

**DEPARTAMENTO DE INGENIERÍA Y CIENCIAS
AGRARIAS
ESCUELA SUPERIOR Y TÉCNICA DE
INGENIERÍA AGRARIA**

**ESTIMACIÓN DE LA BIOMASA AÉREA DE
HERBÁCEAS CON SENSORES
AEROTRANSPORTADOS DE ALTA RESOLUCIÓN**

MIGUEL MARABEL-GARCÍA

Ingeniero de Montes

DIRECTORES

M^a Flor Álvarez Taboada

Dra. Ingeniero de Montes

Fernando Castedo Dorado

Dr. Ingeniero de Montes

PONFERRADA, SEPTIEMBRE 2016

"Todo lo que una persona puede imaginar, otras podrán hacerlo realidad." Julio Verne (1828-1905).

RESUMEN

Las técnicas de teledetección son cada vez más usadas para estimar la cantidad de biomasa aérea, y por tanto para la estimación de la fijación del carbono atmosférico en el contexto del actual cambio climático. El modelado de la biomasa a partir de datos de sensores remotos permite tener información espacialmente explícita sobre los sumideros de carbono (y por tanto de su contribución a la mitigación del cambio climático), así como de las existencias de biomasa para uso como bioenergía. La posibilidad de estimación en zonas dominadas por especies herbáceas como son los pastizales se presenta como una alternativa viable debido a su gran extensión en el planeta, así como a su homogeneidad.

El objetivo principal de la presente tesis fue desarrollar y validar una metodología no destructiva en la estimación de biomasa aérea en formaciones herbáceas a partir de imágenes multiespectrales procedentes de una cámara aérea digital. Para ello se desarrollaron y compararon diferentes métodos. Inicialmente se realizaron estimaciones a partir de Espectro-radiometría de campo, donde se estableció una zona de estudio sobre las que se montó el dispositivo de 30 parcelas para la estimación de biomasa aérea en campo en zonas de pastizal, para el posterior establecimiento de un modelo que relaciona las medidas de campo con la información espectral (corregida radiométricamente) de la imagen. Se analizó qué métodos estadísticos y transformaciones matemáticas eran más adecuadas en el pre-procesamiento de los datos obtenidos con un espectro-radiómetro de campo ASD Fieldspec®3. . Dentro de estos métodos se encuentran la máquinas de soporte de vectores (SVM, *Super Vector Machine*), la regresión lineal por mínimos cuadrados parciales (PLS, *Partial Least Squares*) y la regresión por mínimos cuadrados (OLS, *Ordinary Least Squares*), así como diferentes transformaciones del espectro como *Continuum Removal* (CR), *Savitzky y Golay* (SG), *Multiplicative scatter correction* (MSC). El estudio se realizó teniendo en cuenta las diferentes partes de la firma espectral depurada (VNIR +SWIR1+SWIR2), Los modelos obtenidos explican hasta un 97% de la variabilidad observada, y poseen errores relativos inferiores al 7%.

Por otra parte, las cámaras aéreas digitales de gran formato permiten obtener imágenes multiespectrales de elevada exactitud geométrica e información radiométrica, requiriéndose su calibración y validación para poder extraer información temática

cualitativa y cuantitativa. Para la estimación de variables biofísicas como la biomasa o el contenido de carbono a partir de métodos empíricos e imágenes se requiere, por tanto, realizar una calibración radiométrica absoluta de dichas imágenes, para obtener valores de reflectancia escalada en superficie. En la presente tesis se usó una cámara aérea digital fotogramétrica de gran formato Ultracam-Xp WP. El tipo de calibración elegida se denomina empírica de línea, usándose para su desarrollo diferentes blancos de calibración, tanto fijos y "pseudo-invariantes" como móviles. Para analizar la exactitud de las estimaciones en zonas de pastizal a partir de Espectro-radiometría y a partir de 3 imágenes multiespectrales (R, G, B, NIR) de la cámara aérea digital, estableció una zona compuesta por varios blancos de calibración (móviles y fijos) próxima a las parcelas donde se desarrolló el método para la calibración radiométrica absoluta de imágenes multiespectrales. Se testaron 24 conjuntos de blancos (sets), donde se midió su reflectancia en superficie, obteniendo diferentes rectas de regresión para las diferentes bandas. Los sets que obtuvieron las rectas de calibración más exactas ($R^2=0,99$ en las 4 bandas (R, G, B, NIR) y un RMSE por debajo de 0,020%). fueron el set "a" y el set "mixto". El set "total" compuesto por todos los blancos de calibración se usó de manera comparativa resultando ser idóneo cuando se usan índices de vegetación. También se analizó la robustez de los modelos testando los modelos de calibración radiométrica de las imágenes contiguas sobre la imagen central, obteniéndose resultados muy similares mediante una validación cruzada.

Por último se desarrollaron y compararon diferentes métodos para la estimación de la cantidad de biomasa aérea a partir de imágenes multiespectrales calibradas de Ultracam-Xp WP, validando finalmente las metodologías desarrolladas para la estimación de biomasa aérea. Los resultados obtenidos indican que las imágenes de esta cámara, una vez calibradas radiométricamente, son adecuadas para la estimación de la biomasa aérea herbácea. Los modelos más exactos se obtuvieron a partir de la reflectancia de las 4 bandas (R, G, B, IRc) ajustadas mediante regresión PLS, ($R^2=0,90$; RMSE=4,096 g/m²; %RMSE=12,92%), que resultaron superiores a los modelos lineales basados en índices de vegetación (NDVI, SR, NLI, SAVI y MARAVI). Por tanto, las imágenes de Ultracam-XP WP son adecuadas para estimar biomasa aérea una vez calibradas a reflectancia en superficie, utilizando PLS y la información espectral de las 4 bandas de la imagen.

AGRADECIMIENTOS

Hoy, un del 15 de Septiembre del 2016, lluvioso ha llegado la meta de un corredor, el aeropuerto de un piloto, la cima de un escalador. Realmente me es indiferente este final ya que lo importante no es llegar, sino disfrutar y entregarse al camino. Detenerse, parar, observar... y volver a disfrutar, apasionarse, obsesionarse, saltar al vacío, enfrentarse a los miedos, luchar, soñar, equivocarse, morir, aprender, disculpar, renacer y vivir. Por todo ello seguimos en este ciclo presentando esta Tesis Doctoral, cuyos resultados son producto de largas horas de trabajo, sueño, rabia pasión, pero su realización no habría sido posible sin la ayuda de un buen número de personas que han contribuido en mayor o menor medida en las distintas etapas de su realización. En primer lugar me gustaría agradecer de forma especial a Flor Álvarez Taboada mi maestra y compañera de viaje en el mundo de la investigación, y quien un buen día quiso darme la oportunidad de poner en mis manos una serie de ideas ‘descabelladas’ a priori pero que al final han resultado ser totalmente brillantes. Poca gente como Flor conoce realmente el esfuerzo, que ha supuesto llegar hasta el punto en el que estamos hoy y nadie como ella ha sido modelo en el modo de superar los fracasos y anticipar los triunfos. Gracias Flor, nunca olvidaré que por muy mal que me fueran las cosas en esta investigación, siempre me has apoyado de una manera u otra y son tan solo dos las palabras, que como al igual que el agua mueve al molino, conseguían darme ese empujón y alegría para seguir adelante. Dos palabras que nunca me cansaré de escuchártelas, porque ese “Genial” con una sonrisa suave pero firme o los mil y un “Ánimo” que al igual que una medicina curaban esos momentos de rabia. Menudos últimos días de vértigo, siento que este verano en tus vacaciones una vez estuvieras corrigiéndome los diferentes capítulos desde la otra parte del mundo. Seguimos!!!

Quiero continuar agradeciendo a José Ramón, Rodríguez Pérez quien ha sido un apoyo fundamental en esta aventura y quien desde la carrera me enseñó cómo la agricultura y el mundo forestal se podía interpretar desde un punto de vista científico y metódico. Nunca olvidaré esa ventana que me abriste, dándote las gracias por todo lo que he aprendido estos años sobre todo en Espectro-radiometría y el fabuloso mundo del infrarrojo cercano aunque no me cansaré de seguir este camino de la investigación. Siempre has ido un paso por delante siendo un placer haber podido trabajar a tu lado.

En lo económico siempre me acordaré del día en que me llamaron de la Fundación Villalar para ser unos de los 7 elegidos de Castilla y León en ser becado con 6000 € para el desarrollo de esta Tesis, así como esos contratos económicos tanto por parte de Flor

como de José Ramón para darme ese suspiro en medio de este espacio temporal nada fácil para los que hemos decidido quedarnos en este país. Vaya donde vaya seguro que aplicaré mis conocimientos altruistas con la investigación ya que el único objetivo de la ciencia es ayudar a los demás a vivir una mejor.

Clave fundamental del éxito de este trabajo ha venido por parte de esas manos voluntariosas las cuales han desarrollado una tesis paralela a la mía sobre el mismo ámbito. Aprendimos los dos a la vez lo que era un espectro-radiómetro en Cáceres con esas personas del CSIC, no me olvidaré de cómo empezó todo así como las horas de trabajo y viajes realizados juntos, siempre puedes seguir contando conmigo, un millón de gracias Ana Belén.

Gracias a mis amigos, compañeros del viaje libre, de la noche, del estudio de llegar un lunes sabiendo que hemos desconectado de verdad para volver con mucha energía al trabajo. Por esas horas en la biblioteca el día antes de un examen estudiando las constelaciones o la mitología griega. Por esas noches que se hacían de día a vuestro lado siempre estaré agradecido de haberos conocido, Maykel, Alberto, Manolín, Rodri, Feli, Santines, ya que todos habéis estado dispuestos a arrimar el hombro y a sacar adelante estas ideas, por eso no quiero terminar sin agradecer a todos estos amigos, que siempre han estado ahí a pesar de mi enclaustramiento y mi época ‘antisocial’... gracias a todos. Finalmente quiero dedicar este trabajo a mis padres, Miguel y Esther, GRACIAS a ellos tuve la oportunidad de estudiar y nunca estaré lo suficientemente agradecido por sus sacrificios y su apoyo. Por supuesto a mis hermanos Verónica y David, a Vero por haberme ayudado a separar hierbas verdes de secas jajaja y a David por ser como es, creo que los últimos días fuiste clave así como por darme a mi hija en la Fe Carla. Espero que sigáis en el mundo de la Topografía y de la Filosofía aunque no ejerzáis.

Y por último, y en un lugar especial, quiero agradecer y dedicar esta Tesis a la persona que realmente me ha visto llorar sin lágrimas, la que lleva toda una vida esperando a que cumpla mis objetivos sin pedir nada a cambio. Tú sabes mejor que nadie el esfuerzo que hay tras estas líneas y nada de esto habría sido posible sin tu apoyo incondicional. Siempre has estado ahí con una sonrisa, un abrazo y un consejo. Espero que, sobre todo ahora que empezamos una nueva vida, pueda compensarte por todas las horas que te he robado durante este tiempo. No existen palabras tan grandes de agradecimiento para ti por eso el silencio con una mirada lo dirá todo SARA.

Gracias a los que no estáis pero sé que puedo contar con vosotros.

A la política social como mera herramienta

ÍNDICE GENERAL

RESUMEN

AGRADECIMIENTOS

DEDICATORIAS

ÍNDICE GENERAL.....	I
ÍNDICE DE FIGURAS.....	III
ÍNDICE DE TABLAS.....	V

1 INTRODUCCIÓN Y OBJETIVOS	1
1.1. Contexto.....	1
1.2. Motivación	3
1.3. Utilidad de las imágenes de sensores aerotransportados (cámaras) para la estimación de variables agroforestales cualitativas y cuantitativas.....	5
1.4. La estimación de biomasa aérea mediante sensores remotos.....	8
1.5. Preguntas de investigación	10
1.6. Hipótesis	10
1.7. Objetivos	11
1.8. Estructura de la tesis.....	12
2 ESTADO DEL ARTE	14
2.1. La teledetección y el seguimiento de la vegetación.....	14
2.2. Sensores aerotransportados	18
2.3. Las cámaras fotogramétricas digitales aéreas	22
2.4. La Espectro-radiometría de campo	23
2.5. Estimación de biomasa a partir de percepción remota.....	26
3 ÁREA DE ESTUDIO.....	33
4 ESTIMACIÓN DE LA CANTIDAD DE BIOMASA AÉREA A PARTIR DE DE ESPECTRO-RADIOMETRÍA DE CAMPO.	35
4.1. Introducción.....	35
4.2. Material	38
4.2.1. Datos	38
4.2.1.1. Toma de datos espectrales	39
4.2.1.2. Toma de Datos de campo de biomasa aérea	40
4.3. Métodos	41
4.3.1. Flujo de trabajo.....	41
4.3.2. Pre-procesamiento espectral	42
4.3.3. Transformaciones espectrales	44
4.3.4. Transformación Continuum Removal e índices derivados.....	47
4.3.5. Modelos de ajuste	50
4.3.5.1. Regresión por mínimos cuadrados parciales (PLS).....	50
4.3.5.2. Máquinas de vectores de soporte (Support Vector Machine, SVM).....	53
4.3.5.3. Regresión lineal simple (OLS)	56
4.3.6. Evaluación de los modelos de estimación obtenidos	57
4.4. Resultados.....	59
4.4.1. Estimaciones de biomasa empleando el método PLS	59
4.4.1.1. Transformaciones generales	59
4.4.1.2. Transformaciones CR	63
4.4.2. Estimaciones de biomasa empleando el método SVM	67
4.4.3. Estimaciones de biomasa empleando índices derivados del CR y el método OLS	68
4.4.4. Estimaciones de biomasa empleando índices derivados de la transformación CR y el método PLS.....	69

4.4.5. Estimaciones de biomasa: resumen de resultados	72
4.4.5.1. Modelos para la estimación de la biomasa aérea (Peso Total, PT)	73
4.4.5.2. Modelos para la estimación de la biomasa aérea (Peso Verde seco, PV).....	75
4.4.5.3. Modelos para la estimación de la biomasa aérea (Porcentaje de peso verde seco, %PV) 76	
4.5. Discusión.....	78
5 CALIBRACIÓN RADIOMÉTRICA DE IMÁGENES MULTIESPECTRALES DE CÁMARA FOTOGRAMÉTRICA DIGITAL DE GRAN FORMATO	81
5.1. Introducción y objetivos.....	81
5.2. Material	88
5.2.1. Datos de teledetección	88
5.2.1.1. Características del sensor	88
5.2.1.2. Captura de datos (vuelo fotogramétrico)	91
5.2.2. Campo de calibración: establecimiento y caracterización radiométrica	93
5.2.3. Datos radiométricos auxiliares para la validación	97
5.3. Métodos	97
5.3.1. Flujo de trabajo	97
5.3.2. Pre-procesamiento de las imágenes	98
5.3.3. Procesamiento de los datos auxiliares de campo	99
5.3.3.1. Blancos de calibración	99
5.3.3.2. Parcelas de validación.....	100
5.3.4. Calibración empírica de línea: ajuste.....	100
5.3.5. Validación	104
5.4. Resultados.....	104
5.4.1. Caracterización radiométrica de los blancos de calibración y validación	104
5.4.2. Calibración radiométrica (validación cruzada)	109
5.4.3. Calibración radiométrica (validación independiente)	115
5.5. Discusión.....	117
6 ESTIMACIÓN DE BIOMASA AÉREA CON IMÁGENES MULTIESPECTRALES DE CÁMARA AÉREA DIGITAL	123
6.1. Introducción y objetivos.....	123
6.2. Material	124
6.2.1. Datos de teledetección	124
6.2.2. Datos de biomasa aérea	125
6.3. Métodos	128
6.3.1. Flujo de trabajo	128
6.3.2. Pre-procesamiento de las imágenes	129
6.3.3. Modelos de ajuste para la estimación de biomasa	130
6.3.4. Validación	131
6.4. Resultados.....	134
6.4.1. Modelos de estimación de biomasa aérea	134
6.4.2. Robustez del modelo de calibración radiométrica para la estimación biomasa aérea	143
6.5. Discusión.....	152
7 DISCUSIÓN GENERAL	155
8 CONCLUSIONES	161
9 LÍNEAS DE TRABAJO FUTURO.....	165
10 BIBLIOGRAFÍA.....	167

ÍNDICE DE FIGURAS

Figura 1.1. Esquema de la estructura de la Tesis. Los polígonos de color verde representan la entrada de datos, los círculos representan las zonas donde se realizaron mediciones. Los rectángulos azules representan resultados intermedios, los rombos azules modelos de regresión y los rectángulos amarillos representan los resultados finales. La línea discontinua representa un estudio comparativo. CV: Calibración y Validación	13
Figura 2.2. Signatura espectral típica de una hoja (Datos adquiridos con un espectro-radiómetro ASD) (elaboración propia).....	25
Figura 3.1. Localización del área de estudio.	34
Figura 4.1. Representación de las mediciones espectrales en una parcela (Elaboración propia).....	39
Figura 4.2. Histogramas y curva de normalidad de las variables PV, PT, %PV.....	41
Figura 4.3. Flujo de trabajo	42
Figura 4.4. Aplicación de la línea del continuum a dos partes del espectro.....	48
Figura 4.5. Signatura espectral característica de la vegetación de la zona de estudio, sobre la que se superponen las zonas de aplicación del <i>Continuum Removal</i> en este trabajo (Z1-Z5). El detalle representa a los índices MBD y AOM en la zona Z2.....	50
Figura 4.6. Caracterización de SVR con margen suave: Se observa la relación entre las variables de holgura ($\epsilon_i -$, $\epsilon_j +$) mediante ejemplos que están situados fuera de la zona <i>tubular</i> ϵ -insensible y la función de pérdida, $L\epsilon$ (Carmona-Suarez, 2013).	54
Figura 4.7. Resultados de la validación cruzada en la estimación de biomasa aérea usando (A) PLS mediante la transformación MSCO (B) SVM aplicado en la zona espectral VNIR + SWIR1 (C) PLS sin transformaciones en la zona espectral VNIR + SWIR1 + SWIR2 y (D) OLS a partir del AOM en la zona Z4. Se muestra la línea 1:1	74
Figura 4.8. Resultados de la validación cruzada en la predicción de PV usando (A) Regresión PLS tras la transformación SG aplicado al subconjunto espectral VNIR, (B) SVM aplicado al subconjunto espectral VNIR+SWIR1+SWIR2, (C) Regresión PLS sin transformación aplicado en	

el subconjunto espectral VNIR+SWIR1 y (D) Regresión OLS a partir del AOM en la zona Z4. Se muestra la línea 1:1	76
Figura 4.9. Resultados de la validación cruzada en la predicción del %PV usando (A) Regresión PLS tras la transformación SG en la zona VNIR+SWIR1+SWIR2), (B) SVM basado en los datos nos transformados en la región del VNIR, (C) Regresión PLS sin transformación aplicado en el subconjunto espectral VNIR+SWIR1+SWIR2 y (D) Regresión OLS a partir del MBD en la zona Z4. Se muestra la línea 1:1	77
Figura 5.1. Imagen de la UltraCam-Xp WA (Microsoft Vexcel, 2011).....	89
Figura 5.2. Pasos para la formación de una imagen (adaptación de Santos-Pérez, 2006)	90
Figura 5.3. Respuesta espectral de la UltraCam-Xp WA (Microsoft Vexcel, 2011).	91
Figura 5.4. Representación cartográfica del plan de vuelo. Los límites de color negro representan las 7.....	92
Figura 5.5. Detalle de los blancos de calibración (Elaboración propia).....	94
Figura 5.7. Diagrama de flujo de trabajo para realizar la calibración de las imágenes a reflectancia en superficie (Elaboración propia).	96
Figura 5.8. Reflectancias del blanco de calibración azul (en negro) y su espectro promedio (media) (en azul).	99
Figura 5.9. Blancos móviles rígidos	101
Figura 5.10. Espectros promedio de los diferentes paneles móviles rígidos.....	105
Figura 5.11. Espectros promedio de los diferentes blancos móviles flexibles.....	105
Figura 5.12. Espectros promedio de los diferentes blancos fijos.	106
Figura 5.13. Reflectancias ponderadas de los diferentes blancos de calibración.	107
Figura 5.14. Reflectancias promedio de las diferentes parcelas de validación (vegetación) simuladas para la cámara a partir de los datos del espectroradiómetro.	109
Figura 5.15. Imágenes en reflectancia de la imagen B. La imagen 1 está formada por las ecuaciones de la imagen A sobre la imagen B. La imagen 2, es la imagen formada por las ecuaciones de su propia imagen B y la imagen 3 es la imagen formada con las ecuaciones de la imagen C.....	114
Figura 6.1. Localización de las parcelas de biomasa de herbáceas (Elaboración propia).	126

Figura 6.2. Representación de la parcela (1 m × 1 m) y la cosecha de biomasa aérea en la subparcela (0,5 m × 0,5 m)	127
Figura 6.3. Diagrama de flujo de trabajo seguido en el Capítulo 6. (Elaboración propia).	129
Figura 6.4. Análisis de los residuos en el modelo 1. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q.	117
Figura 6.5. Análisis de los residuos en el modelo 2. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q	142
Figura 6.6. Análisis de los residuos del ajuste entre los valores medidos y predichos por el modelo 3 en la validación cruzada. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q.	146
Figura 6.7. Análisis de los residuos del ajuste entre los valores medidos y predichos por el modelo 4 en la validación cruzada. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q	150
Figura 6.8. Resultados de la validación cruzada en la estimación de biomasa aérea a partir de PV en los 4 modelos más exactos. Regresión PLS: 1 y 3; Regresión OLS: 2 y 4.....	151

ÍNDICES DE TABLA S

Tabla 2.1. Índices de vegetación usados en la estimación de parámetros biofísicos	29
Tabla 2.2. Ejemplos de técnicas estadísticas para la estimación de variables biofísicas en la vegetación a través de datos hiperespectrales.	31
Tabla 4.1 Estadísticos descriptivos de la muestra (n=30) (PT: Peso de la biomasa aérea total, PV: Peso de la fracción verde, %PV: Porcentaje de peso de la fracción verde).	40
Tabla 4.2. Longitudes de onda que definen los tres subconjuntos espectrales considerados en esta investigación.....	43
Tabla 4.3. Transformaciones comparadas en este estudio.....	44
Tabla 4.4. Zonas de aplicación del <i>Continuum Removal</i>	48
Tabla 4.5. Valores medios de las variables de biomasa aérea (PT, PV y %PV) usados para estimar el error cuadrático medio en porcentaje (%RMSE).....	52
Tabla 4.6. Modelos de estimación de biomasa aérea (PV, PT, %PV) empleando PLS y el espectro transformado. ST: Espectro sin transformar; Transformaciones: CyE: Centrado y Escalado del espectro; SG: Transformación <i>Savitzky y Golay</i> 1° derivada; BL: Transformación <i>Baseline</i> ; DE-TREN2: Transformación <i>De-trending</i> usando un polinomio de orden 2; SNV: Transformación aleatoria normal estándar; NME: Normalización usando la media; RAB: Transformación de reflectancia en absorbancia; MSCO (X=X-a): Corrección de dispersión multiplicativa. Zona a: VNIR, Zona b: VNIR+SWIR1, Zona c: VNIR+SWIR1+SWIR2; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R ² : coeficiente de determinación tras aplicar la validación cruzada; RMSE: (RMSE _{PV} : g/m ² ; RMSE _{PT} : g/m ² ; y RMSE _{%PV} : %; %RMSE: %); AIC: criterio de información de Akaike. Se resaltan en negrita los resultados más exactos.	60
Tabla 4.7. Modelos de estimación de biomasa aérea (PV, PT, %PV) empleando PLS y La transformación CR en 5 zonas diferentes del espectro (Z1, Z2, Z3, Z4, Z5). El espectro representa el espectro medio o el espectro mediana de los datos. F: número de factores latentes (PLS); R ² : coeficiente de determinación tras aplicar la validación cruzada; RMSE: (RMSE _{PV} : g/m ² ;	

RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); AIC: criterio de información de Akaike. Se resalta los modelos más exactos. 63

Tabla 4.8. Modelos de estimación de biomasa aérea (PV, PT, %PV) empleando PLS a los resultados de combinar las diferentes zonas (Z1, Z2, Z3, Z4, Z5) donde se aplicó CR a los espectros. El espectro representa el espectro medio o el espectro mediana de los datos. F: número de factores latentes (PLS); R²: coeficiente de determinación; RMSE: (RMSE_{PV}: g/m²; RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos. 65

Tabla 4.9. Modelos de estimación de biomasa aérea (PV, PT y %PV) empleando SVM en diferentes zonas espectrales (VNIR, VNIR+SW1, VNIR+SW1+SW2) al usar las medias o las medianas espectrales; R²: coeficiente de determinación tras aplicar la validación cruzada; RMSE: (RMSE_{PV}: g/m²; RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); C: parámetro, SVs: vectores soporte; Gama: 1, Épsilon: 0,1. Se resaltan en negrita los resultados más exactos. 67

Tabla 4.10. Modelos de estimación de biomasa aérea (PV, PT y %PV) empleando OLS, en las diferentes zonas del CR (Z1, Z2, Z3, Z4, Z5). El espectro representa el espectro medio o el espectro mediana de los datos. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; R²: coeficiente de determinación; RMSE: (RMSE_{PV}: g/m²; RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); Se resaltan en negrita los resultados más exactos. 69

Tabla 4.11. Modelos de estimación de biomasa aérea (PV) empleando PLS, los índices derivados del CR y considerando la zona de absorción espectral Z4 en las combinaciones. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R²: coeficiente de determinación tras aplicar la validación cruzada; RMSE: (RMSE_{PV}: g/m²; RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos. 70

Tabla 4.12. Modelos de estimación de biomasa aérea (PT) empleando PLS, los índices derivados del CR y considerando la zona de absorción espectral Z4

en las combinaciones. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos..... 70

Tabla 4.13. Modelos de estimación de biomasa aérea (%PV) empleando PLS, los índices derivados del CR y considerando la zona de absorción espectral Z5 en las combinaciones. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan en negrita los resultados más exactos. 71

Tabla 4.14. Resumen de los modelos de estimación de biomasa aérea (PV, PT y %PV) empleando PLS, SVM, OLS y transformaciones espectrales. El espectro representa el espectro media o el espectro mediana de los datos. F/C: número de factores latentes (PLS) o el parámetro C (SVM); R^2 : coeficiente de determinación; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos..... 72

Tabla 5.1. Características del sensor UltraCam-Xp WA (Microsoft Vexcel, 2011). 88

Tabla 5.2. Combinaciones (a-T) de los blancos (1-25) testados para calibrar las imágenes (Sets).T=todos los blancos. Las superficies de referencia se han identificado con números, de la siguiente forma: 1-6: Filtro azul, filtro blanco, filtro gris, filtro negro, filtro rojo, filtro verde; 7-21: blancos móviles rígidos con las siguientes reflectancias nominales en la escala de escala de grises (panel 1, panel 2, panel 1+2): 0%, 25%, 50%, 75%, 100%); 22-25: blancos fijos: pista de atletismo I, pista de atletismo II, asfalto, césped artificial. Las “x” en la tabla indican que ese blanco se empleó en el set. 101

Tabla 5.3. Caracterización radiométrica de los blancos utilizados en los sets de calibración: Ref: Reflectancias ponderadas para cada banda (B, G, R, NIR) de la cámara y ND: Nivel digital promedio.	107
Tabla 5.4. Exactitud de la validación en la calibración empírica de línea para cada banda (B, G, R, NIR). RMSE: (%). Dentro de cada banda se destaca los resultados más exactos. Se destacan los resultados más exactos de cada banda así como el RMSE promedio más exacto.	110
Tabla 5.5. Exactitud de la validación en la calibración empírica de línea para la imagen B en cada banda. RMSE:(%), %RMSE: % sobre las reflectancias.	111
Tabla 5.6. Parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia=aND+b.	112
Tabla 5.7. Exactitud de la validación en la calibración empírica de línea para la imagen A en cada banda. RMSE: (%), %RMSE: % sobre las reflectancias.	112
Tabla 5.8. Resultados de los parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia=aND+b.	113
Tabla 5.9. Exactitud de la validación en la calibración empírica de línea para la imagen C en cada banda. RMSE: (%), %RMSE: % sobre las reflectancias.	113
Tabla 5.10. Resultados de los parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia=aND+b.	113
Tabla 5.11. Exactitud de la validación en la calibración empírica de línea usando los modelos de los sets de las imágenes A y C en la imagen B para cada banda. RMSE: (%), %RMSE: % sobre las reflectancias.	114
Tabla 5.12. Resultados de los parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia=aND+b.	115
Tabla 5.13. Exactitud de la validación independiente de la calibración radiométrica en la imagen A. RMSE:(%), %RMSE: % sobre las reflectancias.	116
Tabla 5.14. Exactitud de la validación independiente de la calibración radiométrica en la imagen B. RMSE: (%), %RMSE: % sobre las reflectancias.	116

Tabla 5.15. Exactitud de la validación independiente de la calibración radiométrica en la imagen C. RMSE:(%), %RMSE: % sobre las reflectancias.....	116
Tabla 5.16. Exactitud de la validación independiente de la calibración radiométrica en la imagen B usando las ecuaciones de calibración de la imagen A y C. RMSE: (%), %RMSE: % sobre las reflectancias.	117
Tabla 6.1. Resultados de la validación cruzada de los modelos de estimación de biomasa aérea (PV, PT y %PV) en las imágenes A, B y C, empleando regresión PLS, las reflectancias de las cuatro bandas y los diferentes sets de calibración (a, mixto y total). F: número de factores latentes; R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; AIC: criterio de información de Akaike, %RMSE: %.....	134
Tabla 6.2. Resultados de la validación cruzada de los modelos de estimación de biomasa aérea (PV, PT y %PV) en la imagen A, B y C, empleando la regresión OLS, índices de vegetación y los diferentes sets de calibración (a, mixto y total). R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; $RMSE_{\%PV}$: %; %RMSE: %.....	137
Tabla 6.6. Resultados de la validación cruzada de los modelos de estimación de biomasa aérea (PV, PT y %PT) en la imagen B empleando las correcciones radiométricas ajustadas para las imágenes adyacentes A y C, usando regresión PLS y las reflectancias de las cuatro bandas (Roja, verde, azul e IRc). F: número de factores latentes (PLS); R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; $RMSE_{\%PV}$: %; %RMSE: %; AIC: Criterio de Información de Akaike	143
Tabla 6.7. Resultados de la validación cruzada independiente de los modelos de biomasa aérea (PV, PT y %PV) en la imagen B empleando las ecuaciones de los modelos obtenidos en los diferentes sets de calibración (set “a”, set “mixto” y set “total”), de la imagen A, B y C, regresión OLS, índices de vegetación. R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE: %.....	147

Capítulo 1

1

INTRODUCCIÓN Y OBJETIVOS

1.1. Contexto

La elevada cantidad de información capturada periódicamente con vuelos fotogramétricos en amplias zonas del territorio como los vuelos para el Plan Nacional de Ortofotografía Aérea (PNOA), es empleada en la actualidad únicamente para la generación de cartografía de referencia (e.g. ortofotografías, modelos digitales del terreno). Estos vuelos se enmarcan dentro de la iniciativa INSPIRE, uno de cuyos objetivos es hacer disponible información geográfica relevante, concertada y de calidad. Las imágenes multispectrales obtenidas mediante cámaras digitales fotogramétricas en estos vuelos pueden emplearse potencialmente para extraer información temática cualitativa y cuantitativa, si bien desde el punto de vista cuantitativo existe una

infrautilización de estos datos, puesto que no se emplean habitualmente para obtener variables biofísicas de la superficie terrestre. Una de esas variables es la biomasa aérea, de modo que resultaría de especial interés explorar la posibilidad de establecer una relación entre la cantidad de biomasa y la información radiométrica capturada por las cámaras fotogramétricas, como valor añadido a los productos de PNOA.

