		Total	
	Sup. Dec (Ha)	n° recintos	Sup. Dec (Ha)	n° recintos	Sup. Dec (Ha)	n° recintos	Sup. Dec (Ha)	n° recintos
Guisante-Girasol	4,8	2			73,7	20	78,5	22
Guisante-Maíz	453,7	103	30,3	3	132,8	51	616,8	157
Cebada-Girasol	63,8	27			31,1	10	94,9	37
Cebada-Maíz	923,8	304	36,4	6	146,4	20	1106,6	330
Veza-Girasol	7,8	6			25,5	14	33,3	20
Veza-Maíz	13,8	10			177	161	190,8	171
Raigrás-Maíz	47,6	38			57,2	31	104,8	69
Total	1515,3	490	67,2	10	643,8	307	2226,3	807

2019								
Cultivo	Huesca		Teruel		Zaragoza		Total	
	Sup. Dec (Ha)	n° recintos	Sup. Dec (Ha)	n° recintos	Sup. Dec (Ha)	n° recintos	Sup. Dec (Ha)	n° recintos
Guisante-Girasol					56,7	6	56,7	6
Guisante-Maíz	861,9	139	17,2	1	66,5	26	945,6	166
Cebada-Girasol	54,1	8	3,4	2	32,6	19	90,1	29
Cebada-Maíz	1403,8	437	195,7	42	32,7	17	1632,2	496
Veza-Girasol					77,1	41	77,1	41
Veza-Maíz	173,1	66			189,5	183	362,6	249
Raigrás-Maíz	134,0	27	0,4	1	33,0	15	167,4	43
Total	2627,0	677	216,8	46	488,0	307	3331,8	1030

Las parcelas de dobles cosechas seleccionadas se distribuyen en el área de estudio como se muestra en la Figura V-7. Su distribución depende de la doble cosecha y se concentran en diferentes regadíos, a los que se hará referencia en el texto conforme a la nomenclatura de la Figura II. 7 del Capítulo II.

En los regadíos del Canal de Aragón y Cataluña predominan las dobles cosechas de cebada-maíz y, en menor medida, de raigrás-maíz, tanto en 2018 como en 2019. En Riegos del Alto Aragón son mayoritarias las dobles cosechas de cebada-maíz y de guisante-maíz en 2018; en 2019 se añaden además las de veza-maíz. En los regadíos del Río Guadalupe predominan cebada-maíz y, en menor medida, las de guisante-maíz. En la provincia de Zaragoza, las dobles cosechas de cebada-maíz prácticamente desaparecen y la combinación mayoritaria es veza-maíz, sobre todo en los regadíos del Río Gallego, del Canal Imperial y del Canal de Tauste. En los dos años de estudio se dan también dobles cosechas con raigrás-maíz en el Canal de Tauste y el Canal Imperial. En el Canal de Bardenas y en los regadíos del Ebro medio se observa mezcla de dobles cosechas, incorporándose en esta zona como segundo cultivo el girasol, principalmente en 2019, que era prácticamente inexistente en el año anterior.



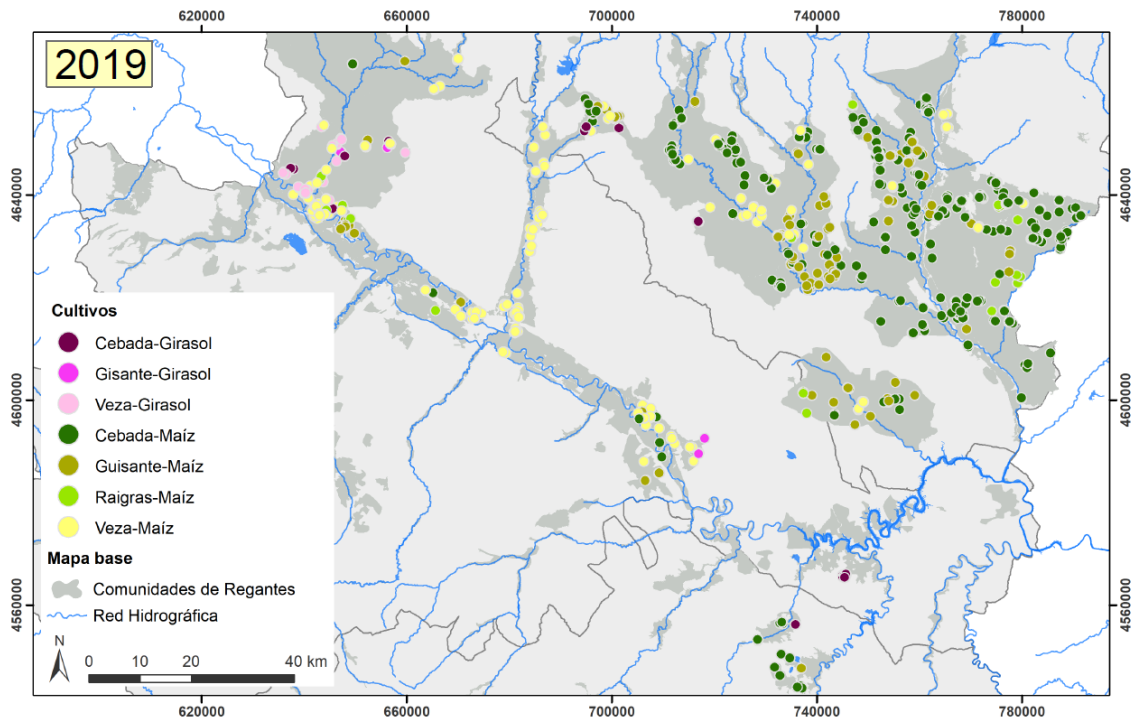
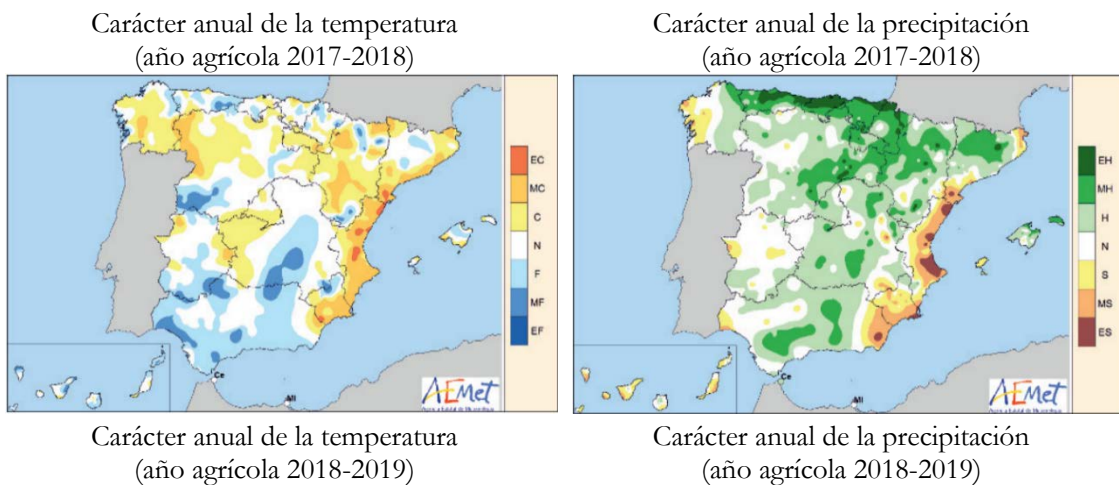


Figura V-7. Parcelas seleccionadas de dobles cosecha con segundo cultivo de girasol y de maíz en 2018 y 2019.

V.2.2 Variabilidad espacial de la precipitación y temperatura

En la Figura V-8 se observa la distribución de temperatura y precipitación en España en los años agrícolas 2017-2018 y 2018-2019. En Aragón, la mayor parte de la superficie presenta temperaturas cálidas en el año 2017-2018. Se aprecia que las temperaturas variaron según las zonas de normal, a cálido y a muy cálido, siendo frías en zonas del noreste y sur de la Comunidad, fuera de los regadíos analizados. Las precipitaciones fueron abundantes y el año fue de húmedo a muy húmedo en general. En el año 2018-2019 las temperaturas fueron más altas que en el año anterior, caracterizándose como muy cálido en la zona de estudio; en cuanto a las precipitaciones, fueron menores que el año anterior, variando el carácter anual entre húmedo, normal y seco según zonas.



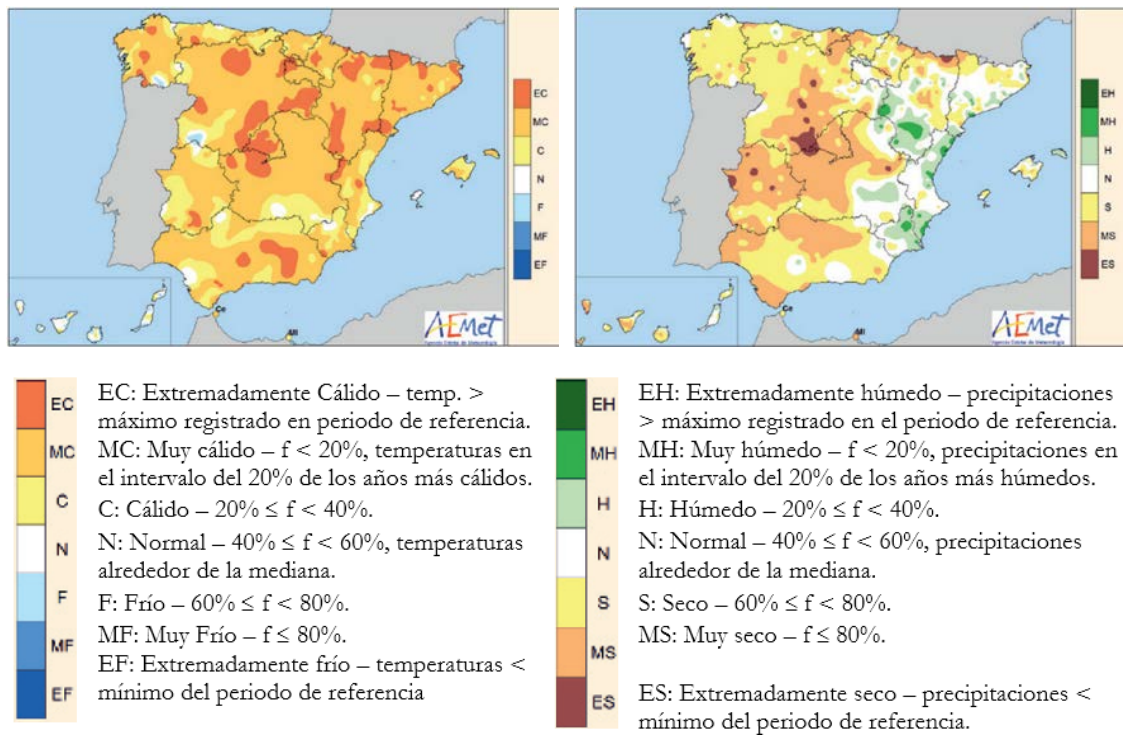
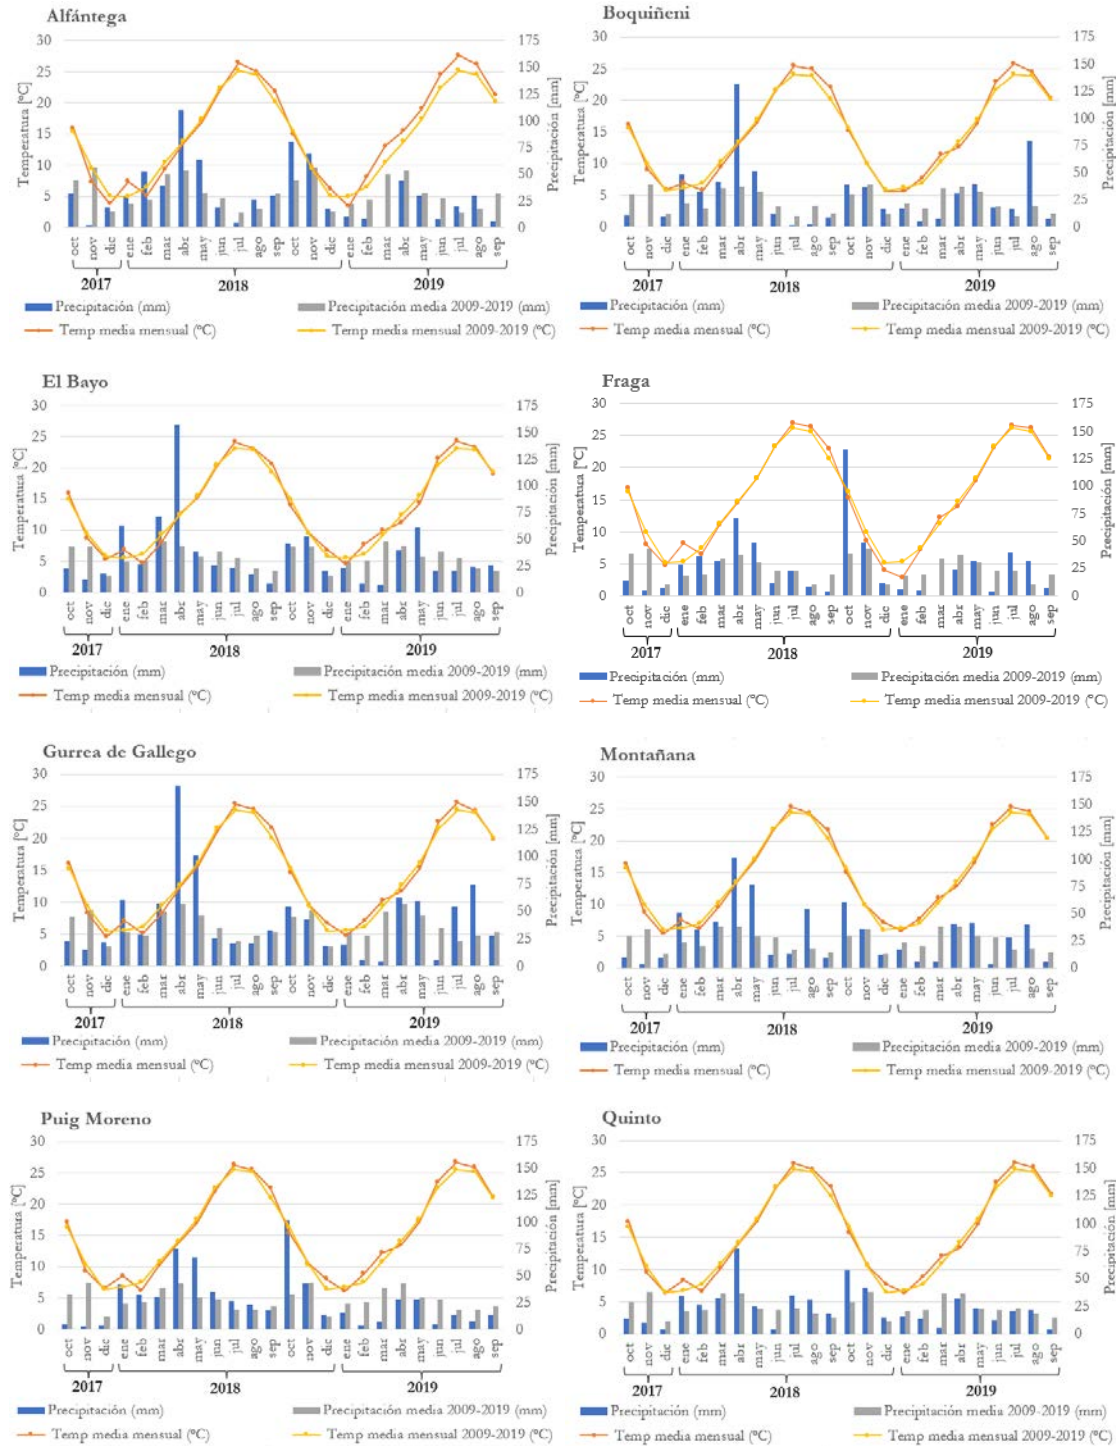


Figura V-8. Carácter de la temperatura y de la precipitación para los años agrícolas 2017-2018 y 2018-2019 (de Cara et al., 2018, 2019).

La distribución anual de las precipitaciones y temperatura condiciona el desarrollo de los cultivos. Por ejemplo, los episodios de lluvias abundantes en la época de la siembra del cereal de invierno –de final de octubre a comienzos de noviembre– provocan que muchas parcelas permanezcan encharcadas o con demasiada humedad en el suelo si no están alternados por días soleados, siendo imposible entrar con la maquinaria para sembrar (Gutiérrez & Aranda, 2019), por lo que se retrasa la siembra del cereal de invierno, su cosecha y la siembra del segundo cultivo en las dobles cosechas. Estas lluvias de otoño también pueden afectar a la cosecha de los cultivos de verano, por no poder entrar con la maquinaria por acumular humedad y no cumplir el grano las condiciones idóneas de humedad para obtener un buen rendimiento. Igualmente, cuando se siembran el maíz y el girasol de segunda cosecha –de mediados de junio a principios de julio– si se dan episodios de lluvias se retrasa la siembra y con ello se va retrasado el ciclo del cultivo principalmente en sus fases iniciales. La falta de precipitaciones, a no ser que se produzca una sequía que obligue a restricciones en el suministro del agua de riego, no afecta tanto a los cultivos de regadío, ya que la falta de agua puede ser suplida con los riegos. En relación con las temperaturas, cuando son frías en el periodo de espigado y maduración de la cebada provocan que el desarrollo sea más lento, retrasando su cosecha y, por tanto, la siembra del segundo cultivo de la doble cosecha. Por el contrario, temperaturas muy altas en los periodos de espigado y maduración hacen que el desarrollo sea más rápido y pueda adelantarse la recolección y la siembra del segundo cultivo.

En los climogramas de la Figura V-9 se aprecia que las temperaturas entre estaciones siguen un patrón similar y no difieren sustancialmente. En cuanto a las precipitaciones el patrón también es bastante similar entre estaciones, si bien las diferencias en la cuantía son generalmente más acusadas para un mismo mes.

Destaca para el año agrícola 2017-2018 un otoño bastante seco en comparación con la media de los años 2009-2019. A pesar de estar caracterizado como un año muy húmedo, es notable la falta de precipitaciones hasta el mes de enero, lo que dificultó la siembra de los cultivos de invierno. A partir de enero, el invierno, con pluviometría bastante importante, ayuda a la nascencia y el desarrollo de las siembras de noviembre y diciembre. En cuanto a la temperatura, la de enero fue superior a la media de los últimos 10 años, pero en los meses de finales de invierno y comienzos de primavera fue menor. Estos periodos de bajas temperaturas alargan el periodo de espigado y maduración de los cereales de invierno, retrasando algo su recolección.






Figura V-9. Climogramas de la zona de estudio para los años agrícolas 2018 y 2019.

Para el año agrícola 2018-2019, a pesar de estar caracterizado como un año de húmedo, normal a seco (Figura V-8), las precipitaciones fueron en general abundantes durante el otoño; estos periodos de lluvias retrasan el periodo de siembra. En los meses de invierno hay una falta de precipitaciones importante que en muchos casos dificulta la nascencia. En cuanto a la temperatura, en los meses de final de invierno y comienzo de primavera son algo más altas en comparación con la media de años de 2009-2019, lo que colabora a que se adelante el proceso de maduración del cultivo de invierno. Aunque las temperaturas en primavera fueron altas, el retraso en el periodo de siembra y la falta de precipitaciones en los meses de invierno hicieron que el cereal de invierno fuese con retraso y, por tanto, se retrasase la siembra del segundo cultivo.

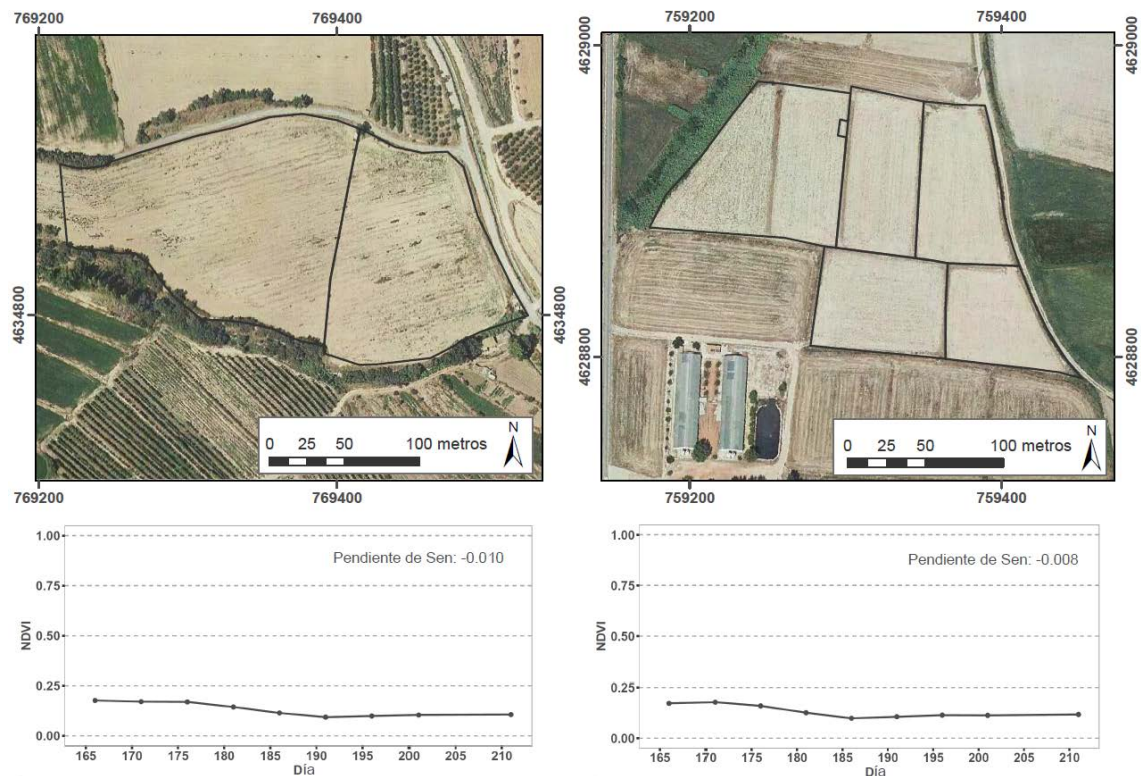


Figura V-10. Ejemplo de parcelas descartadas mediante la pendiente de Sen. Ortofotografía de PNOA de 2018.

V.2.3 Depuración de las parcelas seleccionadas mediante la prueba de la pendiente de Sen

Las parcelas con un valor negativo en la prueba de Sen y, por tanto, no consideradas en el estudio, fueron para el año 2018 un 7% y para el año 2019 un 8% de las parcelas totales. En la Figura V-10 se observan dos ejemplos de parcelas que han sido descartadas. En la ortofoto de PNOA de agosto de 2018 se aprecia que no hay ningún cultivo implantado. El NDVI presenta valores en toda la serie temporal—de mitad de junio a final de julio— inferiores a 0,25 corroborando que se trata de suelo desnudo.

V.2.4 Comportamiento de la prueba de Pettitt

Como se vio en el Capítulo IV, el número de observaciones condiciona los resultados de IED al aplicar la técnica de detección de punto de cambio de Pettitt para su determinación. Para las parcelas localizadas en las teselas TYM y TYL hubo en general un número menor de observaciones que para la tesela TXM. En la Figura V-11 se muestra un ejemplo de la serie de datos para la tesela TYM en 2018 (izquierda) y para la tesela TXM en 2019 (derecha).




Figura V-11. Series temporales de NDVI para dos parcelas de las teselas TYM, en 2018, y TXM, en 2019.

En la Figura V-12 se representan los valores de significación de la prueba de Pettitt. Si el momento de IED se produce en el día juliano 176 o antes, el intervalo de confianza es menor del 90% en la mayoría de los casos ($p\text{-value} > 0,10$). Cuando el IED se produce entre los días julianos 177-181 y entre los días 182-186 el intervalo de confianza establecido del 90% lo cumplen la mayor parte de las parcelas. Se observa cómo a medida que hay menos observaciones en la serie de datos el $p\text{-value}$ es mayor. Cuando el IED es determinado entre los días julianos 187-191 el intervalo de confianza al 90% únicamente ocurre cuando en la serie de datos se incluyen más de 12 observaciones; si hay menos observaciones las parcelas con un intervalo de confianza al 90% disminuyen. Por último, cuando el IED es determinado el día juliano 192 y posteriores las parcelas no alcanzan el intervalo de confianza al 90% fijado, de forma similar a lo que ocurre para el IED en días anteriores a 176. Los dos años de estudio se comportan de la misma forma.

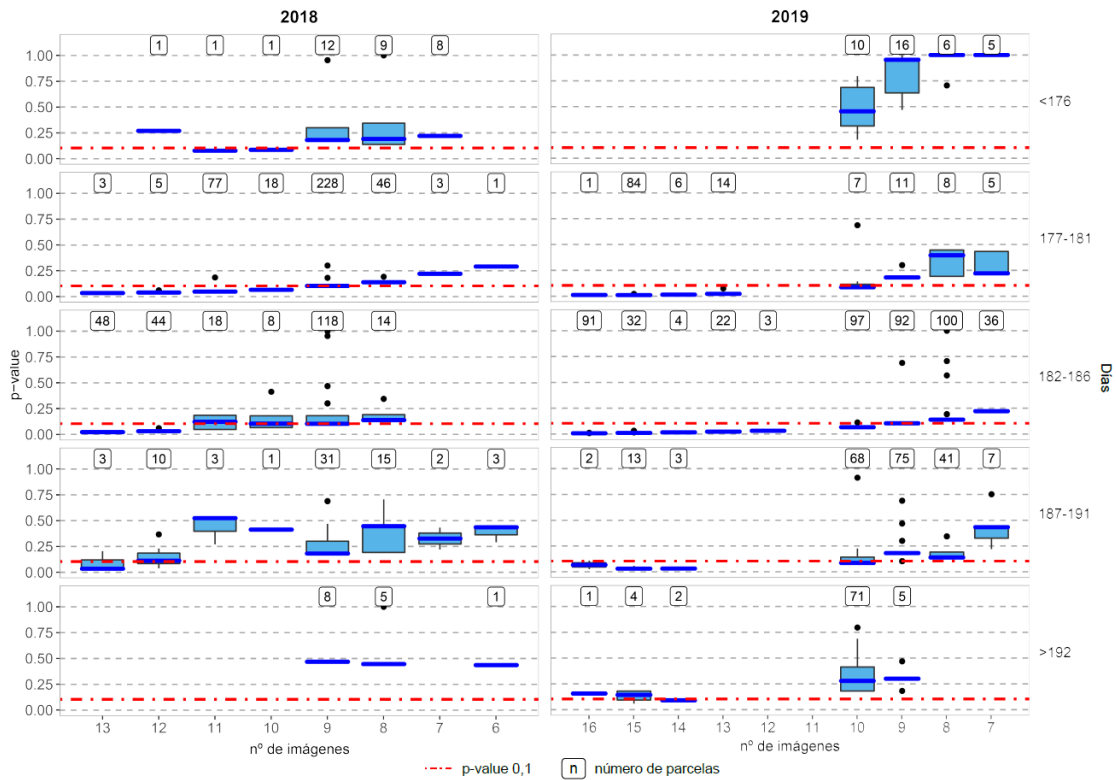


Figura V-12. p-values de la prueba de Pettitt en función del número de datos de la serie temporal de NDVI y del momento en el que se produce el punto de cambio.

En la Figura V-13 se observan los valores de significación por cultivos. Las parcelas con un primer cultivo de guisante suelen cumplir el intervalo de confianza del 90% en 2018. En 2019 hay mayor variación y algunas parcelas no alcanzan este valor crítico. Con la veza como primer cultivo la mayoría de las parcelas presentan un p-value por debajo del valor crítico, a excepción de unas pocas parcelas en el año 2018 cuyo segundo cultivo es girasol. Con el raigrás ocurre algo similar, mayoritariamente el p-value está por debajo del valor crítico, pero en 2018 en algunas parcelas superan el valor crítico. En todas estas dobles cosechas el primer cultivo se suele cosechar a primeros de junio y el segundo cultivo se siembra después, por lo que el IED se sitúa en el centro de la serie de datos.

En el caso de la cebada como primer cultivo, el p-value supera por lo general el valor crítico en los dos años de estudio. La cebada se cosecha más tarde que los cultivos anteriormente mencionados y hace que tanto maíz como girasol se siembren más tarde.

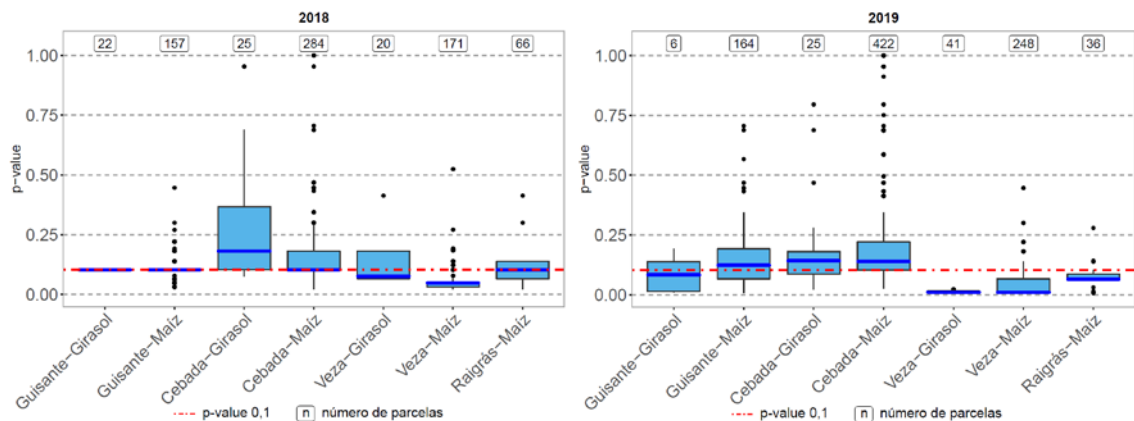


Figura V-13. p-values de la prueba de Pettitt en función de los cultivos.

V.2.5 IED y su distribución en el área de estudio

En la Figura V-14 se representa el IED por cultivos para los dos años de estudio. De forma generalizada, en el año 2019 el IED de maíz y girasol fue unos días más tarde que en 2018. El análisis por cada tipo de doble cosecha muestra que para raigrás-maíz en 2018 la mediana del IED es el día juliano 181 y la mayor parte de las parcelas presentan un IED entre los días 181 al 184; mientras que en 2019 la mediana se sitúa en el día 186 y la mayor parte de las parcelas presentan un IED entre los días julianos 184 y 186. En la doble cosecha de veza-maíz, aunque en ambos años la mediana del IED se sitúa en el día 184, en 2019 se da entre los días 181 y 186; en cambio esta horquilla es menor en 2018, que va desde los días 181 a 184. En la doble cosecha de veza-girasol ocurre algo similar, en los dos años la mediana se sitúa en el día juliano 181, pero el IED para 2019 se da entre los días 181 y 186; en cambio en 2018 es entre los días 181 a 184. En las dobles cosechas con cebada como primer cultivo el IED es más tardío, cuando el segundo cultivo es maíz, el IED se sitúa entre los días 181 y 186 en 2018, mientras que en 2019 se sitúa entre los días 186 y 191; si el segundo cultivo es el girasol el IED todavía se retrasa más, en 2018 entre los días 184 y 191 y en 2019 entre los días 191 y 196. Por último, en las dobles cosechas con guisante como primer cultivo, en 2018 el IED se situó mayoritariamente en el día 181 tanto para dobles cosechas con maíz como con girasol y en 2019 en el día 186, mostrando más variabilidad entre parcelas en la doble cosecha con girasol.

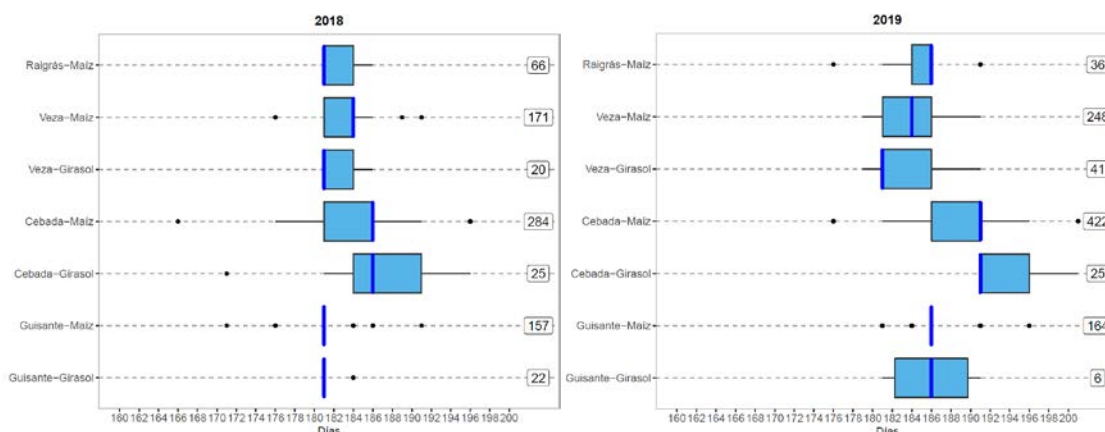


Figura V-14. IED por cultivos.

El análisis espacial de los datos (Figura V-15) muestra que en las zonas de Riegos del Alto Aragón, Canal de Aragón y Cataluña y Río Guadalope el IED no se produce antes del día juliano 177. En cambio, en el resto de las zonas varía mayoritariamente entre 176 y 186. La variación que se produce en el IED parece estar más relacionada con el primer cultivo de la doble cosecha que con una diferencia fenológica entre zonas. Sin embargo, se observa alguna excepción, como es el caso de las dobles cosechas con veza-maíz en 2019. Para esta doble cosecha en la zona del Canal de Tauste y en la zona Regable de la Violada el IED se produce el día juliano 181; en cambio en el resto de los regadíos suele darse entre los días 182 y 186. También se observan diferencias en la zona del río Guadalope, donde las dobles cosechas tienden a ir más retrasadas que en el resto de los regadíos.

Aunque el IED en 2019 fue generalmente unos días más tarde que en 2018, como ya se ha comentado, no en todas las zonas fue así. Por ejemplo, en la parte central del Ebro medio

el IED en 2018 se situaba entre los días julianos 182-186, mientras que en 2019 varió entre los días 177-186. En la zona noroeste de Riegos del Alto Aragón –Zona Regable de La Violada– para la doble cosecha de guisante-maíz el IED fue entre los días julianos 182-186 en 2018; en cambio en 2019 fue entre los días 177-181.

En el Anexo 5 se incluye la cartografía del IED para cada doble cosecha y año.