Existen, sin embargo, numerosas debilidades en el proceso que retrasan el uso de la información radiométrica proporcionada por estos sensores, puesto que el uso óptimo de esta tecnología requiere la calibración y validación de los sistemas fotogramétricos empleados. Esto último se debe a que las condiciones de vuelo (atmosféricas, características de la exposición, altitud solar) y las propiedades del sensor (sensibilidad de las lentes y los filtros) afectan a la radiometría de las imágenes y deben ser corregidos para minimizar su impacto en el proceso. Estos aspectos indican la necesidad de desarrollar un protocolo de procesamiento de la información radiométrica para que los datos capturados con el sensor fotogramétrico permitan generar información temática cuantitativa mediante técnicas de teledetección. En este contexto se define la calibración radiométrica como el proceso de definir cuantitativamente la respuesta de un sensor a una señal de entrada conocida y controlada.

En las zonas con vegetación, la estimación de biomasa es fundamental por la información que aporta sobre la productividad y su aplicación en la planificación y gestión sostenible de los ecosistemas. Su cuantificación y monitorización es muy importante para caracterizar el papel de la vegetación en el ciclo del carbono. La resolución espectral de las imágenes multispectrales de cámaras aéreas digitales de gran formato limita, *a priori*, la precisión de las estimaciones, pero es necesario determinar si es suficiente para realizar una determinación aproximada de la capacidad de secuestro de carbono/biomasa que permita su mapeado y monitorización. Estos mapas de capacidad de secuestro de carbono/biomasa son de mucha utilidad para la gestión forestal y agrícola, desde el punto de vista productivo y ambiental (e.g. estimación y seguimiento de recursos agrícolas y forestales, empleo de la biomasa como biocombustible para la generación de energía), contribuyendo a la movilización de nuevos recursos energéticos, prevención de incendios, monitorización de la regeneración de áreas quemadas, y se obtendrían sin un coste adicional en la captura de la información de partida.

1.2. Motivación

Hoy en día la posibilidad de estimar la cantidad de biomasa aérea en zonas dominadas por especies herbáceas resulta fundamental por su valor energético y su relación directa con el carbono (Barrio *et al.*, 2006), permitiendo el estudio integral de los sistemas agroforestales como sumidero de carbono en su ciclo biogeoquímico, apreciando la intervención humana en el clima y sus efectos sobre el cambio climático.

El protocolo de Kioto requiere la evaluación de la productividad de las zonas forestales para determinar los stocks de carbono. Después de la cumbre de París (*COP21*) los países participantes han dirigido sus miradas a las energías renovables como pieza clave en el nuevo panorama mundial de sostenibilidad energética. Se sabe que más de dos tercios de las emisiones mundiales de gases de efecto invernadero (GEI) se deben al sector de la energía. La capacidad de secuestro de carbono y su modelización puede facilitar la toma de decisiones en la estimación de la cosecha, y del manejo de los residuos tras la misma (Pordesimo *et al.*, 2004).

Las mediciones directas de la capacidad de secuestro de carbono/biomasa son costosas y han de realizarse por técnicas destructivas (Reese *et al.*, 1980). Esto lleva tanto a los investigadores como a los gestores/planificadores a buscar métodos no destructivos de estimación de capacidad de secuestro de carbono/biomasa, que sean repetibles y que permitan la monitorización de la vegetación. En el pasado las técnicas de teledetección satelital han sido capaces de estimar la cantidad de biomasa aérea empleando la reflectancia de las bandas del espectro visible y del infrarrojo cercano, lo que establece la posibilidad de emplear imágenes de cámaras aéreas digitales para estudios de este tipo. Por lo tanto, la aplicación de un método basado en sensores remotos, se plantea como una oportunidad para mejorar los modelos de estimación de biomasa aérea.

En zonas agrícolas y de pastizal la estimación de capacidad de secuestro de carbono/biomasa permite conocer mejor el estado de las cosechas y establecer medidas encaminadas a mejorar la gestión de dichas zonas. En las zonas forestales arboladas se han desarrollado ecuaciones alométricas que permiten estimar biomasa en sus diferentes fracciones y carbono a partir de parámetros de muy sencilla medición en campo como el diámetro normal (Barrio *et al.*, 2006), pero no son habituales para matorral ni pastizales. Las características de este tipo de vegetación dificultan la construcción de estos modelos y sugieren el empleo de técnicas de percepción remota para su estimación. Las técnicas

de teledetección permiten asimismo analizar la distribución espacial y temporal del atributo analizado y tienen la ventaja de proporcionar información sobre las plantas casi instantáneamente y de un modo no destructivo (Clevers, 1988).

El calentamiento global de la Tierra como consecuencia de la acumulación de gases de efecto invernadero (GEI) en la atmósfera, está generando gran preocupación en el mundo, debido a que sus consecuencias son altamente perjudiciales en la sostenibilidad de los ecosistemas y la socioeconomía de los núcleos rurales, por ello es necesario la estimación del secuestro de carbono/biomasa así como su modelización en los diferentes campos de la comunidad científica, empresarial, política y social. En este trabajo se hace relevante la búsqueda de un método no destructivo y con elevada exactitud, que satisfaga esa necesidad en los diferentes campos. Por tanto es necesaria una herramienta que facilite obtener información de la producción de biomasa aérea/fijación de CO₂ en la gestión forestal y agrícola, la cual contribuye a paliar los efectos del cambio climático. Resulta de especial interés explorar la relación entre la variable biomasa aérea y la información radiométrica capturada por las cámaras fotogramétricas, como valor añadido a los productos obtenidos de los vuelos fotogramétricos ya que de esta manera podremos obtener información de la variable sin necesidad de usar métodos destructivos.

Para ello es imprescindible establecer un flujo de trabajo para la calibración de imágenes de cámaras aéreas fotogramétricas para la estimación de la cantidad de biomasa aérea a escalas detalladas pero cubriendo áreas extensas. La creación de mapas disponibles en los cuales se represente la cantidad de biomasa aérea, se presenta como una herramienta informativa en dicha estimación. Este trabajo se llevó a cabo en herbáceas debido a su homogeneidad. Existen biocombustibles compuestos por herbáceas además de matorral y arbolado, y su estimación partir de imágenes representan un avance en los proyectos de ordenación del territorio. Además, el uso de estas especies energéticas en plantas energéticas de biomasa, hace necesaria esta información para su inventario y gestión.

El cambio climático es uno de los principales retos ambientales que se le plantean a medio y largo plazo en la mayoría de los países para alcanzar un desarrollo sostenible. La estimación de la biomasa aérea a partir de modelos realizados en este trabajo se puede relacionar con la cantidad de CO₂ fijado por esa biomasa. Estas estimaciones nos proporcionan información útil en la gestión forestal y agrícola así como en el desarrollo

de herramientas para evitar el efecto invernadero provocado por gases entre los que se encuentran el dióxido de carbono liberados a la atmósfera (Mota *et al.*, 2010).

El desarrollo industrial alcanzado en nuestro planeta ha supuesto que la concentración de estos gases haya aumentado hasta un 30% desde el siglo pasado provocando que la propia naturaleza se encuentre limitada a la hora de equilibrar las concentraciones de dichos gases en la atmósfera. La estimación de biomasa aérea y por consiguiente el CO₂ capturado, cobra especial relevancia por su efecto sobre las condiciones climáticas del planeta debido a que es un gas de larga permanencia, es decir, es un gas que permanece activo en la atmósfera durante mucho tiempo. Así, por ejemplo, del CO₂ emitido a la atmósfera, sobre el 50% tardará 30 años en desaparecer, un 30% permanecerá varios siglos y el 20% restante durará varios millares de años (Solomon *et al.*, 2007).

Las especies vegetales tienen la capacidad de captar el carbono de la atmósfera (en forma de CO₂ atmosférico) y mediante procesos fotosintéticos transformarlo en biomasa. El exceso de CO₂ modifica el balance final del ciclo del carbono influyendo en las condiciones climáticas. El CO₂ secuestrado por las plantas es el resultado de las diferencias entre el CO₂ atmosférico absorbido durante el proceso de la fotosíntesis y el CO₂ emitido por la atmósfera durante la respiración. Esta diferencia es convertida en biomasa y suele oscilar entre el 45-50 % del peso seco de la planta. Por lo tanto, resulta fundamental estimar esa biomasa de una manera no destructiva tal como se lleva a cabo en este trabajo. Las herbáceas se convierten en los sumideros de carbono, los cuales pueden ser estimados. Por tanto la posibilidad de realizar estimaciones de biomasa y de CO₂ atmosférico capturado por dicha biomasa, a través del empleo de técnicas de percepción remota para su estimación se presenta como una solución en el estudio del cambio climático. Las técnicas de teledetección permiten asimismo analizar la distribución espacial y temporal del atributo analizado.

1.3. Utilidad de las imágenes de sensores aerotransportados (cámaras) para la estimación de variables agroforestales cualitativas y cuantitativas

En 1960 Evelyn Pruitt aplica por primera vez el vocablo “teledetección” en su traducción inglesa “*remote sensing*”, para designar cualquier medio de adquisición de

información a distancia de objetos, zonas o fenómenos sin necesidad de contacto material con ellos. Multitud de datos en teledetección se adquieren diariamente en todo el mundo, desde satélites, plataformas aéreas con o sin tripulación o desde el suelo. Los usuarios de estos datos no se limitan sólo a los expertos de teledetección; más bien a cualquier usuario con una conexión a internet tiene libre acceso a las bases de datos globales o servicios (Markelin, 2013).

La captura de información a través de los diferentes sensores de teledetección es posible debido a su capacidad de captar un amplio rango de longitudes de onda del espectro electro-magnético, desde la radiación ultravioleta hasta la de microondas, en un determinado número de canales o bandas, según sean sensores multiespectrales o hiperespectrales. Existen varios tipos de sensores en función de la fuente de energía que reciben, entre los cuales destacaremos en este trabajo dentro de los pasivos las cámaras digitales aerotransportadas, que dependen de una fuente de luz externa como es el sol.

Un área importante de la teledetección es la fotogrametría, que se define como el arte, ciencia o tecnología para obtener información fiable de los objetos físicos y el medio ambiente a través de un proceso de grabación, medición e interpretación de imágenes fotográficas así como de patrones de energía radiante electromagnética y otros fenómenos (Alspaugh, 2004). Una de las ventajas de la fotogrametría es la posibilidad de obtener imágenes con elevado solapamiento (Markelin, 2013).

El desarrollo de la teledetección solo ha sido posible gracias a una mejora de la capacidad de procesado y análisis de datos que amplían las posibilidades de tratamiento, la simplificación de los procesos y la mayor potencia de las plataformas de proceso. Por otro lado el procesamiento de las imágenes es necesario para convertir la información de los sensores en un documento cartográfico con correcciones geométricas y atmosféricas principalmente (García-Ferrer, 2013)

Con el paso del tiempo, la teledetección se ha convertido en una herramienta muy útil para la agricultura. A partir de la medida de la señal espectral reflejada o emitida por las cubiertas y la combinación de técnicas de teledetección, es posible identificar los distintos usos agrícolas así como numerosos parámetros y anomalías que éstos presenten. Las aplicaciones en cubiertas vegetales agrícolas y forestales son áreas de desarrollo de la teledetección más activa en los últimos años en aspectos tales como la estimación de la producción agrícola, control de superficies de cultivo para el seguimiento dentro de la Política Agraria Comunitaria (PAC), control de determinadas

plagas o enfermedades en plantas, evaluación de daños causados por incendios forestales o su seguimiento en tiempo real. La obtención de imágenes a partir de cámaras aéreas digitales permite extraer información tanto temática como biofísica de una forma rápida sin necesidad de utilizar otros métodos destructivos, lentos y muy tediosos. Por lo tanto constituye una herramienta de monitoreo, seguimiento e identificación de diferentes fenómenos. Las cámaras no convencionales acondicionadas con filtros en la región del infrarrojo e instaladas en plataformas aéreas son una alternativa para realizar el levantamiento de información cartográfica y espectral y con ello facilitar el seguimiento periódico (García *et al.*, 2014). Esto es debido a la ventaja de poder tener autonomía en la resolución temporal para realizar el seguimiento en cultivos agrícolas, además de la capacidad de capturar imágenes con una alta resolución espacial (<30 cm) y con información espectral en el visible y en el infrarrojo. Lo anterior se ve reflejado en las aplicaciones que ha tenido en la cartografía, el medio ambiente, o la agricultura (Blackmer *et al.*, 1996, Flowers *et al.*, 2003, Antic *et al.* 2009). No obstante, el procesamiento digital de estas imágenes ha generado nuevos desafíos, realizar procedimientos como: correcciones radiométricas y geométricas, generación de mosaicos y generación de diferentes índices de vegetación.

Aparte de la geometría, la propiedad esencial de las imágenes de un sensor remoto es la radiometría. La radiometría se define como la ciencia que se ocupa de estudiar la medida de la radiación electromagnética (Schott, 2007). Estas imágenes por tanto se someten a un análisis digital en el que se analiza el comportamiento espectral de cada píxel en las distintas regiones del espectro electromagnético en el que se ha registrado información. La base de la teledetección radica en que cada cuerpo presenta un patrón de energía reflejada/emitada propio y diferente que lo distingue del resto de los materiales cuando sobre él incide energía electromagnética (Chuvienco y Huete, 2010).

Las diferentes cubiertas terrestres reflejan la radiación solar en función de sus propiedades espectrales y direccionales, y esta respuesta se almacena en las imágenes como información radiométrica. Mediante el análisis radiométrico podemos identificar las cubiertas y los usos del suelo, estimar diferentes variables biofísicas e identificar cambios a lo largo del tiempo.

La resolución radiométrica o sensibilidad radiométrica se refiere al número de niveles digitales empleados para expresar los datos recogidos por el sensor. En general, a mayor número de niveles, mayor es el detalle en la información (Hernández, 2002). La obtención de información cuantitativa a partir de sensores analógicos fotogramétricos

era extremadamente difícil, pero la aparición de sensores digitales a principios del siglo XXI ha eliminado esta limitación y ha mejorado la calidad radiométrica de los datos significativamente (Sandau, 2010; Cramer, 2011).

1.4. La estimación de biomasa aérea mediante sensores remotos

El protocolo de Kioto y recientemente la Cumbre de Naciones Unidas sobre el Cambio Climático de París (COP21) requiere el equilibrio entre los gases emitidos y los que pueden ser absorbidos a partir de 2050, es decir, cero emisiones netas. Dentro de este contexto, resulta fundamental la estimación y la evaluación de la productividad de las zonas agroforestales (donde se incluyen las herbáceas) para determinar la biomasa aérea y por consiguiente el stocks de carbono.

Por otro lado esta estimación es importante debido a que en el año 2030 se espera un aumento en el uso de la biomasa para la obtención de energía de entre 236 y 255 Mtep, lo que supone un incremento del 210% de su actual cota de mercado. Por otro lado, para 2050 cuando se espera que se alcance el 100% de la demanda energética europea a través de renovables, la biomasa será la fuente de energía que más aportará con 359,1 Mtep/año sobre un consumo total previsto en Europa de 1.004,2 Mtep/año, según el informe realizado por el *European Renewable Energy Council* (EREC) titulado “*Rethinking 2050: a 100% Renewable Energy for the European Union*”, que permitirá la generación de 6 millones de nuevos puestos de trabajo. Desde todos los estamentos se lleva tiempo hablando de la necesidad de alcanzar y desarrollar una economía en torno al monte y que garantice su gestión de una forma sostenible en el medio rural. Dicha sostenibilidad implica sin lugar a dudas su mejora como mitigador del cambio climático debido a dos elementos. El primero de ellos resulta como consecuencia del incremento del almacenamiento de carbono al potenciar su capacidad productora de biomasa a través de la silvicultura del carbono ligada a la gestión forestal. Y el segundo como consecuencia de la sustitución de otros materiales muchos más perjudiciales para la calidad del aire por aquellos derivados del monte (Fernández-Corbis y Otero-Vicario, 2016)

Al contrario que los combustibles fósiles (carbón, petróleo, gas natural), la energía derivada de la biomasa es renovable indefinidamente, y frente a la energía eólica y solar, la de la biomasa es fácil de almacenar y de abastecimiento continuo y

predecible, dependiendo de sí misma en la planificación de la producción y no de elementos ajenos como la existencia de viento y de la ausencia de nubes.

La biomasa frente a otras fuentes de energía, es un recurso renovable que presenta un balance de CO₂ nulo, contribuye a la mitigación del cambio climático por la sustitución de combustibles fósiles y permite el control y disminución de la cantidad de CO₂ y otros gases contaminantes liberados a la atmósfera. La obtención de energía a partir de combustibles fósiles en centrales térmicas, produce gases de efectos invernadero y partículas contaminantes perjudiciales para el medio ambiente, frente a la emisión prácticamente nula de las centrales de biomasa (Fernández-Corbis y Otero-Vicario, 2016).

La estimación de la biomasa aérea asociada al crecimiento de los cultivos agrícolas puede estimarse usando modelos biofísicos a partir de determinados softwares que simulan el desarrollo y producción del cultivo en diferentes condiciones climáticas, orográficas, edáficas etc. y a partir de datos tomados en campo (Scarabotti *et al.* (2002) Estos modelos han sido evaluados posteriormente mediante la comparación de modelos recogidos en diferentes experimentos de campo (Paz-Pellat *et al.*, 2012). Otros trabajos recientemente se basan en la utilización de estimadores para determinar la biomasa aérea en campo mediante en el método de doble muestreo desarrollado por Haydock y Shawn (1975), utilizando la asociación de observaciones visuales con datos obtenidos por muestreo directo a campo para determinar estimadores de regresión (Mónaco *et al.*, 2015).

Una alternativa a los métodos destructivos y que presenta además la ventaja de extrapolar los resultados a grandes escalas para la estimación de la biomasa, es el uso de los sensores remotos. Para la estimación de biomasa, se han utilizado con éxito sensores remotos de tipo activo: sistemas radar activos (Wu, 1987; Le Toan *et al.*, 1992); sensores LIDAR (*Light Detection And Ranging*) aerotransportados (Naesset, 1997; Lim y Treitz, 2004; Rao *et al.*, 2014); laser escáner (Lee *et al.*, 2007; Jaakkola *et al.*, 2010; Raunonen *et al.*, 2013) y sensores de ultrasonidos (Bhardwaj *et al.*, 2015). También sistemas ópticos pasivos de alta y media resolución (Meeuwig y Miller, 1979; Lefsky *et al.*, 2001; Solberg *et al.*, 2009). Para determinar la utilidad potencial de las imágenes de baja altitud y amplia escala en la evaluación de biomasa vegetal en arbustos, Quilter y Anderson (2001), hicieron un estudio, en sensores de tipo pasivo, en el que se correlacionaron los datos de reflectancia de las imágenes con los porcentajes de

defoliación de los arbustos. Así, los altos contrastes en la reflectancia de la vegetación en las bandas del rojo y del infrarrojo cercano se usan para discriminar el crecimiento de ésta (Tucker, 1979), por lo que a partir de este par de bandas se han desarrollado numerosos índices espectrales de la vegetación relacionados con la biomasa aérea (Tucker *et al.*, 1981; Calera *et al.*, 2004; Anaya *et al.*, 2008; Paz *et al.*, 2011). Sin embargo este tipo de enfoque supone una relación fija y que los medios son física y radiativamente homogéneos. Por ello el objetivo del presente es mostrar un enfoque genérico de modelación de la relación entre la biomasa aérea y la información espectral, transformada o no en índices de vegetación.

1.5. Preguntas de investigación

Esta tesis analiza la posibilidad de estimar la cantidad de biomasa aérea en herbáceas a partir de imágenes de cámaras fotogramétricas digitales de gran formato y responde específicamente a las siguientes cuestiones de investigación:

1. ¿Es posible estimar la cantidad de biomasa aérea en herbáceas a partir de imágenes de multiespectrales de cámara aérea digital?
2. ¿Es posible calibrar radiométricamente las imágenes de cámara aérea digital para obtener imágenes de reflectancia en superficie?
3. ¿Es la calibración radiométrica de una imagen aplicable a otras imágenes de la cámara aérea digital en una misma pasada?
4. ¿Cómo afecta a la calibración radiométrica de una imagen el conjunto de blancos de calibración empleados como referencia?
5. ¿Está relacionada la cantidad de biomasa aérea en herbáceas con la respuesta espectral de las cubiertas?

1.6. Hipótesis

La hipótesis de esta tesis se basa en los siguientes puntos:

- Existe una relación estadística entre la biomasa aérea y la respuesta espectral en el visible e infrarrojo. La estimación de biomasa a partir de reflectancias en superficie puede ser extrapolado a la estimación de biomasa a partir de imágenes aéreas.
- Es posible calibrar radiométricamente imágenes de cámara aérea digital

fotogramétrica a partir de blancos de calibración móviles flexibles, móviles rígidos y zonas de referencia (no móviles).

- Las ecuaciones de calibración radiométrica de una imagen pueden emplearse en otras imágenes de la misma pasada, obteniéndose una exactitud en los resultados similar a la alcanzada con sus propias ecuaciones de calibración.
- La exactitud de la calibración radiométrica de una imagen depende del conjunto de blancos de calibración empleados.
- Existe relación entre la cantidad de biomasa aérea en herbáceas y la respuesta espectral de las cubiertas vegetales en diferentes regiones del espectro electromagnético.

1.7. Objetivos

Sobre la base de las hipótesis, se establecieron los siguientes objetivos de la tesis:

El objetivo principal del trabajo fue desarrollar y validar una metodología no destructiva en la estimación de biomasa aérea (peso seco de la fracción verde) en herbáceas a partir de imágenes multiespectrales procedentes de cámara aérea digital.

Este objetivo global se desglosó en los siguientes objetivos específicos:

1. Desarrollar y comparar diferentes métodos para la estimación de la cantidad de biomasa aérea a partir de Espectro-radiometría de campo.
2. Desarrollar un método para la calibración radiométrica absoluta de imágenes multiespectrales de la cámara aérea digital fotogramétrica de gran formato Ultracam-Xp WP.
3. Desarrollar y comparar diferentes métodos para la estimación de la cantidad de biomasa aérea a partir de imágenes multiespectrales calibradas de Ultracam-Xp WP.
4. Validar las metodologías desarrolladas para la estimación de biomasa así como para la calibración radiométrica de imágenes de Ultracam-Xp WP.

1.8. Estructura de la tesis

La estructura de la tesis consta de básicamente de cuatro partes.

En la primera parte (Capítulo 1, 2 y 3) se contextualizó y justificó el interés del estudio, aportando sus antecedentes y definiendo el objetivo del trabajo en el presente capítulo. A continuación, en los capítulos 2 y 3 se presenta una revisión bibliográfica de los trabajos realizados con anterioridad y relacionados con la presente tesis doctoral así como la localización del área de estudio.

En la segunda parte (Capítulo 4) se comparan, desarrollan y validan diferentes modelos estadísticos y transformaciones espectrales con el fin de estimar la cantidad de biomasa aérea a partir de datos espectrales obtenidos mediante Espectro-radiometría de campo. Se estimaron tres variables de medición de biomasa aérea: peso total (PT), peso de la fracción verde (PV) y porcentaje de peso de la fracción verde (%PV).

En la tercera parte (Capítulo 5) se determina la idoneidad de la calibración empírica de línea como un procedimiento adecuado a la hora de realizar una calibración radiométrica absoluta de las imágenes de la cámara aérea Ultracam-Xp WA. Con este fin se comprobó cómo afecta a la calibración radiométrica el conjunto de blancos empleado como referencia y si la calibración radiométrica de una imagen es aplicable a las demás imágenes de una misma pasada.

Por último en la cuarta parte (Capítulo 6) se desarrolla el procedimiento de estimación de biomasa aérea de herbáceas con imágenes multiespectrales corregidas radiométricamente. Se realiza una comparación entre la estimación a partir de los índices de vegetación y regresión por mínimos cuadrados (OLS, *Ordinary Least Squares*) y el uso de las bandas de reflectancia (R, G, B, NIR) y regresión por mínimos cuadrados parciales (PLS, *Partial Least Squares*).

A continuación se muestra en la Figura 1.1 un esquema de la estructura de la tesis.

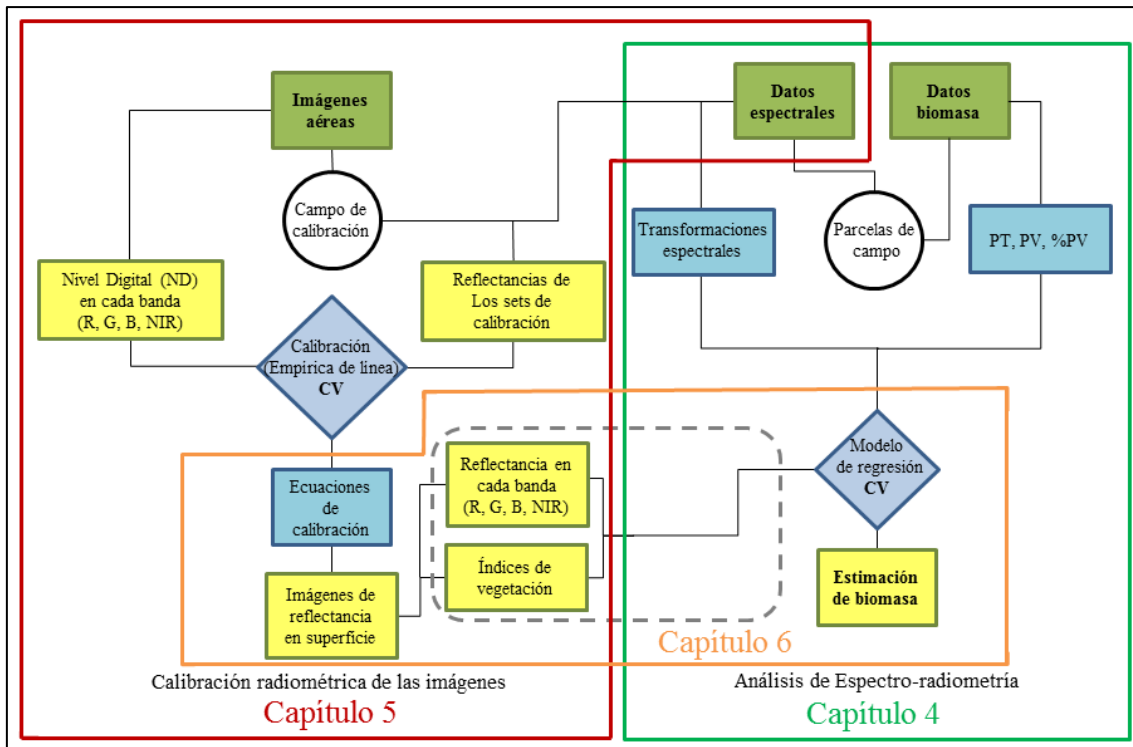


Figura 1.1. Esquema de la estructura de la Tesis. Los polígonos de color verde representan la entrada de datos, los círculos representan las zonas donde se realizaron mediciones. Los rectángulos azules representan resultados intermedios, los rombos azules modelos de regresión y los rectángulos amarillos representan los resultados finales. La línea discontinua representa un estudio comparativo. CV: Calibración y Validación.

CAPÍTULO 2

2 ESTADO DEL ARTE

2.1. La teledetección y el seguimiento de la vegetación

La detección remota y los sensores, tiene su origen en 1859 cuando Gaspard-Félix Tournachon tomó la primera fotografía aérea desde un globo aerostático. En los años siguientes, existe un gran desarrollo de la observación fotográfica desde el avión gracias al progreso en ópticas y emulsiones teniendo lugar en 1909 la primera fotografía aérea realizada por Wilbur Wriyth. La primera cámara aérea propiamente dicha, se desarrolla en 1915 durante la Primera Guerra Mundial en 1915 por J.T.C. Moore-Brabazon. Durante la Segunda Guerra Mundial, se desarrollan las primeras películas en infrarrojo por Kodak Research Laboratories (Chuvieco, 1996; 2000; 2002). Posteriormente las primeras imágenes aéreas para la estimación de diferentes propiedades de la vegetación

datan de 1956 (Keegan et al., 1956) cuando se usaron películas infrarrojas en fotografía aérea para la detección de la “roya” del trigo.

En 1966 el Laboratorio de Teledetección Agrícola (Laboratory for Agricultural Remote Sensing) en Purdue University, Michigan, EEUU se utilizaron los primeros sensores multiespectrales aerotransportados con fines agrícolas. Las primeras aplicaciones, de este tipo de sensores eran la identificación de cultivos (Hofjer, 1967) así como la detección de enfermedades como por ejemplo el tizón del maíz (Bauer et al., 1971). En esta época ya se usaban sensores aerotransportados que contaban un número considerable de bandas (12 en algunos casos) en el rango espectral del ultravioleta al infrarrojo térmico.

En 1972 se lanzó el primer satélite de la serie ERTS (Earth Resources Technology Satellite) que posteriormente pasó a llamarse Landsat 1. Inicialmente era un satélite experimental con el que la NASA quería demostrar la operatividad de aplicaciones como la monitorización agrícola y medioambiental. El satélite incorporaba un sensor llamado MSS (MultiSpectral Scanner), que contaba con 4 bandas en el rango espectral del visible al infrarrojo cercano y una en el térmico, pensadas específicamente para la detección de propiedades de la vegetación.

A partir de los primeros resultados obtenidos de las imágenes de Landsat 1 se definieron una serie de requisitos de bandas, resolución espacial, tiempo de revisita, etc., pensando fundamentalmente en aplicaciones agrícolas y de monitorización ambiental. El resultado fue la creación del sensor TM (Thematic Mapper), instalado a bordo de Landsat-4 y Landsat-5.

Durante los años 70 y 80 se desarrollaron los programas LACIE (Large Area Crop Inventory Experiment) y posteriormente AgRISTARS (Agriculture and Resources Inventory Surveys Through Aerospace Remote Sensing) como un esfuerzo común entre distintos departamentos del gobierno estadounidense por desarrollar metodologías de teledetección que permitiesen identificar cultivos, así como determinar su estado o potencial producción a nivel regional a partir de datos provenientes de Landsat y otros sensores aerotransportados (Bauer, 1985). Estos programas permitieron definir las leyes físicas, tras las relaciones entre las medidas espectrales y las propiedades biofísicas de la vegetación y el suelo.

Durante estos años hasta la entrada del siglo XXI, se ha avanzado mucho en aspectos científicos en la teledetección, varios son los ejemplos de aplicaciones publicadas en diferentes campos como la clasificación de cultivos (Erol y Akdeniz,

1996; Grignetti et al., 1997; PaxLenney y Woodcock, 1997), o su estado (Boissard et al., 1993; Potdar, 1993; Blackmer et al., 1994; Clevers et al., 1994), las predicciones de cosecha y rendimiento (Tucker et al., 1980; Rasmussen, 1992; Moran et al., 1995; Clevers, 1997;), detección de malas hierbas (Peña et al., 2014), detección de enfermedades y deficiencias nutricionales (Malthus y Madeira, 1993; Adams et al., 1999; 2000) o estimación de pigmentos fotosintéticos (Zarco-Tejada et al., 2005; Martin et al., 2007).

Los sensores aerotransportados hiperespectrales y multiespectrales pueden proporcionar resoluciones espaciales de 0,5 a 2 m y anchos de banda a partir de 2 nm en la región del espectro comprendida entre 300 y 2,500 nm. Existen numerosos trabajos que demuestran el uso de sensores como el CASI (Compact Airborne Spectrographic Imager) o el AVIRIS (Airborne Visible Infrared Imaging Spectrometer) para la estimación de parámetros de vegetación como contenido clorofílico (Roberts et al., 1997; Ustin et al., 1998; Serrano et al., 2000; Zarco-Tejada et al., 2004; Cheng et al., 2006; Goodenough et al., 2006; Hadi, 2015), contenido de materia seca (Jacquemoud et al., 1996; Fourty y Baret, 1997; Riaño et al., 2005), y estimación de parámetros estructurales como fracción cubierta e índice de área foliar (LAI) (Haboudane et al., 2004). De igual modo existen trabajos publicados que hacen uso de sensores aerotransportados con bandas en el térmico como el AHS (Airborne Hyperspectral Scanner) y que han demostrado su utilidad en la detección de estrés hídrico en cultivos leñosos (Sepulcre-Cantó et al., 2005; 2006; 2007). Sin embargo, la aplicación de estos sensores sigue siendo casi exclusiva con fines científicos, sin producirse una transferencia de las metodologías desarrolladas a aplicaciones reales en el manejo de cultivos.

Actualmente las imágenes aéreas se utilizan cada vez más de manera automática y cuantitativa en estudios del uso del suelo y de la clasificación de la cubierta de la tierra (Le Bris y Boldo, 2008; Waser et al., 2010; Laliberte et al., 2012), para la clasificación de las especies de árboles (Waser et al., 2010; Heikkinen et al., 2011; Korpela et al., 2011), y para la vigilancia del medio ambiente, como la cartografía de hábitats bentónicos (Green et al., 2011), para la vigilancia de la salud de los bosques (Wulder et al., 2012), y en cálculos del índices de vegetación (Martínez et al., 2012). La llegada de los vehículos aéreos no tripulados (UAVs, Unmanned Aerial Vehicle Systems), permite su uso como plataforma para transportar diferentes tipos de cámaras digitales para la toma de imágenes aéreas, si bien aunque supone una escala de trabajo diferente a la de

las cámaras de gran formato. La comunidad científica pronto adoptó esta tecnología y la NASA fue pionera, en el uso de UAVs solares en campos de café en Hawái (Herwitz et al., 2003; 2004) o el RCATS/APV-3 sobre viñedos en California (Johnson et al., 2003). Yuste Martín et al. (2013), nos muestra la evolución en la microelectrónica y la miniaturización de elementos como los receptores GPS o sensores inerciales y como ambos son necesarios para el desarrollo de sistemas de navegación autónoma (autopilotos). Por otra parte, este tipo de vehículos ha provocado que se desarrollen autopilotos comerciales de bajo peso que puedan ser integrados en vehículos aéreos cada vez más pequeños y sencillos de operar. Paralelamente también se produce un gran avance en el desarrollo de nuevos sensores de imágenes de alta resolución, promovido especialmente por la electrónica de consumo. Como consecuencia, varios autores han publicado trabajos en los que usando este tipo de cámaras en pequeños aviones o helicópteros similares a los usados en radio control, han demostrado su viabilidad como plataformas para la adquisición de imágenes (Ambrosia et al., 2003; Sugiura et al., 2005; Zhao et al., 2006; Esposito, 2007; Haitao y Lei, 2007; Lambers et al., 2007;) así como trabajos más recientes como Díaz García-Cervigon, (2015), donde se hace un estudio de los índices de vegetación a partir de imágenes aéreas tomadas desde UAVS así como su aplicación en agricultura de precisión o trabajos como Peña et al. (2014), en el cual fueron capaces de detectar malas hierbas en girasol en fase temprana mediante imágenes tomada a partir de UAVS o la estimación de biomasa aérea en zonas de pasto (Wang et al., 2014) o campos de arroz (Swain, et al., 2010)

Sin embargo Montesinos (2015), destaca las carencias que tienen los UAS/RPAS respecto a otras plataformas aéreas (satélites o aviones tripulados), principalmente haciendo referencia a la menor utilidad de los drones en la adquisición de datos en grandes superficies de plantaciones (olivares, viñedos) debido a que para estas superficies, es más útil adquirir las imágenes aéreas procedentes de los satélites o aviones tripulados, ya que en una sola imagen se abarca una superficie más extensa. Otra de las desventajas es la (en general) menor resolución espectral de las cámaras con las que están trabajando los drones respecto a las utilizadas en los satélites o aviones tripulados.

2.2. Sensores aerotransportados

En los últimos años se ha producido un gran avance en el desarrollo de los sensores multiespectrales e hiperespectrales a bordo de aviones y como consecuencia, varios autores han publicado trabajos en los que usando este tipo de cámaras en pequeños aviones o helicópteros, han demostrado su viabilidad como plataformas para la adquisición de imágenes (Fricker, 2002; Fernández-Núñez et al., 2009; Molina-Simbaña, 2016)

Los sensores pueden definirse como instrumentos que reúnen la tecnología necesaria para capturar almacenar la señal electromagnética (radiación reflejada o emitida) recibida de la Tierra y la atmósfera, en un determinado intervalo de longitud de onda, y convertirla en una magnitud física que pueda ser tratada y grabada (señal analógica o digital) y transmitir dicha señal a un sistema receptor. Puede capturar información en diferentes regiones del espectro y cada una de estas regiones se denomina canal o banda. Los sensores son transportados en plataformas fijas o móviles, ya sean mástiles, grúas, globos, cohetes, satélites, aeronaves de ala fija o ala giratoria. Las características de la imagen registrada dependen en gran medida de las propiedades del sensor utilizado y de la distancia al suelo desde la cual se realiza la adquisición de datos (Chuvienco, 1996; Jensen, 2000; Sobrino, 2000). Existe diversidad de sistemas de clasificación de sensores remotos. En general, se puede realizar la siguiente clasificación según (Bautista et al., 2004) dependiendo de los siguientes factores:

Según la banda del espectro electromagnético utilizada, los sensores se dividen en ultravioleta, visible, infrarrojo, microondas, de frecuencia ultra alta (UHF), sensores de frecuencias muy altas (VHF).

Según la fuente emisora de energía se diferencian si pertenece al sistema de percepción remota o si es independiente, clasificando los sensores en pasivos (los que registran la energía emitida por otra fuente, generalmente el sol, y reflejada por los objetos) y activos (generan su propia radiación y la reciben rebotada del objeto, actualmente son basados en la tecnología láser, como son el radar y el lidar. El radar (Radio Detection And Ranging) trabaja en una banda entre 1mm y 1m. Puede operar independientemente de las condiciones atmosféricas, y su funcionamiento se basa en captar la dispersión de microondas artificiales enviadas en una dirección, tras su choque contra los objetos. La energía dispersada se recibe, se amplifica y se

analiza para determinar la localización, la distancia y las propiedades de los objetos generando así modelos digitales de elevaciones. El lidar (Light Detection And Ranging) está formado por un láser que emite pulsos de luz polarizada el cual interacciona con las partículas atmosféricas o el suelo, causando su dispersión en función del elemento que se encuentre. La energía de retorno es recogida y transmitida a través de un filtro óptico, a una foto-detector donde posteriormente es grabado en un ordenador. En función del tiempo y la intensidad de la señal de retorno puede obtenerse información del tipo de cubierta presente en la zona. Tiene mayor detalle que el radar, pero no puede penetrar a través de la nubes densas (Chuvieco, 1996).

Según la ubicación espacial de la fuente emisora y receptora de energía se distingue los sensores monestáticos cuando la fuente de emisión y recepción de energía ocupan la misma posición en el espacio (como el radar) y los biestáticos, cuando la fuente de emisión tiene una posición diferente a la del receptor (fotografía aérea).

Según la Información registrada, se clasifican en sensores fotográficos (cuando la información es registrada en una emulsión fotográfica al momento de ser recibida) y sensores no fotográficos (la información que recibe es proyectada sobre una pantalla o es registrada en forma gráfica o digital). Estos últimos, a su vez, pueden ser subdivididos en radiométricos (registran la intensidad de una determinada longitud de onda del espectro), y espectrómetros (cuando registran la intensidad de una banda del espectro).

Según los mecanismos utilizados para captar la información se dividen en:

- Fotográficos: corresponde a los sensores que operan con cámaras y películas.
- De microondas: pueden ser activos o pasivos. Los activos formadores de imagen, son los radares de visión lateral (SLAR) que pueden ser de antena real o de antena sintética (SAR). Los no formadores de imagen, se clasifican en dispersómetros y radiómetros de microondas los cuales son pasivos.
- Electro-ópticos formadores de imagen. Pueden ser de tres tipos: de formato, barredores no oscilantes y barredores mecánicos. Los de formato no necesitan hacer un barrido, para formar la imagen (como los sistemas de TV). Los no oscilantes barren en una sola dirección, mientras que los mecánicos incluyen una gran variedad de sistemas de barrido. En este grupo, podemos meter los radiómetros de barrido y de empuje. Los de barrido disponen de un espejo móvil, que oscila perpendicularmente a la dirección de la trayectoria permitiendo explorar una franja de terreno a ambos lados de esta. Los de empuje eliminan el espejo oscilante al disponer de una cadena con un gran número de

detectores de manera que se cubre todo el campo visual del sensor permitiendo aumentar la resolución espacial y reducir los errores geométricos aunque es necesaria una compleja calibración de los sensores al mismo tiempo para que trabajen de forma homogénea.

- Electro-ópticos no formadores de imagen: no forman imagen a partir de la información captada, sino que produce curvas, grupos de números o números simples que caracterizan la energía electromagnética emitida desde, reflejada por, y/o transmitida a través de una superficie o región del espacio.

En este último grupo electro-óptico, la radiancia recibida se descompone en varias longitudes de onda, enviando cada una de ellas a un conjunto de detectores sensibles a esa región del espectro. Estas longitudes se amplifican y se convierten en señal eléctrica la cual se transforma finalmente, en un valor numérico conocido como Nivel Digital (ND). Estos valores numéricos pueden convertirse, otra vez a valores de radiancia conociendo los coeficientes de calibrado. En los sistemas de sensores de teledetección es importante destacar que la radiación reflejada por la superficie terrestre es un fenómeno continuo en 4 dimensiones (espacio, tiempo, longitud de onda y radiancia). El sensor debe ser capaz, de muestrear esa radiación discretizándola en cada una de esas dimensiones. Se denomina resolución de un sistema sensor a su capacidad para discriminar información de detalle (Chuvienco, 1993) y el modo en que se discretiza la radiación define los cuatro tipos de resolución con los que se trabaja en teledetección, resolución espacial, resolución temporal, resolución espectral y resolución radiométrica.

Resolución espacial: se refiere al tamaño del objeto más pequeño que puede ser distinguido en una imagen producida por un sensor remoto (Pinilla, 1995). Para determinar la resolución espacial, de una plataforma de teledetección, es necesario conocer el Campo de Visión Instantáneo (IFOV, Instantaneous Field Of View). El IFOV es el ángulo sólido de visibilidad entre el sensor y el área de superficie terrestre que es posible detectar con el sensor (Román y Vargas, 2013). Si las imágenes remotas van a ser usadas para identificar y tratar problemas de cultivo en el campo, el productor debe considerar cómo de detallada espacialmente debe ser una imagen para que permita discernir elementos. Hengl (2006), determinó que son necesarios al menos 4 píxeles para detectar el objeto más pequeño.

Resolución temporal: Define la frecuencia con que un sensor puede obtener imágenes de una misma zona de superficie terrestre (Otero, 1999; Chuvienco, 2002). Por otro lado Roman y Vargas (2013) la definen como el tiempo que tarda un sensor en

pasar sobre el mismo punto en un sistema de teledetección y depende de diferentes factores, incluyendo el punto de vista de las capacidades de los sensores, la superposición, y la latitud. La resolución temporal en la aplicación de imágenes es determinante cuando el área de interés está constantemente cubierta por las nubes, cuando es necesario la toma de imágenes para fenómenos ya sean naturales o artificiales cortos y cuando es necesaria una comparación multitemporal.

Resolución espectral: Determinada por la anchura y número de intervalos de longitud de onda específica del espectro electro-magnético, que pueden ser detectados por un sensor (Pinilla, 1995; Chuvieco, 2002). Teniendo en cuenta el número de bandas espectrales que el sensor puede detectar, pueden encontrarse 4 bandas (habitual en cámaras aéreas fotogramétricas digitales de gran formato, con bandas R, G, B, NIR), pero hay sensores que producen imágenes multispectrales con más de 10 bandas. También existen sensores para imágenes hiperespectrales, que tienen más de 100 bandas espectrales (Román y Vargas, 2013).

Resolución radiométrica: Indica la sensibilidad del sensor, es decir la capacidad de discriminar entre pequeñas variaciones en la radiación que capta (Pinilla, 1995). Suele expresarse mediante el número de bits necesarios que se precisan para almacenar cada pixel. Por ejemplo el sensor CCD Matricial de la cámara Ultracam-Xp WA usada en este trabajo utiliza 12 bits, que codifica 4096 niveles de gris o niveles de energía (Niveles Digitales, ND). Por lo tanto la resolución radiométrica se refiere al número de niveles digitales empleados para expresar los datos recogidos por el sensor y generalmente cuanto mayor es el número de niveles, mayor es el detalle de la información obteniendo por consiguiente una mejor interpretación de la imagen. Sin embargo debemos tener en cuenta la relación existente entre la señal y el ruido a la hora de aumentar la resolución de un sistema. El tamaño de paso de un nivel al siguiente no puede ser menor que el nivel de ruido o de lo contrario no se podría saber si un cambio en el nivel ha sido debido a un cambio real en la radiancia del objeto o a un cambio en la magnitud del ruido. Existen estudios en la efectividad, al aumentar la resolución radiométrica en diferentes sensores. Turcker (1980), investigó sobre la relación entre resolución radiométrica y la diferenciación de distintos tipos de vegetación, concluyendo una mejoría del 2% o 3% al usar una imagen con 256 niveles frente a otra de 64. Dada la cantidad de datos que puede tener una imagen multispectral es importante el estudio detallado de la necesidad de aumentar la resolución radiométrica de cualquier sensor (Hernández, 2002).

2.3. Las cámaras fotogramétricas digitales aéreas

En el Congreso Internacional de Fotogrametría y Teledetección (ISPRS *Congress*) de julio del año 2000, se presentaron los dos primeros modelos de cámaras digitales fotogramétricas aerotransportadas. En particular, la cámara Leica ADS40 (Sandau *et al.*, 2000) y la cámara matricial Z/I DMC (Hinz *et al.*, 2000). Con la aparición de estos modelos a los que pronto se añadieron otras cámaras como la Vexcel Ultracam fabricada por Microsoft-Vexcel. Se planteaba un nuevo esquema de producción fotogramétrica dentro de un flujo de trabajo completamente digital sustituyendo las cámaras convencionales de película y la posterior digitalización de los fotogramas, por la captura directa en formato digital con las ventajas en cuanto a calidad geométrica y radiométrica de las imágenes. En menos de una década el empleo de las cámaras analógicas comenzó a ser testimonial, provocando un auge de las ventas a nivel mundial en el mercado de las cámaras digitales.

La imposibilidad de disponer de sensores con una resolución equivalente a la proporcionada por la digitalización de los fotogramas de las cámaras de película, ha dado lugar a dos soluciones diferentes: los sensores de matriz lineal, como la cámara de Leica ADS40/80, y las cámaras matriciales.

En las cámaras matriciales o de área, el sensor de la cámara cubre un área o que está formado por una matriz de píxeles. Tienen varios objetivos que disparan simultáneamente, unos en pancromático y otros en multiespectral (visible e infrarrojo). Cuentan con diferentes planos focales y funden las imágenes en una única. Estas cámaras pueden constar en la actualidad de $nK \times nK$ elementos sensoriales (píxeles), siendo K 1024 elementos y no puede oscilar de 1 a 9 (Santos, 2006). En este grupo, actualmente coexisten varios modelos diferentes unos de primera generación, (UltraCam-D, UltraCam-X, UltraCam-Xp, Ultracam-Xp WA, UltraCam-L, UltraCam-Lp) y otros modelos de segunda generación, (UltraCam Ospre, UltraCam Eagle, UltraCam Falcon y la UltraCam Hawk).

La resolución radiométrica y la espectral de las cámaras fotogramétricas digitales actuales, las cuales llegan a 12 bits y cuatro bandas (R, G, B, NIR) respectivamente, las hace aptas para otro tipo de aplicaciones más avanzadas y hasta no hace mucho tiempo, reservadas exclusivamente a las imágenes satelitales, como puede ser el cálculo de índices de vegetación, la clasificación de usos del suelo, el seguimientos de cultivos (Erol y Akdeniz, 1996; Grignetti *et al.*, 1997; PaxLenney y

Woodcock, 1997), la evaluación del riesgo de desastres naturales (NAIP, 2013), las predicciones de cosecha y rendimiento (Tucker *et al.*, 1980; Rasmussen, 1992; Moran *et al.*, 1995; Clevers, 1997; Darvishzadeh *et al.*, 2014), el estado de los cultivos (Boissard *et al.*, 1993; Blackmer *et al.*, 1994; Clevers *et al.*, 1994), la discriminación de malas hierbas (Anderson *et al.*, 1993; Potdar, 1993; Everitt, 1995; Underwood *et al.*, 2003; Peña *et al.*, 2014), la detección de enfermedades y deficiencias nutricionales en vegetación (Adams *et al.*, 1999; 2000; Malthus y Madeira, 1993) o la estimación de contenido de pigmentos fotosintéticos (Zarco Tejada *et al.*, 2005; Martin *et al.*, 2007; Hadi, 2015). Por otra parte existe un gran interés en estimar la cantidad de biomasa aérea por su relación directa de carbono y su función como sumidero por lo que su análisis en el protocolo de Kioto y las sucesivas Cumbres de Naciones Unidas son un tema de actualidad (e.g. Vila *et al.*, 2007; Álvarez *et al.*, 2010b; Ferdinant y Padmanaban, 2013; Ota *et al.*, 2015).

La realización de trabajos como los descritos anteriormente empleando información radiométrica de las imágenes de cámara aérea de gran formato ha disparado la necesidad de conocimientos sobre los aspectos radiométricos de estas imágenes. Prueba de ello son varios proyectos internacionales como en el EuroSDR (*European Spatial Data Research Network*) con trabajos radiométricos de fotogrametría digital de imágenes (Honkavaara *et al.*, 2009a; 2013), el proyecto del EuroDAC2 (*Certification of Digital Airborne Mapping*) donde la radiometría es una parte de la calibración de las cámaras (Cramer, 2008; EuroDAC2, 2011), o el Plan Geológico de Estados Unidos (USGS, *United States Geological Survey*), para la caracterización de cámaras digitales. En esta línea, otro grupo internacional que trabajan en la calibración y validación de la geometría y radiometría de los sensores y sistemas aerotransportados, es el grupo de calibración y validación del CEOS/ISPRS,

2.4. La Espectro-radiometría de campo

La ciencia que se encarga de la medición de la radiación electromagnética que llega a un sensor, se denomina radiometría (Schott, 2007). La radiometría de campo o también llamada Espectro-radiometría de campo se define como la ciencia encargada de la medida de la reflectividad espectral de cualquier superficie en un medio natural, llevando implícito el estudio de las interrelaciones entre las características espectrales de la misma y sus atributos biológicos (Milton, 1987). La Espectro-radiometría es una herramienta clave en la teledetección de recursos terrestres teniendo un importante auge

y diversificación en los últimos años permitiendo analizar grandes áreas, en tiempo real y sin restricción de accesibilidad.

La Espectro-radiometría de campo juega un papel muy importante en, al menos, dos apartados de la teledetección: por un lado actúa como puente entre las medidas de laboratorio de la reflectividad espectral y la situación real del campo, siendo, además, muy útil en el calibrado de sensores a bordo de aviones y de satélites (Holm *et al.*, 1989). Por otro lado, es de utilidad a la hora de identificar qué bandas espectrales pueden resultar relevantes en un trabajo de teledetección, para de este modo mejorar su planificación y la configuración del sensor a emplear (Danson *et al.*, 1990).