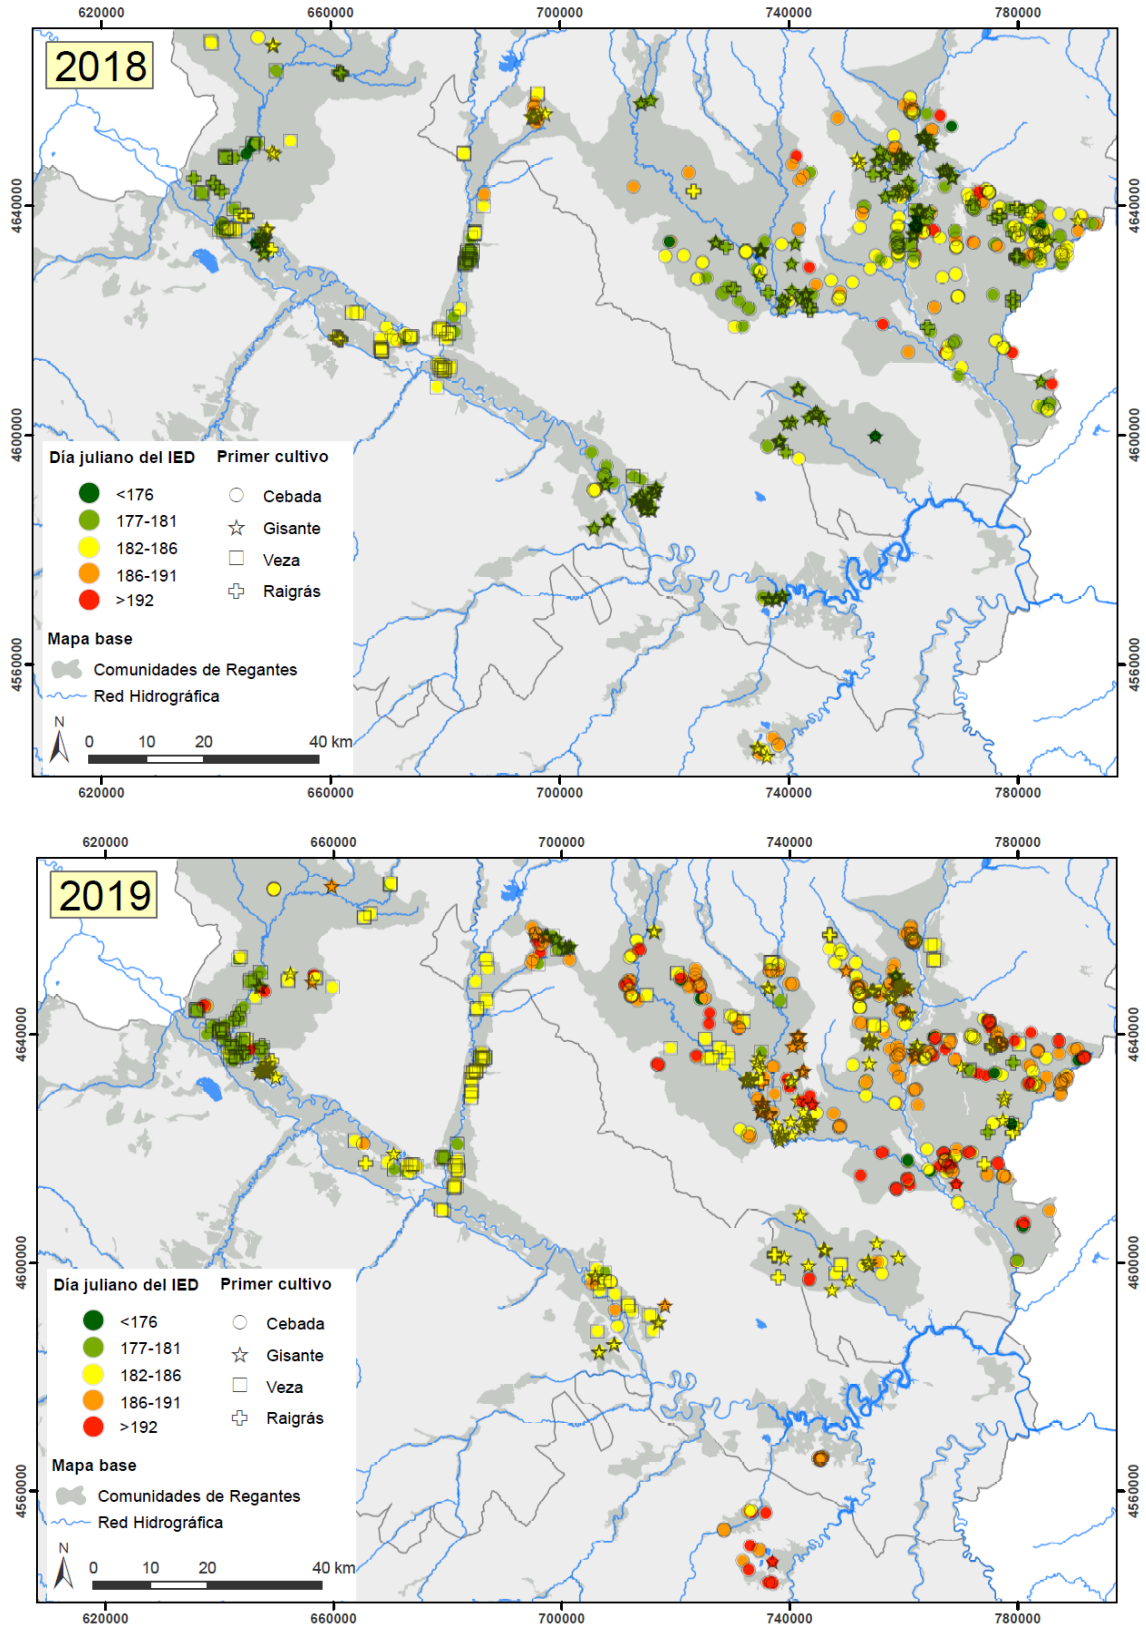
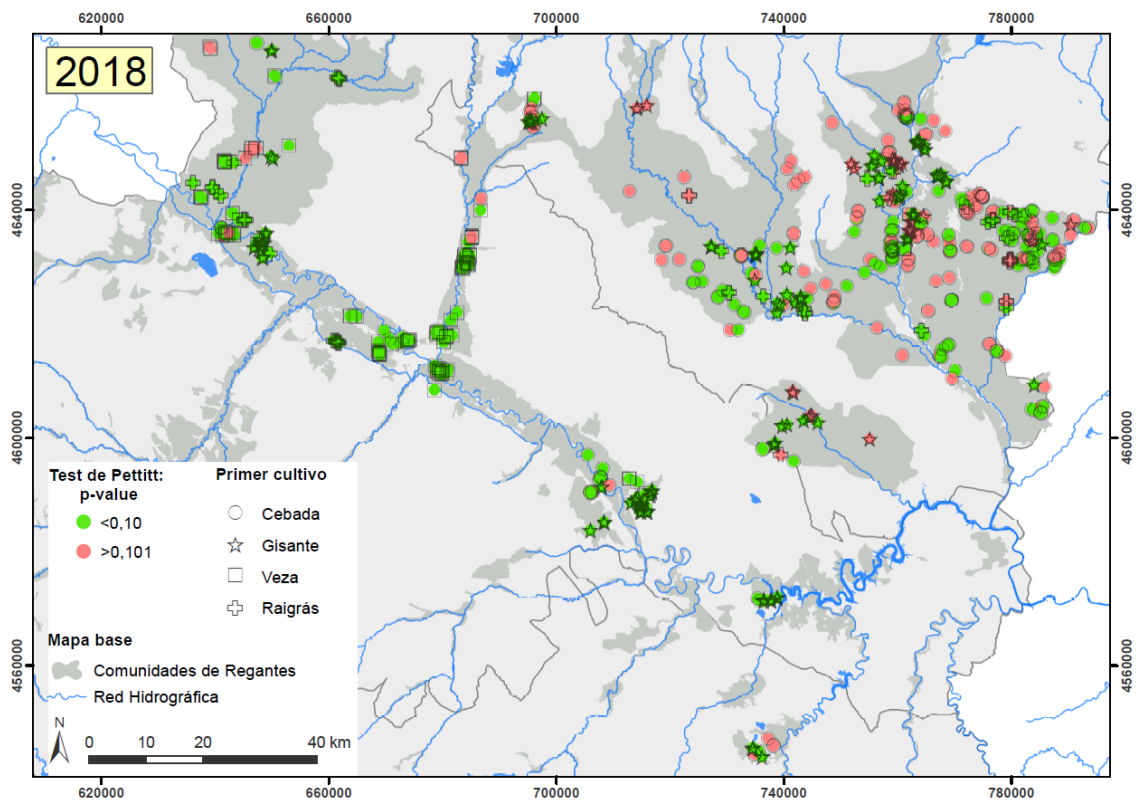


Figura V-15. Distribución del IED de las dobles cosechas de maíz y girasol en el Valle del Ebro para los años 2018 y 2019.

En la Figura V-16 se representa la distribución de la significación de la prueba de Pettitt. En los regadíos de Canal de Bardenas, Canal de Tauste, Canal imperial, Bajo Gállego, zona Sur de Riegos del Alto Aragón y en el Ebro medio se dan mayoritariamente p-values menores al valor crítico (0,1). Esto supone que el IED establecido con un intervalo de confianza del 90%. En estas zonas prevalecen los cultivos de primeras cosechas de guisante, veza y raigrás. En los regadíos de Canal de Aragón y Cataluña, Riegos del Alto Aragón (excepto la zona meridional) y Río Guadalupe predominan los valores de p-values por encima del valor crítico. El hecho de que predomine la cebada como primer cultivo unido a que es la zona donde menos datos hay en la serie hacen que no se alcance el intervalo de confianza del 90%. Ambos años son muy similares en cuanto a la distribución de la significación de la prueba de Pettitt.



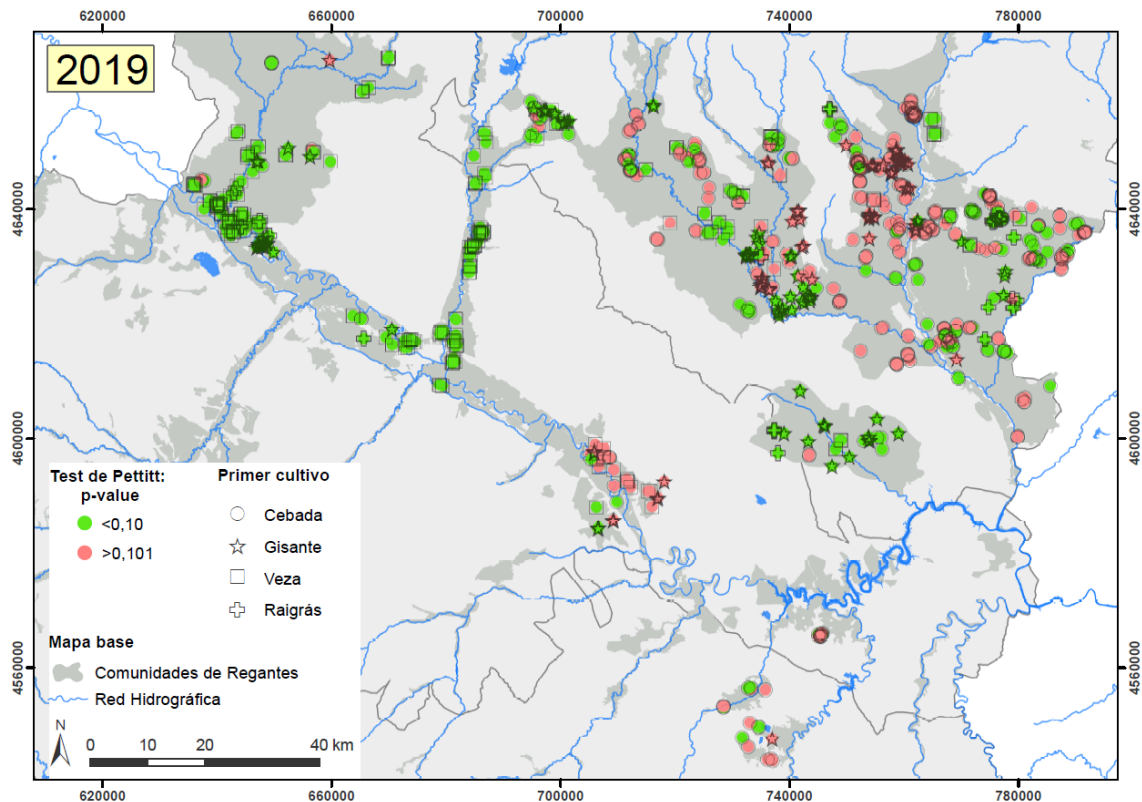


Figura V-16. Distribución de los p-valores de la prueba de Pettitt de las dobles cosechas de maíz y girasol en el Valle del Ebro para los años 2018 y 2019.

En el Anexo 5 se incluye la cartografía de la significación de la prueba de Pettitt para cada doble cosecha y año, con la que se evalúa la determinación el IED.

V.3 Discusión

En este capítulo se ha utilizado la técnica de detección de punto de cambio de la prueba de Pettitt para determinar el IED en las dobles cosechas de maíz y girasol en los regadíos del Valle del Ebro en Aragón a partir de la serie temporal de NDVI de Sentinel 2. Por una parte, se ha evaluado el comportamiento de la prueba de Pettitt en la determinación de IED en función de la temporalidad de los datos en la zona de estudio. Los resultados muestran que el comportamiento varía en función del número de imágenes que conforman la serie temporal de NDVI. En series con más de 10 datos, generalmente se alcanza el intervalo de confianza del 90% en la determinación del IED. Pero en los casos en los que el IED se produce en los extremos de la serie (Figura V-12), aun teniendo series con más de 10 datos no se alcanza el nivel de significación fijado. Por ello los resultados del intervalo de confianza antes del día juliano 176 y después del día juliano 192 están por debajo del 90%. Estos resultados están acordes con Mallakpour & Villarini (2016), que indican que la prueba de Pettitt tiene alguna dificultad para determinar el IED en los momentos extremos de la serie temporal.

Tan importante como la cantidad de imágenes de la serie temporal de NDVI es la calidad de estos datos. Forkel et al. (2013) constataron que los artefactos nubosos podían crear incertidumbres en las estimaciones fenológicas. Esto ha ocurrido cuando se ha aplicado la máscara de bits QA60 para eliminar las nubes, obteniéndose una serie de datos que no tiene

la calidad adecuada al contener valores anómalos (demasiado bajos), coincidentes con efectos nubosos (cirros, neblina y sombras de nubes). Se ha demostrado que las máscaras de nubes defectuosas desvían el inicio estimado de la temporada hasta en 10 días (Shang et al., 2018). La aplicación de la máscara de nubes ampliada ha eliminado esta incertidumbre (apartado V.1.2).

Por otra parte, se ha analizado comportamiento de la prueba de Pettitt en la determinación de IED en función de las dobles cosechas. Las formadas por cebada como primer cultivo muestran un intervalo de confianza que generalmente no alcanza el 90%. Esto sucede principalmente por que la cebada se cosecha más tarde que el resto de los primeros cultivos de las dobles cosechas analizadas, por ello la siembra y el IED del segundo cultivo se producen más tarde en esta doble cosecha, en la segunda mitad de la serie de datos temporal considerada. Estos resultados sugieren que la ventana de datos a utilizar para determinar el IED del maíz y del girasol en las dobles cosechas con cebada debe desplazarse a unos días posteriores para alcanzar el intervalo de confianza del 90%.

Los resultados de la distribución del IED de maíz y de girasol en el área de estudio muestran que para el año 2019 el IED fue por lo general más tardío que para 2018. Esto se debió fundamentalmente a que en el otoño del 2018 las precipitaciones fueron más abundantes que en 2017 (en octubre de 2018 las precipitaciones variaron entre 39 mm y 102 mm según la estación y en octubre de 2017 lo hicieron entre 4 mm y 38 mm), por lo que las siembras del cultivo de invierno se retrasaron. Además, las precipitaciones en los meses de invierno fueron escasas por lo que dificultaron la nascencia alargando todavía más el ciclo del cultivo e influyendo en la fecha de siembra del maíz y girasol. En cambio, en el año agrícola 2017-2018 las siembras en otoño se realizaron sin problema y las precipitaciones en los meses de invierno fueron importantes, lo que ayudó a la nascencia. La temperatura de finales de invierno y comienzos de primavera fue menor en 2018 a la media de los últimos 10 años; estos periodos de bajas temperaturas alargaron el periodo de espigado y maduración de los cereales de invierno. Sin embargo, este retraso tiene menor repercusión en las siembras del maíz y del girasol de 2018 que el provocado por las lluvias otoñales de 2018 en las siembras de 2019.

Además, los resultados de la distribución del IED de maíz y de girasol en el área de estudio muestran, salvo alguna excepción, que las variaciones observadas guardan más relación con el primer cultivo de la doble cosecha que con su localización en el territorio. Oliván (2018) caracterizó la dinámica de las dobles cosechas en el Canal de Aragón y Cataluña y no encontró diferencias importantes en la fenología por la distribución de las parcelas, como tampoco se ha encontrado para esa misma zona en este Capítulo de la tesis doctoral. En la zona de Canal de Tauste se da una de estas excepciones en el IED para veza-maíz en 2019, que tiene lugar antes que en el resto de los regadíos (Figura V-15 y mayor detalle en Anexo 5). Por otra parte, en los regadíos del Río Guadalope las dobles cosechas tienden a ir más retrasadas por lo general. Se da la circunstancia de que, de todas las estaciones consideradas, la de Puig Moreno (para el Río Guadalope) registro en octubre la máxima precipitación (101,7 mm), mientras que fue la menor en la de Boquiñeni (para el Canal de Tauste, 38,9 mm). Como se ha indicado anteriormente las precipitaciones en otoño pueden

condicionar el manejo de las siembras en estos meses influyendo posteriormente en el momento en el que se produce el IED del segundo cultivo de la doble cosecha.

El cultivo que precede al maíz y al girasol en la doble cosecha está relacionado con las variaciones de IED. La cebada suele cosecharse más tarde que las leguminosas, como la veza y el guisante, o el raigrás. Como resultado, el maíz y girasol se siembra más tarde, produciéndose el IED después que en las otras dobles cosechas. La muestra de algunas de estas dobles cosechas no es muy numerosa, fundamentalmente con la doble cosecha de girasol, por lo que los resultados obtenidos deben tomarse con cautela y hasta que se profundice con una muestra mayor.

Además de conocer el IED de los cultivos con la importancia que ello implica, la información que se ha generado puede ayudar a determinar la distribución del momento de las siembras del cultivo, si se tiene una idea de los días que dura fase inicial del ciclo fenológico del cultivo, como hacen Liu et al. (2018). Este tipo de cartografías de distribución de fechas de siembras e IED puede ser una herramienta de ayuda en la verificación de las prácticas asociadas al *Greening*. Sin embargo, su operatividad pasa por disponer información actualizada de la duración de este periodo y obtener cartografía de IED para más años y con mayor muestra para algunas de las dobles cosechas.

VI. Conclusiones y líneas futuras

Esta tesis doctoral se ha orientado a identificar de forma temprana la presencia y el desarrollo de los cultivos en regadío mediante técnicas de teledetección a partir de series temporales de datos de diferentes sensores, a diferentes escalas, para maíz y girasol.

Las curvas fenológicas de la vegetación se han obtenido habitualmente con teledetección mediante series temporales de índices de vegetación (IV) de sensores ópticos pasivos, asumiendo los inconvenientes que ello comporta en relación con la eventual presencia de nubosidad. Para resolver este problema se puede contar con imágenes obtenidas por otros sensores que no se vean condicionados tan fuertemente por la presencia de nubes.

En esta línea, en la tesis doctoral se ha evaluado la consistencia de los datos del sensor Sequoia –a bordo de un UAV de ala fija eBee– y el sensor MSI de Sentinel 2 mediante el espectro-radiometría de campo, obteniéndose resultados consistentes en ambos sensores y buena relación entre ellos, tanto cuando se ha comparado la información de reflectividad de las bandas espectrales como su transformación en IV. No obstante, esta buena consistencia entre sensores presenta la excepción de las bandas del borde del rojo y del infrarrojo cercano en el sensor Sequoia y de los IV de Relación Simple Modificada del Borde del rojo (MSRre) y el Índice de Clorofila del Borde del rojo (CIre), formados a partir de dichas bandas.

Aunque los resultados de Sequoia son consistentes y complementarios con MSI de Sentinel 2, se debe tener en cuenta que el registro con UAV presenta limitaciones en áreas extensas, en gran medida por la duración de los vuelos; en estas circunstancias se plantea la opción de adquirir imágenes de forma selectiva en diferentes localizaciones y cubriendo la variedad fenológica existente, extendiendo después el resultado a otras áreas próxima y de características similares.

El proceso para caracterizar la fenología de los cultivos con series de datos de teledetección normalmente incluye dos pasos fundamentales, la aplicación de técnicas de suavizado y de reconstrucción de la serie temporal y la extracción de las métricas fenológicas. Este proceso requiere una serie de datos completa del ciclo vegetativo. En este sentido, en esta tesis se ha constatado que es posible detectar de forma temprana el inicio de la etapa de desarrollo de los cultivos (IED), considerada como el 10% de cobertura del suelo, aplicando técnicas de detección de punto de cambio, sin necesidad de utilizar la serie de datos del IV del ciclo completo del cultivo.

Con estas técnicas de detección de punto de cambio se obtienen resultados equivalentes o incluso mejores a los obtenidos con la técnica del ajuste logístico de la serie de datos y punto de máxima curvatura, que es la comúnmente utilizada y que presenta la limitación de requerir información hasta que se completa el desarrollo del cultivo. Además, la incorporación de datos obtenidos mediante UAV a la serie de datos de Sentinel 2 arroja

escasas diferencias en la determinación del IED que cuando se utilizan únicamente datos Sentinel 2, en especial cuando se aplica a al índice NDRre en el caso de UAV.

La aplicación de la metodología de técnicas de detección de punto de cambio mediante prueba de Pettitt a la serie temporal del Índice de Vegetación de Diferencia Normalizada (NDVI) a escala regional en parcelas con doble cosecha de maíz y girasol en el Valle del Ebro para dos años de estudio ha puesto de manifiesto que es importante la cantidad y calidad de la serie de datos utilizada. Con series de datos compuestas por menos de 10 datos, el intervalo de confianza generalmente no alcanza el 90%. También es importante conocer la meteorología anual de cada región y el primer cultivo de la doble cosecha para poder ajustar mejor la ventana de la serie de datos a utilizar para la determinación del IED.

Por todo lo anterior, la investigación llevada a cabo constituye una ayuda para la monitorización de cultivos y su fenología, lo que revierte en mejoras en la aplicación de los mecanismos de control de la PAC, en relación con la condicionalidad, y específicamente con las prácticas del *Greening*.

A continuación se presentan las principales conclusiones extraídas en relación con cada uno de los objetivos específicos definidos para esta tesis doctoral.

En relación con el **primer objetivo específico**, la evaluación de la precisión y consistencia de los datos de reflectividad e IV obtenidos de los sensores Sequoia y el sensor MSI de Sentinel 2 a partir de la comparación con los datos de la reflectividad e IV obtenidos con espectro-radiometría:

- Los valores de reflectividad en las regiones del visible presentan buen nivel de consistencia tanto para el sensor MSI de Sentinel 2 como para el sensor Sequoia (comparación con espectro-radiometría, ASD). En las regiones del infrarrojo cercano y, principalmente, del borde del rojo (B7 y B6) las reflectividades de Sequoia difieren de ASD y también de MSI, por lo que se recomienda utilizarlas con cautela, especialmente la del borde del rojo del sensor Sequoia, que es la banda que peor consistencia ofrece.
- Los 12 IV utilizados muestran una precisión y consistencia muy alta cuando se comparan los datos MSI de Sentinel 2 con ASD, del mismo modo que cuando se compara Sequoia con ASD y MSI, a excepción de los índices MSEre y CIre.
- Las diferencias relevantes entre la reflectividad de las bandas B6 y B7 y los índices MSRre y CIre del sensor Sequoia y los derivados de ASD y MSI están relacionadas con la falta de consistencia de esas dos bandas. Consecuentemente, es necesario seguir trabajando para mejorar la precisión del registro que hace el sensor Sequoia para estas bandas espectrales. Por el contrario, para el resto de IV que utilizan B6 o B7 en combinación con bandas del visible (B3 y B4) la precisión es muy alta, ya que el desajuste propiciado por las bandas B6 y B7 se amortigua casi totalmente. Por ello, se constata un buen nivel de consistencia de los índices con bandas del borde del rojo o del infrarrojo cercano cuando se introduce una banda del visible en su formulación.

- Es necesario aplicar con cautela los modelos de regresión lineal entre sensores, pues las condiciones de normalidad, homocedasticidad e independencia de los residuos, que garantizan su validez, no siempre se cumplen. Por otra parte, el momento de ciclo del cultivo es un factor determinante. En la primera etapa del cultivo –desde la siembra a los 400 AGDD– los modelos sí cumplen las citadas condiciones en casi todos los casos, excepción hecha del borde del rojo (B6) y del infrarrojo próximo (B7), así de los IV MSRre y CIre cuando se aplican al sensor Sequoia. También las cumplen en la segunda etapa del cultivo entre ASD-Sentinel; si bien, para esta etapa, los modelos entre ASD-Sequoia no las cumplen en el caso de los índices MSRre, CIre, TVI, MTVI1 y MTVI2. Entre MSI y Sequoia las situaciones que no cumplen las condiciones de validez estadística, que garantizan la validez de los modelos, son más numerosas. En consecuencia, en aquellos casos en los que no se cumplen las condiciones, se recomienda utilizar transformaciones de las variables o modelos lineales generalizados mixtos.
- La totalidad de los datos del sensor MSI de Sentinel 2 ofrece buen nivel de precisión y consistencia, al igual que los registros de las bandas del visible de Sequoia y los IV, a excepción del borde del rojo (B6), del infrarrojo próximo (B7) y de los IV MSRre y CIre, en línea con lo ya señalado. Todo ello es relevante por cuanto los datos de Sentinel 2 son un recurso importante para el monitoreo de la vegetación gracias a su resolución temporal y extensa cobertura, del mismo modo que lo son los obtenidos mediante UAV, por cuanto, a pesar del importante volumen de datos y laborioso procesamiento que requieren, constituyen una alternativa interesante, cuando menos complementaria, para el monitoreo de parcelas agrícolas comerciales. En el contexto de las prácticas de agricultura de precisión y de la digitalización del sector agrícola, en el que se trabaja a una escala de mayor detalle, la integración satélite-UAV supone un avance considerable.
- La fuerte relación que existe entre MSI de Sentinel 2 y Sequoia en UAV, tanto para las bandas del visible como para los índices NDVI, NDRre y OSAVI, avala el potencial para integrar estos datos de UAV en una serie temporal de Sentinel 2, tanto para adoptarlos como alternativa de trabajo para obtener mayor resolución espacial, como para integrar mediciones adicionales en determinadas fases del ciclo en el monitoreo de los cultivos.

En relación con el **segundo objetivo específico** de la tesis doctoral, la determinación temprana del inicio de la etapa de desarrollo de los cultivos de regadío a partir de series temporales de imágenes multispectrales para segundas cosechas de maíz y girasol:

- La metodología presentada en esta tesis, basada en técnicas de detección de punto de cambio aplicadas a series temporales de IV obtenidos con Sentinel 2 con un periodo de recurrencia aproximado a 2-3 días, permite validar la determinación del IED de forma temprana. En general, se logra detectar el IED dos semanas después de que se produzca el 10% de cobertura del suelo (IED-Referencia).
- De las diferentes técnicas de detección de punto de cambio evaluadas, la prueba de Pettitt es la que determina el IED con menor error respecto al IED-referencia. La prueba de

Rangos de Buishand ofrece sistemáticamente el IED posterior a la prueba de Pettitt y al IED de referencia y la Prueba de Homogeneidad Normal Estándar es la que peores resultados arroja, distanciándose hasta 9 días del IED de referencia. Esta última proporciona valores muy semejantes a la metodología más estandarizada de ajuste logístico y punto de máxima curvatura (AjLog_PMC).

- Las series de NDRre y NDVI permiten determinar el IED antes que las de OSAVI, -1,5 a 1 día respecto al IED-referencia frente a -1 a 4 días. El número de imágenes disponibles utilizadas, una más en 2018 que en 2019, es relevante. Disponer de una única imagen más en un momento crítico puede hacer que la determinación del IED sea más ajustada.
- El impacto de los datos perdidos –falta de disponibilidad de imágenes– en la serie temporal para la determinación del IED es variable en función de la duración del periodo sin imágenes y del momento del ciclo en el que se produce. Si el periodo sin imágenes se produce próximo a la siembra la determinación apenas se ve afectada; en cambio, cuando el periodo sin imágenes está cerca al IED, su determinación se adelanta notablemente.
- Las series temporales de IV de Sequoia en UAV y de MSI de Sentinel 2 pueden integrarse y usarse de manera efectiva para detectar el IED. La alta correlación entre sensores durante las primeras etapas de crecimiento del cultivo de la serie NDRre hace que este índice resulte idóneo para determinar el IED.
- La detección del momento del IED aplicando la prueba de Pettitt con series de IV de MSI de Sentinel 2 resulta prometedora. Sin embargo, se debe confirmar su fiabilidad en regiones donde la recurrencia de imágenes sea inferior a la máxima de 2-3 días.

En relación con el **tercer objetivo específico** de la tesis doctoral, la identificación y análisis de la distribución espacial y del inicio de la etapa de desarrollo (IED) en parcelas comerciales de maíz y girasol de segunda cosecha en los regadíos de Aragón:

- Para determinar el IED en los regadíos de Aragón se ha utilizado la técnica de detección de punto de cambio denominada prueba de Pettitt, que se ha aplicado a la serie temporal de NDVI de Sentinel 2. El análisis de la significación de esta prueba revela que su comportamiento para determinar el IED varía en función del número de datos de NDVI de la serie temporal. Utilizando el periodo temporal entre el 15 de junio y el 31 de julio se constata que, con más de 10 datos de NDVI, el intervalo de confianza superior al 90% se alcanza en la mayoría de los casos en los que se aplica el método.
- El momento en la serie de datos en el que se produce el IED influye en el nivel de confianza con el que se determina. Cuando el IED se produce en torno al momento central de la serie temporal de datos o en su primer tercio, el intervalo de confianza de la determinación es superior al 90%. Este nivel de confianza no se supera cuando el IED se produce en los extremos de la serie temporal; por consiguiente, debe ajustarse bien la ventana temporal si se quiere obtener una alta precisión en la determinación del IED.

- Las diferencias en el IED entre los años 2018 y 2019 se relacionan con las abundantes precipitaciones en los meses de otoño del año agrícola 2018-2019 y con las escasas de los meses de final de invierno y principio de primavera. Todo ello provocó que se retrasasen tanto las siembras otoñales de la doble cosecha como la nascencia, alargándose el ciclo del primer cultivo y retrasando, por ende, la siembra y el IED del segundo cultivo.
- Las variaciones del IED de maíz y girasol en el Valle del Ebro en Aragón en los años 2018 y 2019, salvo alguna excepción, guardan más relación con el primer cultivo de la doble cosecha que con la localización en el territorio. La cebada suele cosecharse más tarde que el resto de los cultivos que preceden al maíz y al girasol como segundos cultivos en las dobles cosechas, produciéndose más tarde el IED en estos últimos cultivos. En consecuencia, se recomienda adecuar correctamente la ventana temporal con la que se construye la serie al ciclo de la doble cosecha.

En Aragón existen dificultades para verificar ciertos cultivos y operaciones de manejo en el control de los requerimientos del pago verde de la PAC, por ello se sigue recurriendo a visitas de campo. Una de las dificultades asociadas a esta forma de proceder se encuentra en la identificación temprana de la presencia de los segundos cultivos de las dobles cosechas dentro del periodo de verificación fijado. En este contexto, la presente tesis doctoral aporta soluciones operativas a la identificación temprana de la presencia de estos cultivos mediante series temporales de diferentes sensores.

Futuras líneas de investigación

La investigación llevada a cabo en esta tesis doctoral ha abierto diferentes líneas de trabajo para afrontar en el futuro:

- La evaluación de la consistencia de los sensores se ha realizado antes de que el cultivo llegue a su máximo vigor vegetal, sería necesario considerar también el ciclo completo de los cultivos para analizar la consistencia de los sensores en todas las etapas. En el caso del maíz, dada la estructura vertical del cultivo, sería necesario incorporar plataformas elevadas para el registro de espectro-radiometría.
- Constatado que existe heterogeneidad en los modelos de regresión lineal entre sensores, sería conveniente aplicar modelos lineales generalizados mixtos en los que se incluyeran tanto factores fijos como aleatorios; si bien estos modelos entrañan mayor complejidad estadística, parecen funcionar mejor.
- Se ha demostrado que la técnica de determinación del punto de cambio aplicada en esta tesis doctoral, la prueba de Pettitt, aporta resultados consistentes para determinar el inicio de la etapa de desarrollo de los cultivos, sería conveniente utilizar esta metodología para determinar otras fases del ciclo del cultivo, como podría ser el inicio de la etapa de mediados de temporada o el inicio del final de la temporada –comienzo de la senescencia–

y obtener la duración de las distintas etapas. Por supuesto, se podría extender y probar la técnica en otros cultivos.

- Los IEDs en los regadíos de Aragón se han determinado para los dos años de estudio y se han constatado los factores que influyen en su determinación; sería recomendable abordar el análisis con una serie más larga de años, ampliar la muestra de parcelas e incorporar datos agronómicos para contrastar los resultados obtenidos en esta tesis doctoral. Además, ello permitiría estimar de forma temprana la fecha de siembra a partir del momento en el que se determina el IED. Esta información puede ser de gran ayuda en la verificación de las prácticas asociadas al *Greening*, así como para incorporarla en los modelos de crecimiento de cultivos o modelos de determinación de sus necesidades hídricas.

VII. Bibliografía

- Abendroth, L. J., Elmore, R. W., Boyer, M. J., Marlay, S. K. (2011). *Corn Growth and Development*. Iowa State University. <https://store.extension.iastate.edu/product/Corn-Growth-and-Development>
- Ackermann, F. (1992). Operational Rules and Accuracy Models for GPS-Aerotriangulation. *Arch. ISPRS*, 1, 691-700.
- Agüera Vega, F., Carvajal Ramírez, F., Pérez Saiz, M., Orgaz Rosúa, F. (2015). Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. *Biosystems Engineering*, 132, 19-27. <https://doi.org/10.1016/j.biosystemseng.2015.01.008>
- Alexandersson, H. (1986). A homogeneity test applied to precipitation data. *Journal of Climatology*, 6(6), 661-675. <https://doi.org/10.1002/JOC.3370060607>
- Allen, R. G., Pereira, L. S., Raes, D., Smith, M. (2006). Evapotranspiración del cultivo. Guías para la determinación de los requerimientos de agua de los cultivos. Roma: FAO, vol. 298, n° 0. <https://www.fao.org/3/x0490s/x0490s.pdf>
- Ameztegui, A., Coll, L., Brotons, L., Ninot, J. M. (2015). Land-use legacies rather than climate change are driving the recent upward shift of the mountain tree line in the Pyrenees. *Global Ecology and Biogeography*, 25, 263-273. <https://doi.org/10.1111/geb.12407>
- ASD. (2012). FieldSpec 4 User Manual. <https://doi.org/ASD Document 600979>
- Bargiel, D. (2017). A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sensing of Environment*, 198, 369-383. <https://doi.org/10.1016/J.RSE.2017.06.022>
- Bashir, M. (2017). How to convert Sequoia images to reflectance?. Disponible en línea: https://bit.ly/Reflectance_Sequoia (consultado el 3 de diciembre de 2019).
- Bauer, M., Cipra, J. (1973). Identification of Agricultural Crops by Computer Processing of ERTS MSS Data. LARS Technical Reports. Paper 20 <https://docs.lib.purdue.edu/larstech/20>
- Belda, S., Pipia, L., Morcillo-Pallarés, P., Rivera-Cacedo, J. P., Amin, E., De Grave, C., Verrelst, J. (2020). DATimeS: A machine learning time series GUI toolbox for gap-filling and vegetation phenology trends detection. *Environmental Modelling and Software*, 127, 104666. <https://doi.org/10.1016/j.envsoft.2020.104666>
- Bolea, J. A. (2003). Síntesis Histórica de los Riegos de Aragón. CESA, Uso y gestión del Agua en Aragón. Disponible en línea: http://www.derechoaragones.es/catalogo_imagenes/grupo.cmd?path=201275 (consultado el 18 de marzo de 2022).
- Boschetti, M., Stroppiana, D., Brivio, P. A., Bocchi, S. (2009). Multi-year monitoring of rice crop phenology through time series analysis of MODIS images. *International Journal of Remote Sensing*, 30(18), 4643-4662. <https://doi.org/10.1080/01431160802632249>
- Breusch, T. S., Pagan, A. R. (1979). A Simple Test for Heteroscedasticity and Random Coefficient Variation. *Econometrica*, 47(5), 1287. <https://doi.org/10.2307/1911963>

- Broge, N., Leblanc, E. (2001). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*, 76(2), 156-172. [https://doi.org/10.1016/S0034-4257\(00\)00197-8](https://doi.org/10.1016/S0034-4257(00)00197-8)
- Buishand, T. A. (1982). Some methods for testing the homogeneity of rainfall records. *Journal of Hydrology*, 58(1-2), 11-27. [https://doi.org/10.1016/0022-1694\(82\)90066-X](https://doi.org/10.1016/0022-1694(82)90066-X)
- Cai, Y., Guan, K., Nafziger, E., Chowdhary, G., Peng, B., Jin, Z., Wang, S., Wang, S. (2019). Detecting In-Season Crop Nitrogen Stress of Corn for Field Trials Using UAV-and CubeSat-Based Multispectral Sensing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12), 5153-5166. <https://doi.org/10.1109/JSTARS.2019.2953489>
- Campos-Taberner, M., García-Haro, F. J., Martínez, B., Sánchez-Ruiz, S., Gilabert, M. A. (2019). A Copernicus Sentinel-1 and Sentinel-2 Classification Framework for the 2020+ European Common Agricultural Policy: A Case Study in València (Spain). *Agronomy*, 9(9), 556. <https://doi.org/10.3390/agronomy9090556>
- Cao, R., Chen, J., Shen, M., Tang, Y. (2015). An improved logistic method for detecting spring vegetation phenology in grasslands from MODIS EVI time-series data. *Agricultural and Forest Meteorology*, 200, 9-20. <https://doi.org/10.1016/j.agrformet.2014.09.009>
- Casadesús, J., Biel, C., Savé, R. (2005). Turf color measurement with conventional digital cameras. *EFITA/WCCA Joint Congress in Agricultura*, 804-811.
- Casadesús, J., Villegas, D. (2014). Conventional digital cameras as a tool for assessing leaf area index and biomass for cereal breeding. *Journal of Integrative Plant Biology*, 56(1), 7-14. <https://doi.org/10.1111/JIPB.12117>
- Centro de Transferencia Agroalimentaria. (2022). *Informaciones Técnicas Agrarias*. Publicación Del Departamento de Agricultura, Ganadería y Medio Ambiente. Gobierno de Aragón. Disponible en línea: <https://www.aragon.es/-/informaciones-tecnicas-agrarias> (consultado 18 de marzo de 2022).
- Chakraborty, D., Sehgal, V. K., Dhakar, R., Das, D. K., Sahoo, R. N. (2018). Trends and Change-Point in Satellite Derived Phenology Parameters in Major Wheat Growing Regions of North India During the Last Three Decades. *Journal of the Indian Society of Remote Sensing*, 46(1), 59-68. <https://doi.org/10.1007/s12524-017-0684-8>
- Chastain, R., Housman, I., Goldstein, J., Finco, M. (2019). Empirical cross sensor comparison of Sentinel-2A and 2B MSI, Landsat-8 OLI, and Landsat-7 ETM+ top of atmosphere spectral characteristics over the conterminous United States. *Remote Sensing of Environment*, 221. <https://doi.org/10.1016/j.rse.2018.11.012>
- Chen, P., Haboudane, D., Tremblay, N., Wang, J., Vigneault, P., Li, B. (2010). New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. *Remote Sensing of Environment*, 114(9), 1987-1997. <https://doi.org/10.1016/j.rse.2010.04.006>
- Chuvieco, E. (2010). *Teledetección ambiental: La observación de la Tierra desde el espacio* (Primera ed.). Ariel Ciencia.
- Clevers, J. G. P. W., Kooistra, L. (2012). Using hyperspectral remote sensing data for retrieving canopy chlorophyll and nitrogen content. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 574-583. <https://doi.org/10.1109/JSTARS.2011.2176468>

- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* Second Edition (2nd ed.). Lawrence Erlbaum Associates.
- Comisión Europea. (2011). Estrategia de la UE sobre la Biodiversidad hasta 2020. Disponible en línea: <https://doi.org/10.2779/40184> (consultado el 31 de octubre de 2020).
- Comisión Europea. (2020). Estrategia de la UE sobre la biodiversidad de aquí a 2030. Disponible en línea: https://ec.europa.eu/environment/strategy/biodiversity-strategy-2030_es (consultado el 31 de octubre de 2020).
- Conrad, C., Lamers, J. P. A., Ibragimov, N., Löw, F., Martius, C. (2016). Analysing irrigated crop rotation patterns in arid Uzbekistan by the means of remote sensing: A case study on post-Soviet agricultural land use. *Journal of Arid Environments*, 124, 150-159. <https://doi.org/10.1016/j.jaridenv.2015.08.008>
- Consejo de la Unión Europea. (2022). Política agrícola común para el periodo 2023-2027 - Consilium. Disponible en línea: <https://www.consilium.europa.eu/es/policies/cap-introduction/cap-future-2020-common-agricultural-policy-2023-2027/> (consultado el 18 de abril de 2022).
- Cowley, D., Moriarty, C., Geddes, G., Brown, G., Wade, T., Nichol, C. (2017). UAVs in Context: Archaeological Airborne Recording in a National Body of Survey and Record. *Drones*, 2(1), 2. <https://doi.org/10.3390/drones2010002>
- d'Andrimont, R., Taymans, M., Lemoine, G., Ceglar, A., Yordanov, M., van der Velde, M. (2020). Detecting flowering phenology in oil seed rape parcels with Sentinel-1 and -2 time series. *Remote Sensing of Environment*, 239, 111660. <https://doi.org/10.1016/J.RSE.2020.111660>
- de Cara, J. A., Romero, R., Moreno, J. V., Gallego, T., Martínez, L. (2018). Agrometeorología y Fenología 2017-2018. En Agencia Estatal de Meteorología (Ed.), *Calendario Meteorológico 2019 Información meteorológica y climatológica de España*. Disponible en línea: http://www.aemet.es/documentos_d/conocerlas/recursos_en_linea/calendarios/cm-2019.pdf (consultado el 4 de abril de 2022).
- de Cara, J. A., Romero, R., Moreno, J. V., Gallego, T., Martínez, L. (2019). Agrometeorología y Fenología 2018-2019. En Agencia Estatal de Meteorología (Ed.), *Calendario Meteorológico 2020 Información meteorológica y climatológica de España*. Disponible en línea: http://www.aemet.es/documentos_d/conocerlas/recursos_en_linea/calendarios/cm-2020.pdf (consultado el 4 de abril de 2022)
- Decreto 48/2001, de 27 de febrero de 2001, del Gobierno de Aragón, por el que se establecen ayudas para obras de mejora y modernización de infraestructuras de regadíos existentes, así como creación de nuevos regadíos, en el ámbito de la Comunidad Autónoma, *Boletín Oficial de Aragón* (2001). Disponible en línea: https://bit.ly/Decreto_48_2001 (consultado 18 de mayo de 2022).
- Deng, L., Mao, Z., Li, X., Hu, Z., Duan, F., Yan, Y. (2018). UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 124-136. <https://doi.org/10.1016/j.isprsjprs.2018.09.008>
- Devos, W., Wirnhardt, C., Fasbender, D., Lemoine, G., Loudjani, P., Milenov, P. (2017). Discussion document on the introduction of monitoring to substitute OTSC - Publications Office of the EU. <https://data.europa.eu/doi/10.2760/258531>

- Díaz-Varela, R. A., Zarco-Tejada, P. J., Angileri, V., Loudjani, P. (2014). Automatic identification of agricultural terraces through object-oriented analysis of very high resolution DSMs and multispectral imagery obtained from an unmanned aerial vehicle. *Journal of Environmental Management*, 134, 117-126. <https://doi.org/10.1016/j.jenvman.2014.01.006>
- Domenzain, L. M. (2017). Reflectance Estimation. Parrot SDK. <https://forum.developer.parrot.com/t/reflectance-estimation/5597/2>
- Domingo, D., Ørka, H. O., Næsset, E., Kachamba, D., Gobakken, T. (2019). Effects of UAV Image Resolution, Camera Type, and Image Overlap on Accuracy of Biomass Predictions in a Tropical Woodland. *Remote Sensing*, 11(8), 948. <https://doi.org/10.3390/rs11080948>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25-36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Durbin, J., Watson, G. S. (1950). Testing for Serial Correlation in Least Squares Regression: I. *Biometrika*, 37(3/4), 409. <https://doi.org/10.2307/2332391>
- Ebdon, D. (1982). *Estadística para geógrafos* (oikos-tau ed.). oikos-tau.
- Elzeiny, R., Khadr, M., Zahran, S., Rashwan, I. M. H. (2019). Homogeneity Analysis of Rainfall Series in the Upper Blue Nile River Basin, Ethiopia. *Engineering Research Journal (ERJ)*, 3, 46. <https://doi.org/10.21608/ERJENG.2019.125704>
- ENVI®. (2022). ENVI®. L3Harris Geospatial Solutions. <https://www.l3harrisgeospatial.com/Software-Technology/ENVI>
- ESA. (2016). User Guides - Sentinel-2 MSI - Sentinel Online. Disponible en línea: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi> (consultado 9 de enero de 2019).
- ESRI. (2019). Esri Support ArcMap 10.7 (10.7.1). Disponible en línea: <https://support.esri.com/es/products/desktop/arcgis-desktop/arcmap/10-7-1> (acceso el 4 de abril de 2020).
- Estrada, J., Sánchez, H., Hernanz, L., Checa, M., Roman, D. (2017). Enabling the Use of Sentinel-2 and LiDAR Data for Common Agriculture Policy Funds Assignment. *ISPRS International Journal of Geo-Information*, 6(8), 255. <https://doi.org/10.3390/ijgi6080255>
- ESYRCE. (2021). Encuesta sobre Superficies y Rendimientos Cultivos. Estadísticas agrarias. Disponible en línea: <https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/agricultura/esyrce/default.aspx> (consultado 18 de abril de 2022).
- Fallet, C. (2017a). Reflectance Estimation Sequoia - Parrot. Disponible en línea: <https://forum.developer.parrot.com/t/reflectance-estimation/5597/39> (consultado 17 de noviembre de 2019).
- Fallet, C. (2017b). Parrot Announcement - Release of application notes. Parrot SDK. Disponible en línea: <https://forum.developer.parrot.com/t/parrot-announcement-release-of-application-notes/5455> (consultado 17 de noviembre de 2019).
- FAOSTAT. (2021). Cultivos y productos de ganadería. Disponible en línea:

- <https://www.fao.org/faostat/es/#data/QCL/visualize> (consultado el 16 de abril de 2022).
- Fawcett, D., Panigada, C., Tagliabue, G., Boschetti, M., Celesti, M., Evdokimov, A., Biriukova, K., Colombo, R., Miglietta, F., Rascher, U., Anderson, K. (2020). Multi-Scale Evaluation of Drone-Based Multispectral Surface Reflectance and Vegetation Indices in Operational Conditions. *Remote Sensing*, 12(3), 514. <https://doi.org/10.3390/rs12030514>
- FEGA. (2020). Informe sobre la aplicación del pago para prácticas beneficiosas para el clima y el medio ambiente (“pago verde”) de la campaña 2019. Disponible en línea: <https://www.fega.es/es/node/53118> (consultado 31 de octubre de 2020).
- FEGA. (2021). Controles por Monitorización de ayudas de la PAC en la campaña 2021. Disponible en línea: https://www.fega.gob.es/sites/default/files/20210123_Noticia_Monitorizacion_2021.pdf (consultado el 15 de abril de 2022)
- Fernández-Guisuraga, J. M., Sanz-Ablanedo, E., Suárez-Seoane, S., Calvo, L. (2018). Using unmanned aerial vehicles in postfire vegetation survey campaigns through large and heterogeneous areas: Opportunities and challenges. *Sensors*, 18(2). <https://doi.org/10.3390/s18020586>
- Fernández-Quintanilla, C., Peña, J. M., Andújar, D., Dorado, J., Ribeiro, A., López-Granados, F. (2018). Is the current state of the art of weed monitoring suitable for site-specific weed management in arable crops? *Weed Research*, 58(4), 259-272. <https://doi.org/10.1111/wre.12307>
- Forkel, M., Carvalhais, N., Verbesselt, J., Mahecha, M. D., Neigh, C. S. R., Reichstein, M. (2013). Trend Change Detection in NDVI Time Series: Effects of Inter-Annual Variability and Methodology. *Remote Sensing*, Vol. 5, 2113-2144. <https://doi.org/10.3390/RS5052113>
- Frutos Mejías, L. M., Castelló Puig, A., Hernández Navarro, M. L., Ruiz-Budría, E. (2008). La Modernización de los Regadíos en Aragón: Acciones y Perspectivas. Los espacios rurales españoles en el nuevo siglo: Actas XIV Coloquio de Geografía Rural, 111-126. https://www.um.es/georuralmurcia/pdf/02_CASTELLO.pdf
- Gao, F., Anderson, M. C., Hively, W. D. (2020). Detecting cover crop end-of-season using venus and sentinel-2 satellite imagery. *Remote Sensing*, 12(21), 1-22. <https://doi.org/10.3390/rs12213524>
- Gao, F., Anderson, M. C., Johnson, D. M., Seffrin, R., Wardlow, B., Suyker, A., Diao, C., Browning, D. M. (2021). Towards Routine Mapping of Crop Emergence within the Season Using the Harmonized Landsat and Sentinel-2 Dataset. *Remote Sensing* 2021, Vol. 13, Page 5074, 13(24), 5074. <https://doi.org/10.3390/RS13245074>
- Gao, F., Anderson, M. C., Zhang, X., Yang, Z., Alfieri, J. G., Kustas, W. P., Mueller, R., Johnson, D. M., Prueger, J. H. (2017). Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sensing of Environment*, 188, 9-25. <https://doi.org/10.1016/j.rse.2016.11.004>
- Gao, F., Anderson, M., Daughtry, C., Karnieli, A., Hively, D., Kustas, W. (2020). A within-season approach for detecting early growth stages in corn and soybean using high temporal and spatial resolution imagery. *Remote Sensing of Environment*, 242, 111752. <https://doi.org/10.1016/j.rse.2020.111752>

- Gao, F., Masek, J. G., Wolfe, R. E., Huang, C. (2010). Building a consistent medium resolution satellite data set using moderate resolution imaging spectroradiometer products as reference. <https://doi.org/10.1117/1.3430002>, 4(1), 043526. <https://doi.org/10.1117/1.3430002>
- Gao, F., Zhang, X. (2021). Mapping Crop Phenology in Near Real-Time Using Satellite Remote Sensing: Challenges and Opportunities. <https://doi.org/10.34133/2021/8379391>
- García-Mozo, H., Oteros, J., Galán, C. (2015). Phenological changes in olive (*Olea europaea* L.) reproductive cycle in southern Spain due to climate change. *Annals of Agricultural and Environmental Medicine*, 22(3), 421-428. <https://doi.org/10.5604/12321966.1167706>
- García Ruiz, J. M., Lasanta, T., Biarge, F. (2003). Agua, Tierra y Paisaje. Complejidad y diversidad en el territorio de Riegos del Alto Aragón (Comunidad General de Riegos del Alto Aragón).
- Gerstmann, H., Möller, M., Gläßer, C. (2016). Optimization of spectral indices and long-term separability analysis for classification of cereal crops using multi-spectral RapidEye imagery. *International Journal of Applied Earth Observation and Geoinformation*, 52, 115-125. <https://doi.org/10.1016/j.jag.2016.06.001>
- Gilabert, M. A., Gandía, S., Meliá, J. (1996). Analyses of spectral-biophysical relationships for a corn canopy. *Remote Sensing of Environment*, 55(1), 11-20. [https://doi.org/10.1016/0034-4257\(95\)00187-5](https://doi.org/10.1016/0034-4257(95)00187-5)
- Gilabert, M. A., González-Piqueras, J., García-Haro, J. (1997). Acerca de los Índices de Vegetación. *Revista de Teledetección*, 8, 1-10.
- Gitelson, A. A., Kaufman, Y. J., Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sensing of Environment*, 58(3), 289-298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Gitelson, A. A., Kaufman, Y. J., Stark, R., Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, 32(8), 1-4. <https://doi.org/10.1029/2005GL022688>
- González-Gómez, L., Campos, I., Calera, A. (2018). Use of different temporal scales to monitor phenology and its relationship with temporal evolution of normalized difference vegetation index in wheat. *Journal of Applied Remote Sensing*, 12, 1. <https://doi.org/10.1117/1.JRS.12.026010>
- González-Piqueras, J. (2006). Evapotranspiración de la cubierta vegetal mediante la determinación del coeficiente de cultivo por teledetección. Extensión a escala regional: Acuífero 08.29 Mancha Oriental. [Universidad de Valencia]. En Tesis Doctorals en Xarxa. <https://www.tdx.cat/handle/10803/10340#page=1>
- Goward, S. N., Tucker, C. J., Dye, D. G. (1985). North American vegetation patterns observed with the NOAA-7 advanced very high resolution radiometer. *Vegetatio*, 64(1), 3-14. <https://doi.org/10.1007/BF00033449>
- Greenwood, F. (2015). Drones and aerial observation: New Technologies for Property Rights, Human Rights, and Global Development. Chapter 4: How to make maps with

- drones. New America.
http://www.rhinosourcecenter.com/pdf_files/143/1438073140.pdf
- Guerrero, A. (1999). Cultivos herbáceos extensivos. Ediciones Mundi-Prensa (Sexta Ed.).
- Gutiérrez López, M. (2022). Transferencia de resultados de la red de ensayos de maíz y girasol en Aragón. Campaña 2021. <https://e.pcloud.link/publink/show?code=3C9otalK>
- Gutiérrez, M., Aranda, A. (2019). Transferencia de resultados de la red de ensayos de maíz y girasol en Aragón. Campaña 2018. Disponible en línea:
https://www.aragon.es/documents/20127/674325/IT_271-19.pdf/e013f8fc-2f1e-d71c-d45c-d087853fe06d (consultado 17 de febrero de 2022).
- Gutiérrez, M., Aranda, A. (2021). Transferencia de resultados de la red de ensayos de maíz y girasol en Aragón. Campaña 2020. Disponible en línea:
https://www.aragon.es/documents/20127/77519864/IT_277-21.pdf/8e3eeeee-ab4a-ce3c-18fb-06f0beb67027?t=1617090109271 (consultado 17 de febrero de 2022).
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., Strachan, I. B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3), 337-352. <https://doi.org/10.1016/J.RSE.2003.12.013>
- Huete, A. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25, 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Iizumi, T., Ramankutty, N. (2015). How do weather and climate influence cropping area and intensity? *Global Food Security*, 4, 46-50. <https://doi.org/10.1016/J.GFS.2014.11.003>
- Infoagro. (s. f.). El cultivo del maíz (1ª parte). Disponible en línea:
<https://www.infoagro.com/herbaceos/cereales/maiz.htm> (consultado el 15 de enero de 2022).
- Jaiswal, R. K., Lohani, A. K., Tiwari, H. L. (2015). Statistical Analysis for Change Detection and Trend Assessment in Climatological Parameters. *Environmental Processes*, 2(4), 729-749. <https://doi.org/10.1007/S40710-015-0105-3/FIGURES/3>
- Jiang, J., Zheng, H., Ji, X., Cheng, T., Tian, Y., Zhu, Y., Cao, W., Ehsani, R., Yao, X. (2019). Analysis and Evaluation of the Image Preprocessing Process of a Six-Band Multispectral Camera Mounted on an Unmanned Aerial Vehicle for Winter Wheat Monitoring. *Sensors*, 19(3), 747. <https://doi.org/10.3390/s19030747>
- Jiménez-Aguirre, M. T., Isidoro, D., Usón, A. (2018). Soil variability in La Violada Irrigation District (Spain): I Delineating soil units for irrigation. *Geoderma*, 311, 78-90. <https://doi.org/10.1016/j.geoderma.2017.04.025>
- Jiménez-Ruano, A., Rodrigues, M., de la Riva, J. (2017). Exploring spatial-temporal dynamics of fire regime features in mainland Spain. *Natural Hazards and Earth System Sciences*, 17(10), 1697-1711. <https://doi.org/10.5194/NHESS-17-1697-2017>
- Jönsson, P., Eklundh, L. (2004). TIMESAT - A program for analyzing time-series of satellite sensor data. *Computers and Geosciences*, 30(8), 833-845. <https://doi.org/10.1016/j.cageo.2004.05.006>
- Ju, W., Gao, P., Zhou, Y., Chen, J. M., Chen, S., Li, X. (2010). Prediction of summer grain crop yield with a process-based ecosystem model and remote sensing data for the northern area of the Jiangsu Province, China. *International Journal of Remote Sensing*, 31(6), 1573-1587. <https://doi.org/10.1080/01431160903475357>

- Kowalski, K., Senf, C., Hostert, P., Pflugmacher, D. (2020). Characterizing spring phenology of temperate broadleaf forests using Landsat and Sentinel-2 time series. *International Journal of Applied Earth Observation and Geoinformation*, 92, 102172. <https://doi.org/10.1016/j.jag.2020.102172>
- Lange, M., Dechant, B., Rebmann, C., Vohland, M., Cuntz, M., Doktor, D. (2017). Validating MODIS and Sentinel-2 NDVI Products at a Temperate Deciduous Forest Site Using Two Independent Ground-Based Sensors. *Sensors*, 17(8), 1855. <https://doi.org/10.3390/s17081855>
- Lehnert, L. W., Meyer, H., Obermeier, W. A., Silva, B., Regeling, B., Thies, B., Bendix, J. (2019). Journal of Statistical Software Hyperspectral Data Analysis in R: The hsdar-Package. <https://www.jstatsoft.org/article/view/v089i12>
- Lilliefors, H. W. (1969). On the Kolmogorov-Smirnov Test for the Exponential Distribution with Mean Unknown. *Journal of the American Statistical Association*, 64(325), 387-389. <https://doi.org/10.1080/01621459.1969.10500983>
- Liu, L., Zhang, X., Yu, Y., Gao, F., Yang, Z. (2018). Real-time monitoring of crop phenology in the Midwestern United States using VIIRS observations. *Remote Sensing*, 10(10), 1540. <https://doi.org/10.3390/rs10101540>
- Liu, L., Zhang, X., Yu, Y., Guo, W. (2017). Real-time and short-term predictions of spring phenology in North America from VIIRS data. *Remote Sensing of Environment*, 194, 89-99. <https://doi.org/10.1016/j.RSE.2017.03.009>
- López Bellido, L. (1991). Cultivos herbáceos: cereales. Vol. I, Ediciones Mundi-Prensa.
- Lu, H., Fan, T., Ghimire, P., Deng, L. (2020). Experimental Evaluation and Consistency Comparison of UAV Multispectral Minisensors. *Remote Sensing 2020*, Vol. 12, Page 2542, 12(16), 2542. <https://doi.org/10.3390/RS12162542>
- Mac Arthur, A. (2007). Field Guide for the ASD Fieldspec Pro Radiance/Irradiance Measurements in Raw DN Mode.
- Maimaitijiang, M., Sagan, V., Sidike, P., Daloye, A. M., Erkbol, H., Fritschi, F. B. (2020). Crop Monitoring Using Satellite/UAV Data Fusion and Machine Learning. *Remote Sensing 2020*, Vol. 12, Page 1357, 12(9), 1357. <https://doi.org/10.3390/RS12091357>
- Malede, D. A., Agumassie, T. A., Kosgei, J. R., Linh, N. T. T., Andualem, T. G. (2022). Analysis of rainfall and streamflow trend and variability over Birr River watershed, Abbay basin, Ethiopia. *Environmental Challenges*, 7, 100528. <https://doi.org/10.1016/j.ENVC.2022.100528>
- Malik, W. (2019). Modelización y Control medioambiental de regadíos modernizados por aspersión en el valle medio del Ebro (España) [Universidad de Zaragoza]. <https://dialnet.unirioja.es/servlet/tesis?codigo=258007>
- Malik, W., Dechmi, F. (2019). DSSAT modelling for best irrigation management practices assessment under Mediterranean conditions. *Agricultural Water Management*, 216, 27-43. <https://doi.org/10.1016/j.agwat.2019.01.017>
- Malvern Panalytical. (2014). ViewSpec Pro Software. Disponible en línea: <https://www.malvernpanalytical.com/es/support/product-support/software/viewspecprosoftwareinstall> (consultado el 1 de mayo de 2020).
- Martínez-Casasnovas, J. A., Martín-Montero, A., Casterad, M. A. (2005). Mapping multi-year cropping patterns in small irrigation districts from time-series analysis of Landsat TM images. *European Journal of Agronomy*, 23(2), 159-169.

- <https://doi.org/10.1016/j.eja.2004.11.004>
- Martínez, M. D., Serra, C., Burgueño, A., Lana, X. (2010). Time trends of daily maximum and minimum temperatures in Catalonia (ne Spain) for the period 1975-2004. *International Journal of Climatology*, 30(2), 267-290.
<https://doi.org/10.1002/JOC.1884>
- Mateo Box, J. M., González Torres, F., Rojo Hernández, C. (2005). *Prontuario de agricultura. Cultivos agrícolas*. Mundi-Prensa.
- Matese, A., Toscano, P., Di Gennaro, S., Genesio, L., Vaccari, F., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R., Gioli, B. (2015). Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7(3), 2971-2990.
<https://doi.org/10.3390/rs70302971>
- McMaster, G. S., Wilhelm, W. W. (1997). Growing degree-days: one equation, two interpretations. *Agricultural and Forest Meteorology*, 87(4), 291-300.
[https://doi.org/10.1016/S0168-1923\(97\)00027-0](https://doi.org/10.1016/S0168-1923(97)00027-0)
- Mesas-Carrascosa, F.-J., Clavero Rumbao, I., Torres-Sánchez, J., García-Ferrer, A., Peña, J. M., López Granados, F. (2017). Accurate ortho-mosaicked six-band multispectral UAV images as affected by mission planning for precision agriculture proposes. *International Journal of Remote Sensing*, 38(8-10), 2161-2176.
<https://doi.org/10.1080/01431161.2016.1249311>
- Mesas-Carrascosa, F.-J., Torres-Sánchez, J., Clavero-Rumbao, I., García-Ferrer, A., Peña, J.-M., Borra-Serrano, I., López-Granados, F. (2015). Assessing Optimal Flight Parameters for Generating Accurate Multispectral Orthomosaicks by UAV to Support Site-Specific Crop Management. *Remote Sensing*, 7(10), 12793-12814.
<https://doi.org/10.3390/rs71012793>
- Milenov, P., Lemoine, G., Devos, W., Fasbender, D. (2018). Technical guidance on the decision to go for substitution of OTSC by monitoring - Publications Office of the EU.
<https://data.europa.eu/doi/10.2760/693101>
- Milenov, P., Sima, A., Devos, W., Fasbender, D., Wirnhardt, C., Griffiths, P., Loudjani, P., Lomoine, G. (2018). Second discussion document on the introduction of monitoring to substitute OTSC - Publications Office of the EU.
<https://data.europa.eu/doi/10.2760/344612>
- Milton, E. J., Blackburn, G. A., Rollin, E. M., Danson, F. M. (1994). Measurement of the spectral directional reflectance of forest canopies: a review of methods and a practical application. *Remote Sensing Reviews*, 10(4), 285-308.
<https://doi.org/10.1080/02757259409532251>
- Milton, E. J., Schaepman, M. E., Anderson, K., Kneubühler, M., Fox, N. (2009). Progress in field spectroscopy. *Remote Sensing of Environment*, 113(SUPPL. 1), S92-S109.
<https://doi.org/10.1016/j.rse.2007.08.001>
- Ministerio de Agricultura, Pesca y Alimentación. (2021). Resumen de la propuesta. El Plan Estratégico de la PAC en España (2023-2027). En Catálogo de Publicaciones de la Administración. https://bit.ly/PAC_2023-2027
- Montorio Llovería, R. (2014). Estimación de los productos de combustión mediante espectro-radiometría de campo: modelización empírica en áreas quemadas de matorral mediterráneo [Universidad de Zaragoza].

- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358-371. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2012.08.009>
- Mur, J., Lueza, J., Ríos, N., Campos, J. A., González, I., Angoy, J. L., Casale, J., Arguille, L., Gregorio, D. (2021). Dossier técnico de la campaña de Maíz, Girasol y Alfalfa de la Red Aragonesa de Cultivos Extensivos y Leguminosas. Disponible en línea: https://bit.ly/RED_ARAX_2019-2020 (consultado 17 de febrero de 2022).
- Oliván, J. (2018). Caracterización de la dinámica de las dobles cosechas en el Canal de Aragón y Cataluña mediante series temporales de NDVI. <https://zaguan.unizar.es/record/77607/files/TAZ-TFG-2018-2885.pdf>
- Ottosen, T. B., Lommen, S. T. E., Skjøth, C. A. (2019). Remote sensing of cropping practice in Northern Italy using time-series from Sentinel-2. *Computers and Electronics in Agriculture*, 157, 232-238. <https://doi.org/10.1016/J.COMPAG.2018.12.031>
- Padró, J.-C., Muñoz, F.-J., Ávila, L., Pesquer, L., Pons, X. (2018). Radiometric Correction of Landsat-8 and Sentinel-2A Scenes Using Drone Imagery in Synergy with Field Spectroradiometry. *Remote Sensing*, 10(11), 1687. <https://doi.org/10.3390/rs10111687>
- Pan, L., Xia, H., Yang, J., Niu, W., Wang, R., Song, H., Guo, Y., Qin, Y. (2021). Mapping cropping intensity in Huaihe basin using phenology algorithm, all Sentinel-2 and Landsat images in Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102376. <https://doi.org/10.1016/J.JAG.2021.102376>
- Pancorbo, J. L., Lamb, B. T., Quemada, M., Hively, W. D., Gonzalez-Fernandez, I., Molina, I. (2021). Sentinel-2 and WorldView-3 atmospheric correction and signal normalization based on ground-truth spectroradiometric measurements. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 166-180. <https://doi.org/10.1016/j.isprsjprs.2021.01.009>
- Panda, S., Rao, M., Thenkabail, P., Fitzgerald, J. (2015). Remote sensing systems – Platforms and sensors: Aerial, satellites, UAVs, optical, radar, and LiDAR: Chapter 1. En *Remotely Sensed Data Characterization, Classification, and Accuracies* (pp. 3-57). <https://pubs.er.usgs.gov/publication/70134260>
- Pardo Merino, A., Ruiz Díaz, M. Á. (2005). Análisis de datos con SPSS 13 Base. C. Sánchez González (ed.). McGraw-Hill.
- Parrot Sequoia. (2017). SEQUOIA - User Guide. https://bit.ly/Userguide_Sequoia
- Peña, J. M., Torres-Sánchez, J., Serrano-Pérez, A., López-Granados, F. (2014). Detección de malas hierbas en girasol en fase temprana mediante imágenes tomadas con un vehículo aéreo no tripulado (UAV). *Revista de Teledetección*, 0(42), 39. <https://doi.org/10.4995/raet.2014.3148>
- Pérez, T. (2016). El girasol, otra alternativa para la rotación de cultivos. Disponible en línea: https://bit.ly/Girasol_rotación (consultado 17 de febrero de 2022).
- Pettitt, A. N. (1979). A Non-Parametric Approach to the Change-Point Problem. *Applied Statistics*, 28(2), 126. <https://doi.org/10.2307/2346729>
- Pix4D SA. (2022). PIX4Dmapper - El software líder en fotogrametría para mapeo profesional con drones. https://bit.ly/PIX4Dmapper_software

- Pla, M., Bota, G., Duane, A., Balagué, J., Curcó, A., Gutiérrez, R., Brotons, L. (2019). Calibrating Sentinel-2 Imagery with Multispectral UAV Derived Information to Quantify Damages in Mediterranean Rice Crops Caused by Western Swamphen (*Porphyrio porphyrio*). *Drones*, 3, 45. <https://doi.org/10.3390/drones3020045>
- Pohlert, T. (2020). Non-Parametric Trend Tests and Change-Point Detection. R package version 1.1.4. <https://cran.r-project.org/package=trend>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Qiao, K., Zhu, W., Xie, Z. (2020). Application conditions and impact factors for various vegetation indices in constructing the LAI seasonal trajectory over different vegetation types. *Ecological Indicators*, 112, 106153. <https://doi.org/10.1016/j.ecolind.2020.106153>
- R Core Team. (2020). R: A language and environment for statistical computing. En R Foundation for Statistical Computing. <https://www.r-project.org/>.
- Real Decreto 329/2002, de 5 de abril, por el que se aprueba el Plan Nacional de Regadíos., Boletín Oficial del Estado 15558 (2002). <https://www.boe.es/eli/es/rd/2002/04/05/329>
- Real Decreto 1172/2015, de 29 de diciembre, por el que se modifica el Real Decreto 1075/2014, de 19 de diciembre, sobre la aplicación a partir de 2015 de los pagos directos a la agricultura y a la ganadería y otros regímenes de ayuda, así como sobre la ge, Boletín Oficial del Estado 123406 (2015).
- Reglamento de Ejecución (UE) 2018/746 de la Comisión, de 18 de mayo de 2018, por el que se modifica el Reglamento de Ejecución (UE) 809/ 2014 en lo que respecta a la modificación de las solicitudes únicas y solicitudes de pago y a los controles, 125 Diario Oficial de la Unión Europea (2018). Disponible en línea: <https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=CELEX%3A32018R0746> (consultado el 18 de abril de 2022).
- Ren, J., Campbell, J. B., Shao, Y. (2017). Estimation of SOS and EOS for Midwestern US Corn and Soybean Crops. *Remote Sensing*, 9(7), 722. <https://doi.org/10.3390/rs9070722>
- Reville, A., Florence, A., MacArthur, A., Hoad, S., Rees, R., Williams, M. (2019). The Value of Sentinel-2 Spectral Bands for the Assessment of Winter Wheat Growth and Development. *Remote Sensing*, 11(17), 2050. <https://doi.org/10.3390/rs11172050>
- Reville, A., Florence, A., MacArthur, A., Hoad, S., Rees, R., Williams, M. (2020). Quantifying Uncertainty and Bridging the Scaling Gap in the Retrieval of Leaf Area Index by Coupling Sentinel-2 and UAV Observations. *Remote Sensing*, 12(11), 1843. <https://doi.org/10.3390/rs12111843>
- Ritchie, S., Hanway, J., Benson, G. (1986). How a Corn Plant Develops (48). http://publications.iowa.gov/18027/1/How_a_corn_plant_develops001.pdf
- Ritz, C., Baty, F., Streibig, J. C., Gerhard, D. (2015). Dose-Response Analysis Using R. *PLOS ONE*, 10(12), e0146021. <https://doi.org/10.1371/JOURNAL.PONE.0146021>
- Rodrigo Da Silva, A., Paiva de Lima, R. (2017). Determination of maximum curvature point with the R package soilphysics. *International Journal of Current Research*, 9(01), 45241-45245. <https://www.journalcra.com/sites/default/files/issue-pdf/20162.pdf>

- Rondeaux, G., Steven, M., Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95-107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Rosero-Vlasova, O. A., Pérez-Cabello, F., Montorio, R., Vlassova, L. (2016). Assessment of laboratory VIS-NIR-SWIR setups with different spectroscopy accessories for characterisation of soils from wildfire burns. *Biosystems Engineering*, 152, 51-67. <https://doi.org/10.1016/j.biosystemseng.2016.06.011>
- Roujean, J. L., Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375-384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, J., Haas, R., Schell, J., Deering, D. (1974). Monitoring vegetation systems in the Great Plains with ERTS. NASA. Goddard Space Flight Center 3d ERTS-1 Symp, 1(Sect. A), 309-317.
- Ruzgiene, B., Berteška, T., Gečyte, S., Jakubauskiene, E., Aksamitauskas, V. Č. (2015). The surface modelling based on UAV Photogrammetry and qualitative estimation. *Measurement: Journal of the International Measurement Confederation*, 73, 619-627. <https://doi.org/10.1016/j.measurement.2015.04.018>
- Ryberg, K. R., Hodgkins, G. A., Dudley, R. W. (2020). Change points in annual peak streamflows: Method comparisons and historical change points in the United States. *Journal of Hydrology*, 583, 124307. <https://doi.org/10.1016/J.JHYDROL.2019.124307>
- Sagan, V., Maimaitijiang, M., Sidike, P., Maimaitiyiming, M., Erkbol, H., Hartling, S., Peterson, K. T., Peterson, J., Burken, J., Peterson, J., Fritschi, F. (2019). UAV/Satellite Multiscale Data Fusion for Crop Monitoring and Early Stress Detection. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-715-2019>
- Sakamoto, T., Yokozawa, M., Toritani, H., Shibayama, M., Ishitsuka, N., Ohno, H. (2005). A crop phenology detection method using time-series MODIS data. *Remote Sensing of Environment*, 96(3-4), 366-374. <https://doi.org/10.1016/j.rse.2005.03.008>
- Samy, A., Ibrahim, M. G., Mahmud, W. E., Fujii, M., Eltawil, A., Daoud, W. (2019). Statistical Assessment of Rainfall Characteristics in Upper Blue Nile Basin over the Period from 1953 to 2014. *Water* 2019, Vol. 11, Page 468, 11(3), 468. <https://doi.org/10.3390/W11030468>
- Sanagustín Sanz, M. (2017). 25 años de inversión pública en regadíos en Aragón: análisis y algunos resultados. *Revista Española de Estudios Agrosociales y Pesqueros*, 248. Disponible en línea: https://bit.ly/Regadíos_Aragón (consultado 18 de mayo de 2022).
- Sanz-Ablanedo, E., Chandler, J., Rodríguez-Pérez, J., Ordóñez, C. (2018). Accuracy of Unmanned Aerial Vehicle (UAV) and SfM Photogrammetry Survey as a Function of the Number and Location of Ground Control Points Used. *Remote Sensing*, 10(10), 1606. <https://doi.org/10.3390/rs10101606>
- Schmedtmann, J., Campagnolo, M. (2015). Reliable Crop Identification with Satellite Imagery in the Context of Common Agriculture Policy Subsidy Control. *Remote Sensing*, 7(7), 9325-9346. <https://doi.org/10.3390/rs70709325>
- Schneiter, A. A., Miller, J. F. (1981). Description of Sunflower Growth Stages. *Crop Science*, 21(6), 901-903. <https://doi.org/10.2135/CROPSCI1981.0011183X002100060024X>