No todas las técnicas de teledetección generan imágenes del objeto observado, y así por ejemplo, mediante Espectro-radiometría de campo la energía radiada por un objeto es almacenada como un dato espacialmente adimensional (Peña, 2010). Si se tiene en cuenta la luz reflejada, la propiedad fundamental de estudio es la reflectancia espectral, definiéndose como el porcentaje de la energía reflejada sobre la energía incidente. Esta reflectancia varía con la longitud de onda en los materiales y se expresa generalmente como una fracción entre 0 y 1, o como un porcentaje entre 0 y 100 (Chuvienco, 2008; Markelin, 2013). Cuando se realizan las medidas espectrales de un material en el campo o en el laboratorio, se requieren también los valores de la energía incidente para calcular la reflectancia del material. Estos valores son medidos directamente, o se obtienen de medidas de luz reflejada (bajo las mismas condiciones de iluminación que el material en el cual deseemos obtener las medidas espectrales) usando un material de referencia estándar con una reflectancia espectral conocida (González-Calvo, 2012). El instrumento usado para medir las propiedades de la luz sobre una porción específica del espectro-electromagnético se denomina espectro-radiómetro (Jensen, 2009).

En la zona del visible del espectro electromagnético, este comportamiento diferencial según la longitud de onda, se manifiesta en lo que llamamos color, así un objeto es de un color u otro dependiendo de la intensidad con que esa energía sea reflejada en una banda respecto de las otras. Estas variaciones en la reflectancia se denominan firmas espectrales aunque también se les denomina *signatura espectral*, *espectros*, *firma de reflectividad*, *curva de reflectancia* a los gráficos formados de la relación que existe entre el cociente de la cantidad de energía radiante incidente con la energía reflejada (López-Espinoza, 2014).

En los sistemas vegetales, la firma espectral de una planta (o cultivo) está

directamente relacionada con sus características fenológicas, fisiológicas y morfológicas, por lo que cualquier cambio en la planta también perturbará su reflectancia (Lass y Callihan, 1997; Schmidt y Skidmore, 2003). Estas características determinarán la calidad espectral y la cantidad de energía que será reflejada, absorbida o transmitida. Estas diferencias de comportamiento espectral intrínseco de cada especie y/o planta individual son las que permiten tanto su discriminación mediante técnicas de análisis y clasificación, así como la estimación variables biofísicas (cualitativas y cuantitativas). Son varios los estudios relacionados con los datos de alta resolución espectral en la región principalmente entre 350 y 2500 nm debido a la presencia de características de absorción en las curvas de reflectancia (Goetz et al., 1985; De Jong, 1994^a; Danson y Plummer, 1995; Smith y Curran, 1996; Kokaly y Clark, 1999).

La vegetación presenta un comportamiento muy diferenciado según la zona espectral de estudio. Al analizar una signature espectral típica de una hoja se observa una baja reflectancia en la zona del visible, debida al efecto absorbente de los pigmentos de la hoja (clorofilas, xantofilas y caroteno). Aproximadamente sobre los 550 nm existe una menor absorción por eso aparece un pico coincidente con la banda verde del espectro visible. La elevada reflectancia en el infrarrojo cercano se debe a la baja absorción de las clorofilas y a la estructura celular interna de la hoja. A partir de 1400 nm el efecto absorbente del agua es muy claro, por lo que la reflectancia de la vegetación sana se reduce drásticamente a partir de 1300 nm (Chuvieco, 2002) (Figura 2.2).

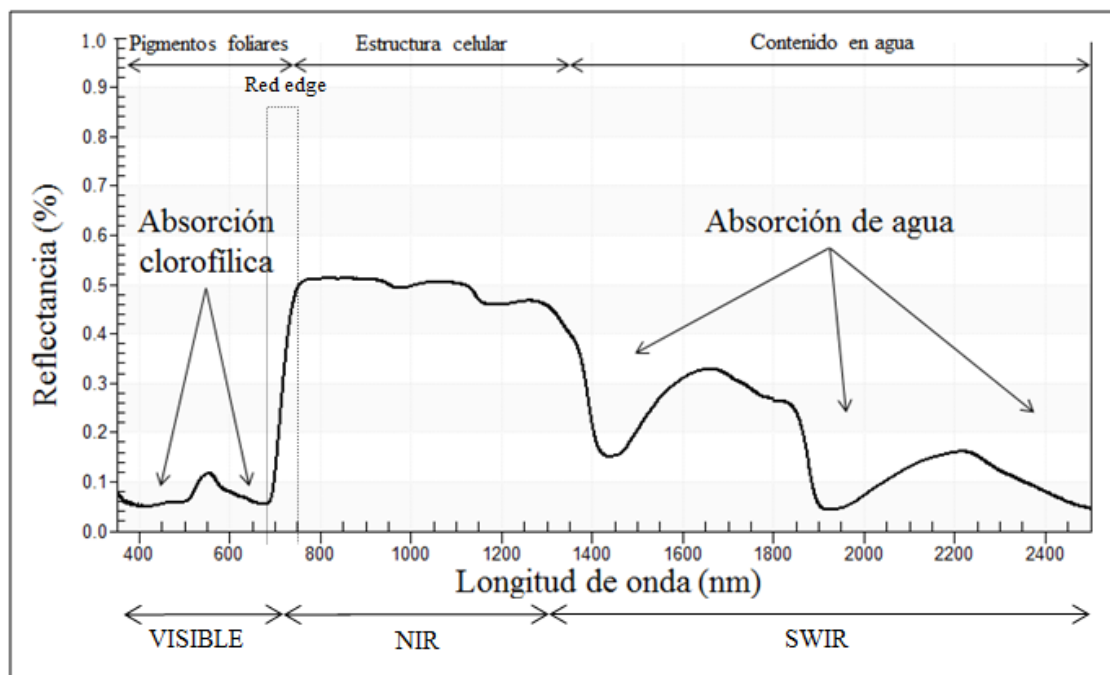


Figura 2.2. Signatura espectral típica de una hoja (Datos adquiridos con un espectro-radiómetro ASD) (elaboración propia)

De acuerdo con Clevers *et al.* (2002), en la franja de transición entre el rango visible (rojo) y el rango del infrarrojo cercano de las firmas espectrales de vegetación, conocida con el nombre de región *red edge*, es donde se presentan las características de absorción más importantes de las curvas de reflectancia de la vegetación, debido al contraste entre el rango rojo y el infrarrojo cercano. La espectroscopia de infrarrojo cercano recoge la información de las estructuras químicas, a través de la valoración de los enlaces moleculares reflejados en el espectro obtenido (e.g. C-H, N-H and O-H, que son los principales componentes estructurales de las moléculas orgánicas (Lucio Gutiérrez, 2012).

Para poder caracterizar una determinada cubierta nos resulta por tanto de interés conocer su comportamiento reflectivo en diversas longitudes de onda, ya que esto facilitará discriminarlo frente a cubiertas espectralmente similares así como conocer diferentes características a partir de su firma espectral. Por tanto a parte de estas zonas de la signatura espectral típica de una hoja, existen diferentes zonas de estudio de absorción donde se han encontrado correlaciones con diferentes variables biofísicas como la celulosa entorno a los 1215 nm o 2359 (Curran, 1989), o la lignina entorno a los 1660 nm (Thenkabail *et al.*, 2014) las cuales están relacionadas directamente con la biomasa aérea.

2.5. Estimación de biomasa a partir de percepción remota

La biomasa es una de las principales variables biofísicas de interés en los estudios de vegetación (cultivados y naturales). La biomasa se puede definir en términos de peso de materia fresca o como peso de la materia seca. La estimación de la biomasa y por tanto la concentración y evolución de CO₂ ante el calentamiento global se consideran, vitales para predecir respuestas al cambio climático (Pardos, 2010). El protocolo de Kioto requiere la evaluación de la productividad de las zonas forestales para determinar los *stocks* de carbono, por tanto se están investigando métodos no destructivos de estimación de capacidad de secuestro de carbono/biomasa. El empleo de técnicas no destructivas como la teledetección ha sido de uso habitual durante los últimos años con diferentes grados de éxito en estudios de vegetación, minerales y propiedades del suelo. Una alta correlación entre datos de biomasa medida en campo y

datos obtenidos mediante teledetección permitiría estimar la biomasa en el ámbito regional (Anaya *et al.*, 2008). Estos estudios están relacionados con los datos de alta resolución espectral en la región de 400-2500 nm debido a la presencia de características de absorción de diagnóstico en las curvas de reflectancia (Kokaly y Clark, 1999). La aplicación de técnicas estadísticas y de transformaciones adecuadas para tratar con datos hiperspectrales se plantea como una oportunidad para mejorar los resultados (Atzberger *et al.*, 2010).

En zonas agrícolas y de pastizal la estimación de capacidad de secuestro de carbono/biomasa es un indicador importante para reflejar el estado de crecimiento del cultivo así como conocer mejor el estado de las cosechas con el fin de lograr un óptimo crecimiento, establecer medidas encaminadas a mejorar la gestión de dichas zonas (Fu *et al.*, 2014) y realizar predicciones de rendimiento (Clevers *et al.*, 2007).

Los pastizales son los tipos de ecosistemas más extendidos y la estimación precisa de la biomasa aérea es cada vez más necesaria para reducir la incertidumbre de este sumidero de carbono terrestre (Scurlock y Hall, 1998; Scurlock *et al.*, 2002), especialmente en las zonas áridas y semiáridas (Eisfelder *et al.*, 2012; Ren y Zhou 2014). Esta variable ecológica también influye en procesos ambientales importantes, como la erosión del suelo, tasas de descomposición, la degradación ambiental, la desertificación (Verstraete, 1986; Eswaran *et al.*, 2001; Hirata *et al.*, 2001; Moleele *et al.*, 2001; Mulligan, 2009), así como su productividad primaria neta anual la cual representa la energía disponible para otros niveles tróficos influyendo la productividad secundaria neta (Pucheta *et al.*, 2004) Por lo tanto, existe una gran necesidad para el establecimiento de métodos robustos y transferibles en la estimación de la biomasa aérea. Tradicionalmente, las estimaciones de la biomasa se basan en un muestreo destructivo (Corrall y Fenlon, 1978), que consume mucho tiempo, y con frecuencia no aplicable a grandes áreas (Boschetti *et al.*, 2007). Para zonas forestales arboladas se han desarrollado ecuaciones alométricas que permiten estimar biomasa en sus diferentes fracciones y carbono a partir de parámetros de muy sencilla medición en campo como el diámetro normal (Barrio *et al.*, 2006), sin embargo no existen ecuaciones de este tipo para matorral ni pastizales. Las características de este tipo de vegetación dificultan la construcción de estos modelos, y sugieren el empleo de técnicas de percepción remota para su estimación. Las técnicas de teledetección permiten asimismo analizar la distribución espacial y temporal del atributo analizado, proporcionando un método rentable en las estimaciones cuantitativas de la biomasa vegetal, tanto a escala local

como regional (Schino *et al.*, 2003; Liu *et al.*, 2004; Elsfelder *et al.*, 2012; Julius, 2013; Darvishzadeh *et al.*, 2014).

Las características de las plantas se han estimado desde los orígenes de la teledetección empleando diversas técnicas (Wiegand *et al.*, 1979; Price y Bausch, 1995). Estas técnicas tienen la ventaja de proporcionar información sobre las plantas casi instantáneamente y de un modo no destructivo (Clevers, 2007; Darvishzadeh *et al.*, 2014; Kokaly y Skidmore, 2015).

Los índices de vegetación calculados a partir del (NIR) bandas de color rojo y el infrarrojo cercano, son buenos indicadores de la actividad fotosintética en la vegetación (Myneni y Los, 1995; Myneni *et al.*, 1995; Liu *et al.*, 2013.; Marino y Alvino, 2014) y se correlacionan bien con la biomasa aérea en pastizales (Schino *et al.*, 2003; Ren *et al.*, 2011). El ratio de la reflectancia en la banda del infrarrojo (NIR, SWIR, MIR) y la reflectancia en el rojo ha demostrado ser adecuado para la estimación de biomasa, además de normalizar en parte el efecto de la variación en la reflectancia del suelo circundante (Colwell, 1973). Las bandas del rojo y del NIR se han combinado en una relación matemática para indicar la presencia de clorofila y para minimizar la interferencia de otros elementos sin clorofila en la zona (Rouse *et al.*, 1974). Un índice de vegetación muy conocido, ahora ampliamente utilizado para la estimación de la biomasa aérea (Wessels *et al.*, 2006; An *et al.*, 2013; Gao *et al.*, 2013; Jin *et al.*, 2014; Xia *et al.*, 2014), es el índice de vegetación de diferencia normalizada (NDVI) descrito por Rouse *et al.*, (1974) el cual está basado en el contraste entre la máxima absorción en el rojo, debido a los pigmentos de clorofila, y la máxima reflexión en el infrarrojo, causado por la estructura celular de la hoja y la reflexión de la cubierta debido a su estructura. Utilizando bandas estrechas multiespectrales, el índice se calcula mediante la ecuación representada en la Tabla 2.1).

Se ha empleado para estimar biomasa de forma satisfactoria en numerosos estudios (e.g. Rouse *et al.*, 1974; Nitsch *et al.*, 1991, Mutanga y Skidmore, 2004; Wamunyima, 2005; Cho *et al.*, 2007, Clevers, 2007, Mutanga *et al.*, 2012), sin embargo a pesar de su aplicación intensiva, el NDVI se satura en caso de cubiertas densas o constituidas por varias capas, así varios estudios han demostrado que el cálculo de NDVI con bandas espectrales anchas puede resultar inestable y por lo tanto inadecuado para la estimación de capacidad de secuestro de carbono/biomasa. También en la mayoría de estos estudios el índice de vegetación NDVI es acompañado por el índice

Simple Ratio definido por Birth y McVey (1968) como una reflectancia en el infrarrojo cercano entre la reflectancia en el rojo (Tabla 2.1).

Ren y Zhou (2014) obtuvieron resultados más exactos usando nuevos índices, estimados a partir del índice SAVI (*Soil-Adjusted Vegetation Index*) introducido por Huete (1988), en zonas áridas o semiáridas y usando un factor de corrección “L” dependiendo del grado de cobertura de la vegetación (alto grado de cubrimiento L=0 y bajo grado de cubrimiento L=1). Usando L=0,5 se minimiza las variaciones de brillo inducido del suelo y pueden reducir los problemas de ruido del suelo para una amplia gama de LAI (Huete, 1988). Para simular las relaciones entre los índices de vegetación y parámetros biofísicos en superficie Goel y Qin, (1994) propusieron el índice de vegetación no lineal (NLI). Los índices de vegetación no lineales intentan linealizar las relaciones con los parámetros de superficie que tienden a ser no lineales

Tabla 2.1. Índices de vegetación usados en la estimación de parámetros biofísicos

Índice de vegetación	Ecuación	Referencia
Normalized Difference Vegetation Index	$NDVI = \frac{NIR - R_o}{NIR + R}$	Rouse <i>et al.</i> (1974)
Simple Ratio	$SR = \frac{NIR}{R}$	Birth y McVey, (1968)
Soil Adjusted Vegetation Index	$SAVI = \frac{(NIR - R)(1 + L)}{(NIR + R + L)}$	Huete, (1988)
Non-Lineal Vegetation Index	$NLI = \frac{NIR^2 - R}{NIR^2 + R}$	Goel y Qin, (1994)

En otros trabajos se han obtenido correlaciones entre parámetros biofísicos y diferentes índices estimados a partir de la reflectancia en el verde y el rojo (Yang y Anderson, 1996; Raun *et al.*, 1999; Wecker *et al.*, 2003; Mutanga y Ismail, 2010).

La inestabilidad del NDVI puede deberse a variaciones en el color del suelo, estructura de la cubierta, propiedades ópticas de las hojas o condiciones atmosféricas (Huete y Jackson, 1988; Middleton, 1991; Kaufman y Tanré, 1992; Boschetti *et al.*, 2007). Además, el NDVI derivado de este modo se acerca asintóticamente a un nivel de saturación una vez que alcanza un determinado valor de biomasa o de índice de área foliar (LAI) (Sellers, 1985). En el caso de trabajar con áreas donde esos valores de saturación no son habituales (zonas abiertas, semiáridas) los inconvenientes de utilizar

estos ratios e índices de vegetación se minimizan, obteniéndose buenos modelos de estimación de capacidad de secuestro de carbono/biomasa a partir de imágenes hiperespectrales (Cho *et al.*, 2007). Para especies pratenses Álvarez *et al.* (2010b) el NDVI y el SR, fueron los mejores predictores para la estimación de biomasa a partir de imágenes de la cámara Ultracam-X ($R^2=0,63$ y $R^2=0,66$, respectivamente, a un nivel de significación del 5%). En este estudio se concluyó que empleando esta cámara es necesaria una ecuación diferente para cada imagen que se emplee para la estimación de biomasa, además de que el GSD tiene un impacto en los resultados.

La mayoría de los estudios han empleado ajustes paramétricos consistentes en el ajuste de ecuaciones matemáticas entre las variables de interés (e.g. biomasa total) y la reflectancia y/o índices espectrales derivados de la imagen. (e.g. Hyypä *et al.*, 2000; Dong *et al.*, 2003; Mallinis *et al.*, 2004; Zheng *et al.*, 2004; Labrecque *et al.*, 2006; Hall *et al.*, 2006). Otros investigadores han empleado métodos no paramétricos como el k-nn (e.g. Tomppo, 1993; Fazakas *et al.*, 1999; Tomppo *et al.*, 1999; Franco-López *et al.*, 2001; Reese *et al.*, 2002, 2003; Tomppo *et al.*, 2002; Holmström y Franson, 2003; Mäkelä y Pekkarinen, 2004; McRoberts *et al.*, 2006) y análisis estadísticos que incluyen variogramas (e.g. Wallerman, 2002; Zawadzki *et al.*, 2005).

La posibilidad de relacionar la biomasa aérea con la información capturada en las imágenes de la cámara digital, se plantea como una opción, debido a la banda del NIR presente, una vez realizadas las correcciones radiométricas necesarias para el cálculo de reflectividades.

Otros métodos, utilizando índices de vegetación derivados del rojo y las bandas de infrarrojo cercano (NIR) (e.g. *Simple Ratio*, *Normalized Difference Vegetation Index*) han sido ampliamente utilizados para estimar la biomasa (e.g. Nitch *et al.*, 1991; Cho *et al.*, 2007). Sin embargo, varios estudios han demostrado que el cálculo de los índices de bandas estrechas a través de bandas anchas puede ser inadecuado para estimar la biomasa, debido a variaciones en el color del suelo la estructura de la cubierta y / o las condiciones atmosféricas (Nitsch *et al.*, 1991; Cho *et al.*, 2007) o porque pueden llegar a un valor asintótico cuando se alcanza un determinado valor de la biomasa (Gao *et al.*, 2000), lo que dificulta su uso en modelos predictivos. En este contexto, la aplicación de transformaciones espectrales y técnicas estadísticas adecuadas que tengan en cuenta la continuidad del espectro se plantea como una oportunidad para mejorar los modelos que estiman la biomasa aérea (Marabel y Álvarez, 2014).

Las mediciones hiperespectrales en los doseles de vegetación obtenidas de los

espectro-radiómetros portátiles (e.g. Atzberger *et al.*, 2010; De Jong, 1994; Smith y Curran, 1996; Kokaly y Clark 1999) o sensores aerotransportados (Cho *et al.*, 2007; Huang *et al.*, 2004; Axelsson, 2011) contienen información útil para la caracterización de la vegetación la cual no podría ser rescatada en las imágenes multiespectrales con anterioridad. Sin embargo estos datos también presentan gran cantidad de información redundante así como zonas del espectro donde existe gran cantidad de ruido. Estas dos deficiencias no han disuadido a los investigadores el uso de datos hiperespectrales para modelar variables biofísicas, sino que han favorecido el desarrollo de técnicas para superarlos.

La fuerte multicolinealidad producida en los análisis de datos hiperespectrales mediante regresiones lineales múltiples con ajustes por mínimos cuadrados provoca altas correlaciones entre los predictores y por ello la invalidez de los resultados (Curran *et al.*, 2001). Este enfoque es bien conocido cuando se trabaja con datos hiperespectrales y existen técnicas estadísticas que pueden tener en cuenta esta multicolinealidad (Williams y Norris, 1987). Dos de las técnicas más dominantes en esta área se enumeran en la Tabla 2.1, la regresión lineal por mínimos cuadrados parciales (PLS, *Partial Least Squares*) y un conjunto de algoritmos de aprendizaje supervisado denominado máquinas de vectores de soporte (SVM, *Support Vector Machine*). PLS y SVM son métodos usados en el espectro completo, que han sido ampliamente utilizados en la quimiometría (Geladi y Kowalski, 1986) y últimamente en estudios relacionados con la estimación de la biomasa a partir de datos hiperespectrales (e.g. Atzberger *et al.*, 2010; Axelsson, 2013; Fu *et al.*, 2013; Darvishzadeh *et al.*, 2014; Vaglio Laurin *et al.*, 2014, Haidi, 2015).

La regresión ordinal de mínimos cuadrados (OLS, *Ordinal Least Squares*) se ha utilizado con éxito en algunos de estos estudios, aunque se requiere una selección previa de los datos de entrada (es decir, sólo un número limitado de características independientes) (Mutanga y Skidmore, 2004; Pu *et al.*, 2003).

A continuación en la Tabla 2.2, se muestran ejemplos de trabajos donde se usaron de las diferentes técnicas estadísticas (PLS, SVM y OLS).

Tabla 2.2. Ejemplos de técnicas estadísticas para la estimación de variables biofísicas en la vegetación a través de datos hiperespectrales.

Código	Técnica	Ejemplos
PLS	Partial least squares	Hansen y Schjoerring (2003), Koistra <i>et al.</i> (2003), Huang <i>et al.</i>

	regression		(2004), Nguyen y Lee (2006), Cho <i>et al.</i> (2007), Clevers <i>et al.</i> (2007), Temmerman <i>et al.</i> (2007), Darvishzadeh <i>et al.</i> (2008c), Vasques <i>et al.</i> (2008), Botero <i>et al.</i> (2009), Atzberger <i>et al.</i> (2010), Axelsson <i>et al.</i> (2013), Fu <i>et al.</i> (2013), Udelhoven <i>et al.</i> (2013), Darvishzadeh <i>et al.</i> (2014), Vaglio Laurin <i>et al.</i> (2014), Hadi (2015).
SVM	Support vector machine	vector	Camps-Valls <i>et al.</i> (2006), Clevers <i>et al.</i> (2007), Durbha <i>et al.</i> (2007) Li <i>et al.</i> (2009), Axelsson <i>et al.</i> (2013), Darvishzadeh <i>et al.</i> (2014), Hadi (2015).
OLS	Ordinal Least Squares Regression		Kokaly y Clark, (1999), Pu <i>et al.</i> (2003), Mutanga y Skidmore (2004), Cho <i>et al.</i> (2007), Clever (2008), Chuvieco y Huete (2010), Marabel y Alvarez-Taboada (2013).

Con el fin de mejorar la relación señal-ruido de estos datos y mejorar la información relacionada con las variables biofísicas, diferentes transformaciones en el pre-procesamiento se han aplicado a los datos espectrales, preparándolos para el modelado. Estas transformaciones en el pre-procesamiento de los datos espectrales han demostrado mejorar la precisión de los modelos de predicción (e.g. Dunn *et al.*, 2002; McCarty *et al.*, 2002; Kooistra *et al.*, 2003, Cho *et al.*, 2007 Vasques *et al.*, 2008,, Axelsson, 2013). Algunas de las transformaciones más comunes incluyen: suavizados, promedios, la normalización, la corrección de dispersión, corrección de línea de base y derivadas (Vasques *et al.*, 2008), mientras que la transformación más usada en la estimación de biomasa es la transformación CR (*Continuum Removal*) (e.g. Mutanga, 2004; Mutanga y Skidmore, 2004; Cho *et al.*, 2007; Axelsson, 2013; Hadi, 2015). El espectro transformado en su conjunto, o bien los índices derivados del mismo, han permitido obtener modelos más exactos para predecir la biomasa aérea y otras variables biofísicas a partir de datos hiperespectrales (e.g. Pu *et al.*, 2003; Mutanga y Skidmore, 2004; Hadi, 2015), en comparación con los obtenidos por los datos sin transformar.

El principal avance en las técnicas espectroscópicas de análisis es la aplicación del conocimiento de diversas y poderosas técnicas matemáticas, llamadas técnicas quimiométricas (Cozzolino *et al.*, 2011c), las cuales pueden ser usadas en el análisis cuantitativo de las firmas espectrales.

CAPÍTULO 3

3

ÁREA DE ESTUDIO

El área de estudio se localizó en el municipio de Villanueva de la Cañada situado en su parte occidental, al noroeste de la ciudad de Madrid. Limita al norte con Valdemorillo y Villanueva del Pardillo, al este con Majadahonda, Boadilla del Monte y Villaviciosa de Odón, al sur con Brunete y al oeste con Quijorna. La superficie delimitada por la toma de las imágenes multiespectrales y de datos de campo queda definida por un rectángulo de coordenadas ETRS89 UTM30 415900 a 417100 en el eje abscisas y de ETRS89 UTM30 4478000 a 4479100 en el eje de ordenadas (Figura 3.1).

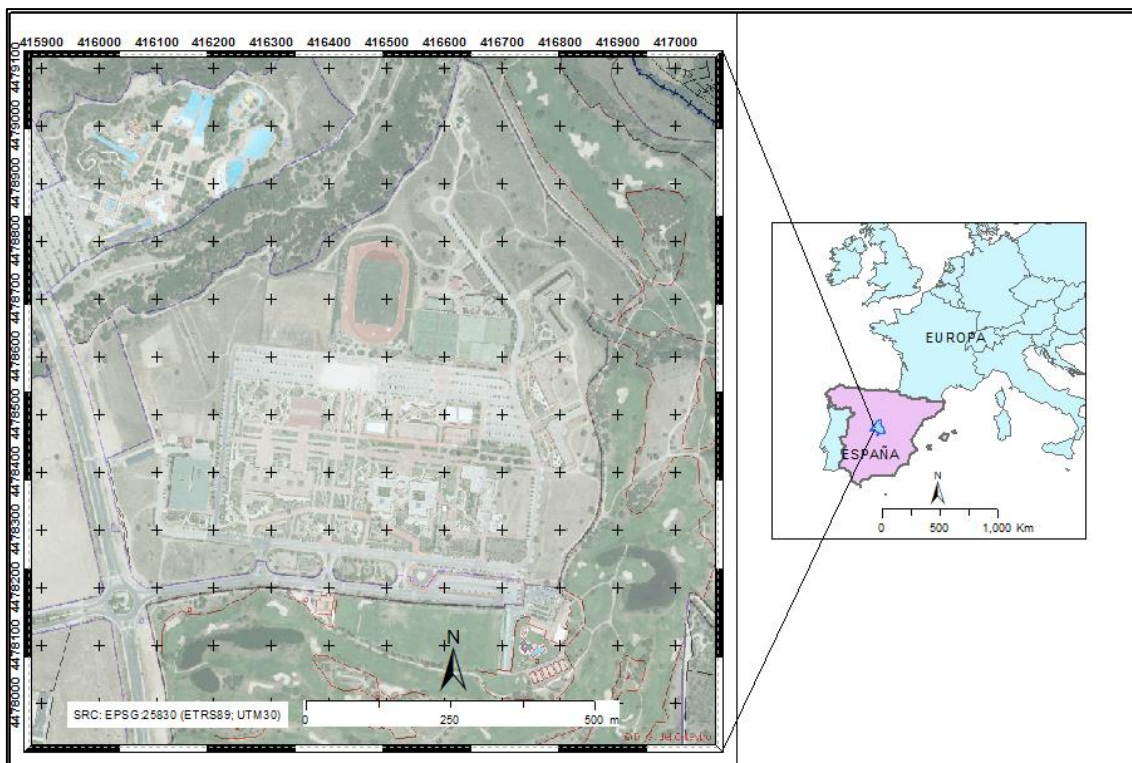


Figura 3.1. Localización del área de estudio.