- Segarra, J., Buchailot, M. L., Araus, J. L., Kefauver, S. C. (2020). Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications. *Agronomy* 2020, Vol. 10, Page 641, 10(5), 641. <https://doi.org/10.3390/AGRONOMY10050641>
- Sen, P. K. (1968). Estimates of the Regression Coefficient Based on Kendall's Tau. *Journal of the American Statistical Association*, 63(324), 1379-1389. <https://doi.org/10.1080/01621459.1968.10480934>
- Sensefly Ltd. (2014). Ebee Sensefly: Extended User Manual. SenseFly a Parrot company, 166.
- Shahbazi, M., Théau, J., Ménard, P. (2014). Recent applications of unmanned aerial imagery in natural resource management. *GIScience and Remote Sensing*, 51(4), 339-365. <https://doi.org/10.1080/15481603.2014.926650>
- Shang, R., Liu, R., Xu, M., Liu, Y., Dash, J., Ge, Q. (2018). Determining the Start of the Growing Season from MODIS Data in the Indian Monsoon Region: Identifying Available Data in the Rainy Season and Modeling the Varied Vegetation Growth Trajectories. *Remote Sensing* 2018, Vol. 10, Page 122, 10(1), 122. <https://doi.org/10.3390/RS10010122>
- Shapiro, S. S., Wilk, M B. (1965). An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52, 591-611.
- Sitokonstantinou, V., Papoutsis, I., Kontoes, C., Arnal, A. L., Andrés, A. P. A., Zurbano, J. A. G. (2018). Scalable Parcel-Based Crop Identification Scheme Using Sentinel-2 Data Time-Series for the Monitoring of the Common Agricultural Policy. *Remote Sensing* 2018, Vol. 10, Page 911, 10(6), 911. <https://doi.org/10.3390/RS10060911>
- Skakun, S., Kalecinski, N. I., Brown, M. G. L., Johnson, D. M., Vermote, E. F., Roger, J. C., Franch, B. (2021). Assessing within-Field Corn and Soybean Yield Variability from WorldView-3, Planet, Sentinel-2, and Landsat 8 Satellite Imagery. *Remote Sensing* 2021, Vol. 13, Page 872, 13(5), 872. <https://doi.org/10.3390/RS13050872>
- Sola, I., García-Martín, A., Sardonís-Pozo, L., Álvarez-Mozos, J., Pérez-Cabello, F., González-Audícana, M., Montorio Llovería, R. (2018). Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes. *International Journal of Applied Earth Observation and Geoinformation*, 73, 63-76. <https://doi.org/10.1016/j.jag.2018.05.020>
- Song, X.-P., Potapov, P. V., Krylov, A., King, L., Di Bella, C. M., Hudson, A., Khan, A., Adusei, B., Stehman, S. V., Hansen, M. C. (2017). National-scale soybean mapping and area estimation in the United States using medium resolution satellite imagery and field survey. <https://doi.org/10.1016/j.rse.2017.01.008>
- Stow, D., Nichol, C. J., Wade, T., Assmann, J. J., Simpson, G., Helfter, C. (2019). Illumination geometry and flying height influence surface reflectance and ndvi derived from multispectral UAS imagery. *Drones*, 3(3), 1-28. <https://doi.org/10.3390/drones3030055>
- Subsecretaría de Agricultura Pesca y Alimentación. (2020). Encuesta sobre superficies y rendimientos de cultivos. Informe sobre regadíos en España. <https://cpage.mpr.gob.es>
- Support pix4d. (2020). Getting GCPs on the field or through other sources (optional but recommended). PIX4D documentation. https://bit.ly/Getting_GCP_Pix4D
- Taravat, A., Wagner, M. P., Oppelt, N. (2019). Automatic Grassland Cutting Status Detection in the Context of Spatiotemporal Sentinel-1 Imagery Analysis and Artificial Neural Networks. *Remote Sensing* 2019, Vol. 11, Page 711, 11(6), 711. <https://doi.org/10.3390/RS11060711>

- Tian, F., Cai, Z., Jin, H., Hufkens, K., Scheffinger, H., Tagesson, T., Smets, B., Van Hoolst, R., Bonte, K., Ivits, E., Tong, X., Ardö, J., Eklundh, L. (2021). Calibrating vegetation phenology from Sentinel-2 using eddy covariance, PhenoCam, and PEP725 networks across Europe. *Remote Sensing of Environment*, 260, 112456. <https://doi.org/10.1016/j.rse.2021.112456>
- Tsouros, D. C., Bibi, S., Sarigiannidis, P. G. (2019). A Review on UAV-Based Applications for Precision Agriculture. *Information*, 10(11), 349. <https://doi.org/10.3390/info10110349>
- Ustin, S. L., Jacquemoud, S. (2020). How the optical properties of leaves modify the absorption and scattering of energy and enhance leaf functionality. *Remote Sensing of Plant Biodiversity*, 349-384. https://doi.org/10.1007/978-3-030-33157-3_14/FIGURES/16
- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J. F., Ceschia, E. (2017). Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sensing of Environment*, 199, 415-426. <https://doi.org/10.1016/J.RSE.2017.07.015>
- Verstraeten, G., Poesen, J., Demarée, G., Salles, C. (2006). Long-term (105 years) variability in rain erosivity as derived from 10-min rainfall depth data for Ukkel (Brussels, Belgium): Implications for assessing soil erosion rates. *Journal of Geophysical Research: Atmospheres*, 111(D22). <https://doi.org/10.1029/2006JD007169>
- Vrieling, A., Meroni, M., Darvishzadeh, R., Skidmore, A. K., Wang, T., Zurita-Milla, R., Oosterbeek, K., O'Connor, B., Paganini, M. (2018). Vegetation phenology from Sentinel-2 and field cameras for a Dutch barrier island. *Remote Sensing of Environment*, 215, 517-529. <https://doi.org/10.1016/J.RSE.2018.03.014>
- Vuolo, F., Žóltak, M., Pipitone, C., Zappa, L., Wennig, H., Immitzer, M., Weiss, M., Baret, F., Atzberger, C. (2016). Data Service Platform for Sentinel-2 Surface Reflectance and Value-Added Products: System Use and Examples. *Remote Sensing*, 8(11), 938. <https://doi.org/10.3390/rs8110938>
- Wang, C., Cao, R., Chen, J., Rao, Y., Tang, Y. (2015). Temperature sensitivity of spring vegetation phenology correlates to within-spring warming speed over the Northern Hemisphere. *Ecological Indicators*, 50, 62-68. <https://doi.org/10.1016/J.ECOLIND.2014.11.004>
- Wang, C., Chen, J., Wu, J., Tang, Y., Shi, P., Black, T. A., Zhu, K. (2017). A snow-free vegetation index for improved monitoring of vegetation spring green-up date in deciduous ecosystems. <https://doi.org/10.1016/j.rse.2017.04.031>
- Wang, J. Y. (1960). A Critique of the Heat Unit Approach to Plant Response Studies. *Ecology*, 41(4), 785-790. <https://doi.org/10.2307/1931815>
- Wu, C., Gonsamo, A., Gough, C. M., Chen, J. M., Xu, S. (2014). Modeling growing season phenology in North American forests using seasonal mean vegetation indices from MODIS. *Remote Sensing of Environment*, 147, 79-88. <https://doi.org/10.1016/J.RSE.2014.03.001>
- Wu, C., Niu, Z., Tang, Q., Huang, W. (2008). Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and Forest Meteorology*, 148(8-9), 1230-1241. <https://doi.org/10.1016/j.agrformet.2008.03.005>

- Yang, L., Villarini, G., Smith, J. A., Tian, F., Hu, H. (2013). Changes in seasonal maximum daily precipitation in China over the period 1961–2006. *International Journal of Climatology*, 33(7), 1646-1657. <https://doi.org/10.1002/JOC.3539>
- You, J., Li, X., Low, M., Lobell, D., Ermon, S. (2017). Deep Gaussian Process for Crop Yield Prediction Based on Remote Sensing Data. *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17) Deep*, 4559-4565. www.aaai.org
- Yu, B., Shang, S. (2017). Multi-Year Mapping of Maize and Sunflower in Hetao Irrigation District of China with High Spatial and Temporal Resolution Vegetation Index Series. *Remote Sensing*, 9(8), 855. <https://doi.org/10.3390/rs9080855>
- Yue, J., Tian, J., Tian, Q., Xu, K., Xu, N. (2019). Development of soil moisture indices from differences in water absorption between shortwave-infrared bands. *ISPRS Journal of Photogrammetry and Remote Sensing*, 154, 216-230. <https://doi.org/10.1016/j.isprsjprs.2019.06.012>
- Yue, S., Wang, C. Y. (2002). The influence of serial correlation on the Mann-Whitney test for detecting a shift in median. *Advances in Water Resources*, 25(3), 325-333. [https://doi.org/10.1016/S0309-1708\(01\)00049-5](https://doi.org/10.1016/S0309-1708(01)00049-5)
- Zarco-Tejada, P. J., Camino, C., Beck, P. S. A., Calderon, R., Hornero, A., Hernández-Clemente, R., Kattenborn, T., Montes-Borrego, M., Susca, L., Morelli, M., Gonzalez-Dugo, V., North, P. R. J., Landa, B. B., Boscia, D., Saponari, M., Navas-Cortes, J. A. (2018). Previsual symptoms of *Xylella fastidiosa* infection revealed in spectral plant-trait alterations. *Nature Plants*, 4(7), 432-439. <https://doi.org/10.1038/s41477-018-0189-7>
- Zarco-Tejada, P. J., Diaz-Varela, R., Angileri, V., Loudjani, P. (2014). Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. *European Journal of Agronomy*, 55, 89-99. <https://doi.org/10.1016/j.eja.2014.01.004>
- Zarco-Tejada, P. J., González-Dugo, V., Berni, J. A. J. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, 117, 322-337. <https://doi.org/10.1016/j.rse.2011.10.007>
- Zhang, C., Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agriculture*, 13(6), 693-712. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, H. K., Roy, D. P., Yan, L., Li, Z., Huang, H., Vermote, E., Skakun, S., Roger, J. C. (2018). Characterization of Sentinel-2A and Landsat-8 top of atmosphere, surface, and nadir BRDF adjusted reflectance and NDVI differences. *Remote Sensing of Environment*, 215, 482-494. <https://doi.org/10.1016/j.rse.2018.04.031>
- Zhang, X., Friedl, M. A., Schaaf, C. B., Strahler, A. H., Hodges, J. C. F., Gao, F., Reed, B. C., Huete, A. (2003). Monitoring vegetation phenology using MODIS. *Remote Sensing of Environment*, 84(3), 471-475. [https://doi.org/10.1016/S0034-4257\(02\)00135-9](https://doi.org/10.1016/S0034-4257(02)00135-9)
- Zhang, X., Wang, J., Henebry, G. M., Gao, F. (2020). Development and evaluation of a new algorithm for detecting 30 m land surface phenology from VIIRS and HLS time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 161, 37-51. <https://doi.org/10.1016/j.isprsjprs.2020.01.012>
- Zhao, L., Shi, Y., Liu, B., Hovis, C., Duan, Y., Shi, Z. (2019). Finer Classification of Crops by Fusing UAV Images and Sentinel-2A Data. *Remote Sensing 2019*, Vol. 11, Page 3012, 11(24), 3012. <https://doi.org/10.3390/RS11243012>

Zhong, L., Gong, P., Biging, G. S. (2014). Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery. *Remote Sensing of Environment*, 140, 1-13. <https://doi.org/10.1016/j.rse.2013.08.023>

Anexos

Anexo 1. Imágenes utilizadas en esta Tesis

2018

Nombre de la imagen	Tesela	Fecha	D	Capítulo III	Capítulo IV	Capítulo V
S2A_MSII.2A_20180613T105621_N0208_R094_T30TXM_20180613T141720	T30TXM	13/06/2018	164			X
S2B_MSII.2A_20180615T105029_N0208_R051_T30TYM_20180615T142918	T30TYM	15/06/2018	166			X
S2B_MSII.2A_20180615T105029_N0208_R051_T30TYL_20180615T142918	T30TYL	15/06/2018	166			X
S2A_MSII.2A_20180620T105031_N0208_R051_T30TXM_20180620T165727	T30TXM	20/06/2018	171			X
S2A_MSII.2A_20180620T105031_N0208_R051_T30TYM_20180620T165727	T30TYM	20/06/2018	171			X
S2A_MSII.2A_20180620T105031_N0208_R051_T30TYL_20180620T165727	T30TYL	20/06/2018	171			X
S2A_MSII.2A_20180623T105621_N0208_R094_T30TXM_20180623T140826	T30TXM	23/06/2018	174		X	X
S2B_MSII.2A_20180625T105029_N0208_R051_T30TXM_20180625T135630	T30TXM	25/06/2018	176		X	X
S2B_MSII.2A_20180625T105029_N0208_R051_T30TYM_20180625T135630	T30TYM	25/06/2018	176			X
S2B_MSII.2A_20180625T105029_N0208_R051_T30TYL_20180625T135630	T30TYL	25/06/2018	176			X
S2B_MSII.2A_20180628T105619_N0208_R094_T30TXM_20180628T134405	T30TXM	28/06/2018	179	X	X	
S2A_MSII.2A_20180630T105031_N0208_R051_T30TXM_20180630T144133	T30TXM	30/06/2018	181		X	X
S2A_MSII.2A_20180630T105031_N0208_R051_T30TYM_20180630T144133	T30TYM	30/06/2018	181			X
S2A_MSII.2A_20180630T105031_N0208_R051_T30TYL_20180630T144133	T30TYL	30/06/2018	181			X
S2A_MSII.2A_20180703T105621_N0208_R094_T30TXM_20180703T141003	T30TXM	03/07/2018	184		X	X
S2B_MSII.2A_20180705T105029_N0208_R051_T30TXM_20180705T152258	T30TXM	05/07/2018	186	X	X	X
S2B_MSII.2A_20180705T105029_N0208_R051_T30TYM_20180705T152258	T30TYM	05/07/2018	186			X
S2B_MSII.2A_20180705T105029_N0208_R051_T30TYL_20180705T152258	T30TYL	05/07/2018	186			X
S2B_MSII.2A_20180708T105619_N0208_R094_T30TXM_20180708T141851	T30TXM	08/07/2018	189		X	X

2018

Nombre de la imagen	Tesela	Fecha	D	Capítulo III	Capítulo IV	Capítulo V
S2A_MSIL2A_20180710T105031_N0208_R051_T30TXM_20180710T141216	T30TXM	10/07/2018	191	X	X	X
S2A_MSIL2A_20180710T105031_N0208_R051_T30TYM_20180710T141216	T30TYM	10/07/2018	191			X
S2A_MSIL2A_20180710T105031_N0208_R051_T30TYL_20180710T141216	T30TYL	10/07/2018	191			X
S2B_MSIL2A_20180715T105029_N0208_R051_T30TXM_20180715T152821	T30TXM	15/07/2018	196	X	X	
S2B_MSIL2A_20180715T105029_N0208_R051_T30TYM_20180715T152821	T30TYM	15/07/2018	196			X
S2B_MSIL2A_20180715T105029_N0208_R051_T30TYL_20180715T152821	T30TYL	15/07/2018	196			X
S2B_MSIL2A_20180718T110039_N0208_R094_T30TXM_20180718T153342	T30TXM	18/07/2018	199		X	X
S2A_MSIL2A_20180720T105031_N0208_R051_T30TXM_20180720T135744	T30TXM	20/07/2018	201		X	X
S2A_MSIL2A_20180720T105031_N0208_R051_T30TYM_20180720T135744	T30TYM	20/07/2018	201			X
S2A_MSIL2A_20180720T105031_N0208_R051_T30TYL_20180720T135744	T30TYL	20/07/2018	201			X
S2A_MSIL2A_20180723T105621_N0208_R094_T30TXM_20180723T140954	T30TXM	23/07/2018	204	X	X	X
S2A_MSIL2A_20180730T105031_N0208_R051_T30TXM_20180730T141204	T30TXM	30/07/2018	209		X	X
S2A_MSIL2A_20180730T105031_N0208_R051_T30TYM_20180730T141204	T30TYM	30/07/2018	211			X
S2A_MSIL2A_20180730T105031_N0208_R051_T30TYL_20180730T141204	T30TYL	30/07/2018	211			X
S2A_MSIL2A_20180802T105621_N0208_R094_T30TXM_20180802T141714	T30TXM	02/08/2018	211	X	X	
S2B_MSIL2A_20180804T105019_N0208_R051_T30TXM_20180804T173100	T30TXM	04/08/2018	216		X	
S2A_MSIL2A_20180809T105031_N0208_R051_T30TXM_20180809T141746	T30TXM	09/08/2018	221		X	
S2A_MSIL2A_20180812T105621_N0213_R094_T30TXM_20201026T165913	T30TXM	12/08/2018	224		X	

2019

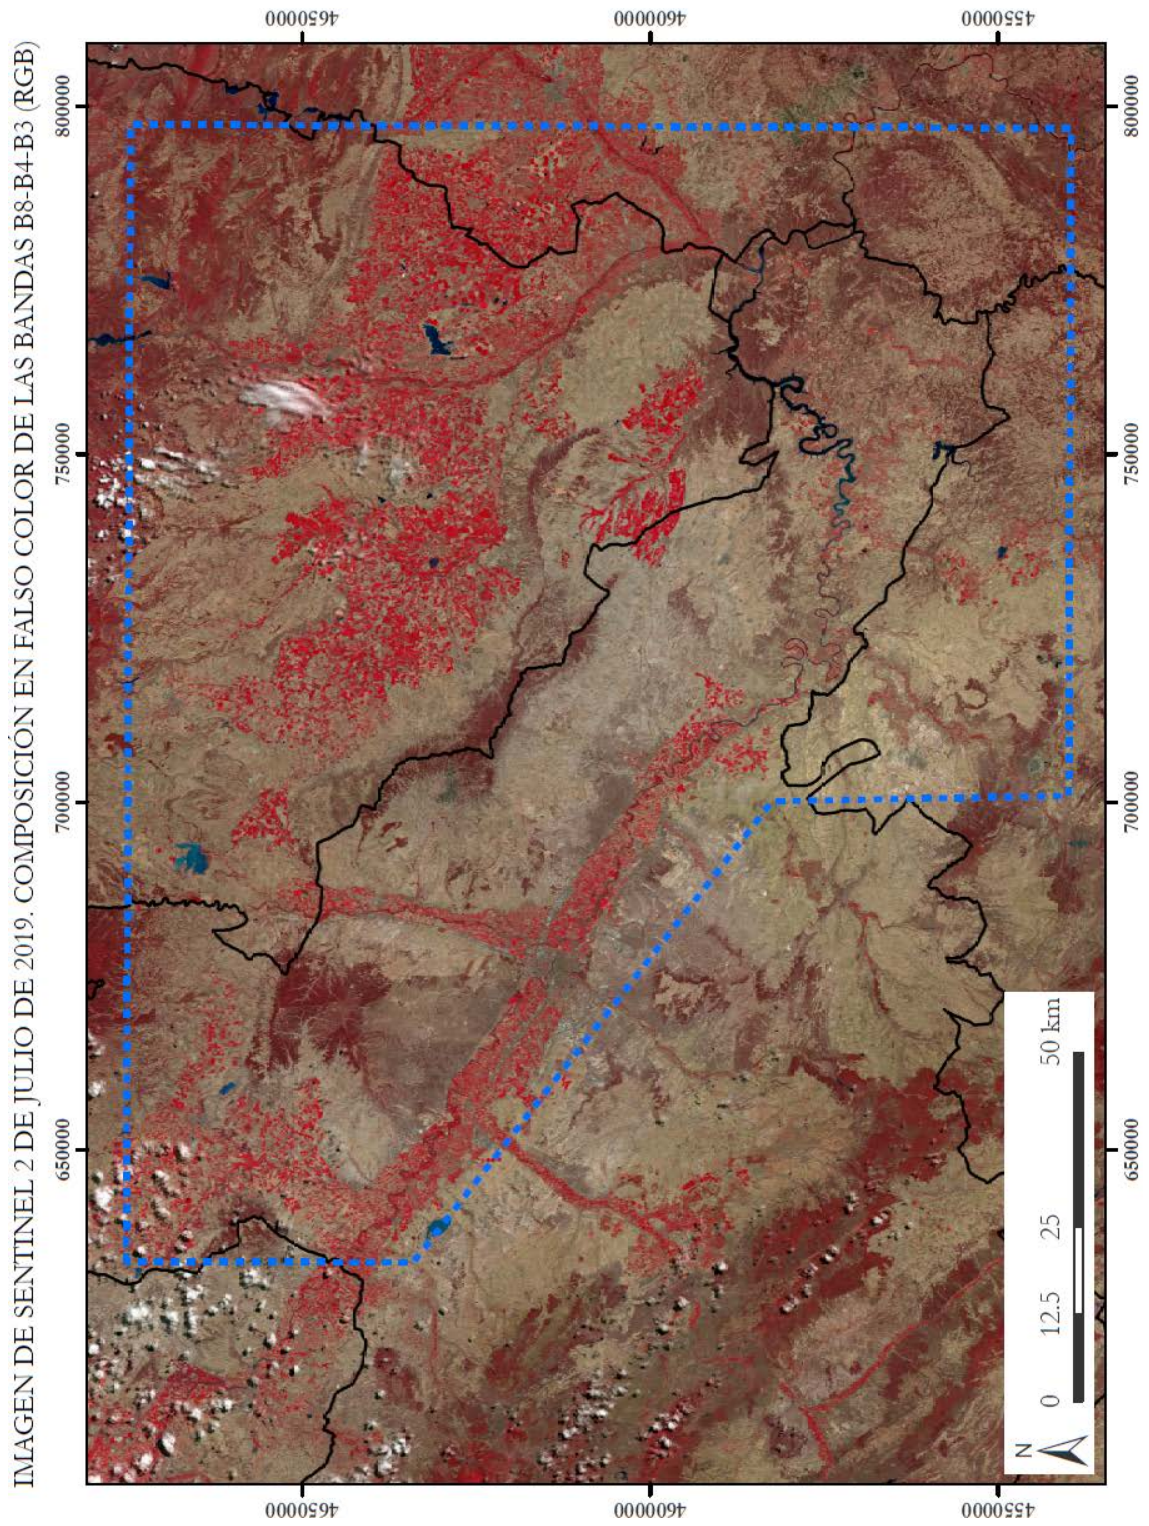
Nombre de la imagen	Tesela	Fecha	D	Capítulo III	Capítulo IV	Capítulo V
S2A_MSIL2A_20190429T105621_N0211_R094_T30TXM_20190429T141414	T30TXM	29/04/2019	119	X		
S2A_MSIL2A_20190506T105031_N0212_R051_T30TXM_20190515T085656	T30TXM	06/05/2019	126	X		
S2B_MSIL2A_20190514T105629_N0212_R094_T30TXM_20190514T125218	T30TXM	14/05/2019	134	X		
S2A_MSIL2A_20190529T105621_N0212_R094_T30TXM_20190529T141618	T30TXM	29/05/2019	149	X		
S2B_MSIL2A_20190531T105039_N0212_R051_T30TXM_20190531T140515	T30TXM	31/05/2019	151	X		
S2B_MSIL2A_20190613T105629_N0212_R094_T30TXM_20190614T143515	T30TXM	13/06/2019	164	X		X
S2A_MSIL2A_20190615T105031_N0212_R051_T30TXM_20190615T121337	T30TXM	15/06/2019	166			X
S2A_MSIL2A_20190615T105031_N0212_R051_T30TYM_20190615T121337	T30TYM	15/06/2019	166			X
S2A_MSIL2A_20190615T105031_N0212_R051_T30TYL_20190615T121337	T30TYL	15/06/2019	166			X
S2A_MSIL2A_20190618T105621_N0212_R094_T30TXM_20190618T142634	T30TXM	18/06/2019	169			X
S2B_MSIL2A_20190620T105039_N0212_R051_T30TYM_20190620T135541	T30TYM	20/06/2019	171			X
S2B_MSIL2A_20190620T105039_N0212_R051_T30TYL_20190620T135541	T30TYL	20/06/2019	171			X
S2B_MSIL2A_20190623T105629_N0212_R094_T30TXM_20190623T141320	T30TXM	23/06/2019	174		X	X
S2A_MSIL2A_20190625T105031_N0212_R051_T30TXM_20190625T134744	T30TXM	25/06/2019	176		X	X
S2A_MSIL2A_20190625T105031_N0212_R051_T30TYM_20190625T134744	T30TYM	25/06/2019	176			X
S2A_MSIL2A_20190625T105031_N0212_R051_T30TYL_20190625T134744	T30TYL	25/06/2019	176			X
S2A_MSIL2A_20190628T105621_N0212_R094_T30TXM_20190628T141522	T30TXM	28/06/2019	179	X	X	X
S2B_MSIL2A_20190630T105039_N0212_R051_T30TXM_20190630T133617	T30TXM	30/06/2019	181		X	X
S2B_MSIL2A_20190630T105039_N0212_R051_T30TYM_20190630T133617	T30TYM	30/06/2019	181			X
S2B_MSIL2A_20190630T105039_N0212_R051_T30TYL_20190630T133617	T30TYL	30/06/2019	181			X

2019

Nombre de la imagen	Tesela	Fecha	D	Capítulo III	Capítulo IV	Capítulo V
S2B_MSII.2A_20190703T105629_N0212_R094_T30TXM_20190703T143747	T30TXM	03/07/2019	184		X	X
S2A_MSII.2A_20190705T105031_N0212_R051_T30TXM_20190705T140734	T30TXM	05/07/2019	186	X	X	X
S2A_MSII.2A_20190705T105031_N0212_R051_T30TYM_20190705T140734	T30TYM	05/07/2019	186			X
S2A_MSII.2A_20190705T105031_N0212_R051_T30TYL_20190705T140734	T30TYL	05/07/2019	186			X
S2B_MSII.2A_20190710T105039_N0213_R051_T30TXM_20190710T133923	T30TXM	10/07/2019	191	X	X	X
S2B_MSII.2A_20190710T105039_N0213_R051_T30TYM_20190710T133923	T30TYM	10/07/2019	191			X
S2B_MSII.2A_20190710T105039_N0213_R051_T30TYL_20190710T133923	T30TYL	10/07/2019	191			X
S2A_MSII.2A_20190715T105031_N0213_R051_T30TXM_20190715T121043	T30TXM	15/07/2019	196		X	X
S2A_MSII.2A_20190715T105031_N0213_R051_T30TYM_20190715T121043	T30TYM	15/07/2019	196			X
S2A_MSII.2A_20190715T105031_N0213_R051_T30TYL_20190715T121043	T30TYL	15/07/2019	196			X
S2A_MSII.2A_20190718T105621_N0213_R094_T30TXM_20190718T135614	T30TXM	18/07/2019	199	X	X	X
S2B_MSII.2A_20190720T105039_N0213_R051_T30TYM_20190720T135105	T30TYM	20/07/2019	201			X
S2B_MSII.2A_20190720T105039_N0213_R051_T30TYL_20190720T135105	T30TYL	20/07/2019	201			X
S2B_MSII.2A_20190723T105629_N0213_R094_T30TXM_20190723T150238	T30TXM	23/07/2019	204		X	X
S2A_MSII.2A_20190725T105031_N0213_R051_T30TXM_20190725T141902	T30TXM	25/07/2019	206	X	X	X
S2A_MSII.2A_20190725T105031_N0213_R051_T30TYM_20190725T141902	T30TYM	25/07/2019	206			X
S2A_MSII.2A_20190725T105031_N0213_R051_T30TYL_20190725T141902	T30TYL	25/07/2019	206			X
S2A_MSII.2A_20190728T105621_N0213_R094_T30TXM_20190728T135007	T30TXM	28/07/2019	209		X	X
S2B_MSII.2A_20190730T105039_N0213_R051_T30TXM_20190730T140936	T30TXM	30/07/2019	211		X	X
S2B_MSII.2A_20190730T105039_N0213_R051_T30TYM_20190730T140936	T30TYM	30/07/2019	211			X

2019

Nombre de la imagen	Tesela	Fecha	D	Capítulo III	Capítulo IV	Capítulo V
S2B_MSII.2A_20190730T105039_N0213_R051_T30TYL_20190730T140936	T30TYL	30/07/2019	211			X
S2B_MSII.2A_20190802T105629_N0213_R094_T30TXM_20190802T140410	T30TXM	02/08/2019	214	X	X	
S2A_MSII.2A_20190804T105031_N0213_R051_T30TXM_20190804T142027	T30TXM	04/08/2019	216		X	
S2B_MSII.2A_20190809T105039_N0213_R051_T30TXM_20190809T133658	T30TXM	09/08/2019	221		X	
S2B_MSII.2A_20190812T105629_N0213_R094_T30TXM_20190812T135547	T30TXM	12/08/2019	224		X	
S2A_MSII.2A_20190814T105031_N0213_R051_T30TXM_20190814T120854	T30TXM	14/08/2019	226		X	
S2A_MSII.2A_20190903T105031_N0213_R051_T30TXM_20190903T142511	T30TXM	03/09/2019	246	X		
S2B_MSII.2A_20190918T105029_N0213_R051_T30TXM_20190918T135152	T30TXM	18/09/2019	261	X		
S2B_MSII.2A_20191008T105029_N0213_R051_T30TXM_20191008T133838	T30TXM	08/10/2019	281	X		



Anexo 2. Pruebas estadísticas y gráficos de los modelos de regresión lineal por cultivo y etapa del cultivo.

Tabla 2-1. Prueba de Breusch-Pagan (B-P) para cada banda espectral e IV entre los sensores ASD y MSI de Sentinel 2. En sombreado rosa se muestran los datos con p value < 0,05.

	General		Maíz		Girasol		Etapa primera		Etapa segunda		E-1 maíz laboreo		E-1 maíz cebada		E-1 girasol	
	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value
B2	0,003		0,021	0,078	0,098	0,398	0,485	0,889	0,746							
B3	0,005		0,064	0,012	0,143	0,598	0,778	0,823	0,209							
B4	0,005		0,176	0,000	0,179	0,224	0,833	0,447	0,092							
B5	0,016		0,179	0,007	0,140	0,671	0,817	0,241	0,105							
B6	0,999		0,818	0,152	0,432	0,855	0,556	0,993	0,275							
B7	0,770		0,941	0,184	0,292	0,966	0,564	0,562	0,198							
B8A	0,978		0,666	0,075	0,352	0,857	0,388	0,652	0,286							
B11	0,056		0,629	0,029	0,878	0,207	0,980	0,713	0,253							
B12	0,057		0,515	0,050	0,879	0,600	0,753	0,782	0,772							
NDVI	0,038		0,001	0,919	0,000	0,218	0,539	0,187	0,185							
RDVI	0,036		0,001	0,942	0,001	0,559	0,157	0,157	0,123							
GNDVI	0,032		0,013	0,835	0,023	0,206	0,240	0,743	0,955							
MSRre	0,016		0,124	0,013	0,113	0,895	0,008	0,868	0,900							
Clre	0,010		0,097	0,010	0,103	0,813	0,009	0,829	0,866							
NDRre	0,024		0,000	0,910	0,000	0,319	0,311	0,122	0,208							
SAVI	0,041		0,001	0,915	0,001	0,575	0,181	0,153	0,091							
MSAVI	0,013		0,000	0,993	0,002	0,938	0,196	0,151	0,090							
OSAVI	0,046		0,001	0,882	0,001	0,334	0,247	0,161	0,124							
TVI	0,021		0,003	0,673	0,001	0,767	0,713	0,126	0,030							
MTVI1	0,018		0,002	0,739	0,001	0,906	0,152	0,124	0,025							
MTVI2	0,004		0,000	0,877	0,001	0,692	0,211	0,126	0,036							

Tabla 2-2. Prueba de Kolmogorov-Smirnov (K-S) para cada banda espectral e IV entre los sensores ASD y MSI de Sentinel 2. En sombreado rosa se muestran los datos con p value < 0,05.

	General		Maíz		Girasol		Etapa primera		Etapa segunda		E-1 maíz laboreo		E-1 maíz cebada		E-1 girasol	
	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value	B-P	p-value
B2	0,612		0,487		0,735		0,996		0,984		0,213		0,394		0,524	
B3	0,050		0,412		0,204		0,989		0,945		0,130		0,075		0,083	
B4	0,312		0,550		0,028		0,549		0,148		0,244		0,677		0,325	
B5	0,055		0,577		0,110		0,974		0,630		0,385		0,374		0,082	
B6	0,051		0,886		0,044		0,145		0,171		0,775		0,174		0,038	
B7	0,048		0,701		0,021		0,460		0,249		0,618		0,235		0,104	
B8A	0,046		0,883		0,015		0,298		0,236		0,929		0,153		0,026	
B11	0,569		0,901		0,884		0,453		0,463		0,781		0,301		0,521	
B12	0,795		0,052		0,399		0,063		0,112		0,173		0,347		0,952	
NDVI	0,200		0,012		0,000		0,664		0,466		0,038		0,389		0,231	
RDVI	0,113		0,038		0,004		0,894		0,984		0,416		0,167		0,237	
GNDVI	0,843		0,788		0,058		0,911		0,657		0,165		0,326		0,555	
MSRre	0,159		0,417		0,884		0,302		0,066		0,912		0,659		0,330	
CIre	0,147		0,284		0,874		0,238		0,052		0,908		0,674		0,324	
NDRre	0,693		0,013		0,000		0,693		0,527		0,276		0,253		0,359	
SAVI	0,162		0,018		0,003		0,895		0,953		0,503		0,161		0,246	
MSAVI	0,458		0,026		0,008		0,999		0,957		0,810		0,156		0,332	
OSAVI	0,121		0,044		0,001		0,791		0,807		0,144		0,193		0,293	
TVI	0,325		0,047		0,030		0,975		0,467		0,265		0,032		0,808	
MTVI1	0,270		0,006		0,025		0,994		0,867		0,755		0,080		0,418	
MTVI2	0,612		0,487		0,735		0,996		0,984		0,213		0,394		0,524	

Tabla 2-3. Prueba de Durbin-Watson (D-W) para cada banda espectral e IV entre los sensores ASD y MSI de Sentinel 2. En sombreado rosa se muestran los datos con un valor > 3 y < 1 .

	General		Maíz		Girasol		Etapa primera		Etapa segunda		E-1 maíz laboreo		E-1 maíz cebada		E-1 girasol	
	D-W		D-W		D-W		D-W		D-W		D-W		D-W		D-W	
B2	1,915		1,948		2,414		1,896		1,715		1,280		2,009		2,921	
B3	1,950		1,946		2,628		1,874		2,111		1,419		2,209		2,777	
B4	2,069		2,098		2,385		1,976		2,311		1,425		2,275		2,468	
B5	2,072		2,199		2,640		1,948		2,226		1,574		2,321		2,734	
B6	2,201		2,255		2,466		2,111		2,328		1,504		2,402		2,302	
B7	2,201		2,418		2,202		2,193		2,246		1,604		2,440		2,178	
B8A	2,179		2,391		2,319		2,232		2,240		1,672		2,626		2,249	
B11	1,912		2,294		1,573		1,925		1,903		1,837		1,680		1,593	
B12	1,864		2,267		1,053		1,704		2,174		1,669		1,753		1,144	
NDVI	2,612		2,547		0,958		2,414		2,563		2,236		2,815		2,267	
RDVI	2,655		2,476		1,431		2,412		2,557		2,708		2,987		2,405	
GNDVI	2,514		2,231		1,221		2,190		2,438		1,622		2,163		2,487	
MSRre	2,342		2,117		2,425		1,920		2,349		1,662		1,859		2,435	
CIre	2,354		2,142		2,433		1,924		2,359		1,658		1,850		2,444	
NDRre	2,625		2,704		0,969		2,430		2,606		2,616		2,608		2,179	
SAVI	2,647		2,466		1,423		2,430		2,541		2,708		2,984		2,392	
MSAVI	2,653		2,601		1,588		2,413		2,537		2,814		3,020		2,419	
OSAVI	2,637		2,516		1,175		2,430		2,561		2,471		2,914		2,321	
TVI	2,650		2,461		1,730		2,545		2,575		1,735		2,801		2,034	
MTVI1	2,665		2,407		1,779		2,482		2,546		2,487		2,959		2,341	
MTVI2	2,650		2,780		1,556		2,476		2,557		2,228		2,963		2,251	

Tabla 2-4. Prueba de B-P para cada banda espectral e IV entre los sensores ASD y Sequoia. En sombreado rosa se muestran los datos con p value $< 0,05$.

	General	Maíz	Girasol	Primera etapa	Segunda etapa
	B-P p-value	B-P p-value	B-P p-value	B-P p-value	B-P p-value
B3	0,018	0,006	0,488	0,613	0,552
B4	0,001	0,039	0,022	0,289	0,052
B6	0,996	0,923	0,015	0,745	0,932
B7	0,001	0,066	0,004	0,521	0,105
NDVI	0,006	0,049	0,029	0,736	0,618
RDVI	0,001	0,011	0,008	0,894	0,081
GNDVI	0,368	0,356	0,317	0,988	0,859
MSRre	0,421	0,176	0,144	0,676	0,664
CIre	0,236	0,045	0,150	0,695	0,924
NDRre	0,000	0,008	0,021	0,400	0,357
SAVI	0,001	0,011	0,009	0,963	0,081
MSAVI	0,000	0,005	0,007	0,874	0,066
OSAVI	0,001	0,021	0,017	0,862	0,217
TVI	0,002	0,060	0,008	0,284	0,015
MTVI1	0,000	0,013	0,004	0,471	0,019
MTVI2	0,000	0,008	0,008	0,848	0,043

Tabla 2-5. Prueba de K-S para cada banda espectral e IV entre los sensores ASD y Sequoia. En sombreado rosa se muestran los datos con p value $< 0,05$.

	General	Maíz	Girasol	Primera etapa	Segunda etapa
	K-S p-value	K-S p-value	K-S p-value	K-S p-value	K-S p-value
B3	0,516	0,389	0,904	0,178	0,233
B4	0,942	0,875	0,881	0,309	0,960
B6	0,182	0,214	0,666	0,088	0,165
B7	0,051	0,315	0,600	0,804	0,742
NDVI	0,089	0,073	0,658	0,187	0,513
RDVI	0,013	0,033	0,638	0,079	0,398
GNDVI	0,608	0,138	0,077	0,719	0,875
MSRre	0,008	0,725	0,245	0,106	0,158
CIre	0,009	0,767	0,238	0,095	0,234
NDRre	0,074	0,113	0,797	0,743	0,858
SAVI	0,016	0,038	0,709	0,067	0,460
MSAVI	0,048	0,001	0,213	0,089	0,728
OSAVI	0,141	0,296	0,881	0,054	0,444
TVI	0,623	0,142	0,199	0,173	0,591
MTVI1	0,047	0,012	0,152	0,038	0,701
MTVI2	0,124	0,003	0,431	0,093	0,875

Tabla 2-6. Prueba de D-W para cada banda espectral e IV entre los sensores ASD y Sequoia, En sombreado rosa se muestran los datos con un valor > 3 y < 1 .

	General	Maíz	Girasol	Primera etapa	Segunda etapa
	D-W	D-W	D-W	D-W	D-W
B3	1,469	1,049	1,219	1,254	1,078
B4	1,656	1,254	1,955	1,608	1,630
B6	0,523	0,326	1,947	0,706	1,162
B7	0,867	1,068	1,681	1,420	1,524
NDVI	1,258	1,345	1,893	1,560	1,678
RDVI	1,193	1,369	1,806	1,524	1,761
GNDVI	0,905	0,814	1,924	1,019	1,382
Msre	1,588	1,122	1,461	0,619	0,794
CIre	1,571	1,213	1,460	0,624	0,844
NDRre	1,064	1,062	1,950	1,713	1,250
SAVI	1,226	1,400	1,806	1,540	1,776
MSAVI	1,286	1,459	1,849	1,524	1,813
OSAVI	1,264	1,385	1,858	1,553	1,763
TVI	1,534	1,416	1,505	1,366	1,621
MTVI1	1,669	1,438	1,627	1,415	1,694
MTVI2	1,829	1,527	1,767	1,429	1,756

Tabla 2-7. Prueba de B-P, Shapiro Wilks (S-W) y D-W para cada una de las longitudes de onda espectrales e IV entre los datos de Sentinel 2 y UAV en el píxel de medidas. En sombreado rosa se muestran los datos con p value $< 0,05$.

	General	General	General
	B-P p-value	S-W p-value	D-W
B3	0,687	0,771	2,171
B4	0,979	0,876	2,426
B6	0,491	0,002	2,075
B7	0,075	0,540	2,556
NDVI	0,757	0,167	1,496
RDVI	0,122	0,457	1,881
GNDVI	0,521	0,401	1,774
MSRre	0,227	0,688	1,663
CIre	0,162	0,601	1,707
NDRre	0,112	0,700	1,532
SAVI	0,144	0,616	1,877
MSAVI	0,151	0,831	1,733
OSAVI	0,666	0,064	1,651
TVI	0,086	0,458	2,048
MTVI1	0,025	0,899	2,138
MTVI2	0,526	0,291	1,763

	Maíz	Girasol	Etapa primera	Etapa segunda
	S-W p-value	S-W p-value	S-W p-value	S-W p-value
B6	0,165	0,849	0,520	0,410
	Maíz	Girasol	Etapa primera	Etapa segunda
	P-B p-value	P-B p-value	P-B p-value	P-B p-value
MTVI1	0,275	0,643	0,394	0,350

En el caso del escenario 4 (comparativa entre Sequoia y MSI de Sentinel 2, para los datos medidos por parcela) las pruebas estadísticas se aplicaron para el 10% del total de la muestra

(3240). Este proceso se repitió 10 veces para asegurar que el resultado no es sensible a la muestra.

En las siguientes tablas se muestra el número de veces que los valores de significación en cada una de las repeticiones de las pruebas de B-P, K-S y S-W tiene un p value $< 0,05$. Así como también los valores < 1 y >3 en cada repetición de la prueba de D-W.

Tabla 2-8. Número de repeticiones con p values $< 0,05$ obtenidos al aplicar la prueba de B-P para cada una de las longitudes de onda espectrales e IV, para la comparativa de los datos MSI de Sentinel 2 y UAV para toda la parcela. El sombreado rosa oscuro indica que hay más de 8 repeticiones con p values $< 0,05$, el rosa claro que hay entre 5 y 7 repeticiones con p values $< 0,05$.

	General	Maíz	Girasol	E-1	E-2	E-3
	B-P p-value	B-P p-value	B-P p-value	B-P p-value	B-P p-value	B-P p-value
B3	2	1	4	3	0	1
B4	1	0	2	2	0	3
B6	10	8	8	2	0	2
B7	10	10	7	4	7	8
NDVI	5	9	10	0	0	2
RDVI	10	3	3	0	3	1
GNDVI	4	10	5	0	7	1
MSRre	0	0	10	5	1	0
CIre	7	7	10	5	3	0
NDRre	0	9	10	0	0	6
SAVI	10	2	1	0	2	1
MSAVI	10	3	0	0	3	1
OSAVI	1	9	8	0	0	1
TVI	10	10	7	2	7	7
MTVI1	10	10	10	1	10	10
MTVI2	8	9	6	1	6	8

Tabla 2-9. Número de repeticiones con p values $< 0,05$ obtenidos al aplicar la prueba de K-S para cada una de las longitudes de onda espectrales e IV, para la comparativa de los datos MSI de Sentinel 2 y UAV para toda la parcela. El sombreado rosa oscuro indica que hay más de 8 repeticiones con p values $< 0,05$, el rosa claro que hay entre 5 y 7 repeticiones con p values $< 0,05$.

	General	Maíz	Girasol	E-1	E-2	E-3
	K-S p-value	K-S p-value	K-S p-value	K-S p-value	K-S p-value	K-S p-value
B3	10	0	3	4	2	0
B4	10	10	10	1	10	0
B6	7	3	10	2	8	0
B7	5	2	10	7	5	0
NDVI	8	10	10	1	8	2
RDVI	5	4	3	1	10	1
GNDVI	5	10	10	4	8	0
MSRre	0	3	1	6	3	2
CIre	2	6	1	7	4	3
NDRre	3	7	8	1	9	1
SAVI	7	4	2	1	10	0
MSAVI	6	2	4	1	10	1
OSAVI	1	2	2	1	9	1

	General	Maíz	Girasol	E-1	E-2	E-3
	K-S p-value	K-S p-value	K-S p-value	K-S p-value	K-S p-value	K-S p-value
TVI	2	3	5	1	1	0
MTVI1	2	3	9	2	1	1
MTVI2	5	10	9	1	8	1

Tabla 2-10. Número de repeticiones con valores < 1 y > 3 obtenidos al aplicar la prueba de D-W para cada una de las longitudes de onda espectrales e IV, para la comparativa de los datos MSI de Sentinel 2 y UAV para toda la parcela.

	Todos	Maíz	Girasol	E-1	E-2	E-2
	D-W	D-W	D-W	D-W	D-W	D-W
B3	0	0	0	0	0	0
B4	0	0	0	0	0	0
B6	0	0	0	0	0	0
B7	0	0	0	0	0	0
NDVI	0	0	0	0	0	0
RDVI	0	0	0	0	0	0
GNDVI	0	0	0	0	0	0
Msre	0	0	0	0	0	0
Cire	0	0	0	0	0	0
NDRre	0	0	0	0	0	1
SAVI	0	0	0	0	0	0
MSAVI	0	0	0	0	0	0
OSAVI	0	0	0	0	0	0
TVI	0	0	0	0	0	0
MTVI1	0	0	0	0	0	0
MTVI2	0	0	0	0	0	0

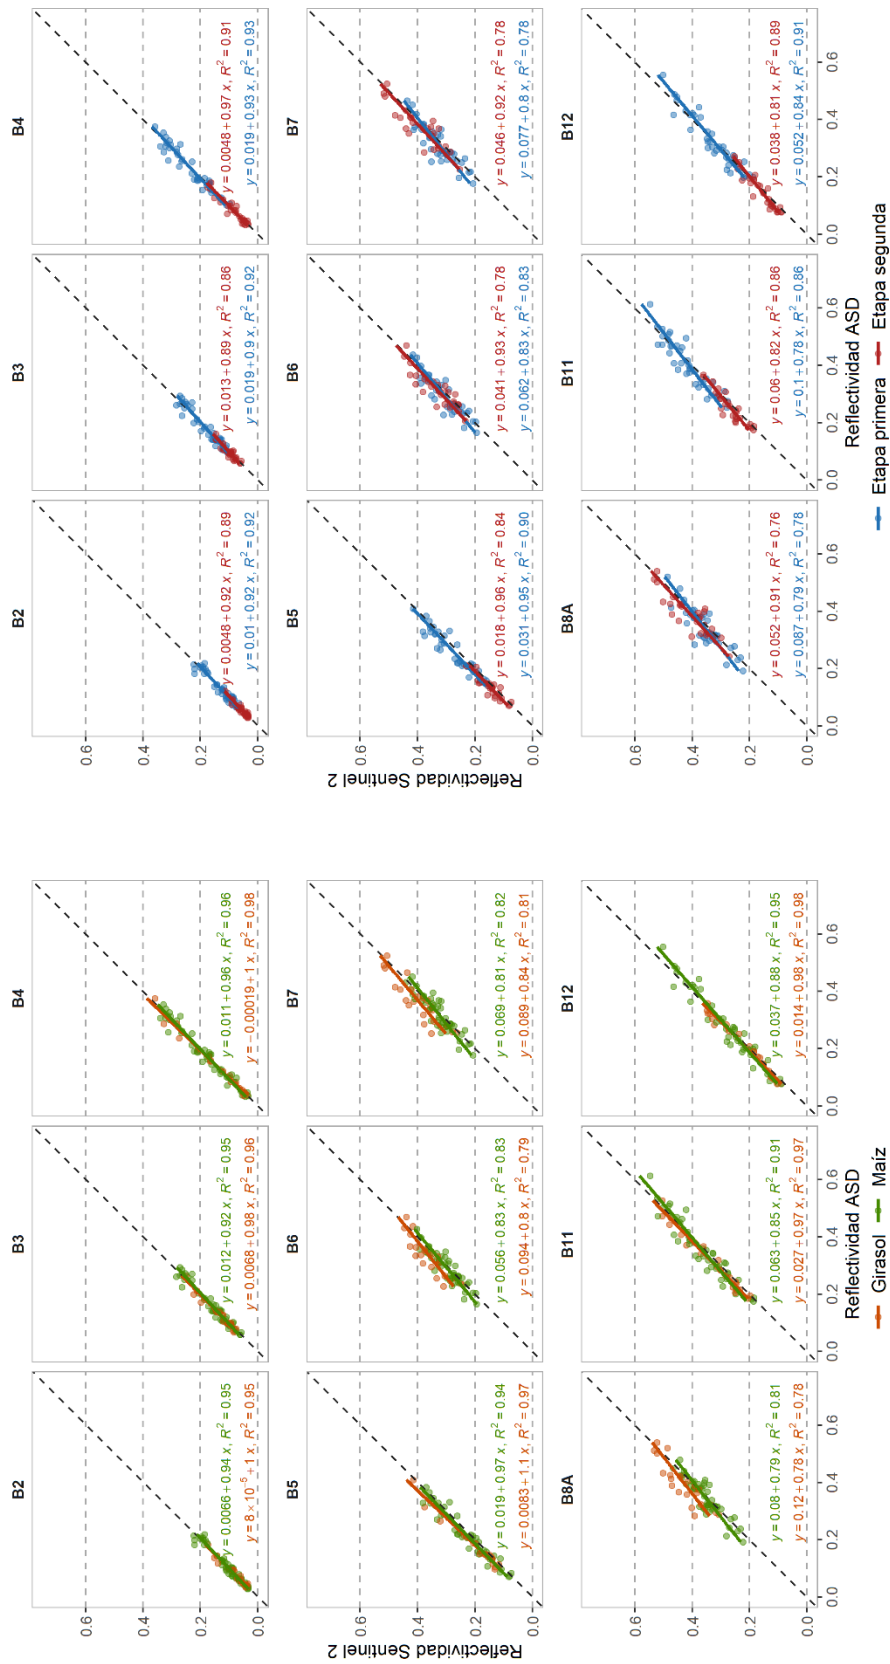


Figura 2-1. Reflectividad en cada banda espectral por tipo de cultivo y etapa del cultivo entre medidas ASD y Sentinel 2 (n=68).

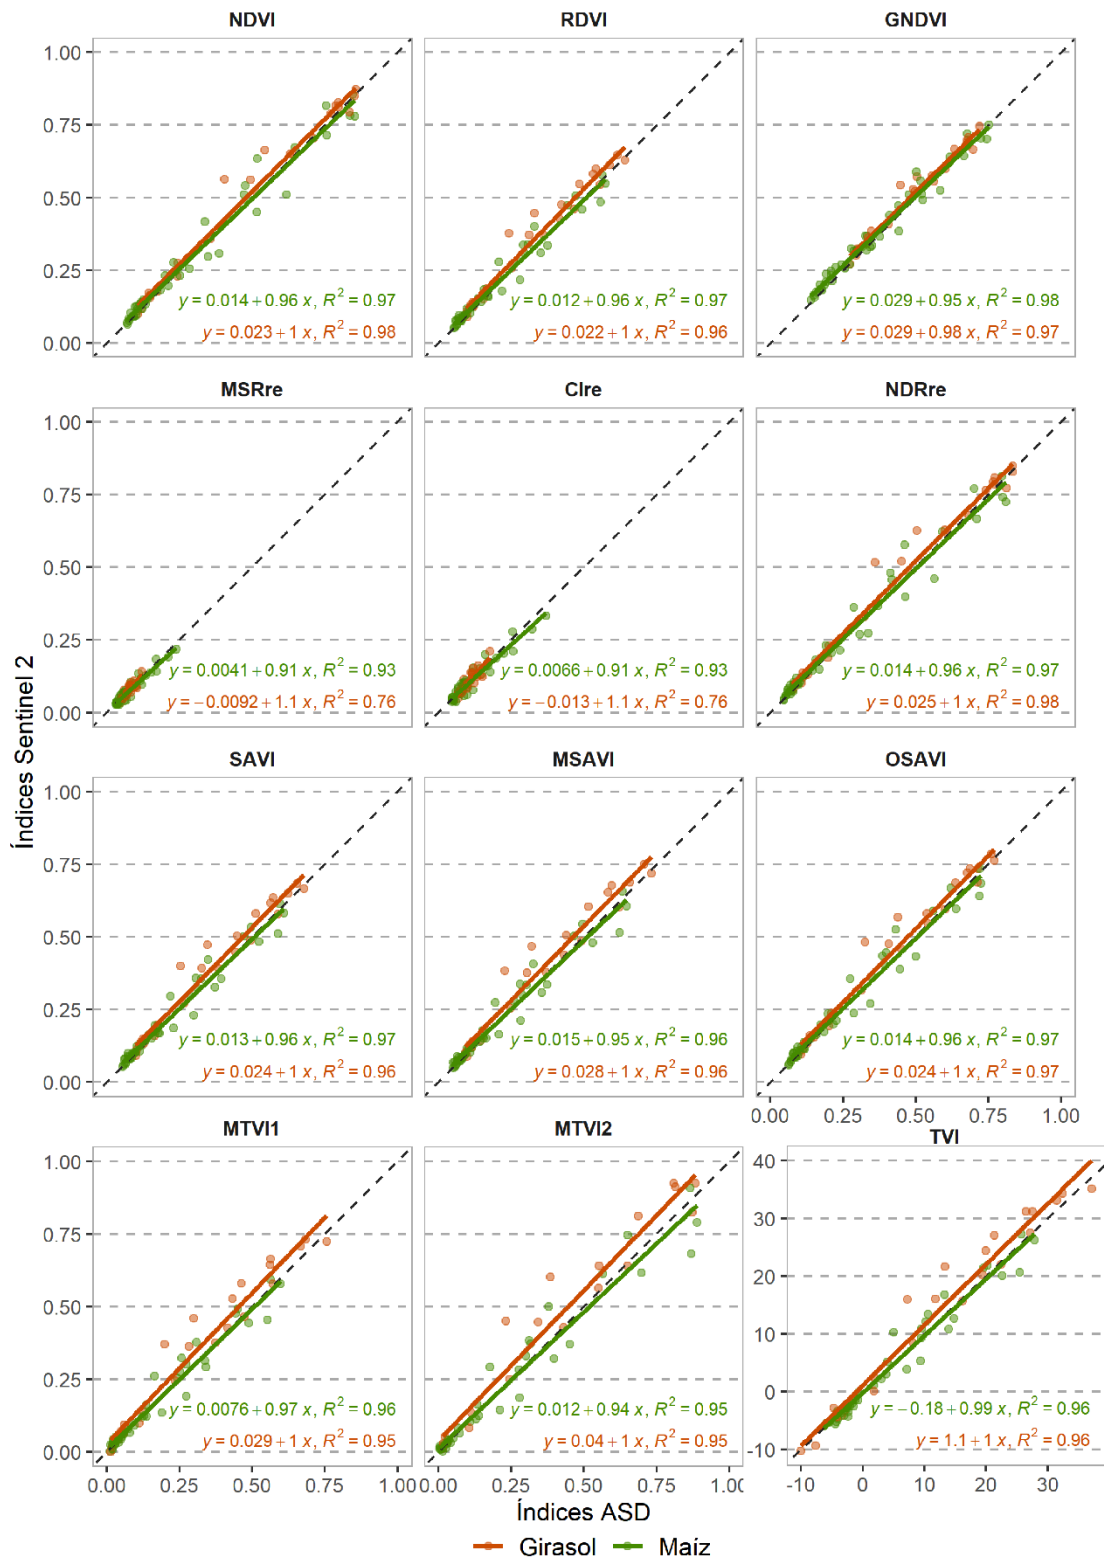


Figura 2-2. Índices de vegetación por tipo de cultivo entre ASD y Sentinel 2 (n=68).

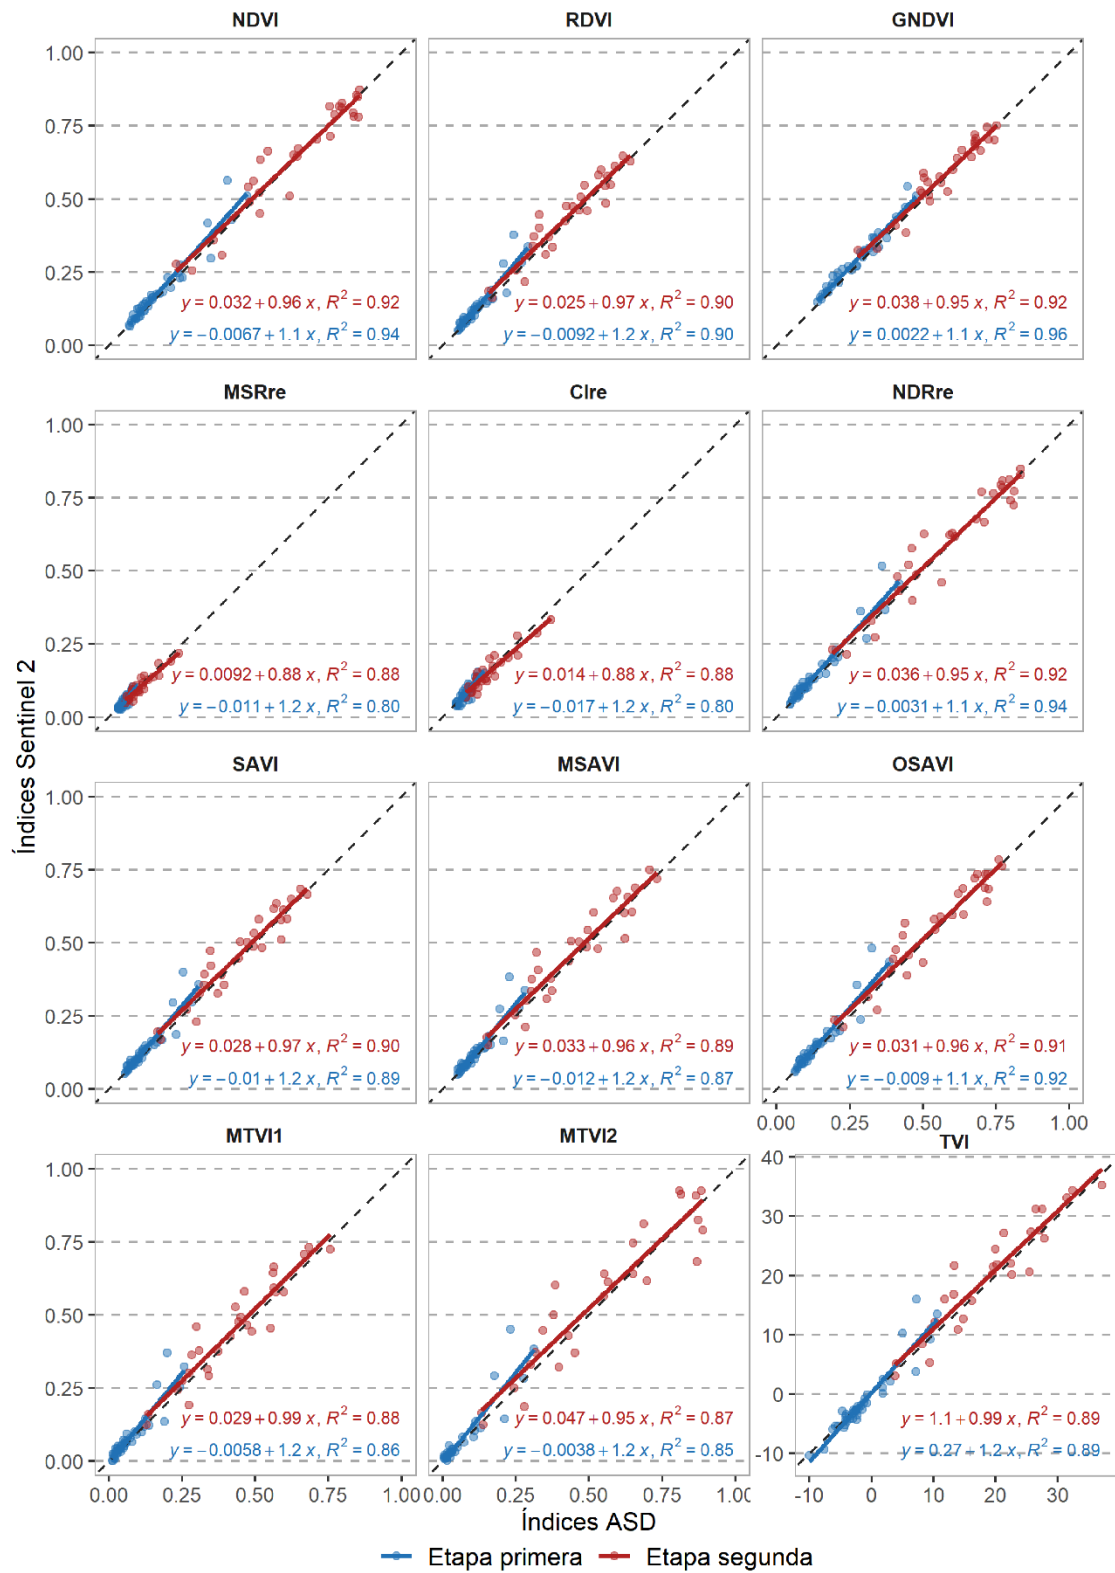


Figura 2-3. Índices de vegetación por etapa de cultivo entre ASD y Sentinel 2 (n=68).




Figura 2-4. Reflectividad en cada banda espectral por tipo de cultivo entre las medidas de ASD y UAV (n=82).




Figura 2-5. Reflectividad en cada banda espectral por etapa de cultivo entre las medidas de ASD y UAV (n=82).

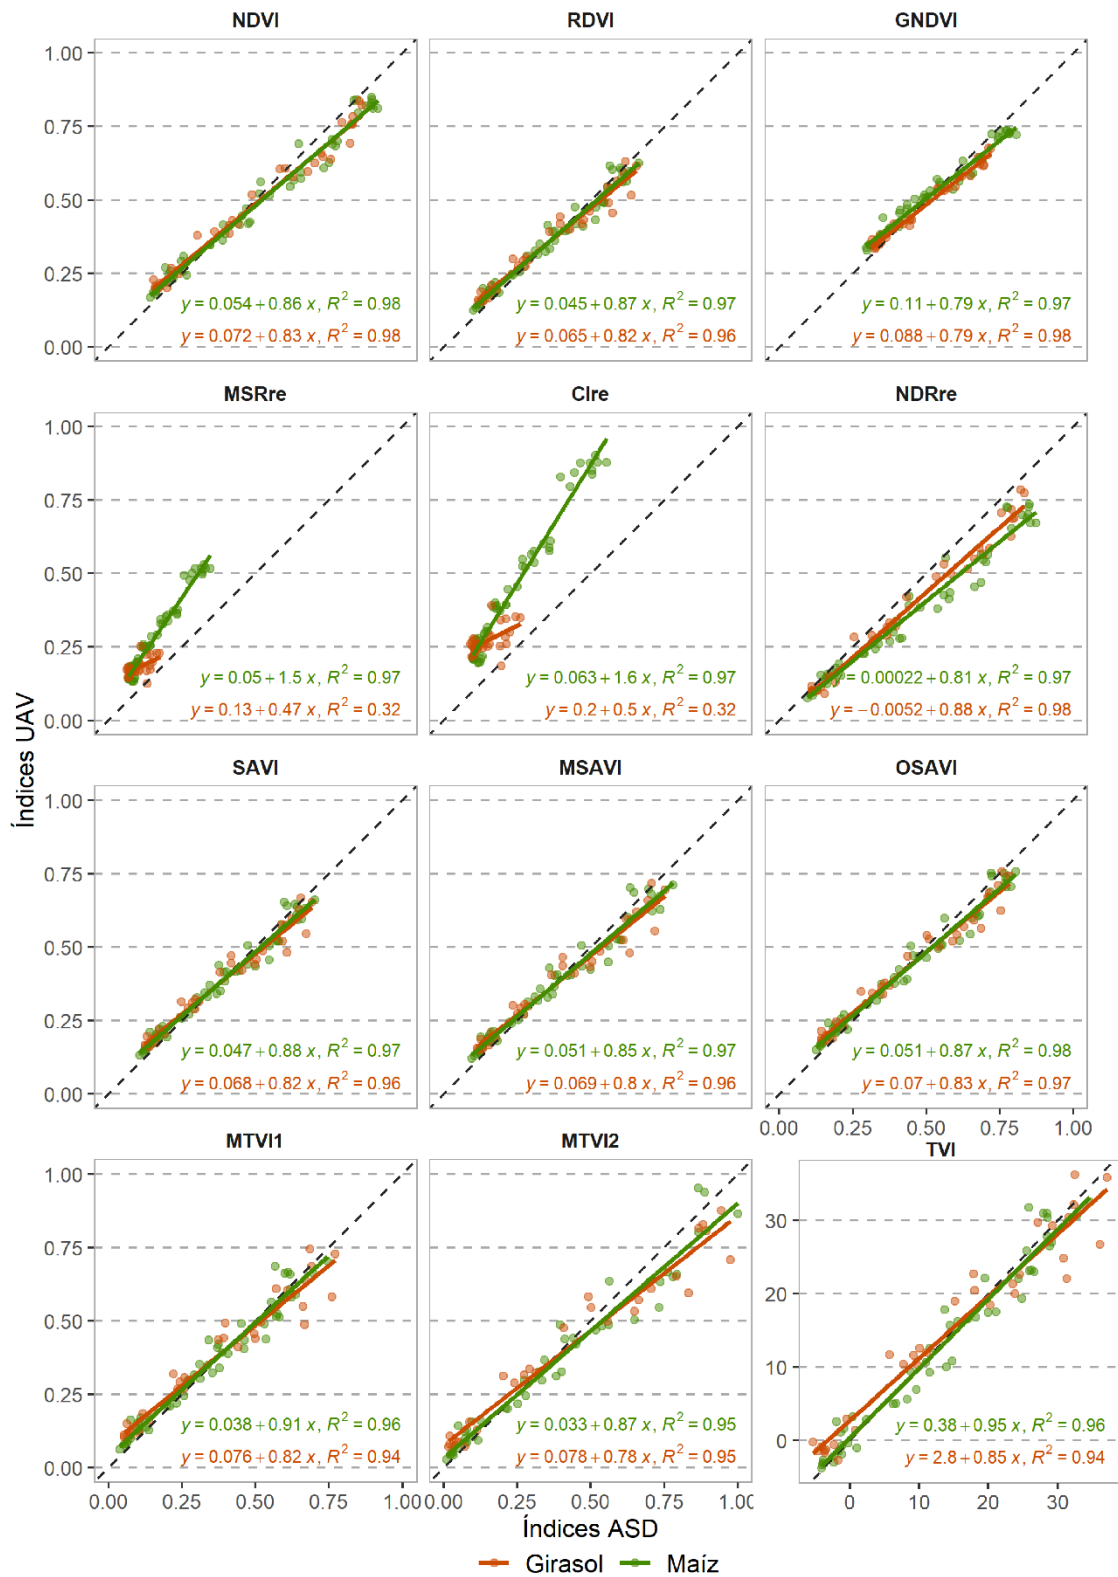


Figura 2-6. Reflectividad en cada IV por tipo de cultivo entre las medidas de ASD y UAV (n=82).

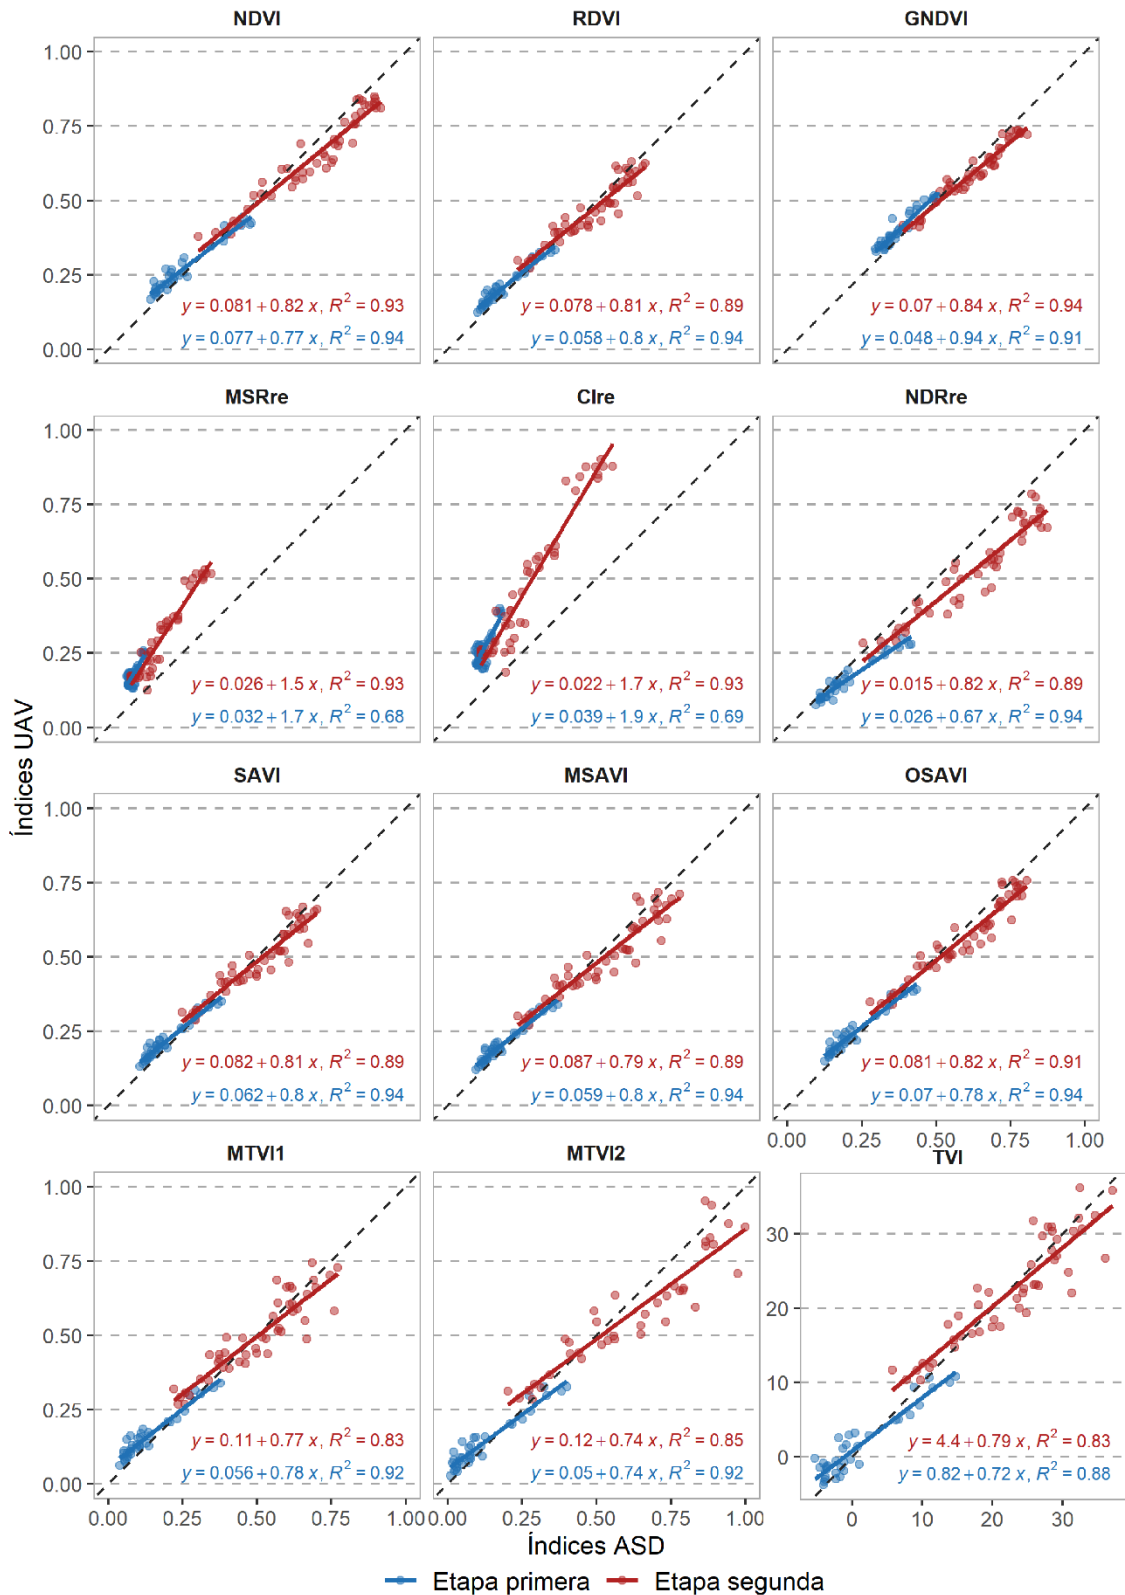


Figura 2-7. Reflectividad en cada IV por etapa de cultivo entre las medidas de ASD y UAV (n=82).