CAPÍTULO 4

4 ESTIMACIÓN DE LA CANTIDAD DE BIOMASA AÉREA A PARTIR DE DE ESPECTRO-RADIOMETRÍA DE CAMPO.

4.1. Introducción

La biomasa aérea es una de las principales variables biofísicas de interés en los estudios de vegetación, independientemente de estar en zonas cultivadas o naturales (Clevers *et al.*, 2008) La posibilidad de estimar la cantidad de biomasa aérea y su modelado puede ayudar en la gestión de la cosecha y su bioenergía (Udelhoven *et al.*, 2013). Esta posibilidad de estimación sobre el terreno en zonas dominadas por especies

herbáceas permite el estudio como sumidero de carbono así como su contribución al ciclo global del carbono. La biomasa aérea se puede medir en términos de peso de la materia fresca o como peso de la materia seca, estando estas dos variables fuertemente relacionadas (Rollin y Milton, 1998). En los últimos años la medición de la biomasa aérea directamente era un proceso costoso y destructivo (Reese et al., 1980), por lo que el empleo de técnicas no destructivas como la teledetección reúne tanto el análisis espacial como temporal de una manera económica y no destructiva (Alcaraz-Segura et al., 2010). Estos estudios están relacionados con los datos de reflectividad espectral en la región de 400-2500 nm, debido a la presencia de características de absorción de diagnóstico en las curvas de reflectancia (Goetz et al., 1985, Kokaly y Clark, 1999). Estas técnicas han sido de uso habitual para caracterizar la vegetación mediante la estimación, por ejemplo, de la cantidad de clorofila o el contenido de agua.

Para la estimación de biomasa aérea se han utilizado diferentes índices de vegetación derivados de las bandas del rojo y el infrarrojo cercano, como por ejemplo el ratio simple o el índice de vegetación de diferencia normalizada (Nitsch *et al.*, 1991; Cho *et al.*, 2007). Sin embargo, varios estudios han mostrado que el cálculo de estos índices puede ser inadecuado para estimar la biomasa aérea, debido a las variaciones de determinados factores como es el color del suelo, la estructura de la cubierta y/o las condiciones atmosféricas (Nitsch *et al.*, 1991) o porque pueden llegar a un valor asintótico cuando se alcanza un determinado valor de la biomasa (Gao *et al.*, 2000), lo que dificulta su uso en modelos predictivos. Por el contrario, algunos estudios han encontrado que los índices calculados a partir de bandas estrechas específicas (datos hiperespectrales) mejoran la estimación de la biomasa (Lee *et al.*, 2004, Mutanga *et al.*, 2004).

En este contexto, la aplicación de transformaciones espectrales y técnicas estadísticas adecuadas que tengan en cuenta la continuidad del espectro se plantea como una oportunidad para mejorar los modelos que estiman la biomasa aérea (Atzberger *et al.*, 2010). Las mediciones hiperespectrales de cubiertas vegetales obtenidas mediante espectro-radiómetros (e.g. De Jong, 1994; Smith y Curran, 1996; Kokaly y Clark, 1999; Atzberger *et al.*, 2010) o sensores aerotransportados hiperespectrales (e.g. Huang *et al.*, 2004; Cho *et al.*, 2007; Axelsson *et al.*, 2013) contienen información útil para caracterizar la vegetación, si bien este conjunto de datos contiene mucha información redundante (Grossman *et al.*, 1996 y Schlerf *et al.*, 2005) y presenta un menor ratio señal/ruido que los datos de sensores multiespectrales. Estas dos deficiencias no han

disuadido a los investigadores en el uso de datos hiperespectrales para modelar variables biofísicas, sino que han fomentado el desarrollo de técnicas que permitan superar dichos problemas. Uno de los retos habituales al emplear datos de espectrorradiómetro como datos de entrada en un modelo de estimación de una variable biofísica es la fuerte multicolinealidad entre las bandas del espectro, lo que desaconseja su uso como variables predictoras en un modelo de regresión lineal por mínimos cuadrados (OLS) (Curran *et al.*, 2001). Este método se ha utilizado con éxito en algunos de estos estudios, aunque se requiere una selección previa de los datos de entrada (es decir, sólo un número limitado de variables independientes) (Pu *et al.*, 2003; Mutanga *et al.*, 2004).

Otro de los problemas en el ajuste de estos modelos es que el número de muestras es mucho menor que el de variables descriptoras. Un enfoque bien conocido que se puede utilizar para evitar estos problemas es la selección de técnicas estadísticas adecuadas (Curran *et al.*, 2001). Dos de estas técnicas son (i) la regresión por mínimos cuadrados parciales (PLS, *Partial Least Squares*) y (ii) las máquinas de vectores de soporte (SVM, *Support Vector Machine*), usadas en valiosos estudios relacionados con la estimación de variables biofísicas de la vegetación (e.g. Clevers *et al.*, 2007; Axelsson *et al.*, 2013; Darvishzadeh *et al.*, 2014). PLS y SVM son métodos que usan la firma espectral completa, los cuales han sido ampliamente utilizados en quimiometría (Geladi y Kowalski, 1986) y últimamente en los estudios relacionados con la estimación de la biomasa a partir de datos hiperespectrales (e.g. Atzberger *et al.*, 2010; Mutanga *et al.*, 2012; Axelsson *et al.*, 2013; Darvishzadeh *et al.*, 2014). Por tanto estos dos métodos tienen en cuenta la elevada correlación entre las variables resolviendo también el problema del menor número de muestras que de variables predictoras. La regresión PLS genera nuevas variables descriptoras en número inferior a las variables originales (Williams *et al.*, 1987).

Con el fin de mejorar la relación entre la información derivada del espectro y las variables biofísicas, en este caso la biomasa aérea, se pueden aplicar diferentes preprocesamientos y transformaciones espectrales, que mejoren la precisión de los modelos de predicción (e.g. Dunn *et al.*, 2002; Kooistra *et al.*, 2003; Cho *et al.*, 2007; Vasques *et al.*, 2008; Axelsson *et al.*, 2013). Algunas de estos procesos más comunes antes de realizar los modelos de predicción, consisten en hacer suavizados, promedios, normalizaciones, correcciones de la línea base y de la dispersión, derivadas (Vasques *et al.*, 2008), si bien la transformación más utilizada para la estimación de biomasa es la transformación *Continuum Removal* (CR) (e.g. Mutanga y Skidmore, 2004; Cho *et al.*,

2007; Sun *et al.*, 2008; Axelsson, 2013). El espectro transformado en su conjunto, o bien los índices derivados del mismo, han permitido obtener modelos más exactos para predecir la biomasa aérea y otras variables biofísicas a partir de datos hiperespectrales (e.g. Pu *et al.*, 2003; Mutanga y Skidmore, 2004; Sun *et al.*, 2008; Hadi, 2015), en comparación con los obtenidos por los datos sin transformar. Aunque se han propuesto algunas transformaciones en el pre-procesamiento, la elección de cuales utilizar, podría estar relacionada con la técnica estadística y la región de los espectros considerados como datos de entrada.

El principal objetivo de este estudio fue evaluar el desempeño de diferentes técnicas estadísticas avanzadas (PLS, OLS y SVM) para estimar la biomasa aérea a partir de datos del espectrómetro de campo averiguando qué transformaciones de los datos eran más adecuadas, con el fin de reducir el ruido en los datos y aumentar la exactitud de los métodos estadísticos. Se compararon los resultados en la estimación de la biomasa aérea de herbáceas medida como el peso seco de la fracción verde (Peso verde, PV), el peso seco de la biomasa aérea total (Peso total, PT), y el porcentaje del peso seco de la fracción verde (Porcentaje de peso verde, %PV). Por lo tanto, se compararon los siguientes enfoques: (i) PLS aplicado a diferentes partes del espectro (no transformado y transformado mediante CR y otros métodos de transformación), (ii) PLS aplicado a los índices derivados de la transformación CR, (iii) SVM usando regresión aplicada a diferentes partes del espectro, y (iv) OLS aplicada a los índices derivados de la transformación CR (como referencia).

Este análisis espectroscópico es importante debido a que si no existe una relación clara entre la biomasa aérea y la respuesta espectral medida con espectrorradiómetro, difícilmente la habrá con los datos obtenidos del sensor aerotransportado multiespectral.

4.2. Material

4.2.1. Datos

El trabajo de campo se llevó a cabo el 22 de julio de 2012 y la posición de las parcelas se determinó utilizando el receptor GNSS Topcon Hiper II. Los datos GPS fueron post-procesados utilizando estaciones de referencia con el fin de obtener las coordenadas en el sistema ETRS89 UTM huso 30.

4.2.1.1. Toma de datos espectrales

Los datos espectrales se tomaron en 30 unidades de muestreo homogéneas con herbáceas, fundamentalmente *Trifolium repens*, *Lolium perenne* y *Poa pratense*, sometidas a riego y sembradas en la misma época. Cada una de estas unidades fue una parcela de 1 m × 1 m, dividida en 4 subparcelas de 0,5 m × 0,5 m. En cada subparcela se midieron 15 espectros, por lo que se recogieron un total de 60 espectros por parcela (Figura 4.1). Cada parcela de 1 m² quedó caracterizada espectralmente por el espectro promedio de las 60 mediciones correspondientes.

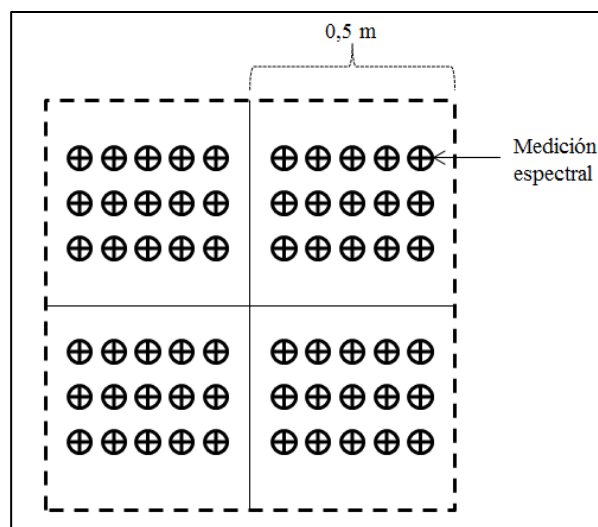


Figura 4.1. Representación de las mediciones espectrales en una parcela (Elaboración propia)

Las muestras espectrales se tomaron con un espectrorradiómetro de campo ASD Fieldspec®4, con un rango espectral de 350-2,500 nm. Se usó el cabezal para medir denominado “*pistol grip*” con un campo de visión (FOV- *Field Of View*) de 25° a 1,5 m en condiciones de cielo despejado y alrededor del mediodía solar. Este instrumento codifica la luz entrante en 16 bits y la separa en tres espectrómetros: Visible/Infrarrojo cercano (VNIR) [350-1000] nm, Infrarrojo de onda corta1 (SWIR1) [1000-1800] nm e Infrarrojo de onda corta 2 (SWIR2) [1800-2500] nm. Las lecturas espectrales se registraron en intervalos de 1 nm con una resolución espectral de 3 nm en el VNIR y de 8 nm en el SWIR. Antes de cada medición se calibró el instrumento empleando un blanco estándar de referencia (*Spectralon Labsphere®*), lo que permitió obtener reflectancias absolutas en superficie.

4.2.1.2. Toma de Datos de campo de biomasa aérea

Se emplearon las mismas 30 unidades de muestreo donde se midieron los datos espectrales. En cada parcela se estimó el peso de la biomasa aérea a partir de la corta de la biomasa aérea de la correspondiente subparcela de 0,5 m × 0,5 m localizada en el extremo NE de cada parcela y que se usó como muestra representativa. Con el fin de evitar una pérdida de humedad, las muestras se introdujeron en bolsas herméticas y fueron transportadas al laboratorio en neveras frigoríficas. En el laboratorio se realizó su pesado y se procedió a su separación en fracción seca y fracción verde. Posteriormente se procedió al secado de cada una de las fracciones en una estufa a 65°C durante 48 horas, obteniendo: el peso seco de la biomasa aérea verde (PV), el peso seco de la biomasa aérea total (PT) y el porcentaje de peso verde respecto al total (%PV). El peso seco de la biomasa aérea verde (PV), se utilizó como equivalente a la biomasa aérea seca (ABD, *Aboveground Dry Biomass*) de cada parcela. Posteriormente se procedió a la creación de una base de datos con diferentes pesos de la biomasa para cada subparcela, asignándole finalmente un valor promedio a cada parcela (Herrera-Arango *et al.*, 2001; Cho *et al.*, 2007; Clever *et al.*, 2008).

La biomasa se calculó dividiendo el peso de la biomasa cosechada por el área de las parcelas (expresado como g/m²). La Tabla 4.1, resume los estadísticos descriptivos, más relevantes de las variables peso verde, peso total y porcentaje de peso verde para las 30 parcelas de césped/trébol, mientras que la Figura 4.2, muestra la distribución de frecuencias de la muestra para las tres variables. El test de *Shapiro-Wilk* mostró que las tres variables son normales ($\alpha=0,01$).

Tabla 4.1 Estadísticos descriptivos de la muestra (n=30) (PT: Peso de la biomasa aérea total, PV: Peso de la fracción verde, %PV: Porcentaje de peso de la fracción verde).

	PV (g/m ²)	PT(g/m ²)	%PV (%)
Media	31,71	45,05	68,34
Mediana	34,75	49,1	69,77
Desviación. típica	12,63	15,4	13,57
Max.	50,50	75,6	90,04
Min.	4,40	9,52	29,76




Figura 4.2. Histogramas y curva de normalidad de las variables PV, PT, %PV.

4.3. Métodos

4.3.1. Flujo de trabajo

La metodología consistió en dos pasos principales: el procesamiento de datos espectrales y análisis estadístico (Figura 4.3). En primer lugar se realizó un pre-procesamiento y se aplicaron varias transformaciones a los espectros, derivándose índices a partir de los datos transformados. Posteriormente, la información espectral se empleó como dato de entrada para estimar PT, PV y % PV usando PLS, OLS y SMV. A continuación se describen los procesos descritos en la Figura 4.3.

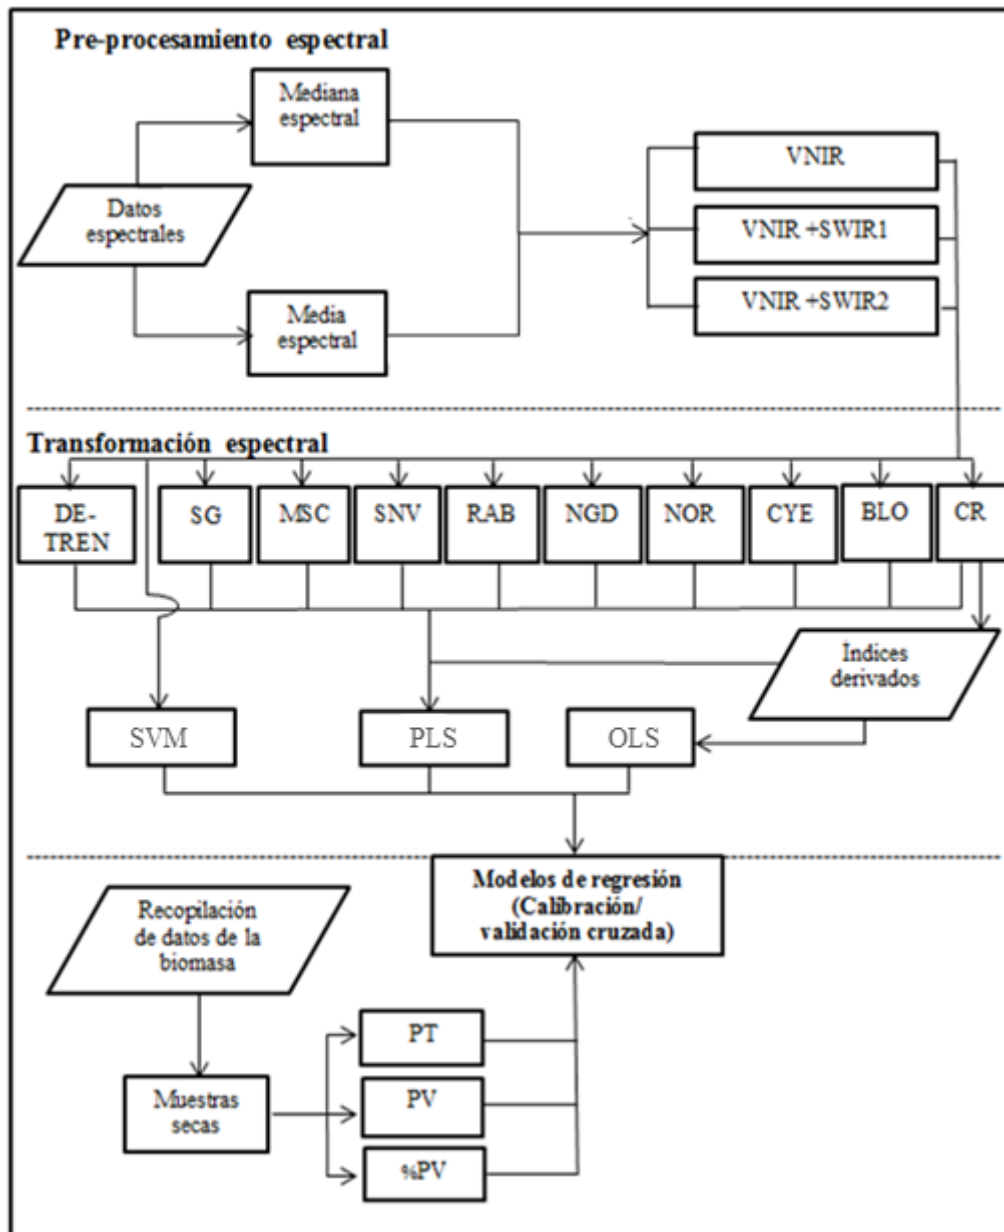


Figura. 4.3. Flujo de trabajo

4.3.2. Pre-procesamiento espectral

El pre-procesamiento es la modificación de los datos realizados antes de construir un modelo matemático o antes de aplicar otra forma de analizar los datos. La finalidad es hacer lineal la respuesta de las variables así como eliminar las fuentes extrañas de variación que no son de interés en el análisis, ya que de no ser eliminadas, la varianza debida a los errores sistemáticos presentes en los experimentos aumentará y se requerirá un trabajo más complejo para obtener información de interés (Hendriks et al., 2005; Wise *et al.*, 2006; Lucio-Gutiérrez, 2012).

Una vez en laboratorio se procedió a la depuración de los datos de reflectancia absoluta en superficie mediante el software *ViewSpecPro*. El ruido de alta frecuencia es aleatorio, por lo que el promediado de varias señales de una misma muestra reduce la contribución del ruido el cual puede aparecer por diferentes causas (ruido instrumental, variaciones en la temperatura o humedad del ambiente, naturaleza del material que se mide) y por ende aumenta la relación señal/ruido (Nicolai *et al.*, 2007; Cozzolino *et al.*, 2011d; Lourenco *et al.*, 2012; Martelo, 2014).

El espectro final que se usará el procesado, es el resultado de promediar un número determinado de espectros individuales (Nicolai *et al.*, 2007; Tao *et al.*, 2013b) por lo que el primer paso en el pre-procesado de los datos, consistió en aplicar el promediado de los espectros. Esta operación permite que todos los resultados sean interpretados en términos de variación alrededor de la media (Nicolai *et al.*, 2007; Moros *et al.*, 2010;).

Se calculó tanto la media como la mediana de los 15 espectros de reflectancia en superficie de cada subparcela, obteniéndose un espectro media y un espectro mediana por subparcela. Posteriormente se calculó el espectro promedio por parcela de ambas, quedando así caracterizada cada parcela por dos espectros. La segunda fase consistió en visualizar todos los espectros promedios por parcela para localizar y excluir las zonas con irregularidades debidas al ruido atmosférico, obteniéndose así un espectro depurado sin las regiones comprendidas entre [1360- 1385 nm], [1800-1930 nm] y [2400-2500 nm]. Una vez depurados los espectros, las longitudes de onda se agruparon en tres subconjuntos espectrales, teniendo en cuenta los tres sensores diferentes que definen el espectrorradiómetro (VNIR, SWIR 1, SWIR 2). En la Tabla 4.2, muestra las longitudes de onda comprendidas en los tres subconjuntos espectrales consideradas en esta investigación: (i) VNIR; (ii) VNIR + SWIR 1; y (iii) VNIR + SWIR 1 + SWIR 2. Estos espectros depurados se emplearon como base para los análisis estadísticos posteriores.

Tabla 4.2. Longitudes de onda que definen los tres subconjuntos espectrales considerados en esta investigación.

Subconjunto espectral	Longitudes de onda (nm)
VNIR	[350- 1000]
VNIR + SWIR 1	[350-1359],[1386-1799]
VNIR +SWIR1 + SWIR2	[350-1359], [1386-1799], [1931-2399]

4.3.3. Transformaciones espectrales

En este estudio comparativo, se aplicaron varios tipos de transformaciones espectrales: métodos de corrección de la dispersión, métodos de derivación y la transformación *Continuum Removal* (CR). Se emplearon 20 transformaciones espectrales. Estas transformaciones se muestran en la Tabla 4.3, y han sido ampliamente utilizadas en trabajos con datos hiperespectrales, tal y como se muestra en los ejemplos incluidos en la misma (Macho-Aparicio, 2002; Valdés-Calviño, 2005; Clever *et al.*, 2008; Vargas-Patiño, 2011; Lucio-Gutiérrez, 2012; Thulin *et al.*, 2012; Martelo-Vidal, 2014). Todas estas técnicas de pretratamiento de los datos son las más usadas en la biblioteca científica cuando se trabaja con firmas espectrales.

Los métodos de corrección de la dispersión incluyen: normalizaciones, corrección de la línea base (BLO: *Baseline offset*), transformación de la reflectancia en absorbancia (RAB) la corrección efecto multiplicativo de la dispersión (MSC: *Multiplicative Scatter Correction*), transformación variable normal estándar (SNV) así como el centrado y escalado (CYE) (CAMO Technologies Inc., 2013). Los métodos de derivación incluyen: Norris (NGD: *Norris gap derivative* (Norris y Williams, 1984), y *Savitzky-Golay* (SG: Savitzky y Golay, 1964),

La Tabla 4.3, muestra la lista completa de las transformaciones utilizadas, con sus respectivos parámetros. Por lo tanto, se utilizaron las transformaciones de las reflectancias en el análisis en lugar de las propias reflectancias aplicándose tanto al espectro medio como el espectro mediana, a fin de eliminar el ruido del sensor y mejorar el rendimiento del modelo para estimar la biomasa aérea. Los análisis se llevaron a cabo utilizando el software *Unscrambler® X 10.2* (CAMO Software Inc., Woodbridge, Noruega).

Tabla 4.3. Transformaciones comparadas en este estudio

Código	Transformación	Ejemplos
BLO	Baseline offset	Macho-Aparicio, (2002); Valdés-Calviño, (2005); Burger, (2006); Vargas-Patiño, (2011); Lucio-Gutiérrez, (2012); Martelo, (2014)

Código	Transformación	Ejemplos
CR	Continuum Removal	Kokaly y Clark, (1999); Curran <i>et al.</i> (2001); Pu <i>et al.</i> (2003); Huan <i>et al.</i> (2004); Cho <i>et al.</i> (2007); Clevers <i>et al.</i> (2008); Sun <i>et al.</i> (2008); Mutanga e Ismail, (2010); Adjorlolo <i>et al.</i> (2012); Thulin <i>et al.</i> (2012); Ramoelo <i>et al.</i> (2013)
DE-TREN1	De-trending using a 1st-order polynomial	Huan <i>et al.</i> (2004); Rinnan <i>et al.</i> (2009)
DE-TREN2	De-trending using a 2st-order polynomial	
DE-TREN3	De-trending using a 3st-order polynomial	
MSCA	Multiplicative Scatter Correction Common amplification $f(X=X/b)$	Koistra <i>et al.</i> (2003); Huan <i>et al.</i> (2004); Burger, (2006); Temmerman <i>et al.</i> (2007); Botero <i>et al.</i> (2009); Armgren <i>et al.</i> (2011)
MSCF	Multiplicative Scatter Correction Full MSC $f(X=X-a/b)$	
MSCO	Multiplicative Scatter Correction Common off set $f(X=X-a)$	
NAR	Normalise by the area	Vasques <i>et al.</i> (2008); Vargas-Patiño, (2011)
NMX	Normalise by de maximum value	
NME	Normalise by the mean	
NRA	Normalise by the range	
NUV	Normalise by the unit vector	
SG	Savitzky y Golay	Macho-Aparicio, (2002); Valdés-Calviño, (2005); Rinnan <i>et al.</i> (2009); Vargas-Patiño, (2011); Bian, (2013); Ramoelo <i>et al.</i> (2013); Martelo, (2014); Wang <i>et al.</i> (2014)
NGD-3	Norris gap derivative 1st derivative-gap size=3	Valdés-Calviño, (2005); Vasques <i>et al.</i> (2008); Vargas-Patiño, (2011)
NGD-5	Norris gap derivative 1st derivative-gap size=5	
NGD-7	Norris gap derivative 1st derivative-gap size=7	
NGD-9	Norris gap derivative 1st derivative-gap size=9	
RAB	Reflectancia en absorbancia	Vasques <i>et al.</i> (2008); Thulin <i>et al.</i> (2012)
SNV	Standard normal variate transformation	Barnes <i>et al.</i> (1989); Dhanoa <i>et al.</i> (1994); Koistra <i>et al.</i> (2003); Huan <i>et al.</i> (2004); Burger, (2006); Vasques <i>et al.</i> (2008); Botero <i>et al.</i> (2009); Moros <i>et al.</i> (2010)

La transformación BLO usada en este trabajo, intenta corregir determinadas tendencias en la línea base que aporta el ruido a la señal. Consiste en aproximar la línea

de base del espectro con una función polinómica, que se resta posteriormente al espectro para obtener el espectro corregido. El caso más sencillo sería el polinomio de grado 0 (una constante), también denominada *offset correction* y consiste en restar a cada espectro la absorbancia medida a una determinada longitud de onda. El método detallado se describe en (CAMO Technologies Inc., 2013). Cuando se selecciona este tipo de corrección de línea base el software resta un valor constante al valor de la intensidad obtenida para cada uno de los puntos de la región específica seleccionada. Se pueden utilizar polinomios de grado superior, para adaptar la corrección a las características de la variación de la línea base. Los más habituales son el uso de una línea recta (polinomio de grado 1) o de una curva (polinomio de grado 2) o incluso un polinomio de grado 3. Cuando se utilizan polinomios de grado 1, 2 o 3, esta corrección se denomina *De-trending* (Macho Aparicio, 2002; Huang *et al.*, 2004; Rinnan *et al.*, 2009). Este método *De-trending* se usa también para corregir la interferencia de fondo, sobre todo cuando una constante, lineal, o curva de desplazamiento está presente (Barnes *et al.*, 1989).

Otro método que intenta reducir los efectos de dispersión es la corrección de dispersión multiplicativa (MSC). El MSC se basa en el ajuste de todas las observaciones a un espectro "ideal", por lo que el espectro media de todas las observaciones se utiliza de referencia y todos los espectros se estiman afín con respecto a esta referencia (Arngren *et al.*, 2011). Cabe señalar que el MSC es, por lo tanto sensible a la espectro medio y tiene que ser recalculado cualquier momento nuevas observaciones se añaden al conjunto de datos. Según la función usada este método se dividió en tres diferentes (MSCA, MSCF, MSCO). Las características de cada método MSC aplicadas a los espectros se describen en CAMO Technologies Inc. (2013).