Figura 2-8. Reflectividad en cada banda espectral por tipo de cultivo entre medidas Sentinel 2 y UAV (n=22).

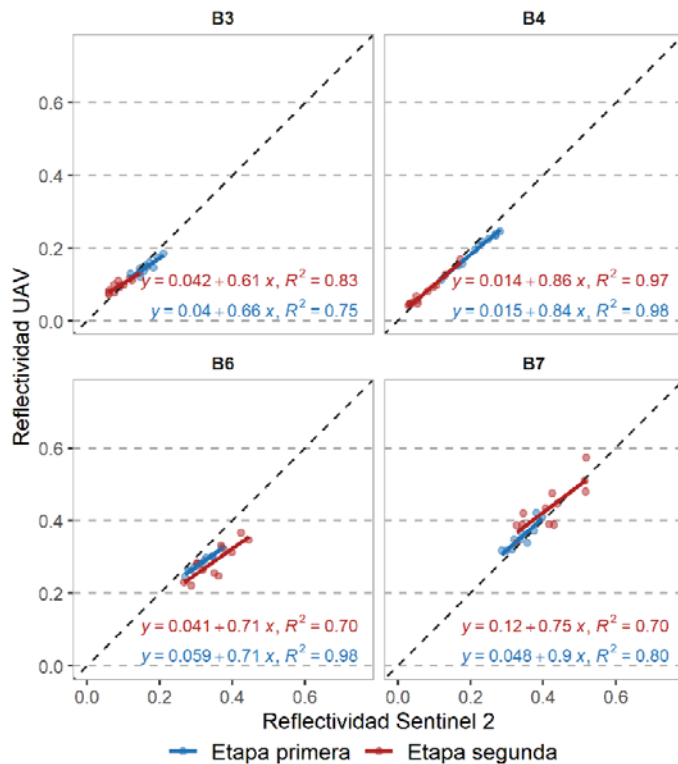


Figura 2-9. Reflectividad en cada banda espectral por etapa de cultivo entre medidas Sentinel 2 y UAV (n=22).

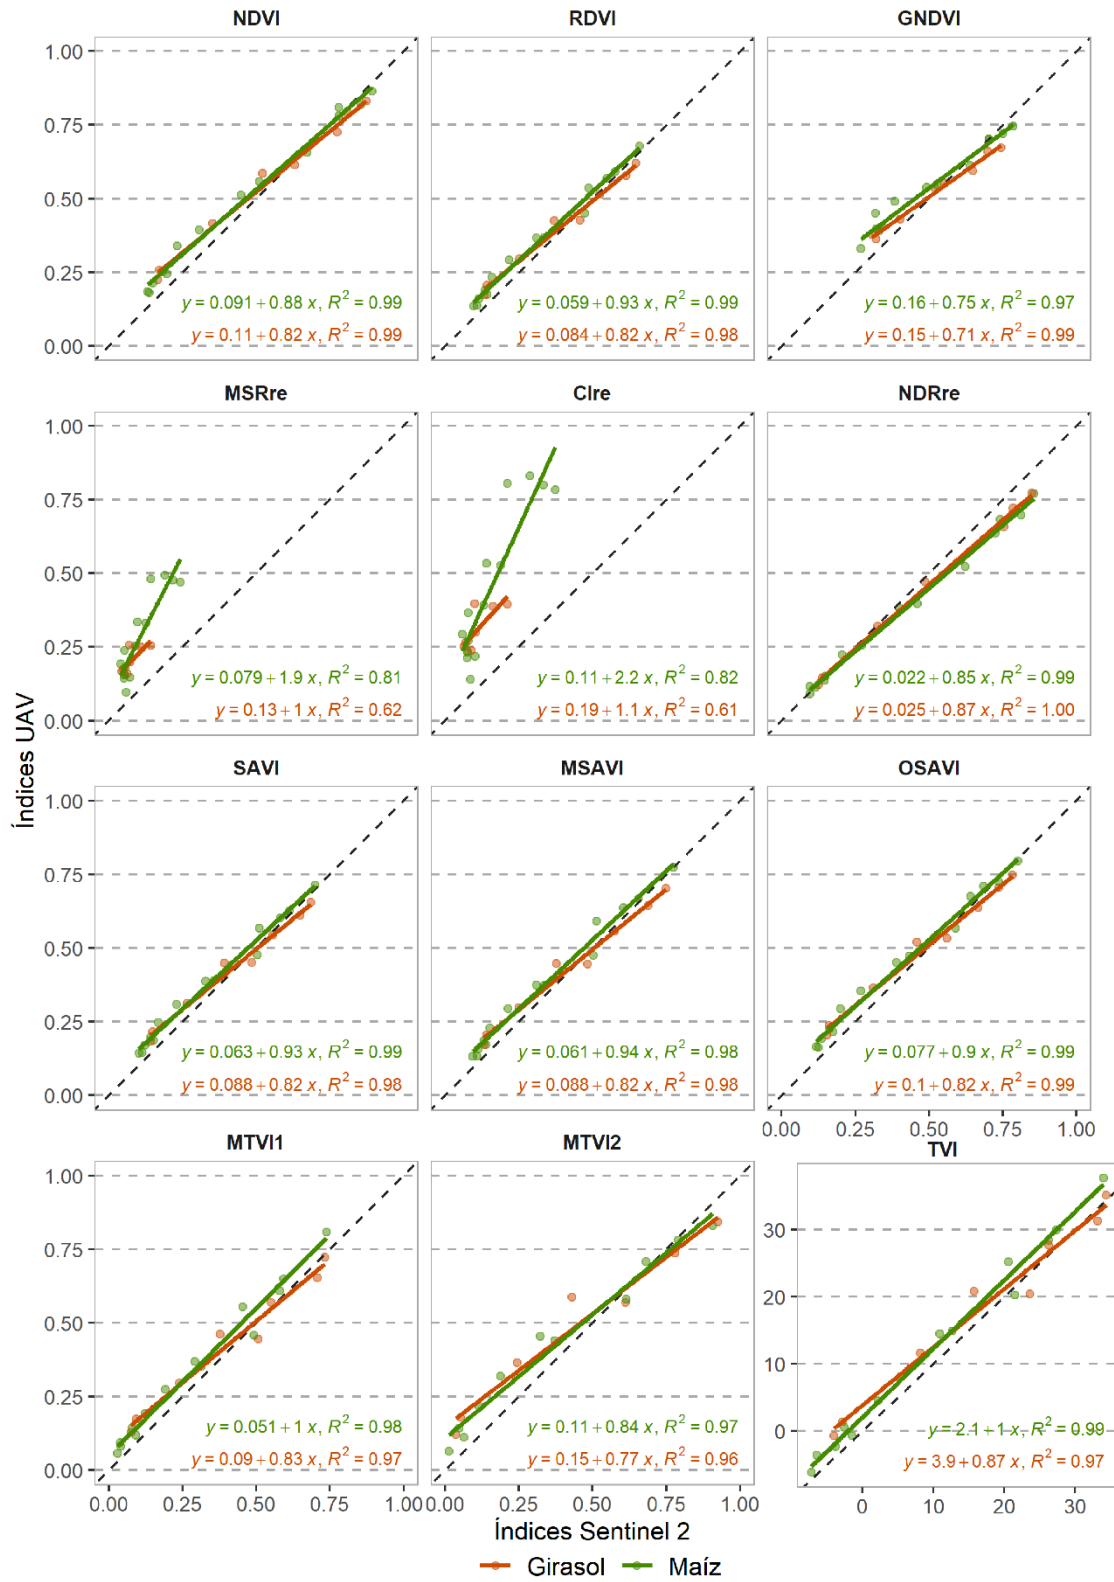


Figura 2-10. Índices de vegetación por tipo de cultivo entre medidas Sentinel 2 y UAV (n=22).

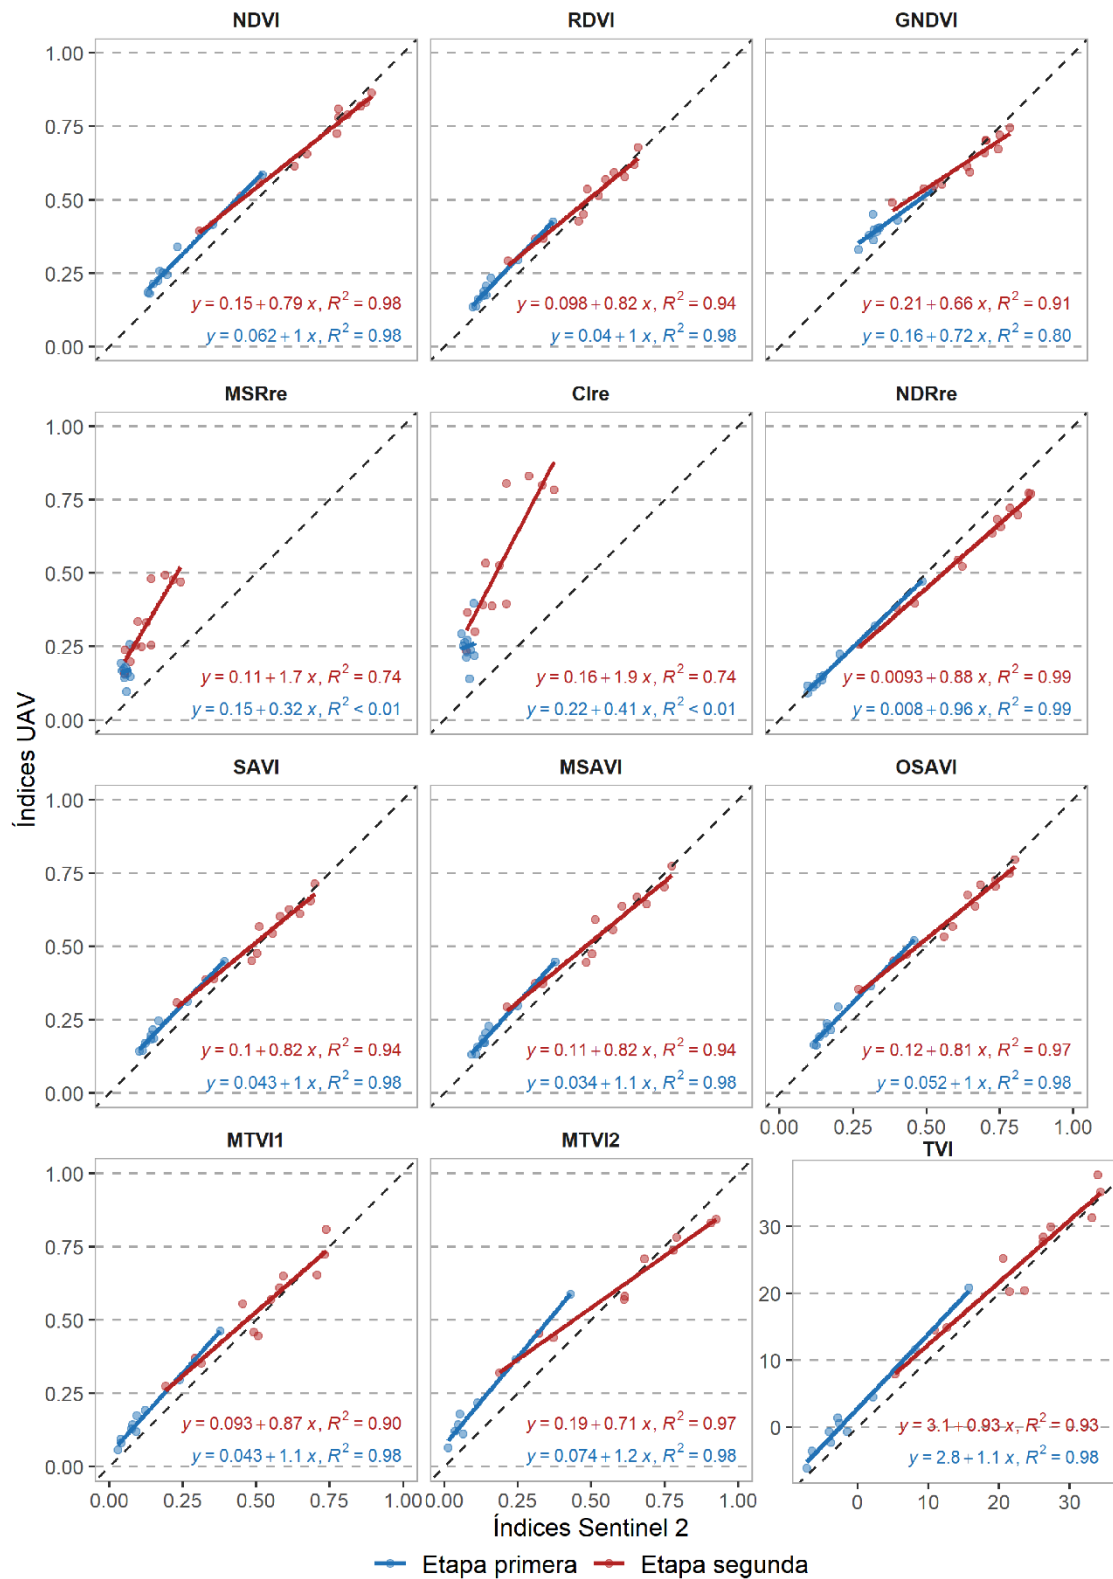


Figura 2-11. Índices de vegetación por etapa de cultivos entre medidas Sentinel 2 y UAV (n=22).




Figura 2-12. Reflectividad en cada banda espectral para todos los píxeles Sentinel de las parcelas por tipo de cultivo entre medidas de MSI y UAV (n=3240).




Figura 2-13. Reflectividad en cada banda espectral para todos los píxeles Sentinel de las parcelas por etapa de cultivo entre medidas de MSI y UAV (n=3240).

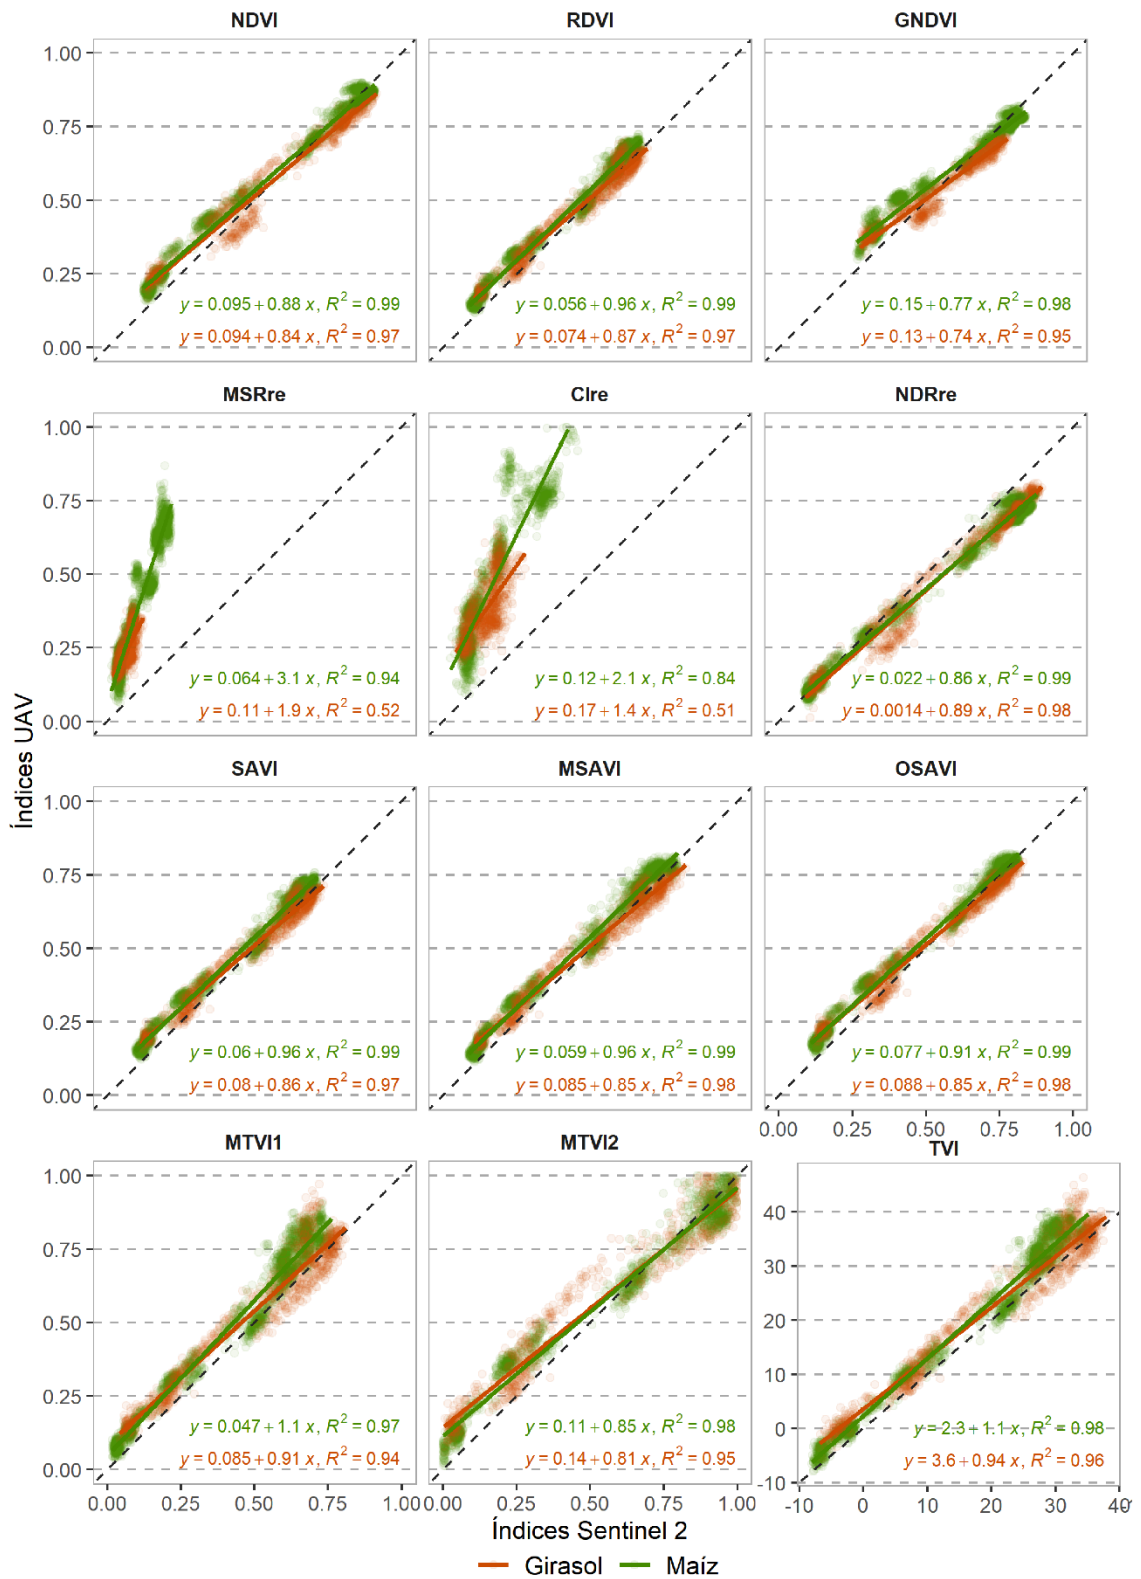


Figura 2-14. Reflectividad en cada IV para todos los píxeles Sentinel de las parcelas por tipo de cultivo entre medidas de MSI y UAV (n=3240).

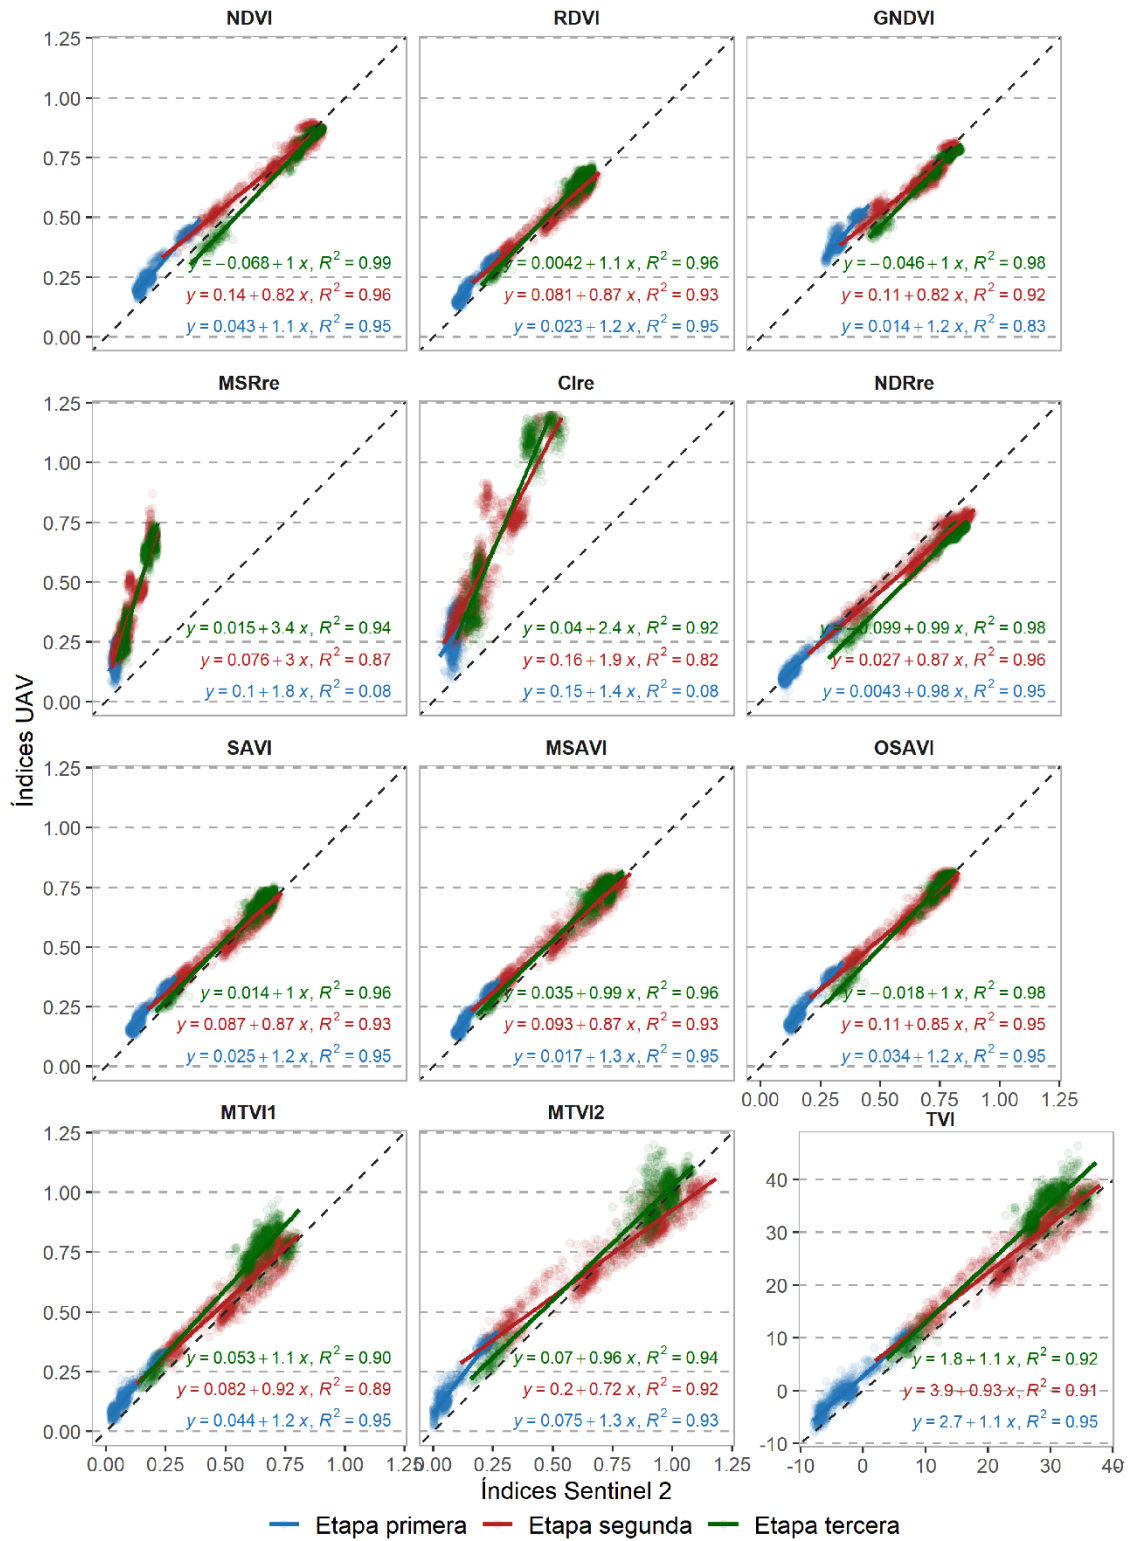




Figura 2-15. Índices de vegetación para todos los píxeles Sentinel de las parcelas por etapa de cultivo entre medidas de MSI y UAV (n=3240).

Anexo 3. Fotografías RGB cenitales



AÑO 2018

Parcela A (Maíz)



05/07/2019 (Estadio V3)

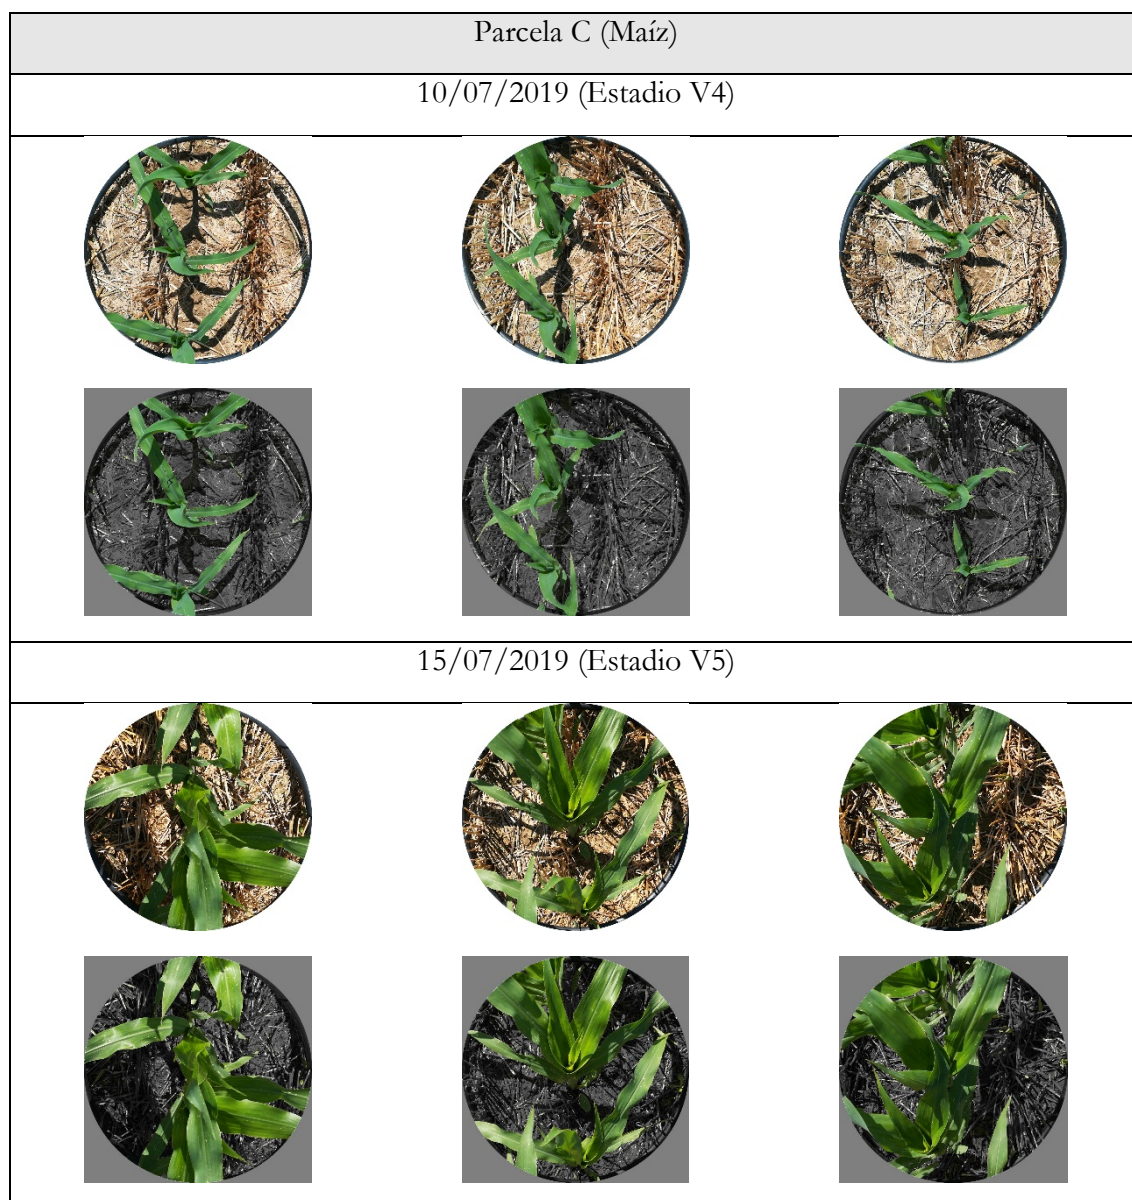
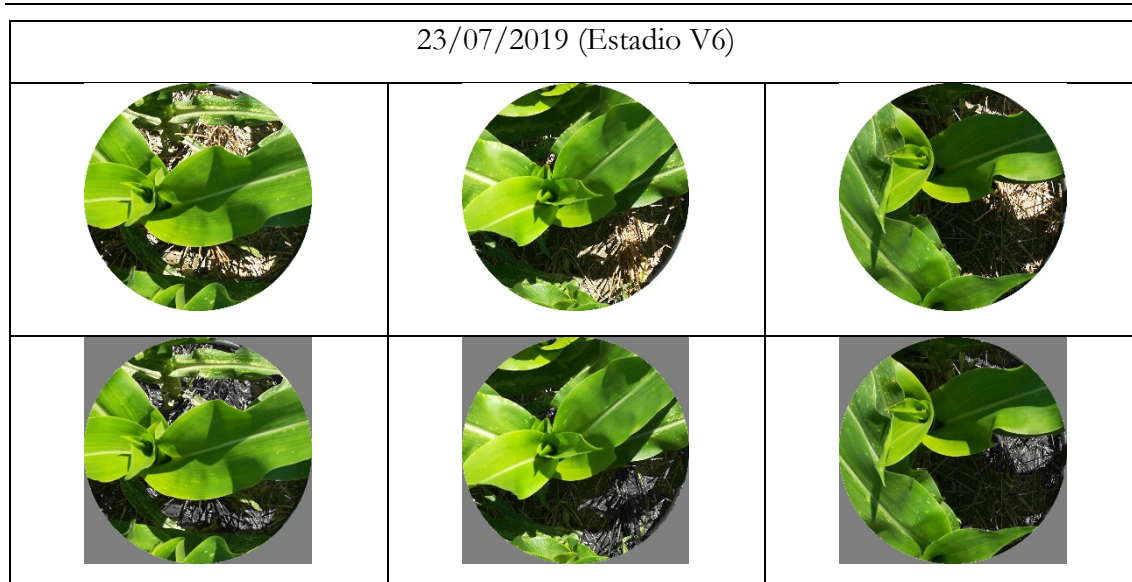


10/07/2019 (Estadio V4)





15/07/2019 (Estadio V5)








23/07/2019 (Estadio V6)






Parcela D (Maíz)



05/07/2019 (Estadio V2)





10/07/2019 (Estadio V3)



15/07/2019 (Estadio V4)






23/07/2019 (Estadio V5)





Parcela E (Girasol)


05/07/2019 (Estadio VE)



10/07/2019 (Estadio V2)




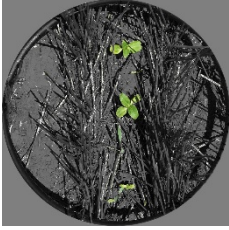
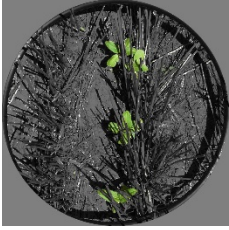
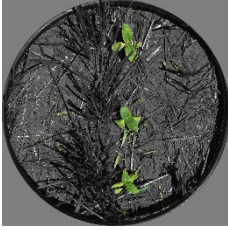














15/07/2019 (Estadio V4)



23/07/2019 (Estadio V6)




Parcela F (Girasol)		
05/07/2019 (Estadio V2)		
		
		
10/07/2019 (Estadio V4)		
		
		
15/07/2019 (Estadio V6)		
		
		

23/07/2019 (Estadio V8)



Parcela G (Girasol)


10/07/2019 (Estadio V2)



15/07/2019 (Estadio V4-V6)





23/07/2019 (Estadio V8)






AÑO 2019

Parcela H (Maíz)

05/07/2019 (Estadio V2)



10/07/2019 (Estadio V3)




18/07/2019 (Estadio V5)




Parcela I (Maíz)

05/07/2019 (Estadio V2)



10/07/2019 (Estadio V3)



18/07/2019 (Estadio V5)





25/07/2019 (Estadio V6)




Parcela D' (Maíz)


05/07/2019 (Estadio V1)



10/07/2019 (Estadio V2)




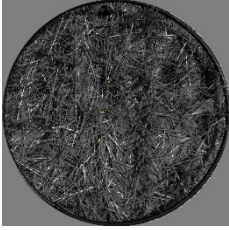
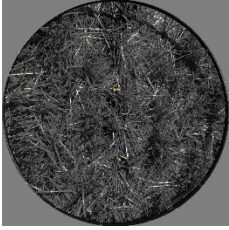
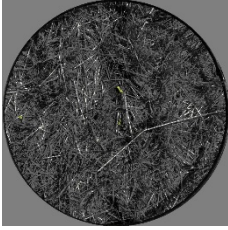



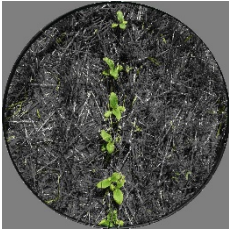
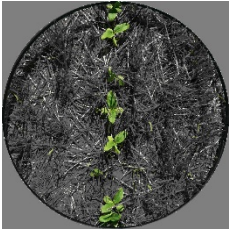
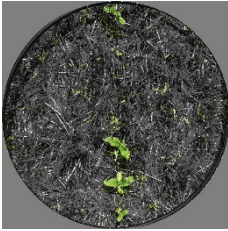






18/07/2019 (Estadio V4)



25/07/2019 (Estadio V5)






Parcela J (Girasol)		
05/07/2019 (Estadio VE)		
		
		
10/07/2019 (Estadio V2)		
		
		
18/07/2019 (Estadio V6)		
		
		

25/07/2019 (Estadio V10)





Parcela K

05/07/2019 (Estadio VE)




10/07/2019 (Estadio V2)



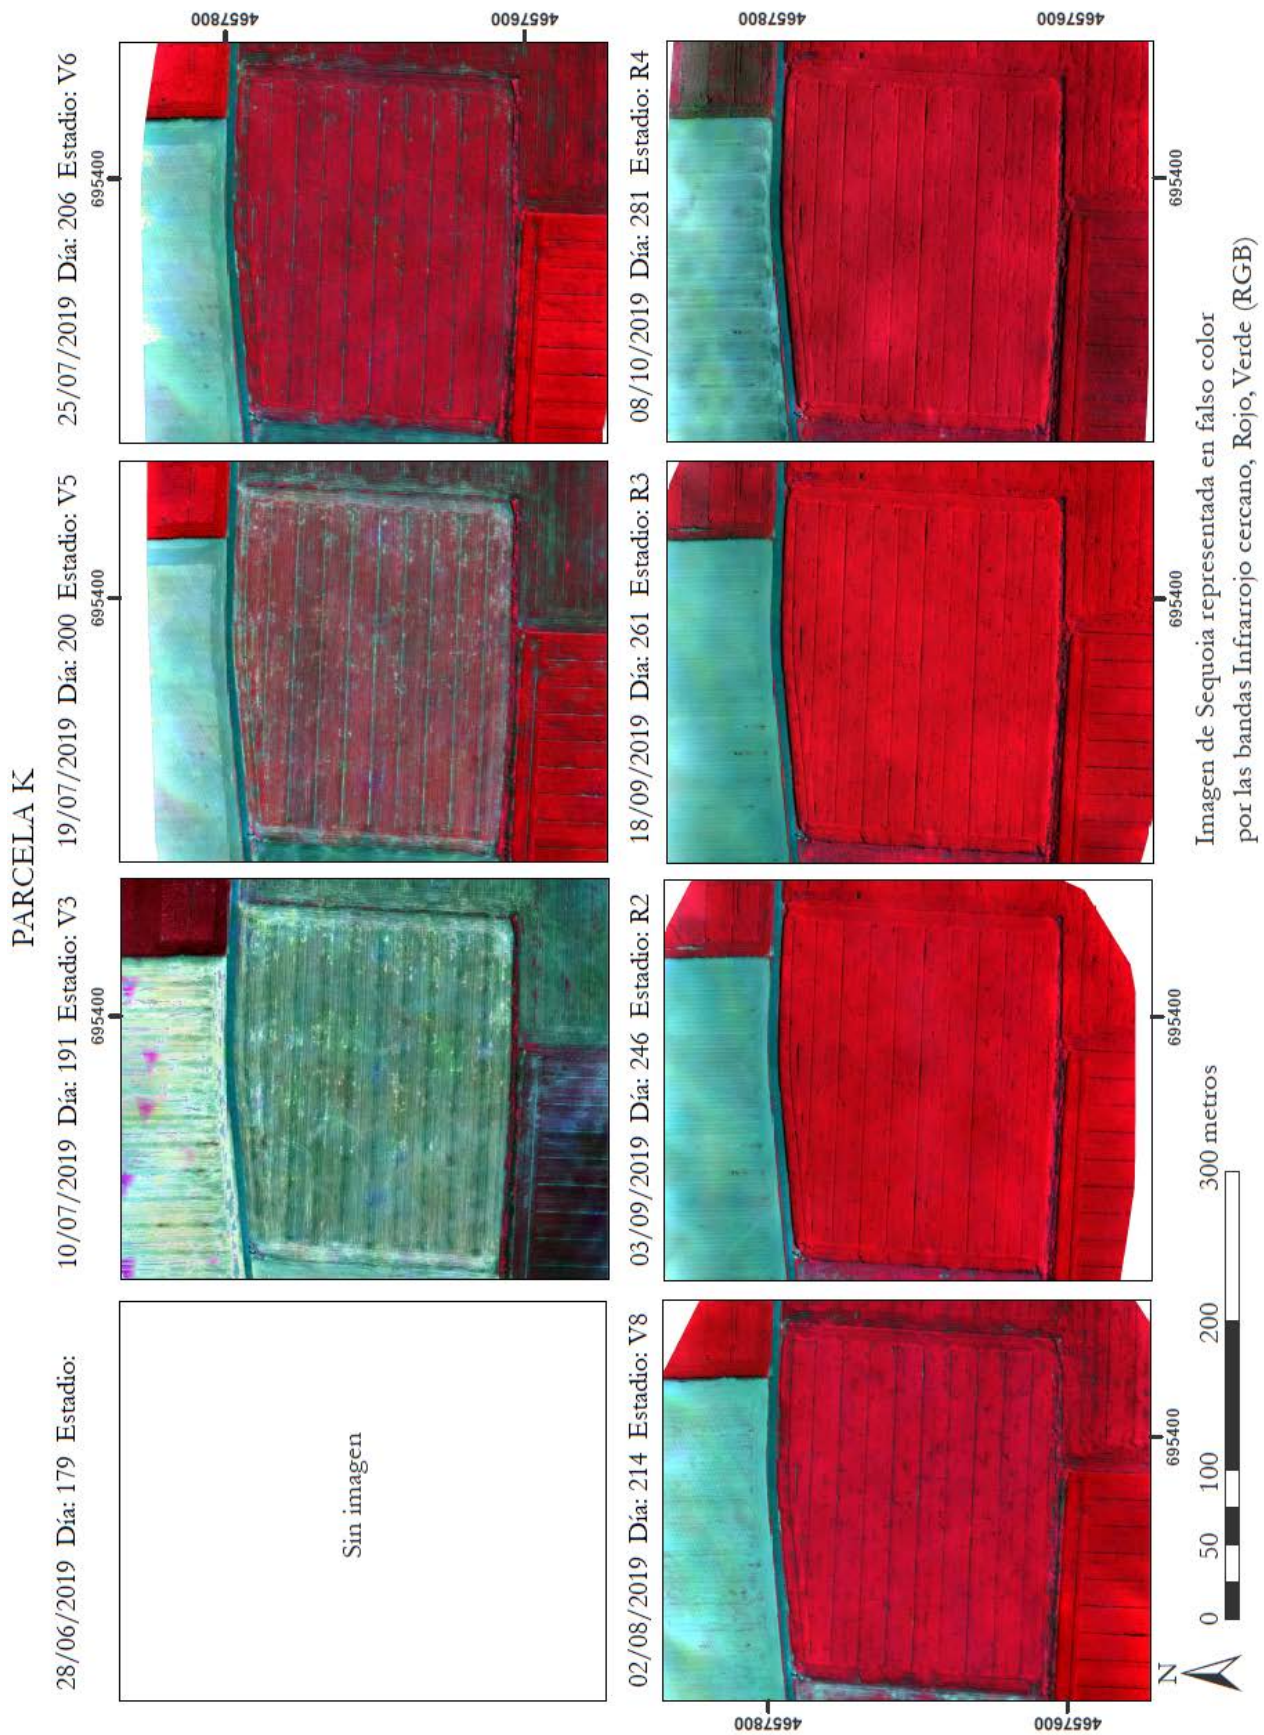
18/07/2019 (Estadio V6)




25/07/2019 (Estadio V10)



Anexo 4. Imágenes de UAV



PARCELA I



PARCELA D'













Imagen de Sequoia representada en falso color por las bandas Infrarrojo cercano, Rojo, Verde (RGB)

PARCELA J


28/06/2019 Día: 179 Estado:




10/07/2019 Día: 191 Estado: V2




19/07/2019 Día: 200 Estado: V6




25/07/2019 Día: 206 Estado: V10




02/08/2019 Día: 214 Estado: R1



03/09/2019 Día: 246 Estado: R5



18/09/2019 Día: 261 Estado: R7



08/10/2019 Día: 281 Estado: R8



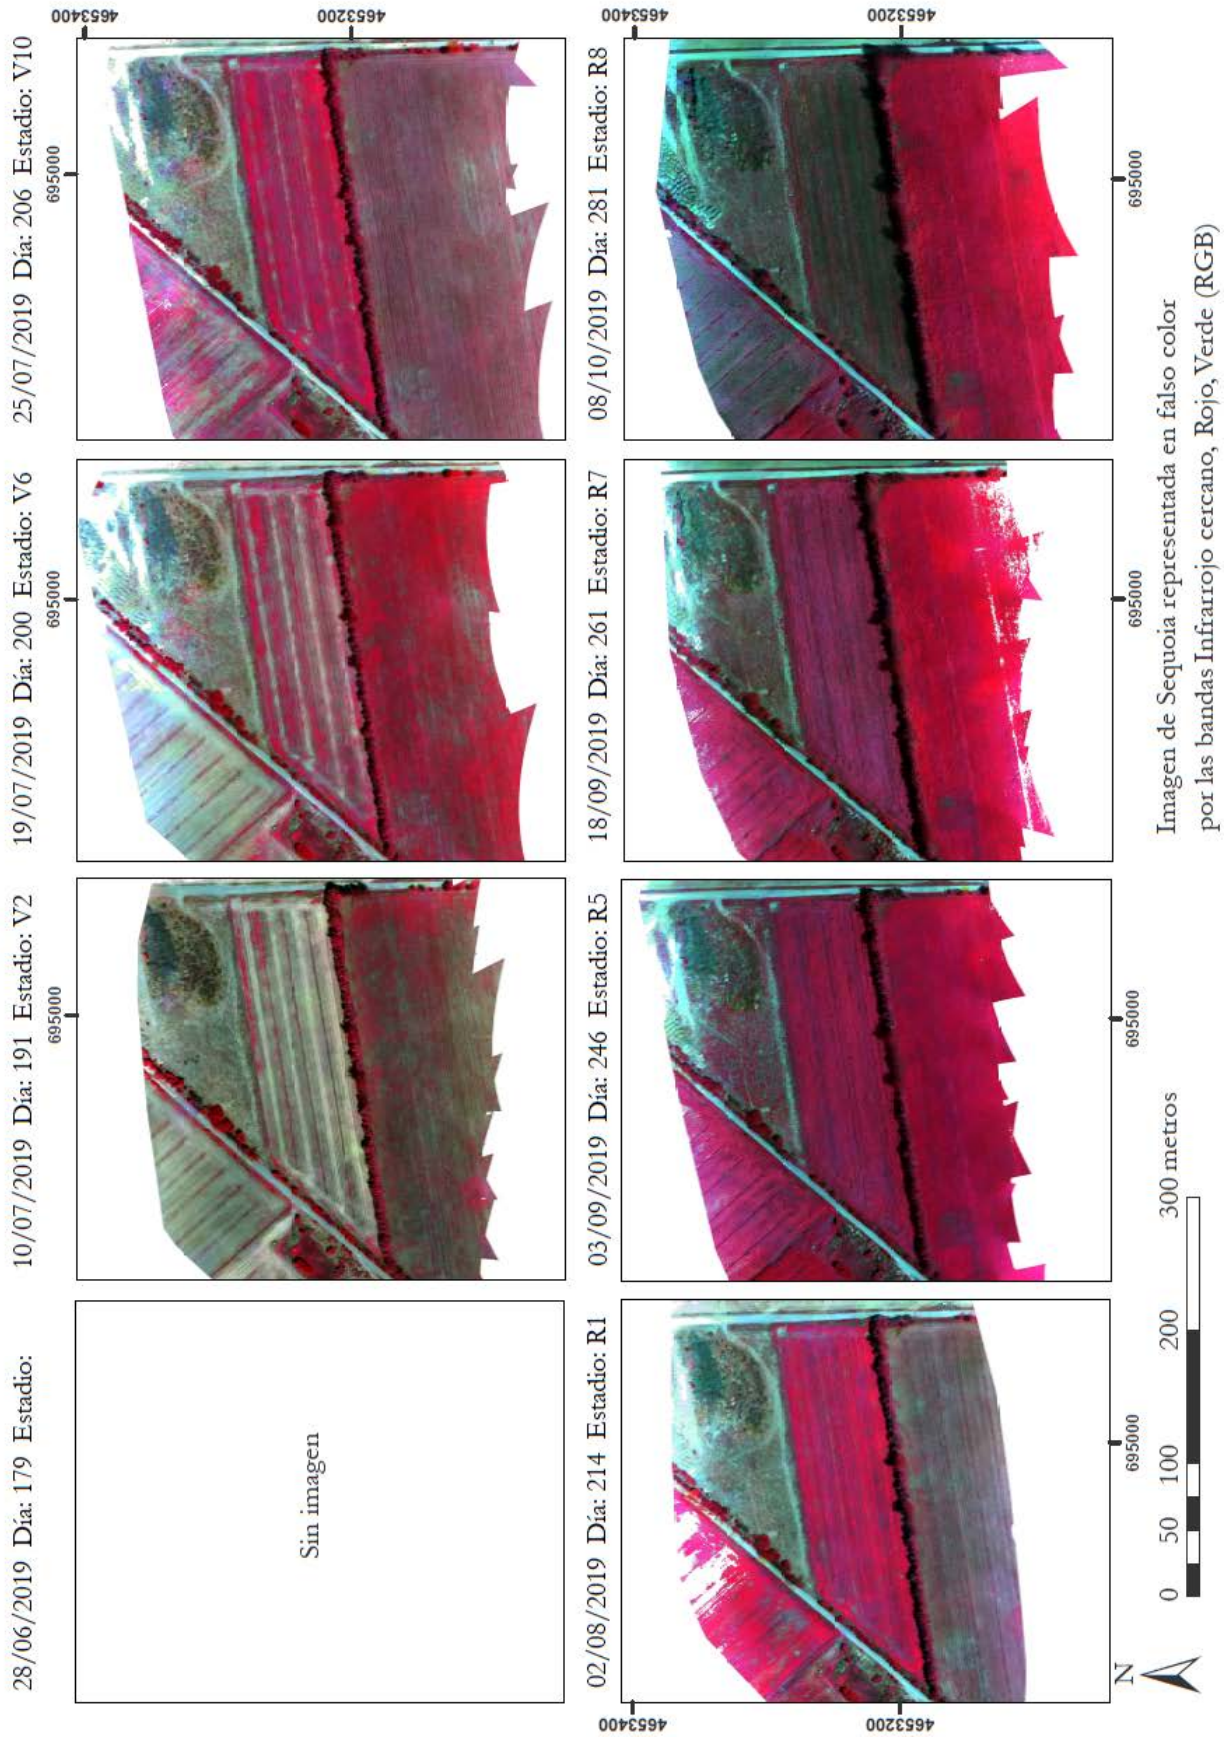


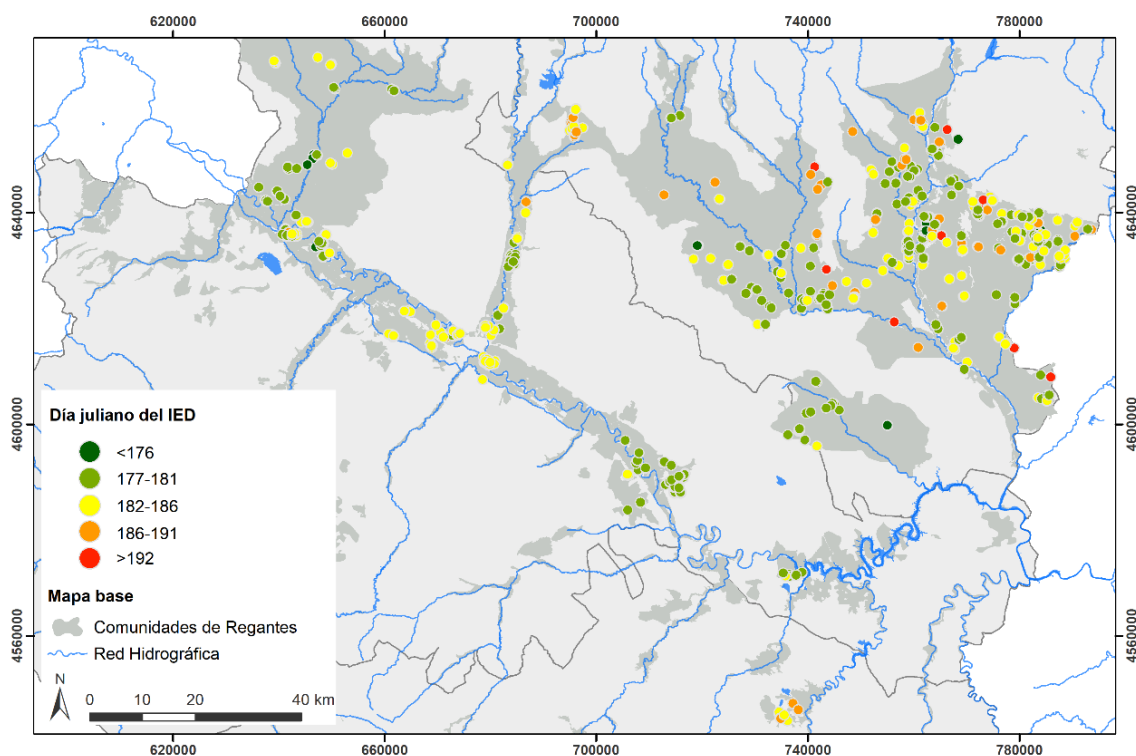
Imagen de Sequoia representada en falso color por las bandas Infrarrojo cercano, Rojo, Verde (RGB)

PARCELA K

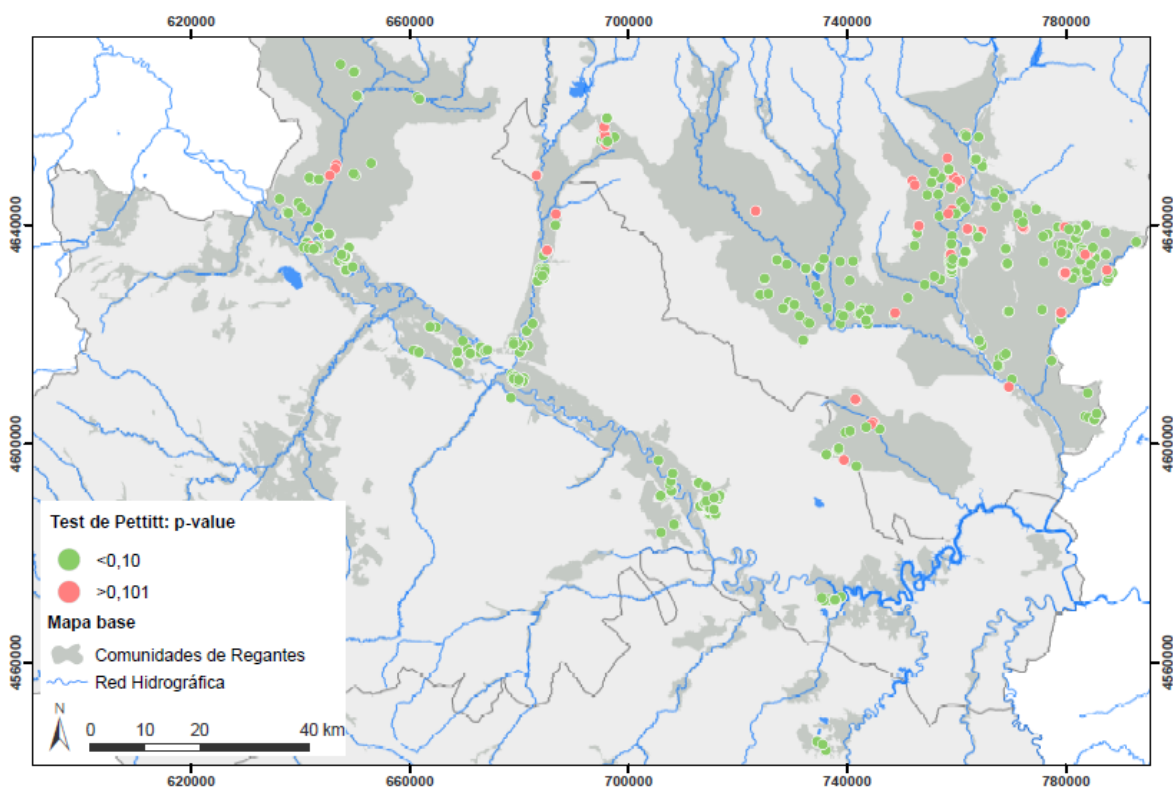


Anexo 5. Cartografía del IED

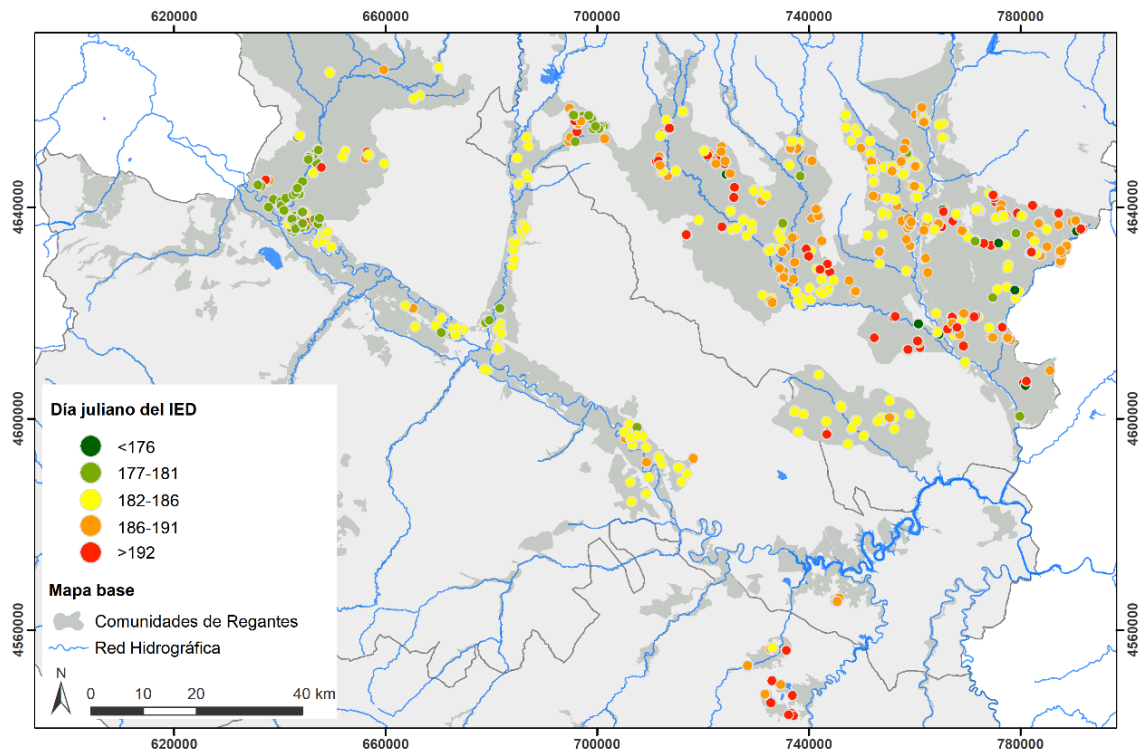
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA EN ARAGÓN (2018)



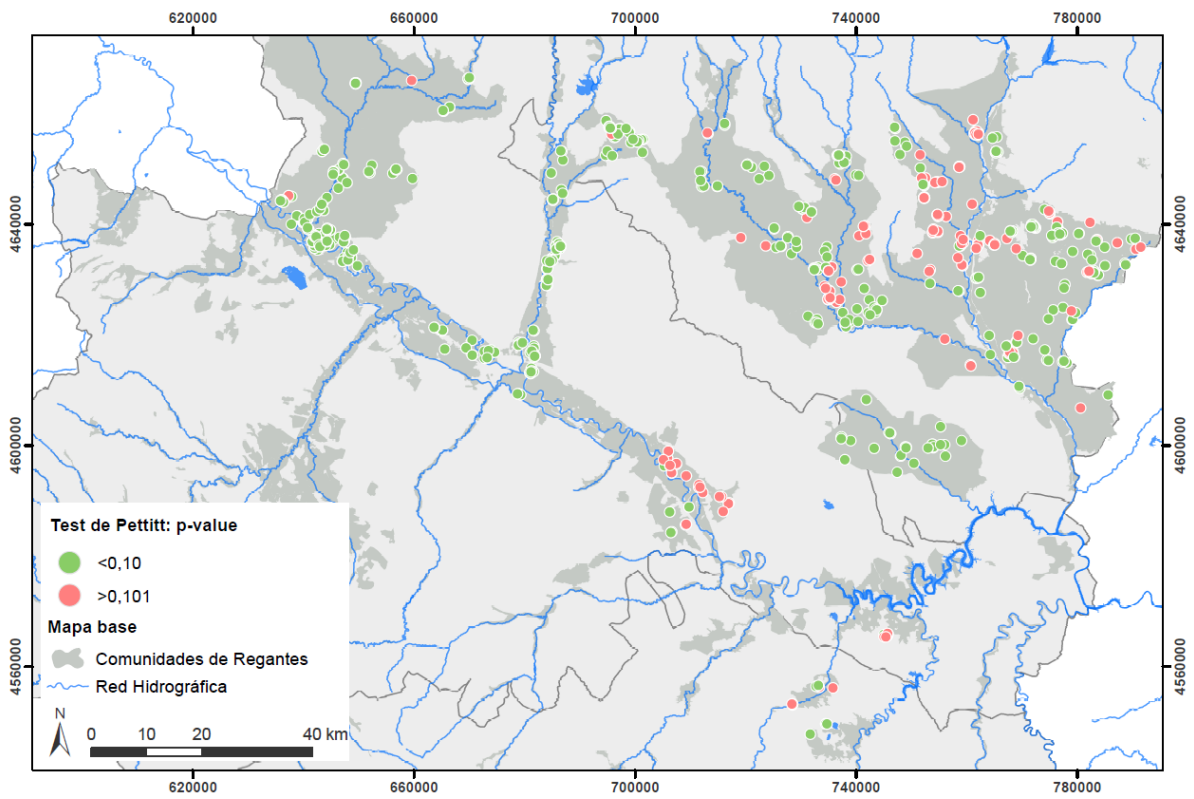
DOBLE COSECHA EN ARAGON (2018)



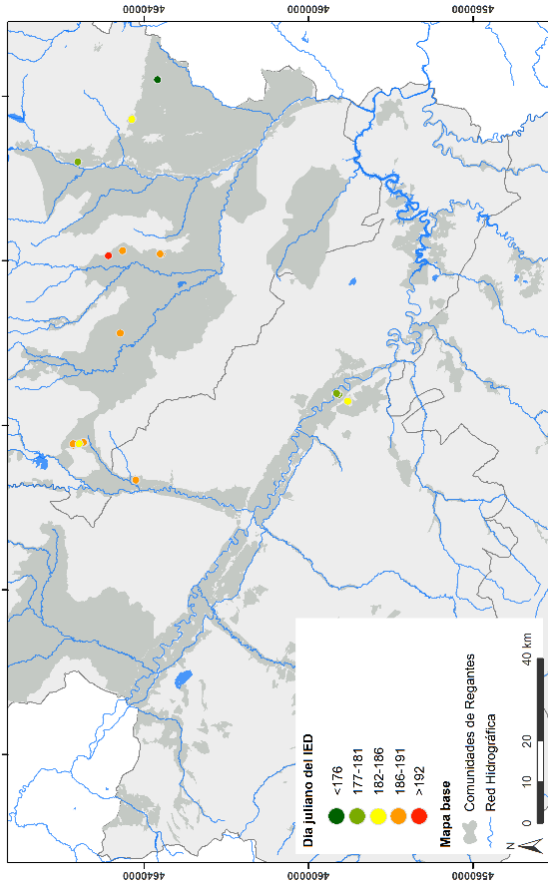
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA EN ARAGÓN (2019)



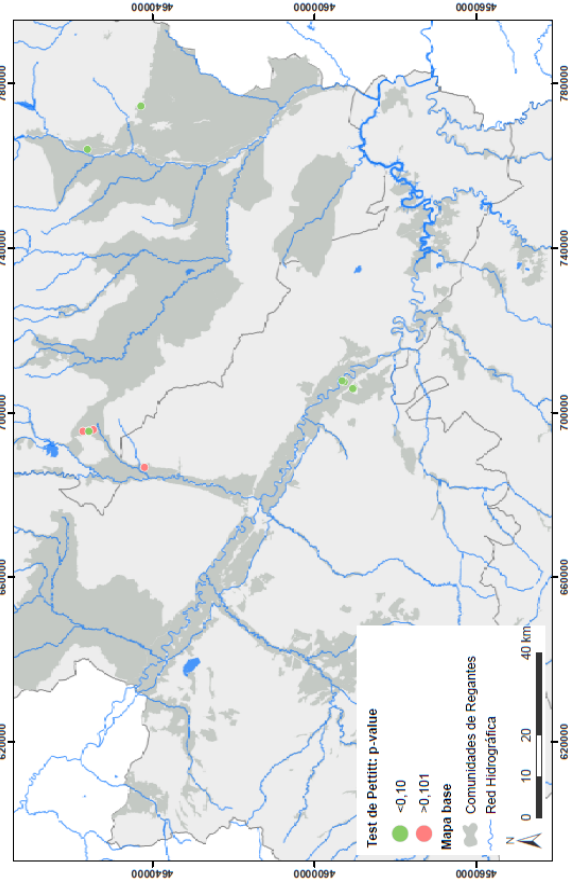
DOBLE COSECHA EN ARAGON (2019)



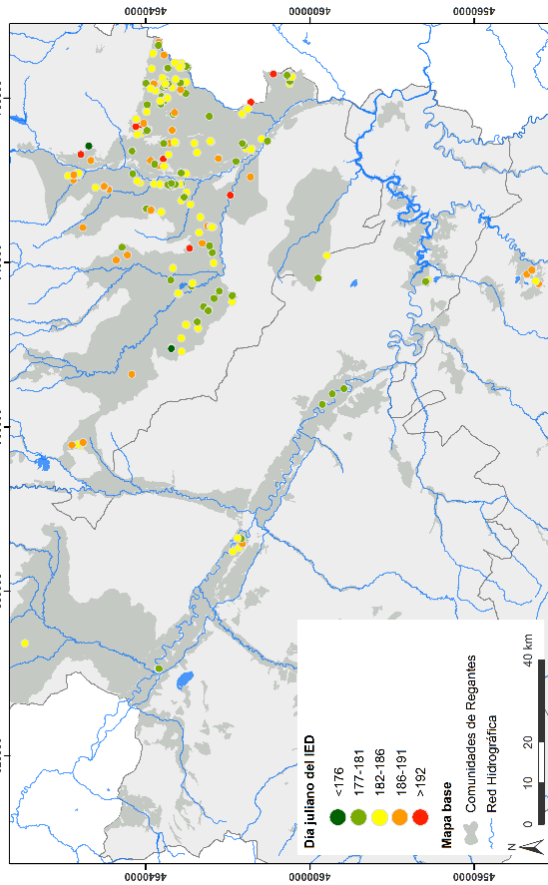
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE CEBADA-GIRASOL (2018)



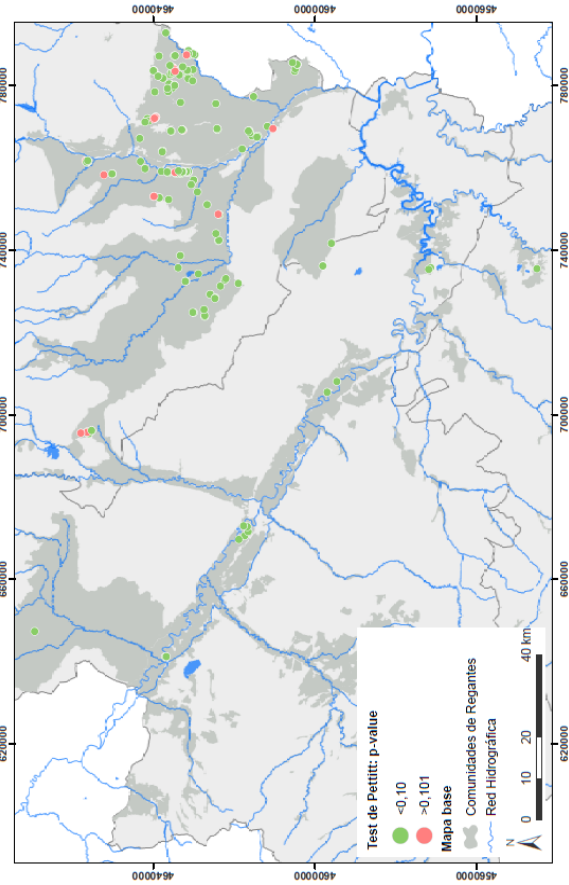
DOBLE COSECHA DE CEBADA-GIRASOL (2018)