Por otro lado, los métodos de normalización tratan de corregir el efecto de factores multiplicativos en los valores originales de una variable, pretendiendo obtener todos los datos aproximadamente en la misma escala. Estos métodos identifican una característica en una muestra que debe permanecer constante independientemente de la muestra considerada y corregir la escala de todas las variables utilizando esa característica. En este estudio, las variables se normalizaron por el valor máximo, la media, el rango, el área y el vector unitario (NAR, NMX, NME, NRA, NUV) (CAMO Technologies Inc., 2013).

Las transformaciones que implican derivadas permiten aumentar las diferencias entre la superposición y anchura de las bandas espectrales, corrigiendo así los efectos de

línea de base (CAMO Technologies Inc., 2013). La primera derivada elimina los desplazamientos de línea de base que son paralelos al eje horizontal. El método que se aplicó en este estudio fue la primera derivada de *Savitzky-Golay* y de *Norris gap* (Norris y Williams, 1984). En este último se aplicaron 4 puntos diferentes que definen el espacio entre segmentos que van a ser promediados, los cuales se usarán en la estimación de la aproximación polinómica (NGD-3, 5, 7, 9).

La variable aleatoria normal estándar (SNV) se aplica a la espectroscopía de datos para eliminar los efectos de dispersión, y reduce al mínimo las interferencias de la dispersión causada por partículas de diferentes tamaños (Verboven *et al.*, 2012). En esta transformación cada espectro se transforma individualmente mediante la eliminación de la compensación de intensidad y el escalado a la unidad desviación estándar (Barnes *et al.*, 1989; Dhanoa *et al.*, 1994) y ha sido ampliamente utilizado en muchos trabajos referentes a la normalización de los espectros (Tabla 4.3).

También se evaluó el centrado y escalado como tratamiento de las reflectancias así como su uso combinado con otras transformaciones. El centrado y escalado asegura que el modelo resultante pueda ser interpretado en términos de variación alrededor de la media (Nicolai *et al.*, 2007). La finalidad es centrar las diferencias entre las observaciones, en lugar de sus valores absolutos. Por otro lado el centrado y escalado permite obtener diferencias entre las muestras y la respuesta espectral así como proporcionar la exactitud en las predicciones.

4.3.4. Transformación Continuum Removal e índices derivados

Además de las transformaciones descritas en la sección anterior, se testó también la transformación *Continuum Removal* (CR) (Tabla 4.3) en los espectros depurados. La transformación CR es un método de normalización, el cual puede enfatizar tanto la ubicación como la profundidad de unas determinadas zonas de absorción individuales del espectro dibujando una curva con valores de absorción entre 0 y 1 (Clark y Roush, 1984). Esta técnica se utiliza para minimizar los efectos del ruido y para mejorar las características de absorción del espectro, resaltando las zonas de absorción que pueden estar más relacionadas con la biomasa (Kokaly y Clark, 1999).

Es una línea situada en la parte superior de los espectros la cual, se aplica en la conexión de máximos locales del espectro (Figura 4.4). Se trata de una estimación de

características generales de los espectros, aparte de las características de absorción bioquímicas de interés.

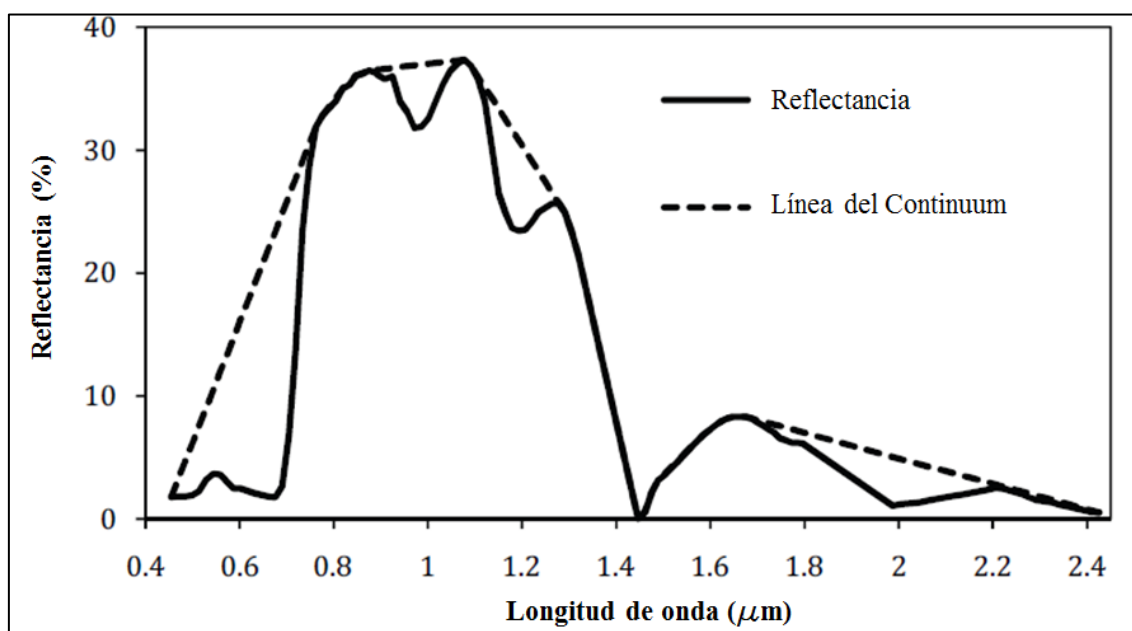


Figura 4.4. Aplicación de la línea del continuum a dos partes del espectro

La transformación CR se obtiene dividiendo los valores de reflectancia originales en la zona de absorción por los valores correspondientes del continuum (recta que representa la tendencia) (Kokaly y Clark, 1999). Para realizar la transformación es necesario identificar los límites de las regiones a las que se va a aplicar, teniendo en cuenta las ubicaciones de los máximos espectrales. Estas zonas deben ser sensibles a cambios en el contenido de la variable que se quieran detectar (en este caso la biomasa), aunque el método también muestra gran eficiencia cuando se trabaja con el espectro completo (Huang *et al.*, 2004). Mediante el software *ENVI 4.7* (<http://www.harrisgeospatial.com/>, IDL Workbench) se identificaron cinco zonas y se aplicó la transformación. El rango espectral de cada zona se muestra en la Tabla 4.4.

Tabla 4.4. Zonas de aplicación del *Continuum Removal*.

Zona	Rango espectral (nm)	Región electromagnética
Z1	[440-567]	VNIR
Z2	[554-762]	VNIR
Z3	[916-1120]	VNIR+SWIR1
Z4	[1079-1297]	SWIR1
Z5	[1265-1676]	SWIR1

Sun *et al.* (2008) seleccionaron tres bandas de frecuencia para calcular el CR, 400-530 nm (azul, la absorción de la clorofila), 550-730nm (rojo, la absorción de la clorofila) y 930-1000nm (Infrarrojo Cercano, NIR, absorción de agua) en la identificación de especies en humedales. Estas zonas se usaron como referencia en este trabajo (Z1, Z2 y Z3). Las zonas Z1 y Z2 se han usado con éxito también en estudios previos en la estimación de componentes bioquímicos de las hojas (Kokaly y Clark, 1999; Curran *et al.*, 2001, Mutanga *et al.*, 2012) así como para la identificación de diferentes especies de gramíneas (Adjorlolo *et al.*, 2012). Asimismo, las zonas Z3, Z4 y Z5 se han empleado satisfactoriamente en estudios relacionados con la variación del contenido de agua foliar (Kokaly *et al.*, 2003; Stimson *et al.*, 2005; Clevers *et al.*, 2008; Mutanga e Ismail, 2010). Para este trabajo ha sido necesario redefinir los límites de cada región para ajustarlos a los datos de la muestra. Se descartó aplicar la transformación CR en regiones comprendidas entre [1800-2100] nm, debido a la elevada cantidad de ruido (Mutanga, 2004) que representaban cuando se analizaron visualmente las firmas espectrales. La Figura 4.5, muestra gráficamente las regiones definidas para la transformación CR.

Para caracterizar cada una de las zonas del CR se derivaron dos índices: la profundidad (*Maximum Band Depth*, MBD) y el área sobre el mínimo (*Area Over the Minimum*, AOM) (Huang *et al.*, 2004). La MBD es la magnitud de la diferencia frente a la tendencia (Chuvieco y Huete, 2010) y está relacionada con la intensidad de la absorción en esa región (Clevers *et al.*, 2008). El AOM se describe como el producto de la profundidad y la anchura (ancho total a la mitad de la profundidad) (Pu *et al.*, 2003). Ambos índices se han empleado con éxito en estudios de estimación de biomasa (Clevers *et al.*, 2008) y de contenido en agua y bioquímicos foliares (Curran *et al.*, 2001; Pu *et al.*, 2003) Los cálculos de estos índices se realizaron con un aplicativo IDL desarrollado por Shuti Khanna (CSTARS. UC-DAVIS).

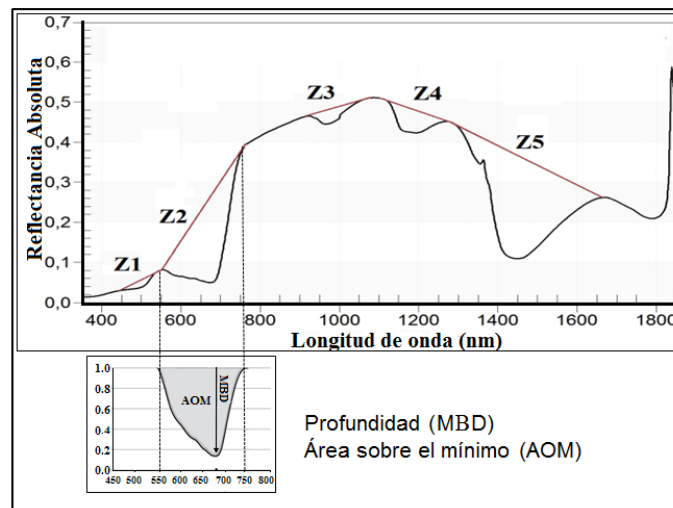


Figura 4.5. Signatura espectral característica de la vegetación de la zona de estudio, sobre la que se superponen las zonas de aplicación del *Continuum Removal* en este trabajo (Z1-Z5). El detalle representa a los índices MBD y AOM en la zona Z2.

4.3.5. Modelos de ajuste

El ajuste estadístico entre la biomasa aérea (PV, PT, %PV) y la información espectral se realizó empleando tres técnicas: regresión por mínimos cuadrados parciales (PLS), máquina de vectores de soporte (SVM) y regresión lineal por mínimos cuadrados (OLS). Debido a su simplicidad, esta última se incluyó en el análisis como referencia y como base para comparar los resultados obtenidos mediante el uso de PLS y SVM.

4.3.5.1. Regresión por mínimos cuadrados parciales (PLS)

En los análisis de datos hiperespectrales mediante regresiones lineales múltiples con ajuste por mínimos cuadrados suelen producirse fenómenos de multicolinealidad, que provocan altas correlaciones entre los predictores y por ello la invalidez de los resultados. El método de regresión PLS fue elegido para este trabajo porque es adecuado para trabajar con datos hiperespectrales procedentes de muestras pequeñas y con problemas de colinealidad, así como con muestras con ruido en los datos biofísicos (Atzberger *et al.*, 2010). Se ha empleado anteriormente en trabajos similares para la el estudio de la vegetación y del suelo (Cho *et al.*, 2007; Darvishzadeh *et al.*, 2008; Atzberger *et al.*, 2010; Axelsson, 2011; Mutanga *et al.* 2012; Ramoelo *et al.*, 2013; Abdel-Rahman *et al.*, 2014; Fu *et al.*, 2014; Wang *et al.*, 2015). Este método es una generalización de la regresión lineal múltiple que puede trabajar con partes continuas del espectro, empleando todas las longitudes de onda disponibles. Combina las características de un análisis de componentes principales (PCA) y regresiones múltiples

(Cho *et al.* 2007), comprimiendo un gran número de variables en unas pocas variables latentes (PLS factores). Esto lo consigue ya que la regresión la realiza en un espacio ortogonal, evitando estos problemas de la colinealidad entre variables (Blanco y Maspoch, 2007), evitando pérdida de información relevante y reduciendo además el ruido presente en la señal (Brereton, 2007).

Es utilizado para estudiar la estructura de covarianza entre los espacios correspondientes a dos matrices (X e Y), para predecir un conjunto de variables dependientes a partir de un conjunto grande de variables independientes. Cada dirección en estos espacios es representada por un factor, ya que la suposición básica de todos los modelos PLS, es que el sistema o proceso estudiado depende de un número pequeño de factores. Por tanto su finalidad es encontrar las relaciones fundamentales entre las variables independientes (X) y las variables dependientes (Y), las cuales son modeladas simultáneamente teniendo en cuenta no sólo la varianza de X , sino la covarianza entre X e Y (Harald y Tormod 1989, Martens y Naes, 1989). Entonces, X e Y se descomponen simultáneamente en un producto de otras dos matrices de *scores* y *loadings*; como es descrito por las siguientes ecuaciones:

$$X = TP^T + E \quad \text{Ec. 4.1}$$

$$Y = UQ^T + F \quad \text{Ec. 4.2}$$

Donde TP^T se aproxima a los datos de la matriz X y UQ^T a los verdaderos valores de Y . La descomposición no es independiente y existe una relación lineal entre los scores T y U . Los términos E y F de las ecuaciones son matrices de error y el superíndice T significa la transpuesta de la matriz. Una explicación detallada del algoritmo PLS se puede consultar en Geladi y Kowalski (1986).

Como predictores en este trabajo se emplearon los siguientes conjuntos de datos: (i) Datos pre-procesados pero no transformados (subconjuntos espectrales definidos en la Tabla 4.2: VNIR, VNIR+SWIR1, VNIR+SWIR1+SWIR2); (ii) Subconjunto espectral VNIR, VNIR+SWIR1, VNIR+SWIR1+SWIR2 después de la aplicación de filtros y transformaciones espectrales (Tabla 4.3); (iii) los valores de la transformación CR para cada una de las zonas mostradas en la Tabla 4.4, (valor para cada longitud de onda). (iv) los índices derivados de la transformación CR (Profundidad máxima de la banda-MBD y el área por encima de mínimo-AOM) (Tabla 4.4)

Se realizó un ajuste independiente PLS para cada una de las regiones ya que se ha demostrado que una cuidadosa selección de los datos de entrada lleva a un mejor rendimiento del método (Adjorlolo *et al.*, 2015). Además, con fines comparativos, se

realizó un ajuste empleando como datos de entrada el espectro depurado sin transformar (ST, Sin Transformación).

La selección del modelo más adecuado para cada variable se realizó teniendo en cuenta la construcción de un modelo sólido, con un número bajo de factores, un error cuadrático medio (RMSE) bajo en la predicción de la validación cruzada, y un coeficiente de determinación (R^2) lo más cercano a uno posible (Botero-Herrera, 2009). El número de factores fue optimizado por el software, considerando que no hubiera mucha divergencia entre la varianza explicada por el modelo en la fase de calibración y en la fase de validación y procurando que la varianza explicada fuera máxima en los dos primeros factores. Además con el fin de elegir el modelo más óptimo entre los modelos obtenidos y con un error aceptable se usó el criterio de información de Akaike (AIC, Akaike, 1969), el RMSE (valor absoluto), el %RMSE (calculado como: $100 * \text{RMSE} / \text{valor medio de la variable de biomasa aérea considerada}$) (Tabla 4.5.) y el coeficiente de determinación R^2 de las validaciones.

Tabla 4.5. Valores medios de las variables de biomasa aérea (PT, PV y %PV) usados para estimar el error cuadrático medio en porcentaje (%RMSE).

PV (g/m ²)	PT (g/m ²)	%PV (%)
31,72	45,05	68,34

La ventaja de AIC frente a otros posibles indicadores como R^2 o RMSE es que éste tiene en cuenta el número de factores utilizados en el modelo penalizando la inclusión de factores que no mejoran significativamente el modelo. Minimizando este criterio se obtienen modelos más adecuados para la predicción. Esta herramienta fue usada en este trabajo para cada modelo (con 1,2,3,...,n factores), seleccionando como modelo óptimo aquél con un resultado menor al aplicar la ecuación AIC. Se empleó la siguiente ecuación para calcular el AIC:

$$\text{AIC} = N \ln(\text{RMSE}) + 2 \text{NC} \quad \text{Ec.4.3}$$

donde N es el tamaño de la muestra y NC el número de componentes PLS.

Se realizó una validación cruzada del tipo *Leave-One-Out* (LOOCV) (Geladi y Kowalski, 1986; Huang *et al.*, 2004; Clevers *et al.*, 2008; Atzberger *et al.*, 2010). Los análisis se realizaron con el software Unscrambler® X 10.2 (CAMO Software Inc., Woodbridge).

4.3.5.2. Máquinas de vectores de soporte (Support Vector Machine, SVM)

Últimamente, el uso de máquinas de vectores de soporte (SVMs) sobre diversos problemas de clasificación y regresión se ha vuelto cada vez más popular y este método se ha utilizado con éxito en la estimación de la biomasa de pastizales (Clevers *et al.*, 2007; Darvishzadeh *et al.*, 2014), índice de área foliar (Durbha *et al.*, 2007) o variables bioquímicas de la hoja (Camps-Valls *et al.*, 2006; Axelsson *et al.*, 2013) a partir de datos obtenidos por teledetección. Las Máquinas de vectores de soporte fueron inicialmente usadas como aprendizaje estadístico (Vapnik, 1995) y posteriormente introducidas por Vapnik en 1997 (Vapnik y cols., 1997) para resolver problemas de clasificación y regresión. Cuando se usa en la regresión, como en este trabajo, se les suele designar por el acrónimo SVR (*Support Vector Regression*). El objetivo es estimar una función valuada-continua desconocida basada en un conjunto finito número de muestras ruidosas. La máquina de soporte de vectores en la regresión utiliza el principio de minimización del riesgo estructural para optimizar simultáneamente el rendimiento y la generalización, minimizando también el problema relacionado con el sobre ajuste de los modelos (Comesaña-García *et al.*, 2010). Esta metodología encuentra soluciones únicas tanto a sistemas lineales como a no lineales (Axelsson *et al.*, 2013).

Dado un conjunto de entrenamiento, en el que se asume que los valores de todos los ejemplos del conjunto se pueden ajustar (o cuasi-ajustar) mediante una función lineal, el objetivo de la tarea de la regresión es encontrar los parámetros que permitan definir dicha función lineal. La representación por medio de las funciones de transformación (*Kernel*) de las variables de entrada ofrece una solución al problema de la representación de las características sobre el espacio. Un *Kernel* no es más que la proyección de la información a un espacio de características de mayor dimensión el cual aumenta la capacidad computacional de las máquinas de aprendizaje lineal. Los *Kernel* normalmente utilizados para este tipo de transformación son: el Lineal, el Polinomial y las Funciones de Base Radial (Audain, 2014).

Existen diferentes variantes de SVR, con diferentes algoritmos de optimización; dos que se utilizan comúnmente son ϵ -SVR y η -SVR. El ϵ -SVR, usado en este trabajo, transforma los datos de entrada representándolos en un espacio de mayor dimensión mediante el uso de una función o *Kernel*. Con una transformación no lineal apropiada de los datos, se minimiza no sólo el error de entrenamiento, sino también la complejidad

del modelo (Axelsson *et al.*, 2013). Una descripción completa de ambos métodos puede encontrarse en (Ben-Hur y Weton, 2010).

La calidad del modelo del SVM depende de un ajuste adecuado de los meta-parámetros: Parámetro ϵ y parámetro C (Cherkassky y Ma, 2004). El primero de ellos controla la anchura de la zona de ϵ -insensible, que se utiliza para ajustar los datos de entrenamiento, y su valor puede afectar al número de vectores de soporte utilizados para construir la función de regresión. Por lo tanto, cuanto mayor sea el ϵ , menores serán los vectores de apoyo seleccionados (Vapnik, 1995), mientras que los valores ϵ más grandes resultan en más estimaciones “planas” (Durbha *et al.*, 2006).

Para permitir cierto ruido en los ejemplos de entrenamiento se puede relajar la condición de error entre el valor predicho por la función y el valor real utilizando una función denominada de pérdida ϵ -insensible de Vapnik, en la cual el error es nulo reduciendo de este modo el número de vectores soporte (Figura 4.6.) Dada la dificultad práctica de que los ejemplos de entrenamiento se ajusten al modelo lineal con un error de predicción igual a cero, se recurre al concepto de margen suave, definiendo dos variables de holgura (ϵ_i^- , ϵ_j^+), que permitirán cuantificar la magnitud de dicho error (Carmona-Suarez, 2013).




Figura 4.6. Caracterización de SVR con margen suave: Se observa la relación entre las variables de holgura (ϵ_i^- , ϵ_j^+) mediante ejemplos que están situados fuera de la zona *tubular* ϵ -insensible y la función de pérdida, L_ϵ (Carmona-Suarez, 2013).

Se eligió esta función ya que permite cierta dispersión en la función solución, de tal forma que todos los ejemplos situados en la región *tubular* definida por $\pm\varepsilon$ no serán considerados vectores de soporte reduciendo por tanto el número de estos. Una explicación detallada del algoritmo se puede consultar en Carmona-Suarez, (2013).

Por lo tanto dentro de los modelos lineales existen datos separables linealmente (margen duro) y no son separables linealmente (margen suave). Este último es más robusto al ruido y a los *outliers* y siempre tiene una solución, pero requiere estimar el parámetro C. Este parámetro determina el equilibrio entre la complejidad del modelo y el grado en el cual las desviaciones mayores que ε son toleradas en la optimización. Por lo tanto, los valores más grandes de C tienen como objetivo minimizar el riesgo empírico independientemente de la complejidad del modelo así como controlar el peso que se le da a los componentes y permitiendo controlar el sobreaprendizaje. El ajuste del parámetro se llevó a cabo probando diferentes valores hasta encontrar el que maximizara la exactitud de los modelos usando validación cruzada.

Por lo tanto se aplicó este método para la estimación de la biomasa aérea, usando la función de pérdida ε -insensible de Vapnik, para minimizar los errores de entrenamiento, que no fueron penalizados, siempre y cuando estos resultaron más pequeños que ε . Como parte del proceso, se aplicó una función *Kernel* con el fin de asignar los datos en un nuevo espacio. El tipo de *Kernel* lineal considerado en este estudio fue elegido debido a que requiere un menor número de parámetros a definir y porque no es tan susceptible a sobreajuste como el radial o polinómico (Axelsson *et al.*, 2013).

Con el fin de encontrar el modelo más sencillo y con un error aceptable, el criterio para agregar un vector de apoyo adicional para el modelo era que tenía que reducir el error cuadrático medio de la validación cruzada (RMSE) por lo menos 2 %. El RMSE se determinó a partir de los residuos de cada fase de validación cruzada. Con el fin de evitar un sobreajuste, se comprobó que los valores RMSE de las etapas de calibración y de validación cruzada eran también menor que 2%. El desempeño de los modelos de SVM se comparó con el número de vectores de soporte, el RMSE (valor absoluto), %RMSE (porcentaje de la media / mediana del valor de la variable que supone el RMSE) y el coeficiente de determinación (R^2) para la validación cruzada. Los

análisis se llevaron a cabo utilizando el software *Unscrambler® X 10.2* (CAMO Software Inc.).

4.3.5.3. Regresión lineal simple (OLS)

En general, un modelo de regresión lineal simple consiste en estudiar la relación existente entre una variable denominada dependiente (Y) y otra variable denominada independiente o explicativa (X) a través de una recta, que toma el nombre de recta de regresión (Rojo-Abuín, 2007). El análisis de regresión lineal simple, consiste en calcular una recta, denominada recta de regresión de forma que pase lo más cerca posible de todos los puntos. El estudio de los coeficientes de la recta van a resumir la relación entre este par de variables. El modelo de regresión lineal simple es el siguiente:

$$Y = a + b * X + U \quad \text{Ec.4.4}$$

donde:

- Y es la variable respuesta o dependiente.
- X es la variable independiente o explicativa.
- U una variable aleatoria.

Es decir, el valor de la variable Y va depender del valor que toma la variable X, más una cierta perturbación aleatoria U, denominada residuo.

La estimación de los parámetros de la recta de regresión en este trabajo se realizó mediante el método mínimos cuadrados. Este método, minimiza la varianza de la perturbación aleatoria o varianza residual, es decir, se buscan unos valores a y b de forma que la distancia de cada punto a la recta de regresión (o valor pronosticado) sea mínimo; esto equivale a minimizar la varianza residual, teniendo en cuenta que la media de la perturbación es 0. Una explicación más detallada del método se puede encontrar en Rojo-Abuín (2007).

La regresión lineal simple por mínimos cuadrados se empleó en este trabajo utilizando como variables de respuesta las medidas de biomasa aérea (PV, PT, %PV) y como predictores los índices (i) MBD y (ii) AOM derivados de la transformación CR para las regiones Z1-Z5 (Tabla 4.4.). Este método se eligió por su sencillez y rapidez de cálculo. Estas dos variables se emplearon como datos de entrada para la regresión dando resultados adecuados en otros estudios (Kokaly y Clark, 1999; Pu *et al.*, 2003; Huang *et al.*, 2004; Clevers *et al.*, 2008). Las regiones continuas del espectro de reflectancias

fueron rechazadas como datos de entrada en este método ya que tienden al sobreajuste del modelo y en ocasiones las bandas seleccionadas no corresponden con las bandas de absorción conocidas (Huang *et al.*, 2004)

La validación de los modelos fue similar a la realizada para PLS, empleando una validación cruzada completa (Geladi y Kowalski, 1987; Huang *et al.*, 2004; Clever *et al.*, 2008; Atzberger *et al.*, 2010) y como criterios para la comparación el RMSE (valor absoluto y en porcentaje) y el coeficiente de determinación R^2 de la validación. El ajuste estadístico y la validación se realizaron con el software *Unscrambler® X 10.2* (CAMO Software Inc., Woodbridge).

4.3.6. Evaluación de los modelos de estimación obtenidos

La validación de un modelo basado en datos empíricos significa evaluar la validez del funcionamiento cuando sea utilizado en la predicción de nuevas muestras, del mismo tipo que las utilizadas en su construcción estimando la incertidumbre de las futuras predicciones. Si la incertidumbre es razonablemente baja, el modelo puede ser considerado válido. La verificación de la bondad del modelo se puede ensayar sobre un nuevo conjunto de muestras, distintas de las utilizadas en la construcción del mismo (llamado conjunto de prueba, test set) o mediante un sistema de validación cruzada (*cross-validation*) como el usado en distintas partes de este trabajo. Con el método de la validación cruzada, las mismas muestras se utilizan tanto para la estimación del modelo, como para su evaluación. Unas cuantas muestras quedan fuera del conjunto de calibración y se construye un modelo con las muestras restantes. Entonces, son predichas las muestras que han quedado fuera de la calibración y se calculan los residuales de predicción. El proceso se repite con otro subconjunto de muestras del conjunto de calibración, y así sucesivamente hasta que todos los objetos se ha dejado fuera una vez (Gemperline, 2006). A partir de la validación cruzada se pueden calcular figuras de mérito para evaluar cómo se comporta el modelo cuando se aplica a nuevos datos y también se puede determinar el número óptimo de factores válidos (Wise *et al.*, 2006).

Los modelos de estimación de biomasa obtenidos en este estudio mediante diferentes técnicas de procesamiento y de ajuste se evaluaron en términos de coeficiente de determinación de la validación cruzada (R^2) y de RMSE de la validación cruzada (valor absoluto) y %RMSE(calculado como: $100 * \text{RMSE} / \text{valor medio de la variable de}$

biomasa aérea considerada) los cuales representan la medida de la capacidad del modelo para predecir las muestras que no fueron utilizadas para construirlo durante el procedimiento de validación cruzada. También se tuvo en cuenta la relación entre las longitudes de onda/región identificadas como importantes por el análisis estadístico así como las zonas conocidas de absorción de agua/biomasa (Huang *et al.*, 2004). Una descripción completa del procedimiento de validación cruzada y su aptitud para detectar valores atípicos y su capacidad de proporcionar estimaciones casi imparciales de error de predicción, se puede revisar en Efron y Gong, (1983), Schlerf *et al.* (2005) o Darvishzadeh *et al.* (2008).