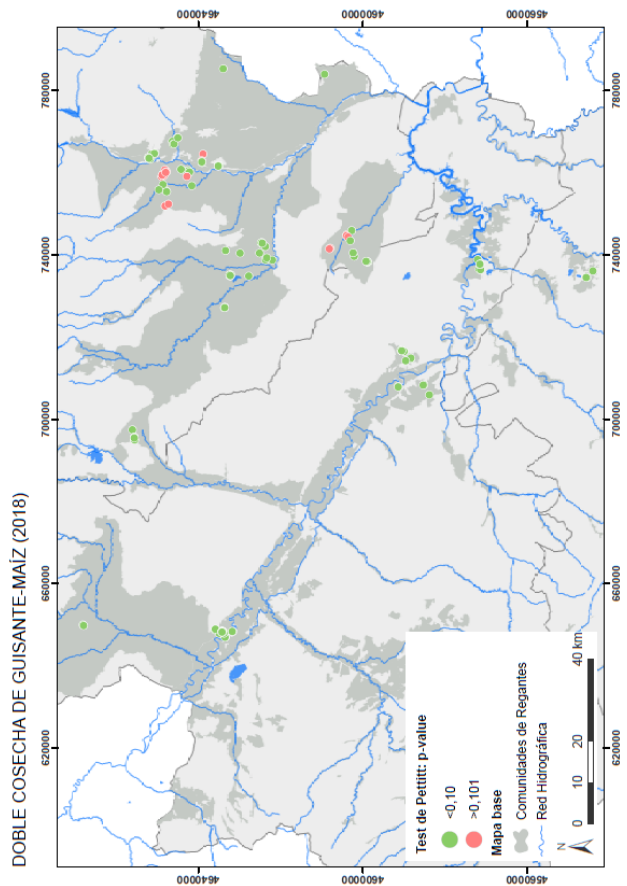
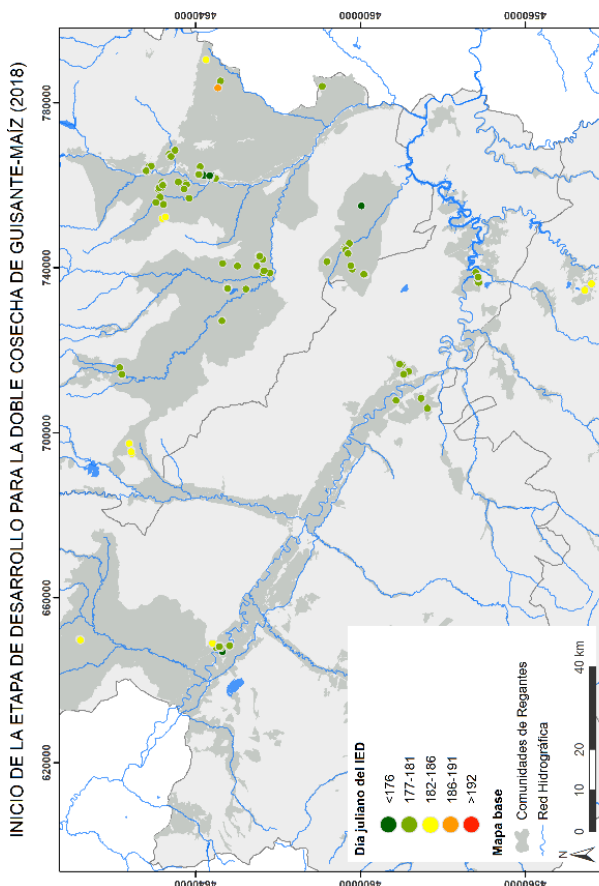
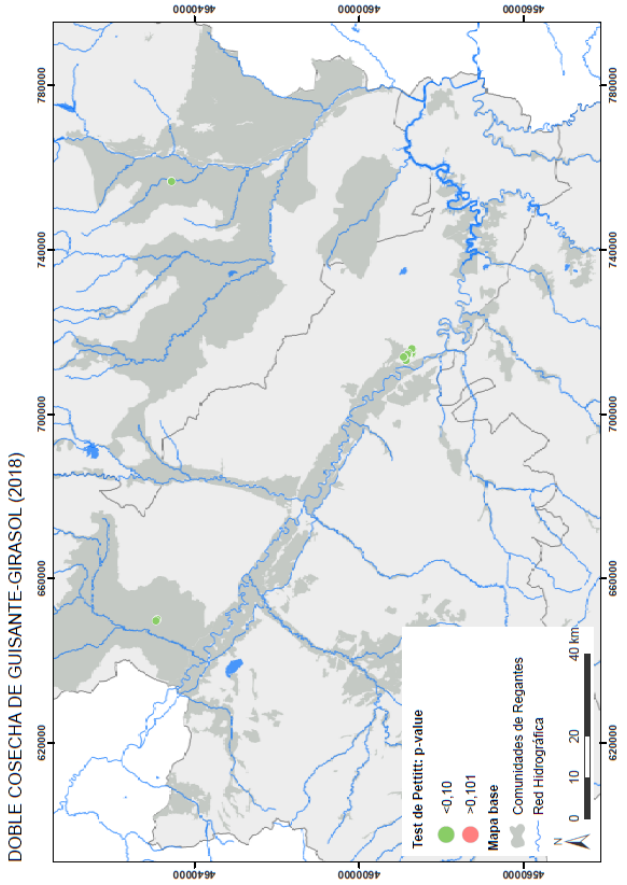
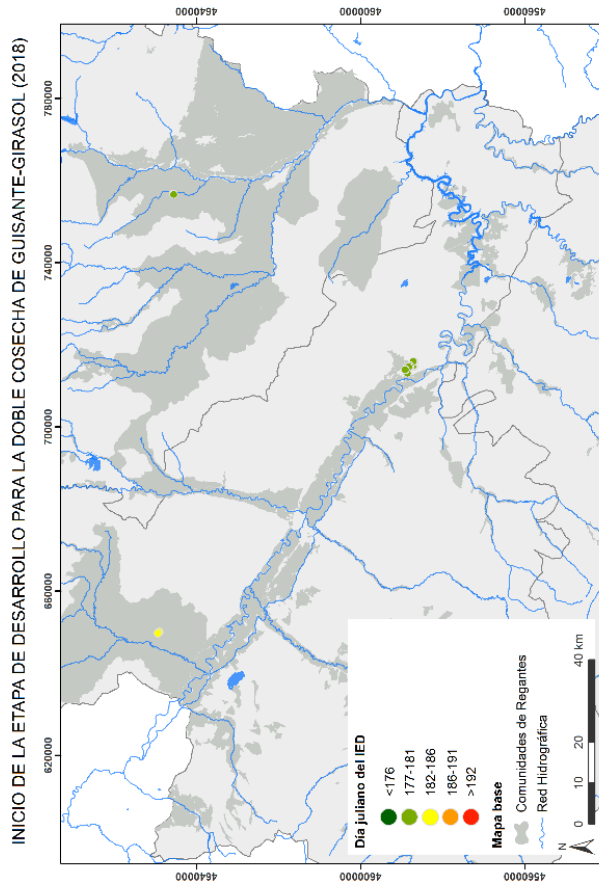


INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE CEBADA-MAÍZ (2018)

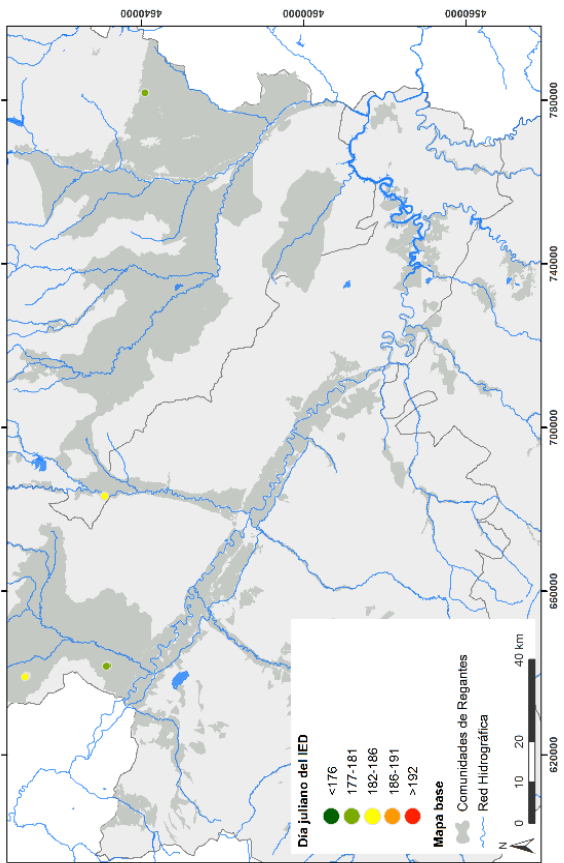


DOBLE COSECHA DE CEBADA-MAÍZ (2018)

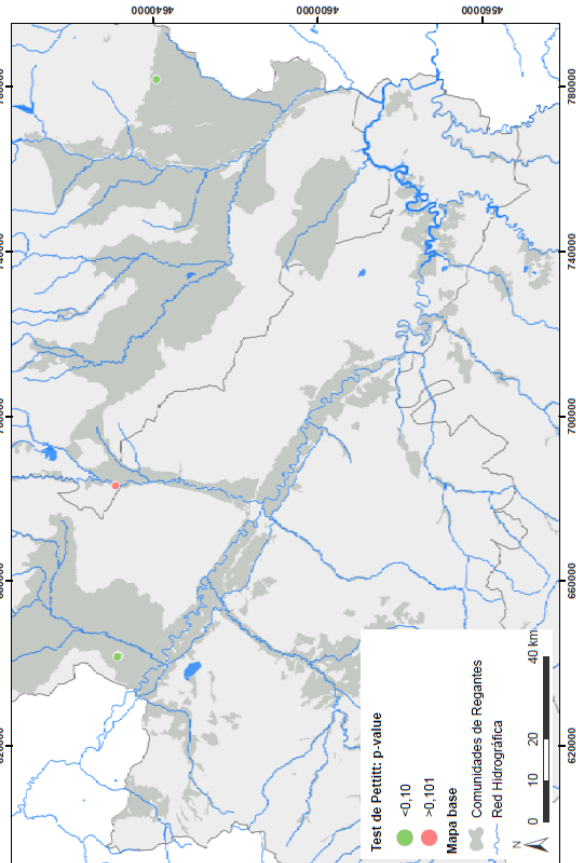




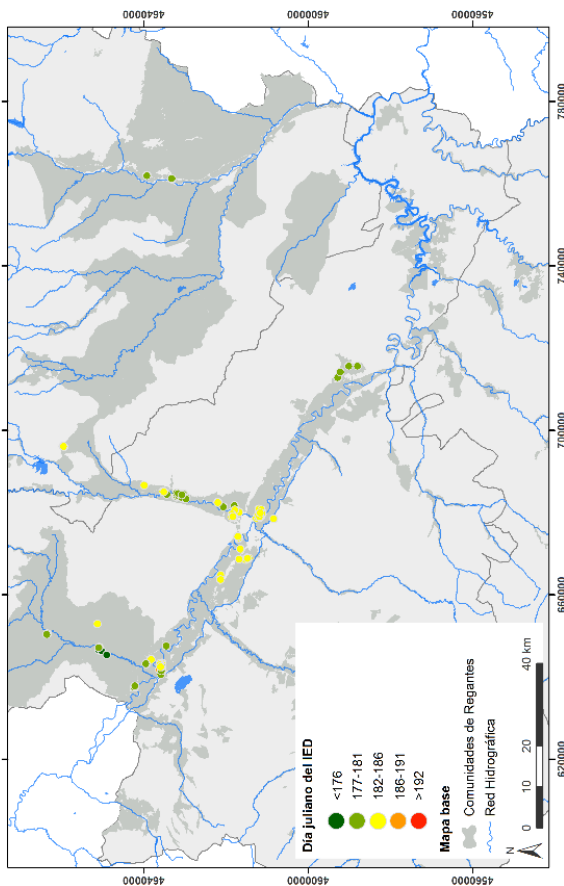
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE VEZA-GIRASOL (2018)



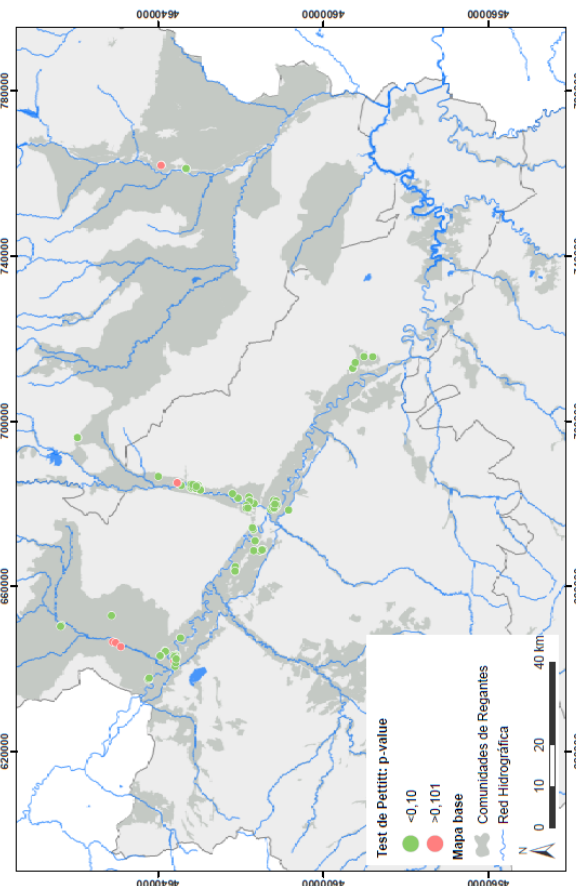
DOBLE COSECHA DE VEZA-GIRASOL (2018)



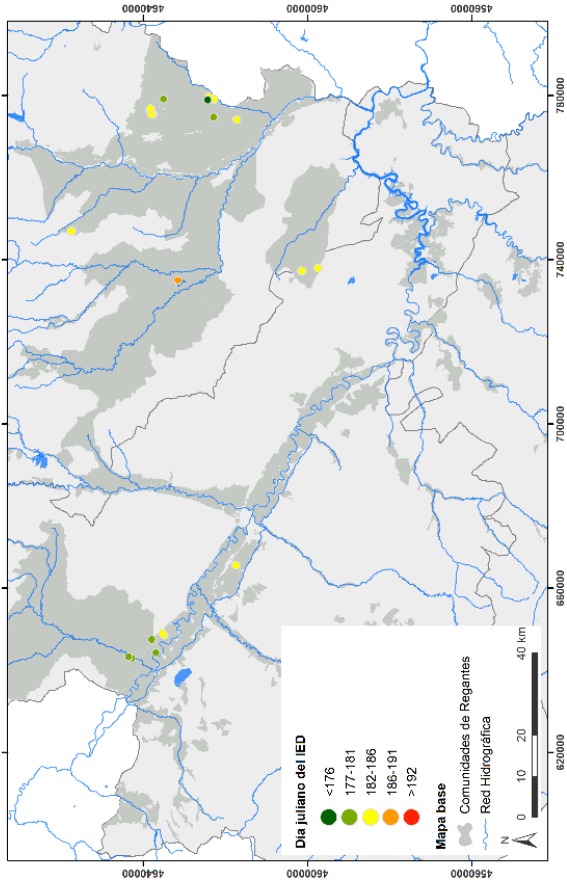
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE VEZA-MAÍZ (2018)



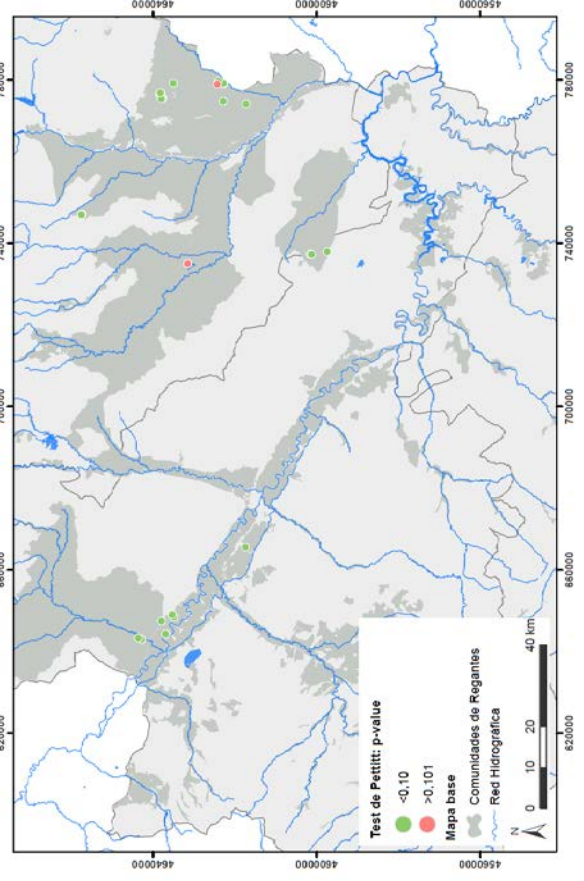
DOBLE COSECHA DE VEZA-MAÍZ (2018)



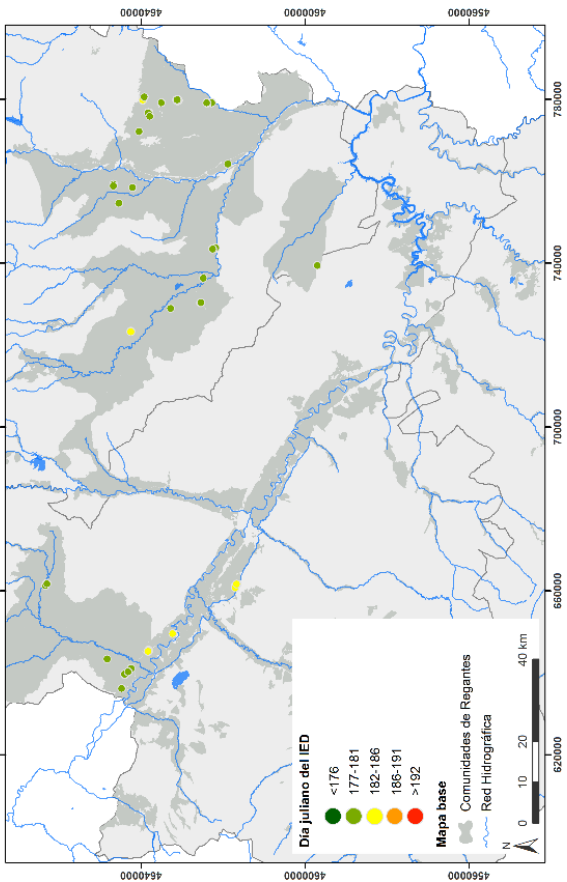
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE RAIGRÁS-MAÍZ (2019)



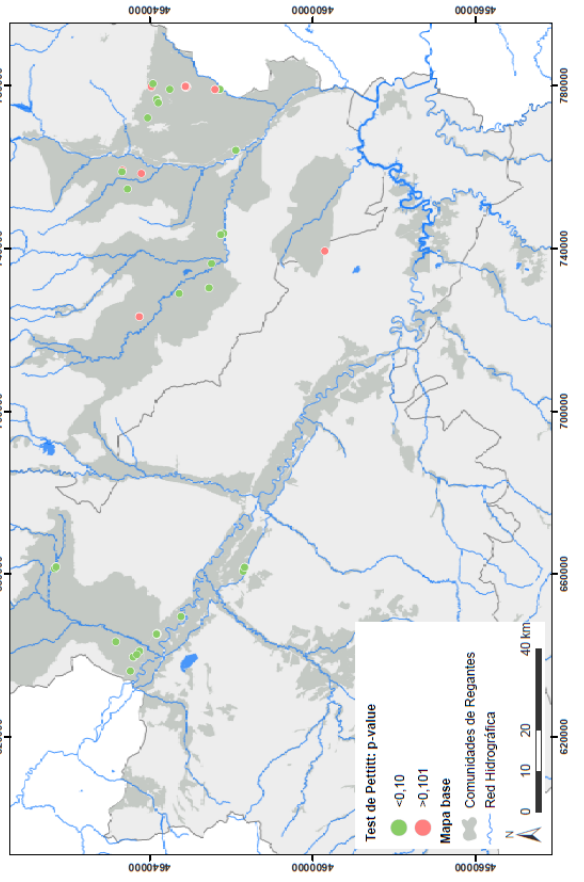
DOBLE COSECHA DE RAIGRÁS-MAÍZ (2019)



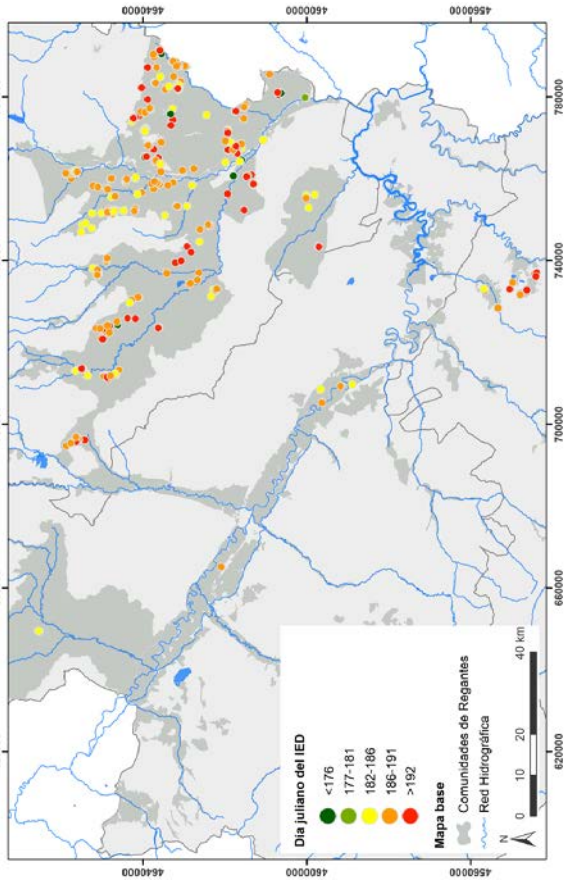
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE RAIGRÁS-MAÍZ (2018)



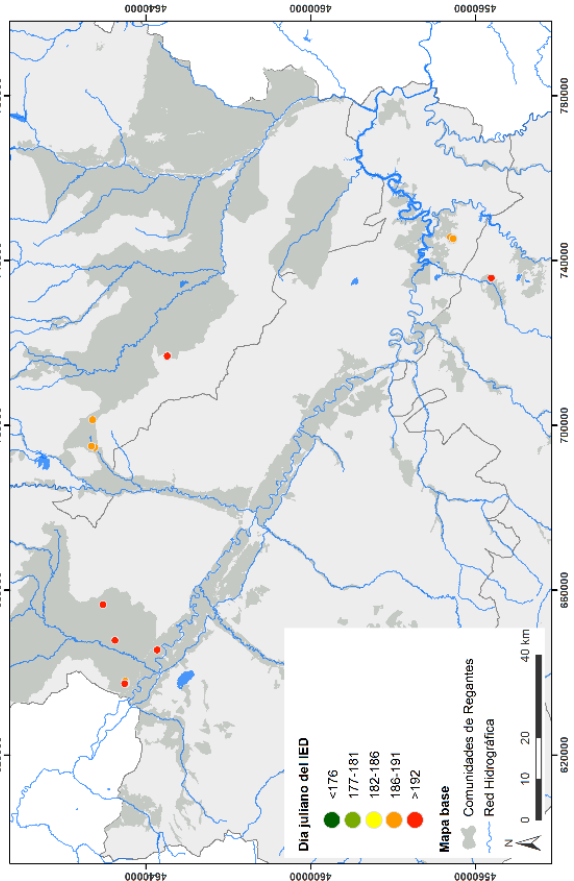
DOBLE COSECHA DE RAIGRÁS-MAÍZ (2018)



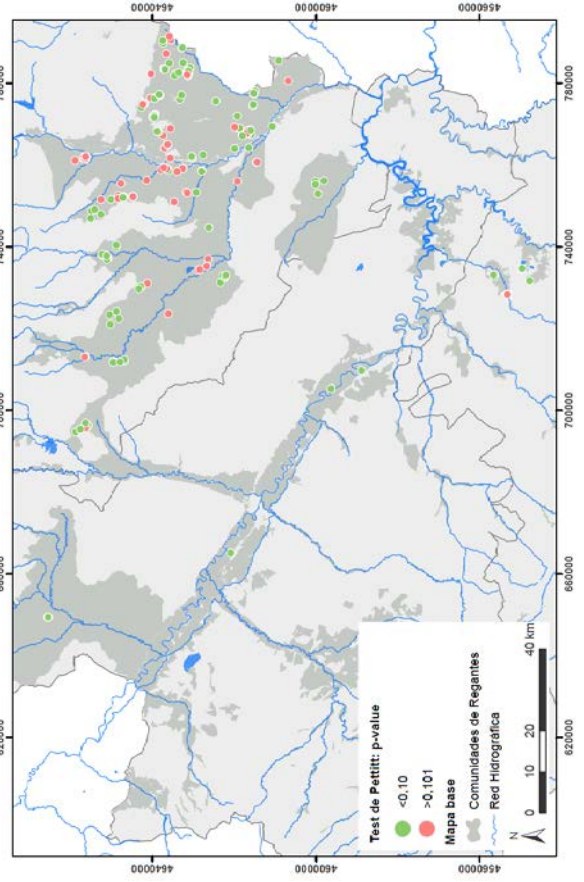
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE CEBADA-MAÍZ (2019)



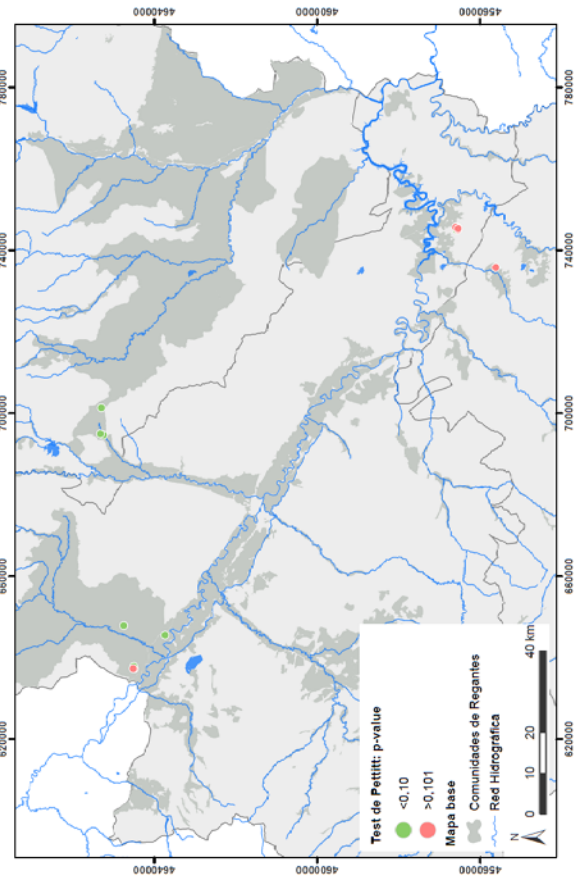
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE CEBADA-GIRASOL (2019)



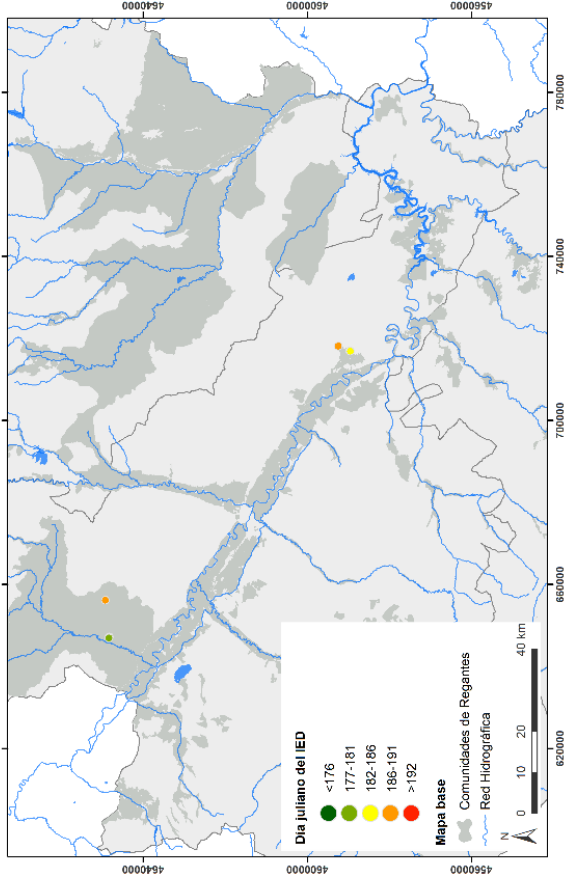
DOBLE COSECHA DE CEBADA-MAÍZ (2019)



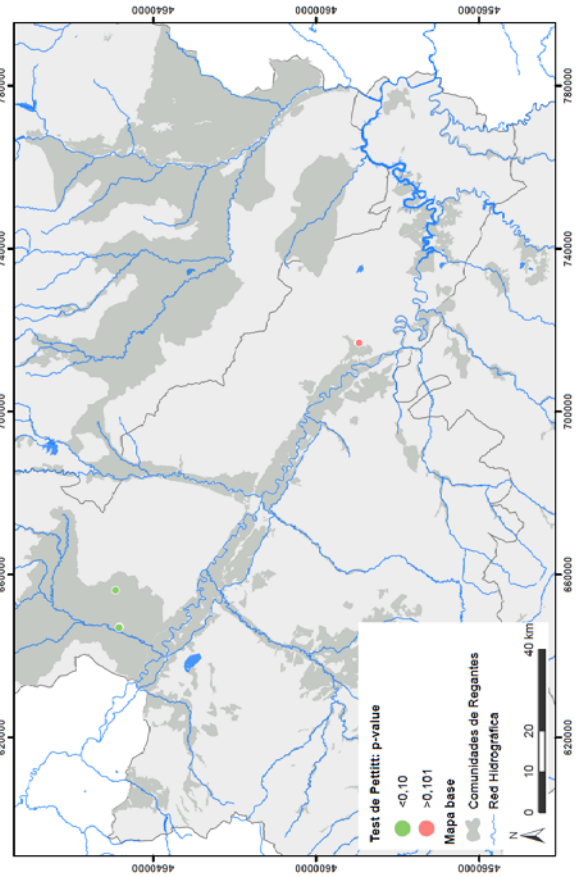
DOBLE COSECHA DE CEBADA-GIRASOL (2019)



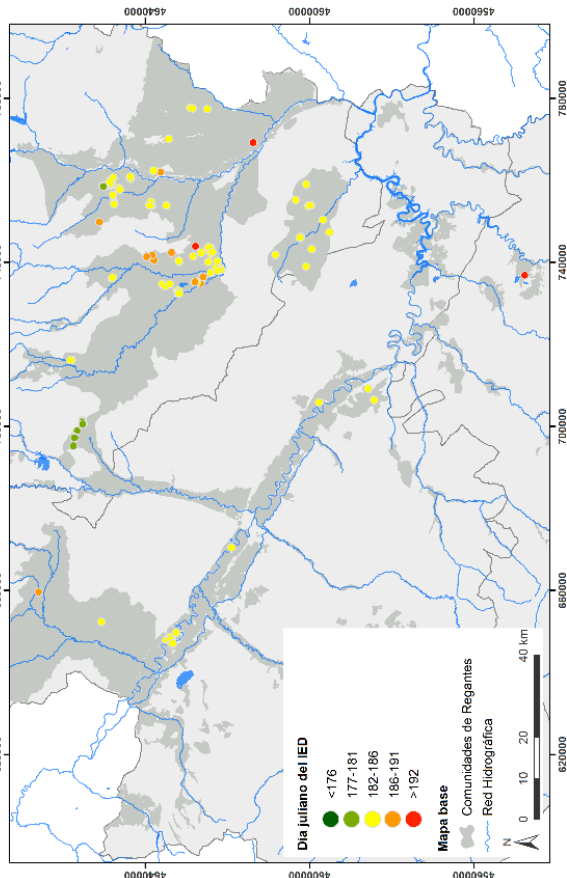
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE GUISANTE-GIRASOL (2019)



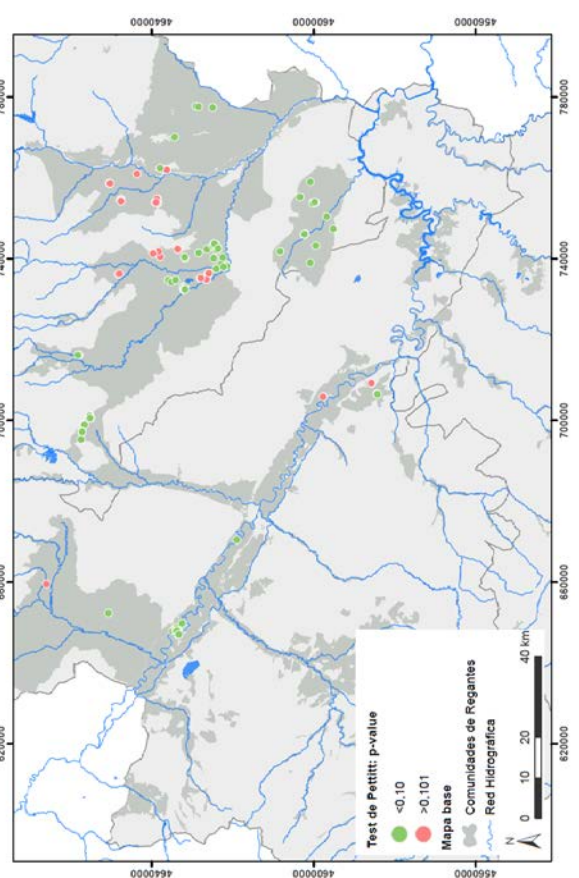
DOBLE COSECHA DE GUISANTE-GIRASOL (2019)



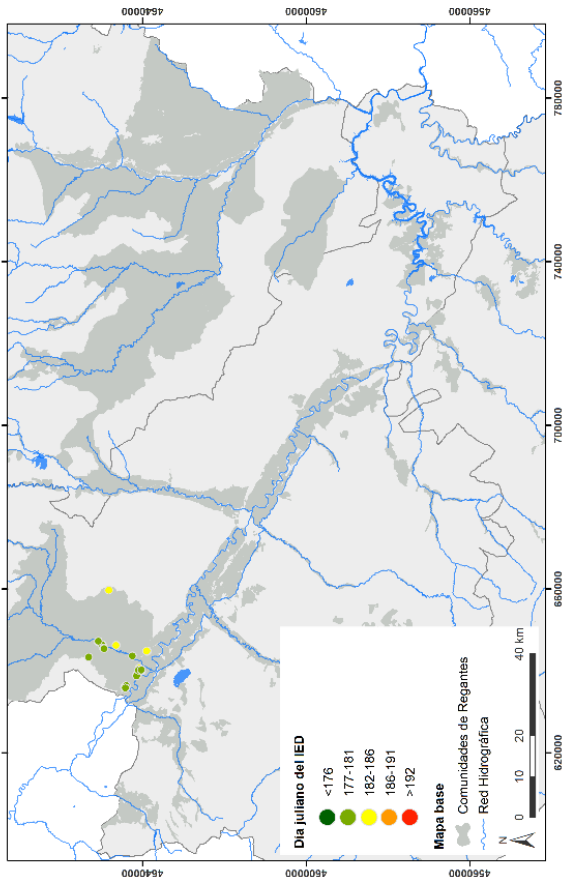
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE GUISANTE-MAÍZ (2019)



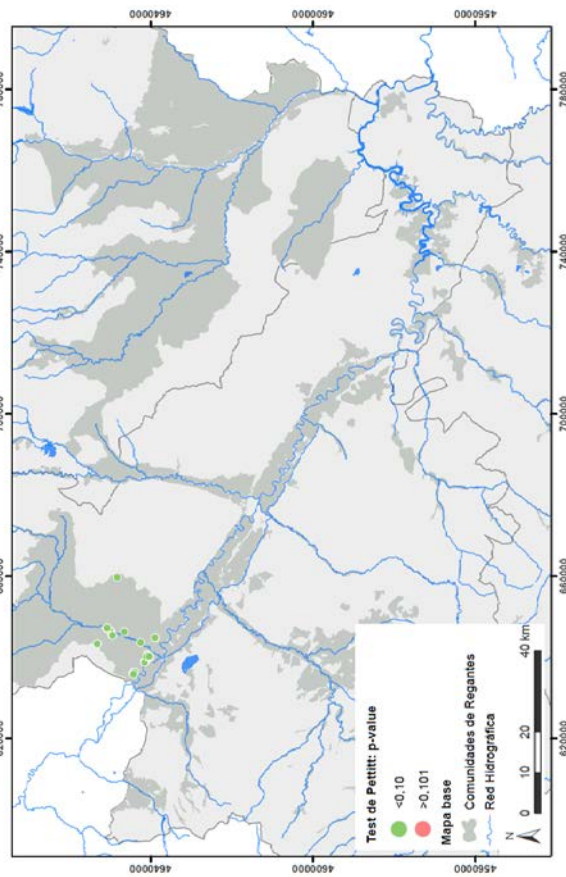
DOBLE COSECHA DE GUISANTE-MAÍZ (2019)



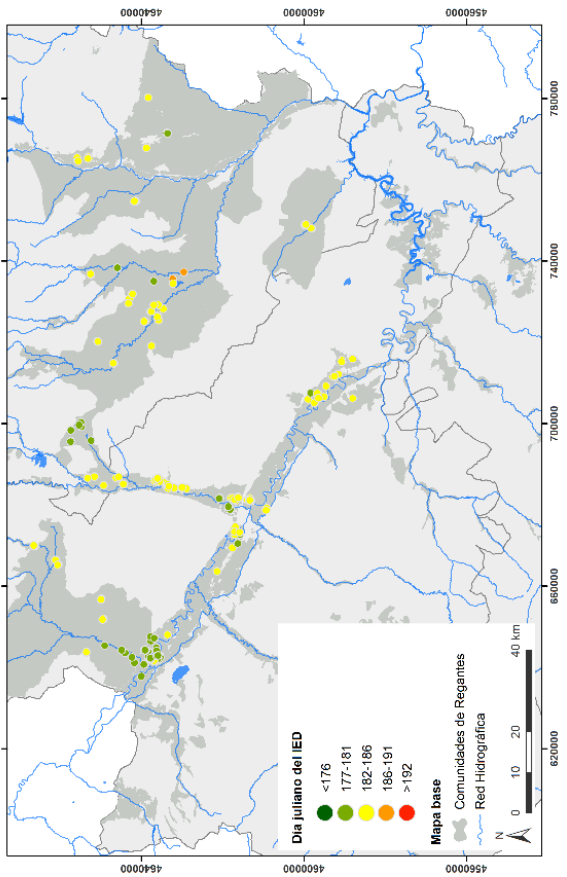
INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE VEZA-GIRASOL (2019)



DOBLE COSECHA DE VEZA-GIRASOL (2019)



INICIO DE LA ETAPA DE DESARROLLO PARA LA DOBLE COSECHA DE VEZA-MAÍZ (2019)



DOBLE COSECHA DE VEZA-MAÍZ (2019)