Para considerar un modelo más preciso que otro, el primero tuvo que reducir el error cuadrático medio de la validación cruzada (RMSE) al menos un 2% (Clever *et al.*, 2008). Dentro de los modelos en los cuales se aplicó PLS se tuvo en cuenta el criterio de Akaike (AIC), el cual tiene en cuenta tanto el RMSE como el número de factores. El número de factores óptimo en cada modelo de validación se eligió teniendo en cuenta que el error del modelo fuera mínimo (Brereton, 2007; Wise *et al.*, 2006). El software *Uncrambler X* usado en este trabajo, proporciona las curvas de varianza explicada (o las curvas de varianza residual), tanto para la calibración como para la predicción obtenida por la validación cruzada donde se compararon dichas curvas para elegir el número de factores, no obstante automáticamente el programa arroja la solución más exacta según estas curvas.

Akaike, (1969) desarrolló un método denominado el criterio de información de Akaike (AIC) para la selección del modelo óptimo, es decir, aquél que representa la variabilidad de los datos sin sobreajuste. La ventaja de AIC frente a otros posibles indicadores como R^2 o RMSE es que éste tiene en cuenta el número de factores utilizados en el modelo penalizando la inclusión de factores que no mejoran significativamente el modelo. Minimizando este criterio se obtienen modelos más óptimos en la predicción. Esta herramienta fue usada en este trabajo para cada modelo (con 1,2,3,...,n factores) seleccionando como modelo óptimo aquél con un resultado menor al aplicar la ecuación AIC (menor AIC, mayor parsimonia). Se empleó la siguiente expresión para calcular AIC:

$$AIC = N \ln(RMSE) + 2 F \quad (\text{Ec.4.5})$$

donde N es el tamaño de la muestra y F el número de factores PLS.

4.4. Resultados

En conjunto se testaron 319 modelos para la estimación de cada una de las tres variables respuesta de biomasa (PV, PT y %PV). 18 de los modelos emplearon datos espectrales sin transformar y regresión PLS. 321 de los modelos se correspondieron con datos sin transformar y SVM. 558 implicaron transformaciones/índices y regresión PLS, y 60 se basaron en los índices derivados de la transformación CR y regresión OLS. Por lo tanto se ajustaron 957 modelos de predicción, a fin de encontrar las combinaciones más exactas entre el método de regresión, el tipo de transformación, el subconjunto espectral/zona/índice y el método de promedios de los espectros para la estimación de biomasa en los pastizales.

4.4.1. Estimaciones de biomasa empleando el método PLS

En este apartado se representan los resultados de los modelos obtenidos en la estimación de biomasa aérea, mediante la regresión PLS y aplicado este método estadístico a diferentes partes del espectro. A continuación se mostrarán tanto los resultados de los modelos obtenidos mediante transformaciones generales (correcciones de la línea base, correcciones de los efectos multiplicativos, normalizaciones, derivadas, absorbancia centrado y escalado) y en otro apartado los modelos obtenidos tras la transformación CR aplicada en las diferentes zonas de estudio del espectro.

4.4.1.1. Transformaciones generales

A continuación se muestran los resultados de los modelos PLS usando tanto el espectro sin transformaciones, como con las siguientes transformaciones (Tabla 4.6): CyE, SG, la transformación BLO y DE-TREN2, SNV, NME, también se usó la transformación RAB así como la MSCO. Se aplicó tanto al espectro medio como el espectro mediana.

La siguiente Tabla 4.6. muestra los valores de los estadísticos empleados para comparar los resultados de la regresión PLS a la hora de estimar las tres medidas de biomasa (PV, PT y %PV), indicando además si ese resultado (el más exacto) se obtuvo con el espectro medio o con la mediana. Los resultados completos para el espectro medio como la mediana se pueden consultar en el anexo I.

Tabla 4.6. Modelos de estimación de biomasa aérea (PV, PT, %PV) empleando PLS y el espectro transformado. ST: Espectro sin transformar; Transformaciones: CyE: Centrado y Escalado del espectro; SG: Transformación *Savitzky y Golay* 1° derivada; BL: Transformación *Baseline*; DE-TREN2: Transformación *De-trending* usando un polinomio de orden 2; SNV: Transformación aleatoria normal estándar; NME: Normalización usando la media; RAB: Transformación de reflectancia en absorbancia; MSCO ($X=X-a$): Corrección de dispersión multiplicativa. Zona a: VNIR, Zona b: VNIR+SWIR1, Zona c: VNIR+SWIR1+SWIR2; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE: %); AIC: criterio de información de Akaike. Se resaltan en negrita los resultados más exactos.

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

Transf.	Zona	PV						PT						%PV					
		R ²	RMSE	%RMSE	F	AIC	Espectro	R ²	RMSE	%RMSE	F	AIC	Espectro	R ²	RMSE	%RMSE	F	AIC	Espectro
ST	1	0,904	3,971	12,52	4	49,371	mediana	0,752	7,932	17,61	4	70,127	media	0,739	7,178	10,50	2	63,131	mediana
	2	0,938	3,200	10,09	6	46,895	media	0,802	7,080	15,72	3	64,718	media	0,670	8,070	11,81	1	64,645	mediana
	3	0,920	3,651	11,51	3	44,850	media	0,805	7,026	15,60	3	64,489	media	0,742	7,126	10,43	2	62,913	mediana
CyE	1	0,824	5,386	16,98	1	52,514	mediana	0,677	9,050	20,09	1	68,083	mediana	0,734	7,239	10,59	2	63,384	mediana
	2	0,918	3,679	11,60	3	45,079	mediana	0,783	7,421	16,47	3	66,129	media	0,734	7,243	10,60	4	67,401	mediana
	3	0,908	3,886	12,25	3	46,721	media	0,797	7,169	15,91	3	65,093	media	0,668	8,087	11,83	2	66,708	media
SG	1	0,950	2,879	9,08	2	35,723	media	0,925	4,356	9,67	2	48,147	media	0,904	4,360	6,38	2	48,174	media
	2	0,931	3,384	10,67	3	42,572	mediana	0,910	4,766	10,58	2	50,845	media	0,901	4,426	6,48	2	48,625	media
	3	0,911	3,836	12,09	1	42,333	media	0,923	4,417	9,80	2	48,564	media	0,942	3,367	4,93	2	40,421	media
CyE+SG	1	0,800	5,74	18,10	1	54,424	mediana	0,617	9,853	21,97	1	70,633	mediana	0,904	4,345	6,36	4	52,071	mediana
	2	0,938	3,187	10,05	2	38,772	media	0,815	6,859	15,23	1	59,767	mediana	0,869	5,080	7,43	3	54,759	media
	3	0,943	3,101	9,78	2	37,952	media	0,815	6,859	15,23	1	59,767	mediana	0,932	3,650	5,34	5	48,842	mediana
BLO	1	0,891	4,234	13,35	4	51,294	media	0,690	8,872	19,69	2	69,487	mediana	0,718	7,452	10,90	2	64,254	media
	2	0,898	4,094	12,91	1	44,286	mediana	0,782	7,440	16,51	3	66,206	mediana	0,742	7,127	10,43	2	62,917	media
	3	0,910	3,861	12,17	3	46,528	media	0,782	7,436	16,51	3	66,190	mediana	0,730	7,300	10,68	2	63,636	mediana
DE-TREN2	1	0,891	4,239	13,36	2	47,330	mediana	0,775	7,562	16,79	2	64,694	media	0,716	7,486	10,95	2	64,391	media
	2	0,900	4,129	13,02	1	44,541	media	0,781	7,441	16,52	2	64,210	media	0,664	8,134	11,90	1	64,882	media
	3	0,895	4,154	13,10	1	44,722	media	0,763	7,748	17,20	1	63,423	mediana	0,780	6,581	9,63	2	60,526	mediana
DE-TREN2+SNV	1	0,907	3,928	12,38	2	45,044	mediana	0,758	7,834	17,39	2	65,754	mediana	0,724	7,372	10,79	1	61,931	mediana
	2	0,907	3,923	12,37	2	45,006	mediana	0,796	7,190	15,96	2	63,181	media	0,687	7,857	11,50	1	63,842	mediana
	3	0,903	4,000	12,61	2	45,589	mediana	0,782	7,432	16,50	2	64,174	mediana	0,723	7,387	10,81	1	61,992	mediana
NME	1	0,913	3,783	11,93	3	45,916	mediana	0,776	7,530	16,71	2	64,567	media	0,722	7,402	10,83	2	64,053	media
	2	0,914	3,770	11,89	4	47,812	mediana	0,791	7,287	16,18	2	63,583	media	0,735	7,229	10,58	2	63,343	mediana
	3	0,892	4,225	13,32	2	47,231	mediana	0,769	7,651	16,98	2	65,045	media	0,742	7,130	10,43	2	62,929	media
RAB	1	0,828	5,336	16,82	2	54,234	mediana	0,671	9,141	20,29	1	68,383	media	0,918	4,001	5,85	6	53,596	mediana
	2	0,908	3,901	12,30	4	48,837	mediana	0,737	8,171	18,14	2	67,018	mediana	0,815	6,038	8,84	3	59,942	mediana
	3	0,898	4,103	12,94	1	44,352	media	0,733	8,23	18,27	1	65,234	media	0,764	6,816	9,97	3	63,578	media
MSCO (X=X-a)	1	0,919	3,647	11,50	3	44,817	mediana	0,895	5,158	11,45	6	61,216	media	0,816	6,127	8,97	2	58,381	media
	2	0,930	3,435	10,83	3	43,021	media	0,970	2,753	6,11	4	38,381	media	0,819	5,984	8,76	2	57,673	media

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

3	0,952	2,805	8,84	4	38,942	media	0,970	2,851	6,33	4	39,430	media	0,818	5,992	8,77	2	57,713	media
---	-------	-------	------	---	--------	-------	-------	-------	------	---	--------	-------	-------	-------	------	---	--------	-------

En la Tabla 4.6., se observa que los resultados más exactos del ajuste PLS, se han obtenido para el PV, mediante la transformación SG en el espectro medio y usando en el análisis la zona del VNIR. Mediante esta transformación se obtuvo el modelo de predicción más adecuado, de modo que con dos factores (F) se obtuvo un $R^2=0,95$ y un error en la predicción de $2,879 \text{ g/m}^2$ ($\%RMSE<9,1\%$), mientras que usando el espectro sin transformar como predictor las estimaciones no fueron tan exactas y se necesitaron más factores.

Para la biomasa aérea PT el modelo más exacto se obtuvo mediante la transformación MSCO, obteniendo un error en la predicción del modelo de $2,753 \text{ g/m}^2$ ($\%RMSE<6,2\%$) y un $R^2=0,97$ con 4 factores. Aunque se observa que el error es menor para en el PT al usar el criterio de información de Akaike (AIC), se penaliza el número de factores por lo que en la estimación de biomasa, mediante el PV se obtiene un modelo más adecuado.

En cuanto al %PV, la mejor estimación se obtiene nuevamente aplicando a los espectros la transformación SG, obteniendo un error en la predicción de $3,367\%$ ($\%RMSE<5\%$) y un $R^2=0,942$ usando 2 factores y el espectro medio completo.

4.4.1.2. Transformaciones CR

Se ha valorado en un apartado a parte la transformación CR, debido a que se llevó un estudio más detallado dentro de las diferentes transformaciones. A continuación se muestra la Tabla 4.7 con los resultados de aplicar la transformación CR a diferentes partes del espectro (Z1, Z2, Z3, Z4 y Z5), aplicando posteriormente el método PLS en la predicción de biomasa aérea (PV, PT, %PV). En la Tabla 4.7., siguiente se muestra qué espectro arrojó modelos más exactos.

Tabla 4.7. Modelos de estimación de biomasa aérea (PV, PT, %PV) empleando PLS y La transformación CR en 5 zonas diferentes del espectro (Z1, Z2, Z3, Z4, Z5). El espectro representa el espectro medio o el espectro mediana de los datos. F: número de factores latentes (PLS); R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: $\%$; $\%RMSE:\%$); AIC: criterio de información de Akaike. Se resalta los modelos más exactos.

Zonas	PV						PT						%PV					
	R ²	RMSE	%RMSE	F	AIC	Espectro	R ²	RMSE	%RMSE	F	AIC	Espectro	R ²	RMSE	%RMSE	F	AIC	Espectro
z1	0,804	5,690	17,94	2	56,161	mediana	0,616	9,864	21,89	1	70,667	media	0,821	5,940	8,69	4	61,451	mediana
z2	0,887	4,322	13,63	4	51,912	mediana	0,694	8,808	19,55	1	67,270	mediana	0,621	8,641	12,64	1	66,696	mediana
z3	0,888	4,295	13,54	1	45,724	mediana	0,682	8,988	19,95	1	67,877	mediana	0,591	8,977	13,14	1	67,840	media
z4	0,921	3,622	11,42	1	40,611	mediana	0,752	7,938	17,62	1	64,150	media	0,720	7,432	10,90	4	68,174	mediana
z5	0,861	4,788	15,10	2	50,983	media	0,698	8,752	19,43	1	67,078	media	0,625	8,602	12,59	1	66,560	mediana

El resultado más exacto del ajuste mediante la regresión PLS, se ha obtenido para el PV (Tabla 4.7.). Dividiendo las zonas del espectro para aplicar la transformación CR, los resultados del trabajo mostraron una mejor capacidad de predicción en la zona Z4, obteniéndose un error en la predicción de $3,622 \text{ g/m}^2$ (%RMSE<11,5%) y un modelo que explica más del 92% de la varianza del PV. Estos resultados se obtuvieron con el uso de un solo factor (F) para el espectro mediana mientras que empleando es espectro sin transformar como predictor las estimaciones no fueron tan exactas y se necesitaron 3 factores.

Para la biomasa aérea PT, empleando la zona Z4 se obtuvo un error en la predicción del modelo de $7,938 \text{ g/m}^2$ (%RMSE<18%) y un R^2 de 0,752 con un solo factor. En este caso respecto al espectro sin transformar mejoró los resultados obteniendo un AIC=64,150 frente a un AIC=64,489.

El %PV presenta como resultado más exacto el de la zona Z1, con un error en la predicción de 5,94% (%RMSE<8,7%) y un ajuste del 82% y 4 factores usando la mediana.

Los resultados completos de los modelos aplicados a la media y a la mediana del espectro se pueden consultar en el anexo I. Una vez obtenido los resultados mostrados en la Tabla 4.7, se realizaron combinaciones de dos, tres, cuatro y cinco zonas del espectro, con el fin de mejorar los resultados obtenidos al trabajar con las zonas por separado. Los resultados de los modelos obtenidos se muestran en la Tabla 4.8. .

Tabla 4.8. Modelos de estimación de biomasa aérea (PV, PT, %PV) empleando PLS a los resultados de combinar las diferentes zonas (Z1, Z2, Z3, Z4, Z5) donde se aplicó CR a los espectros. El espectro representa el espectro medio o el espectro mediana de los datos. F: número de factores latentes (PLS); R^2 : coeficiente de determinación; RMSE: (RMSE_{PV}: g/m^2 ; RMSE_{PT}: g/m^2 ; y RMSE_{%PV}: %; %RMSE:%); AIC: criterio de información de *Akaike*. Se resaltan los resultados más exactos.

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

Zonas	PV						PT						%PV					
	R ²	RMSE	%RMSE	F	AIC	Espectro	R ²	RMSE	%RMSE	F	AIC	Espectro	R ²	RMSE	%RMSE	F	AIC	Espectro
Z12	0,834	5,233	16,50	3	55,650	mediana	0,606	10,000	22,20	1	71,078	media	0,859	5,263	7,70	5	59,821	mediana
Z13	0,889	4,275	13,48	1	45,584	mediana	0,682	8,987	19,95	1	67,873	mediana	0,600	8,895	13,02	1	67,565	media
Z14	0,932	3,349	10,56	2	40,260	mediana	0,852	6,124	13,59	3	60,366	media	0,811	6,109	8,94	4	62,293	mediana
Z15	0,863	4,748	14,97	1	48,732	mediana	0,693	8,821	19,58	1	67,314	media	0,621	8,638	12,64	1	66,685	mediana
Z23	0,891	4,248	13,39	1	45,393	mediana	0,699	8,734	19,39	2	69,017	mediana	0,622	8,634	12,63	1	66,671	mediana
Z24	0,905	3,953	12,46	2	45,234	mediana	0,733	8,222	18,25	1	65,204	media	0,622	8,626	12,62	1	66,643	mediana
Z25	0,862	4,776	15,06	2	50,908	mediana	0,690	8,872	19,69	1	67,487	mediana	0,627	8,575	12,55	1	66,466	mediana
Z34	0,934	3,310	10,44	2	39,908	media	0,789	7,309	16,22	2	63,673	media	0,811	6,098	8,92	4	62,239	media
Z35	0,867	4,693	14,80	2	50,382	mediana	0,700	8,719	19,35	1	66,965	media	0,749	7,033	10,29	3	64,518	media
Z45	0,921	3,621	11,42	1	40,603	mediana	0,710	8,576	19,04	1	66,469	media	0,624	8,605	12,59	1	66,570	mediana
Z123	0,890	4,260	13,43	1	45,478	mediana	0,607	9,987	22,17	1	71,039	media	0,883	4,803	7,03	5	57,077	mediana
Z124	0,921	3,621	11,42	1	40,603	mediana	0,788	7,341	16,30	2	63,804	media	0,613	8,734	12,78	1	67,017	media
Z125	0,868	4,676	14,74	2	50,273	mediana	0,713	8,537	18,95	1	66,332	media	0,626	8,587	12,57	1	66,507	mediana
Z134	0,935	3,282	10,35	2	39,654	media	0,792	7,271	16,14	2	63,517	media	0,832	5,762	8,43	5	62,539	mediana
Z135	0,931	3,393	10,70	2	40,651	media	0,785	7,378	16,38	2	63,955	media	0,622	8,635	12,64	1	66,675	mediana
Z145	0,921	3,621	11,42	1	40,603	mediana	0,734	8,207	18,22	1	65,150	mediana	0,621	8,638	12,64	1	66,685	mediana
Z234	0,920	3,750	11,82	1	41,653	media	0,789	7,321	16,25	2	63,722	media	0,623	8,619	12,61	1	66,619	mediana
Z235	0,866	4,698	14,81	2	50,414	mediana	0,713	8,529	18,93	1	66,304	media	0,625	8,602	12,59	1	66,560	mediana
Z245	0,881	4,424	13,95	2	48,611	mediana	0,833	6,501	14,43	3	62,159	media	0,627	8,571	12,54	1	66,452	mediana
Z345	0,891	4,235	13,35	2	47,301	mediana	0,710	8,577	19,04	1	66,473	media	0,625	8,602	12,59	1	66,560	mediana
Z1234	0,934	3,304	10,42	2	39,854	media	0,782	7,433	16,50	2	64,178	media	0,708	7,585	11,10	4	68,785	mediana
Z1235	0,873	4,578	14,43	2	49,638	mediana	0,697	8,764	19,45	1	67,120	mediana	0,626	8,585	12,56	1	66,500	mediana
Z1245	0,922	3,581	11,29	1	40,269	media	0,731	8,258	18,33	1	65,335	mediana	0,626	8,584	12,56	1	66,497	mediana
Z1345	0,921	3,620	11,41	1	40,594	mediana	0,785	7,378	16,38	2	63,955	media	0,622	8,635	12,64	1	66,675	mediana
Z2345	0,884	4,380	13,81	2	48,311	media	0,750	7,962	17,67	1	64,240	media	0,627	8,569	12,54	1	66,445	mediana
Z12345	0,940	3,176	10,01	2	38,669	media	0,733	8,233	18,28	1	65,245	media	0,626	8,582	12,56	1	66,490	mediana

En la Tabla 4.8., se observa que los modelos más exactos se han obtenido para el PV, obteniéndose en todas las predicciones modelos con un error por debajo de 6 g/m^2 ($\%RMSE < 16,5\%$) y un R^2 por encima de 0,80. El resultado más exacto se obtuvo combinando las 5 zonas del espectro. Mediante esta combinación se obtuvo, con dos factores (F), un $R^2=0,94$ y un error en la predicción de $3,176 \text{ g/m}^2$ ($\%RMSE=10,01\%$).

Para la biomasa aérea PT todos los modelos predictivos en las diferentes combinaciones obtuvieron un RMSE menor o igual a 10 g/m^2 $\%RMSE < 22,3\%$ y un R^2 por encima de 0,60. El modelo más exacto se obtuvo mediante la combinación de dos zonas (Z1 y Z4) para el espectro medio, obteniendo un error en la predicción del modelo de $6,124 \text{ g/m}^2$ ($\%RMSE < 13,6\%$). y un $R^2=0,85$ usando 3 factores.

En cuanto al %PV, todos los modelos predictivos en las diferentes combinaciones obtuvieron resultados con un error menor a 9% ($\%RMSE < 13,1\%$ y un R^2 mayor a 0,60. La mejor estimación se obtuvo mediante la combinación de 3 zonas (Z1, Z2 y Z3), obteniendo un error en la predicción de $4,803 \text{ g/m}^2$ ($\%RMSE < 7,1\%$). y un $R^2=0,88$ usando 5 factores y el espectro mediana.

4.4.2. Estimaciones de biomasa empleando el método SVM

En este apartado se representan los resultados de los modelos obtenidos en la estimación de biomasa aérea, mediante el uso del método estadístico SVM así como su aplicación en las diferentes partes del espectro. La siguiente Tabla 4.9., muestra un resumen de los resultados tras aplicar el método SVM, tanto a las medias como a las medianas espectrales del espectro sin transformar. En el anexo 1 se muestran todas las tablas usadas para la estimación del resto de los modelos más exactos a partir del parámetro “C”.

Tabla 4.9. Modelos de estimación de biomasa aérea (PV, PT y %PV) empleando SVM en diferentes zonas espectrales (VNIR, VNIR+SW1, VNIR+SW1+SW2) al usar las medias o las medianas espectrales; R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: $\%$; $\%RMSE$: $\%$); C: parámetro, SVs: vectores soporte; Gama: 1, Épsilon: 0,1. Se resaltan en negrita los resultados más exactos.

		MEDIAS					MEDIANAS				
		SVs	C	R^2	RMSE	$\%RMSE$	SVs	C	R^2	RMSE	$\%RMSE$
VNIR	PV	20	0,58	0,842	4,960	15,64	21	0,16	0,846	4,895	15,43
	PT	21	0,1	0,671	8,862	19,67	21	0,11	0,684	8,691	19,29
	%PV	25	0,1	0,724	7,134	10,44	25	0,07	0,701	7,240	10,59
VNIR +	PV	17	0,14	0,909	3,759	11,85	21	0,18	0,906	3,811	12,02

SW1	PT	16	0,1	0,750	7,681	17,05	18	0,02	0,738	7,860	17,45
	%PV	25	0,02	0,650	8,047	11,78	21	0,001	0,635	8,221	12,03
VNIR + SW1+SW2	PV	16	0,1	0,933	3,229	10,18	19	0,11	0,917	3,622	11,42
	PT	16	0,03	0,745	7,780	17,27	18	0,02	0,721	8,102	17,98
	%PV	25	0,01	0,635	8,214	12,02	26	0,02	0,655	7,991	11,69

En la Tabla 4.9., se observan resultados muy similares al usar las medias o las medianas. En la estimación de biomasa en PV observamos que el resultado más exacto se alcanza cuando la estimación se hace usando el espectro completo (VNIR + SWIR1 + SWIR2), obteniéndose un $R^2=0,93$ y un $RMSE=3,229 \text{ g/m}^2$ ($\%RMSE<10,2\%$). en el caso de las medias. En la estimación de biomasa referente al PT, se obtienen resultados más exactos si la estimación se realiza usando únicamente la parte del espectro VNIR + SWIR1 como en el caso de las medias obteniendo un modelo en la estimación con un $R^2=0,75$ y $RMSE=7,681 \text{ g/m}^2$ ($\%RMSE<17,1\%$). Finalmente la estimación más exacta en %PV se obtiene en la parte del espectro VNIR con un $R^2=0,72$ tanto en las medias como en las medianas y un $\%RMSE<7,6\%$).

4.4.3. Estimaciones de biomasa empleando índices derivados del CR y el método OLS

La Tabla 4.10., muestra los valores de los estadísticos empleados para comparar los resultados del empleo de índices derivados del CR y la regresión lineal (OLS) a la hora de estimar las tres medidas de biomasa aérea (PV, PT y %PV).

Los resultados más exactos se han obtenido para el PV. Dividiendo el espectro en zonas, se observa que en la zona 4 se obtuvieron los resultados más exactos en la estimación a partir de los dos índices derivados de la transformación CR. La idoneidad de este método disminuyó rápidamente cuando se utilizaron otras zonas de absorción. Aunque los resultados son semejantes, en todos los casos, el índice AOM produjo modelos más precisos que el índice MBD para predecir la biomasa aérea. Por un lado usando el índice AOM de la zona 4 se obtuvo un error en la predicción de $3,615 \text{ g/m}^2$ ($\%RMSE<11,4\%$) para el PV y un $R^2=0,915$, mientras que usando el índice MBD para la misma zona 4 se obtuvo un $RMSE=3,720 \text{ g/m}^2$ ($\%RMSE <11,8\%$) y un $R^2=0,910$.

Al analizar los resultados para la estimación de PT, de nuevo los índices de la zona 4 proporcionaron la solución más exacta. El modelo construido con el índice MBD logra predecir con un error $8,30 \text{ g/m}^2$ ($\%RMSE<18,5\%$) y un ajuste del 71%, y el índice (AOM) predice con un error del $8,15 \text{ g/m}^2$ ($\%RMSE<18,1\%$) y un ajuste del 72%. El

(%PV) presenta el mejor resultado para ambos índices en la zona 5 con errores de predicción de 8,502% (%RMSE<12,5%) y 8,648 (%RMSE<12,7%) para los modelos contruidos con el índice MBD y AOM respectivamente y un ajuste en torno al 60% en ambos casos.

Tabla 4.10. Modelos de estimación de biomasa aérea (PV, PT y %PV) empleando OLS, en las diferentes zonas del CR (Z1, Z2, Z3, Z4, Z5). El espectro representa el espectro medio o el espectro mediana de los datos. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; R²: coeficiente de determinación; RMSE: (RMSE_{PV}: g/m²; RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); Se resaltan en negrita los resultados más exactos.

	Zona	Espectro	MBD			AOM				
			R ²	RMSE	%RMSE	Zona	Espectro	R ²	RMSE	%RMSE
PV	Z1	Mediana	0,728	6,483	20,44	Z1	Media	0,722	6,546	20,64
	Z2	Mediana	0,669	7,146	22,53	Z2	Mediana	0,719	6,587	20,77
	Z3	Media	0,870	4,470	14,09	Z3	Media	0,866	4,550	14,34
	Z4	Mediana	0,910	3,720	11,73	Z4	Mediana	0,915	3,615	11,40
	Z5	Media	0,743	6,293	19,84	Z5	Mediana	0,797	5,593	17,63
PT	Z1	Mediana	0,582	9,950	22,09	Z1	Media	0,594	9,810	21,78
	Z2	Media	0,537	10,476	23,25	Z2	Mediana	0,577	10,008	22,22
	Z3	Mediana	0,650	9,110	20,22	Z3	Media	0,641	9,226	20,48
	Z4	Media	0,709	8,301	18,43	Z4	Media	0,720	8,150	18,09
	Z5	Media	0,599	9,748	21,64	Z5	Media	0,642	9,216	20,46
%PV	Z1	Mediana	0,567	8,931	13,07	Z1	Mediana	0,554	9,064	13,26
	Z2	Mediana	0,603	8,551	12,51	Z2	Mediana	0,591	8,674	12,69
	Z3	Mediana	0,557	9,034	13,22	Z3	Media	0,552	9,080	13,29
	Z4	Mediana	0,524	9,359	13,70	Z4	Media	0,523	9,370	13,71
	Z5	Mediana	0,608	8,502	12,44	Z5	Mediana	0,594	8,648	12,65

Los resultados completos de los modelos aplicados a la media y a la mediana del espectro se pueden consultar en el anexo I.

4.4.4. Estimaciones de biomasa empleando índices derivados de la transformación CR y el método PLS.

Las zonas de absorción del espectro que permitieron obtener modelos de estimación más exactos mediante índices derivados de la transformación CR y OLS fueron las regiones Z4 (PV y PT) y Z5 (%PV), lo que sugiere el potencial de las zonas para estimar la biomasa aérea. Por lo tanto, mediante PLS se ajustaron modelos con los índices derivados del CR (MBD y AOM) para diferentes zonas de absorción (incluyendo Z4 y Z5). La regresión OLS no se consideró con el fin de evitar problemas de colinealidad. A continuación se muestran en la Tabla 4.11., un resumen de los

resultados de ajustar estos modelos para PV, indicando si las estimaciones más exactas se obtuvieron con la media o la mediana del espectro.

Tabla 4.11. Modelos de estimación de biomasa aérea (PV) empleando PLS, los índices derivados del CR y considerando la zona de absorción espectral Z4 en las combinaciones. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos.

Zonas	MBD						AOM					
	R^2	RMSE	%RMSE	F	Espectro	AIC	R^2	RMSE	%RMSE	F	Espectro	AIC
Z1,4	0,914	3,762	5,37	2	Media	43,747	0,924	3,539	5,06	2	Media	41,917
Z2,4	0,913	3,783	5,40	2	Mediana	43,917	0,918	3,675	5,25	2	Media	43,048
Z3,4	0,919	3,661	5,23	2	Media	42,932	0,929	3,433	4,90	2	Media	41,002
Z4,5	0,913	3,786	5,41	2	Mediana	43,942	0,921	3,607	5,15	2	Mediana	42,486
Z1,2,4	0,915	3,745	5,35	3	Mediana	45,616	0,925	3,512	5,02	3	Mediana	43,689
Z1,3,4	0,923	3,566	5,09	3	Mediana	44,144	0,939	3,172	4,53	3	Media	40,631
Z1,4,5	0,918	3,689	5,27	2	Media	43,160	0,922	3,599	5,14	3	Media	44,422
Z2,3,4	0,915	3,738	5,34	3	Media	45,555	0,929	3,432	4,90	3	Media	42,997
Z2,4,5	0,900	4,060	5,80	2	Media	46,039	0,921	3,607	5,15	3	Mediana	44,486
Z3,4,5	0,915	3,755	5,36	3	Media	45,691	0,931	3,377	4,83	3	Media	42,511
Z1,2,3,4	0,922	3,588	5,13	3	Mediana	44,325	0,939	3,173	4,53	4	Media	42,636
Z1,2,4,5	0,913	3,782	5,40	3	Media	45,904	0,921	3,618	5,17	4	Mediana	46,578
Z1,3,4,5	0,917	3,703	5,29	3	Mediana	45,274	0,936	3,249	4,64	4	Media	43,353
Z2,3,4,5	0,898	4,098	5,85	2	Media	46,313	0,929	3,427	4,90	4	Media	44,946
Z1,2,3,4,5	0,917	3,702	5,29	3	Mediana	45,262	0,931	3,367	4,81	5	Media	46,422

Los resultados de la Tabla 4.11., indican que el modelo PLS que considera el índice de AOM derivado del CR en las zonas entre 440 y 567 nm (Z1), 916 y 1.120 nm (Z3) y 1.079 y 1.297 nm (Z4) ($R^2=0,939$; $RMSE=3,172 g/m^2$; %RMSE<4,6%) del espectro media, tan solo con 3 factores se obtiene un AIC=40,631, el menor obtenido en todas las combinaciones de zonas, siendo el modelo más preciso para predecir el PV. A continuación se muestran en la Tabla 4.12., un resumen de los resultados de ajustar estos modelos para PT, indicando si las estimaciones más exactas se obtuvieron con la media o la mediana del espectro.

Tabla 4.12. Modelos de estimación de biomasa aérea (PT) empleando PLS, los índices derivados del CR y considerando la zona de absorción espectral Z4 en las combinaciones. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R^2 : coeficiente de determinación tras aplicar la validación cruzada; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos.

Zonas	MBD						AOM					
	R ²	RMSE	%RMSE	F	Espectro	AIC	R ²	RMSE	%RMSE	F	Espectro	AIC
Z1,4	0,709	8,595	19,08	2	Mediana	68,534	0,708	8,612	19,12	2	Mediana	68,593
Z2,4	0,724	8,369	18,58	2	Mediana	67,736	0,721	8,406	18,66	2	Mediana	67,870
Z3,4	0,800	7,120	15,81	2	Mediana	62,889	0,719	8,436	18,73	2	Mediana	67,974
Z4,5	0,725	8,347	18,53	2	Mediana	67,659	0,723	8,386	18,62	2	Mediana	67,798
Z1,2,4	0,683	8,971	19,91	2	Mediana	69,819	0,679	9,023	20,03	2	Mediana	69,993
Z1,3,4	0,786	7,375	16,37	3	Mediana	65,944	0,727	8,317	18,46	3	Mediana	69,548
Z1,4,5	0,685	8,934	19,83	2	Mediana	69,697	0,692	8,838	19,62	2	Mediana	69,371
Z2,3,4	0,792	7,270	16,14	3	Mediana	65,513	0,736	8,178	18,15	2	Media	67,045
Z2,4,5	0,710	8,579	19,04	2	Media	68,480	0,705	8,646	19,19	2	Media	68,715
Z3,4,5	0,794	7,237	16,06	3	Mediana	65,376	0,730	8,274	18,37	3	Mediana	69,394
Z1,2,3,4	0,772	7,599	16,87	4	Mediana	68,842	0,739	8,144	18,08	3	Mediana	68,918
Z1,2,4,5	0,679	9,025	20,03	2	Media	70,001	0,672	9,121	20,25	2	Mediana	70,318
Z1,3,4,5	0,772	7,611	16,89	4	Mediana	68,888	0,716	8,489	18,84	3	Mediana	70,162
Z2,3,4,5	0,780	7,473	16,59	4	Mediana	68,339	0,725	8,347	18,53	2	Mediana	67,656
Z1,2,3,4,5	0,758	7,832	17,39	5	Mediana	71,747	0,724	8,360	18,56	2	Media	67,702

Los resultados mostrados en la Tabla 4.12., indican que el modelo PLS que considera el índice de MBD derivado del CR en las zonas entre 916 y 1.120 nm (Z3) y 1.079 y 1.297 nm (Z4) ($R^2=0,800$; $RMSE=7,120$ g/m²; %RMSE<16%) del espectro mediana, tan solo con 2 factores se obtiene un AIC=62,889, el menor obtenido en todas las combinaciones de zonas y siendo el modelo más preciso para predecir el PT

A continuación se muestran en la Tabla 4.13., un resumen de los resultados de ajustar estos modelos para %PV, indicando si las estimaciones más exactas se obtuvieron con la media o la mediana del espectro.

Tabla 4.13. Modelos de estimación de biomasa aérea (%PV) empleando PLS, los índices derivados del CR y considerando la zona de absorción espectral Z5 en las combinaciones. MBD: índice de profundidad; AOM: índice del área sobre el mínimo; Espectro: espectro medio o el espectro mediana de los datos; F: número de factores latentes (PLS); R²: coeficiente de determinación tras aplicar la validación cruzada; RMSE: (RMSE_{PV}: g/m²; RMSE_{PT}: g/m²; y RMSE_{%PV}: %; %RMSE:%); AIC: criterio de información de Akaike. Se resaltan en negrita los resultados más exactos.

Zonas	MBD						AOM					
	R ²	RMSE	%RMSE	F	Espectro	AIC	R ²	RMSE	%RMSE	F	Espectro	AIC
Z1,5	0,620	8,650	12,66	1	Mediana	66,726	0,619	8,660	12,67	1	Mediana	66,761
Z2,5	0,633	8,509	12,45	1	Mediana	66,233	0,625	8,592	12,57	1	Mediana	66,5262
Z3,5	0,678	7,972	11,67	2	Mediana	66,278	0,616	8,697	12,73	1	Media	66,889
Z4,5	0,634	8,488	12,42	1	Mediana	66,161	0,620	8,651	12,66	1	Mediana	66,729
Z1,2,5	0,629	8,552	12,51	1	Mediana	66,384	0,625	8,599	12,58	1	Mediana	66,551
Z1,3,5	0,648	8,328	12,19	3	Mediana	69,588	0,614	8,722	12,76	1	Media	66,974
Z1,4,5	0,622	8,637	12,64	1	Mediana	66,680	0,619	8,662	12,67	1	Mediana	66,767
Z2,3,5	0,675	8,009	11,72	3	Mediana	68,416	0,684	7,897	11,56	3	Mediana	67,994
Z2,4,5	0,634	8,489	12,42	1	Mediana	66,164	0,625	8,592	12,57	1	Mediana	66,526
Z3,4,5	0,630	8,539	12,49	1	Media	66,339	0,616	8,699	12,73	1	Media	66,895
Z1,2,3,5	0,620	8,655	12,66	1	Media	66,743	0,679	7,956	11,64	3	Mediana	68,218
Z1,2,4,5	0,630	8,539	12,49	1	Mediana	66,339	0,625	8,599	12,58	1	Mediana	66,550
Z1,3,4,5	0,610	8,763	12,82	1	Media	67,117	0,614	8,723	12,76	1	Media	66,978
Z2,3,4,5	0,667	8,105	11,86	3	Mediana	68,774	0,667	8,105	11,86	3	Mediana	68,774
Z1,2,3,4,5	0,621	8,642	12,64	1	Media	66,698	0,669	8,080	11,82	3	Mediana	68,684

Los resultados mostrados en la Tabla 4.13., indican que el modelo PLS que considera el índice MBD derivado del CR en la zona entre 916 y 1.120 nm (Z4) y la zona entre 1265 y 1676 nm (Z5), ($R^2=0,634$; $RMSE=8,488\%$; $\%RMSE <12,5\%$) del espectro mediana, tan solo con un factor se obtiene un $AIC=66,161$ el menor obtenido en todas las combinaciones de zonas y siendo el modelo más preciso para predecir el %PV.

4.4.5. Estimaciones de biomasa: resumen de resultados

Como resultado del análisis exhaustivo de las relaciones entre PV, PT y %PV de biomasa aérea de gramíneas/trébol y los datos espectrales (transformados y no transformados), la Tabla 4.14., muestra los resultados más exactos para los diferentes enfoques que se han testado. Debido a la gran cantidad de resultados obtenidos, sólo se muestran las siguientes salidas:

- (i) Modelos ajustados mediante PLS y SVM en cada subconjunto espectral (no transformado).
- (ii) Modelos más precisos en cada subconjunto espectral.
- (iii) Modelos más precisos combinando PLS y CR, así como PLS y los índices derivados del CR.
- (iv) Modelos más precisos basados los índices derivados del CR y OLS.

Los resultados se muestran en el orden de exactitud (R^2) decreciente para cada variable. Los resultados representados en la Tabla 4.14 se comentan en los apartados 4.4.5.1, 4.4.5.2., y 4.4.5.3, para cada variable independiente.

Tabla 4.14. Resumen de los modelos de estimación de biomasa aérea (PV, PT y %PV) empleando PLS, SVM, OLS y transformaciones espectrales. El espectro representa el espectro media o el espectro mediana de los datos. F/C: número de factores latentes (PLS) o el parámetro C (SVM); R^2 : coeficiente de determinación; RMSE: ($RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; $\%RMSE$: %); AIC: criterio de información de Akaike. Se resaltan los resultados más exactos.

Var.	Modelo de regresión/ Transformación	Datos de entrada	Espectro	F/C	R^2	RMSE	%RMSE	AIC
PT	PLS/MSCO	VNIR+SWIR1	Media	4	0,970	2,753	6,11	38,381
	PLS/MSCO	VNIR+SWIR1+SWIR2	Media	4	0,970	2,851	6,33	39,430
	PLS/SG	VNIR	Media	2	0,925	4,356	9,67	48,147
	PLS/CR/COMB	Z1-Z4	Media	3	0,852	6,124	13,59	60,366

	PLS/CR/SG	Z2	Media	2	0,803	7,060	15,67	62,633	
	PLS/ninguna	VNIR+ SWIR1+SWIR2	Media	3	0,805	7,026	15,60	64,489	
	PLS/ninguna	VNIR+ SWIR1	Media	3	0,802	7,080	15,72	64,718	
	PLS/MBD	Z3-Z4 (MBD)	Media	2	0,800	7,120	15,80	62,887	
	PLS/ninguna	VNIR	Media	4	0,752	7,932	17,61	70,127	
	PLS/CR	Z4	Media	1	0,752	7,938	17,62	64,150	
	SVM/ninguna	VNIR+ SWIR1	Media	0,04	0,751	7,684	17,06	-	
	SVM/ninguna	VNIR+SWIR1+SWIR2	Media	0,03	0,745	7,780	17,27	-	
	OLS/AOM	Z4 (AOM)	Media	1	0,720	8,150	18,09	-	
	SVM/ninguna	VNIR	Mediana	0,11	0,683	8,690	19,29	-	
	PLS/SG	VNIR	Media	2	0,950	2,879	9,08	35,723	
	PLS/CYE/SG	VNIR+SWIR1+SWIR2	Media	2	0,943	3,101	9,78	37,952	
	PLS/CR/COMB	Z1-Z2-Z3-Z4-Z5	Media	2	0,940	3,176	10,01	38,669	
	PLS/AOM	Z1-Z3-Z4 (AOM)	Media	3	0,939	3,172	10,00	40,631	
	PLS/ninguna	VNIR+SWIR1	Media	6	0,938	3,200	10,09	46,895	
	SVM/ninguna	VNIR+SWIR1+SWIR2	Media	0,1	0,933	3,229	10,18	-	
PV	PLS/SG	VNIR+SWIR1	Mediana	3	0,931	3,384	10,67	42,572	
	PLS/CR	Z4	Mediana	1	0,921	3,622	11,42	40,611	
	PLS/ninguna	VNIR+SWIR1+SWIR2	Media	3	0,920	3,651	11,51	44,850	
	PLS/CR/SG	Z4	Mediana	1	0,915	3,749	11,82	41,645	
	OLS/AOM	Z4 (AOM)	Media	1	0,914	3,646	11,49	-	
	SVM/ninguna	VNIR+SWIR1	Media	0,14	0,909	3,759	11,85	-	
	PLS/ninguna	VNIR	Mediana	4	0,904	3,971	12,52	49,371	
	SVM/ninguna	VNIR	Mediana	0,16	0,846	4,895	15,43	-	
		PLS/SG	VNIR+SWIR1+SWIR2	Media	2	0,942	3,367	4,93	40,421
		PLS/SG	VNIR	Media	2	0,904	4,360	6,38	48,174
	PLS/SG	VNIR+SWIR1	Media	2	0,901	4,426	6,48	48,625	
	PLS/CR/COMB	Z1-Z2-Z3	Mediana	5	0,883	4,803	7,03	57,077	
	PLS/CR/SG	Z1	Mediana	2	0,831	5,767	8,44	56,565	
	PLS/CR	Z1	Mediana	4	0,821	5,940	8,69	61,451	
	PLS/ninguna	VNIR+SWIR1+SWIR2	Mediana	2	0,742	7,126	10,43	62,913	
	PLS/ninguna	VNIR	Mediana	2	0,739	7,178	10,50	63,131	
	SVM/ninguna	VNIR	Media	0,07	0,724	7,134	10,44	-	
	PLS/ninguna	VNIR+SWIR1	Mediana	1	0,670	8,070	11,81	64,645	
	SVM/ninguna	VNIR+SWIR1+SWIR2	Mediana	0,02	0,655	7,991	11,69	-	
	SVM/ninguna	VNIR+SWIR1	Media	0,02	0,650	8,047	11,77	-	
	PLS/AOM	Z4-Z5 (AOM)	Mediana	1	0,634	8,488	12,42	66,161	
	OLS/MBD	Z5	Mediana	1	0,608	8,502	12,44	-	

4.4.5.1. Modelos para la estimación de la biomasa aérea (Peso Total, PT)

Como se muestra en la Tabla 4.14., los modelos PLS producen valores más bajos de RMSE que el SVM o el OLS considerando los mismos datos de entrada. El modelo más exacto para predecir la biomasa aérea representada como PT sobre el suelo, se obtiene usando PLS y la transformación MSCO en la zona espectral VNIR+SWIR1 (RMSE=2,753 g/m²; %RMSE<6,2%) usando 4 factores.

Fijándonos en la estimación de biomasa aérea referida a PT, la combinación de zonas tras aplicar PLS y CR produjo rangos más bajos de error en el análisis de la validación cruzada (RMSE=6,124 g/m²; %RMSE<14%), así como para el criterio AIC, en comparación con la combinación PLS/CR (RMSE=7,932 g/m²; %RMSE<17,7%) o la combinación PLS/CR más una transformación, obteniéndose en el mejor de los casos un

$RMSE=7,060 \text{ g/m}^2$, ($\%RMSE<15,7\%$). Teniendo en cuenta el análisis comparativo entre los modelos PLS y los modelos SVM no transformado utilizado como datos de entrada, se mostró un mayor R^2 y menor RMSE para los modelos PLS. En ese caso, se obtuvieron los modelos más precisos mediante el subconjunto VNIR + SWIR1+ SWIR2, tanto para PLS ($R^2=0,805$; $RMSE=7,026 \text{ g/m}^2$; $\%RMSE<15,7\%$) y SVM ($R^2=0,751$; $RMSE=7,684 \text{ g/m}^2$; $\%RMSE<17,1\%$) (Tabla 4.14).

La combinación del índice MBD derivado del CR en la Z3 y Z4 así como la posterior aplicación de PLS, permite obtener estimaciones más exactas según el criterio de AIC, que usar PLS sin ninguna transformación. Esto es debido a su bajo número de factores (2), aunque los resultados de exactitud sean muy similares (R^2 , RMSE y $\%RMSE$).

Con el fin de comparar la idoneidad de los modelos obtenidos empleando PLS y SVM, la Figura 4.6., muestra la distribución de valores medidos y predichos de la validación cruzada. Ambos modelos eran adecuados ya que los valores medidos y predichos se distribuyen a lo largo de la recta 1:1 y próximos a ella.

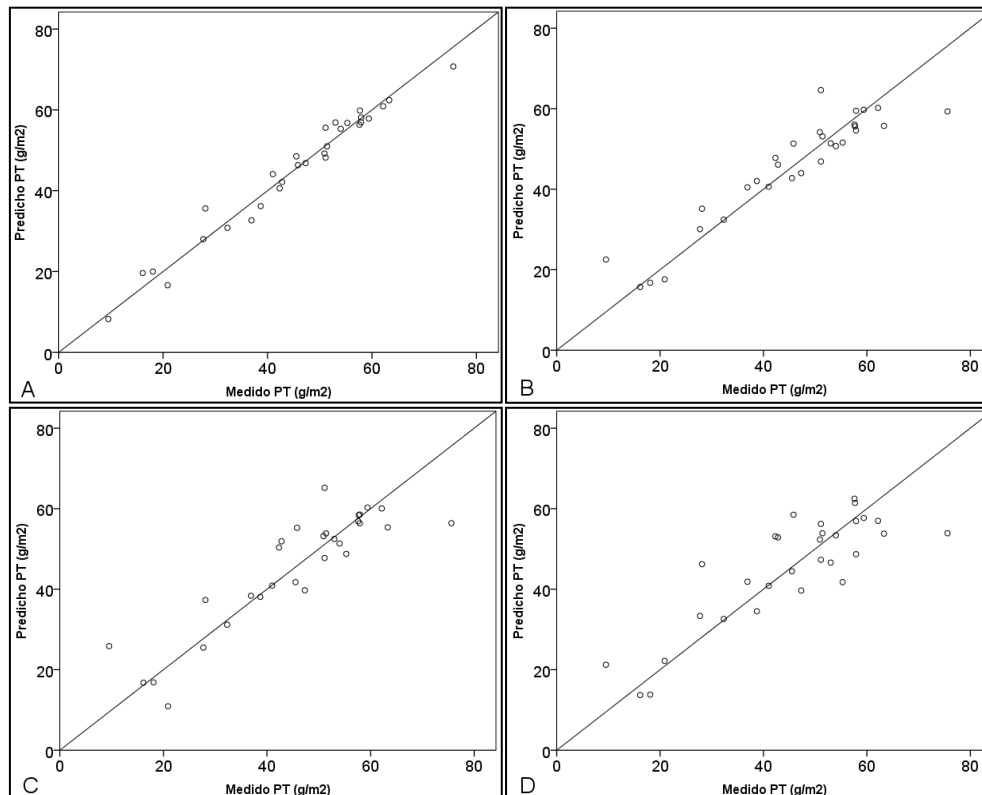


Figura 4.6. Resultados de la validación cruzada en la estimación de biomasa aérea usando (A) PLS mediante la transformación MSCO (B) SVM aplicado en la zona espectral VNIR + SWIR1

(C) PLS sin transformaciones en la zona espectral VNIR + SWIR1 + SWIR2 y (D) OLS a partir del AOM en la zona Z4. Se muestra la línea 1:1

La regresión OLS proporcionó los resultados más exactos cuando se utilizó el índice de la AOM derivado de la aplicación del CR en la función de absorción entre 1079 y 1297 nm (Z4) (RMSE=8,150 g/m², %RMSE<18,1%). Este enfoque resultó ser más preciso y más simple que usando SVM y la reflectancia no transformada del subconjunto VNIR.

4.4.5.2. Modelos para la estimación de la biomasa aérea (Peso Verde seco, PV)

Si la predicción de biomasa aérea es representada como PV, el modelo más exacto (RMSE=2,879 g/m²; %RMSE<9,1) se obtiene en la zona VNIR mediante la transformación *Savitzky y Golay* y aplicando el método estadístico PLS obteniendo un modelo con solo dos factores y un R²=0,95.

Los datos no transformados modelados por SVM fueron capaces de explicar en la estimación de biomasa aérea (PV), el 93,3% de la varianza de los datos (RMSE=3,229 g/m²; %RMSE<10,2%) usando el espectro depurado (VNIR + SWIR1+ SWIR2).

Utilizando la transformación CR no mejoró el rendimiento del modelo PLS tras la transformación de SG, aunque se obtuvieron resultados muy próximos (R²=0,94; RMSE=3,176 g/m²; %RMSE<10,1%) combinando las 5 zonas donde se realizaron la transformación de manera independiente.

Al aplicar PLS a los datos obtenidos del índice de AOM derivado del CR en las zonas (Z1, Z3, Z4) se obtuvo un modelo más preciso (R²=0,938; RMSE=3,2 g/m²; %RMSE<11%) que usar PLS sin ningún tipo de transformación (R²=0,939; RMSE=3,172 g/m²; %RMSE<11%) Aunque son modelos muy similares, al usar el índice AOM se reduce de 6 a 3 el número de factores.

El modelo ajustado por regresión OLS para el índice AOM (zona de absorción Z4) resultó más exacto (R²=0,914; RMSE=3,646 g/m²; %RMSE<12%) que otros modelos de regresión PLS y SVM más complejos. En la Tabla 4.14, se muestra que los resultados de la regresión OLS y el índice derivado del CR fueron satisfactorios, siempre y cuando la zona de absorción fuera la Z4, logrando un R²=0,914 y un error en la predicción de 3,646 g/m² (%RMSE<12,5%).

El análisis comparativo de los resultados de los modelos de regresión PLS y SVM mostraron mayor R^2 así como un menor RMSE y %RMSE en los modelos de PLS sólo cuando los subconjuntos espectrales no transformados utilizados eran diferentes de VNIR + SWIR1 + SWIR2, en cuyo caso SVM era el más exacto. La Figura 4.7 muestra la idoneidad de los modelos PLS y SVM más precisos, de acuerdo con los resultados de la validación cruzada.

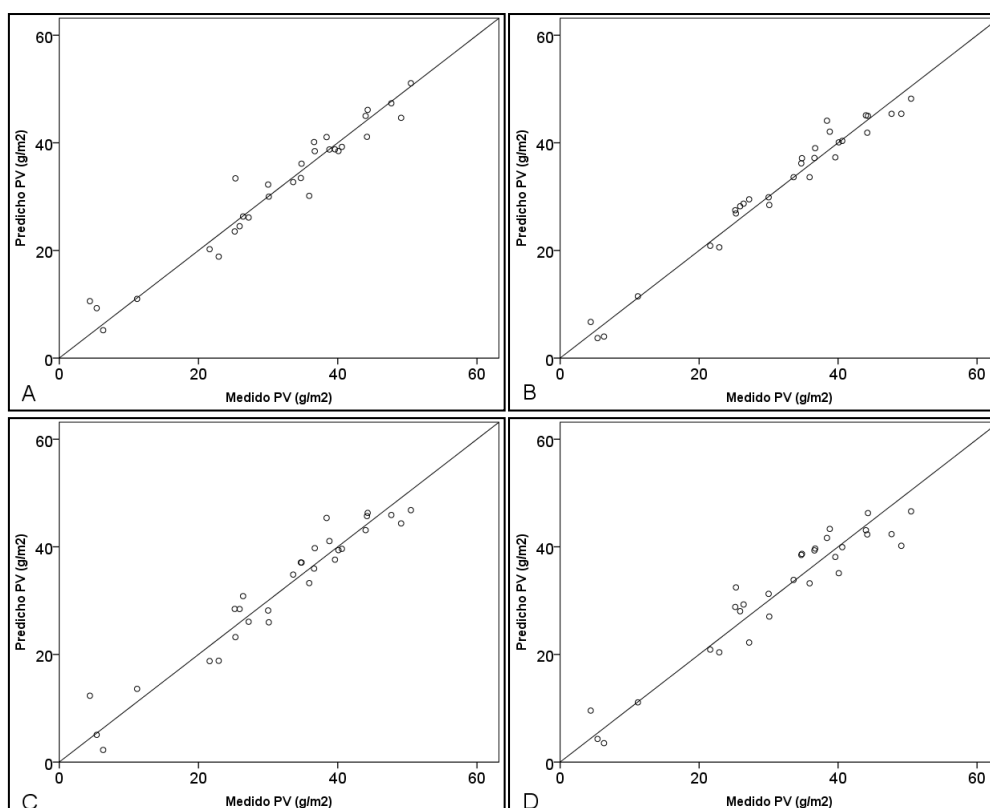


Figura 4.7. Resultados de la validación cruzada en la predicción de PV usando (A) Regresión PLS tras la transformación SG aplicado al subconjunto espectral VNIR, (B) SVM aplicado al subconjunto espectral VNIR+SWIR1+SWIR2, (C) Regresión PLS sin transformación aplicado en el subconjunto espectral VNIR+SWIR1 y (D) Regresión OLS a partir del AOM en la zona Z4. Se muestra la línea 1:1

4.4.5.3. Modelos para la estimación de la biomasa aérea (Porcentaje de peso verde seco, %PV)

Los modelos con un error menor y mayor R^2 al estimar el %PV, se caracterizan por el uso del método PSL tras la transformación SG. El modelo más exacto fue el

estudiado en la zona VNIR + SW1 + SW2 ($R^2=0,942$; $RMSE=3,367\%$; $\%RMSE<5\%$), siendo este modelo altamente fiable.

La combinación de las zonas Z1, Z2 y Z3 del CR, tras aplicar PLS produjo errores más bajos en el análisis de la validación cruzada ($RMSE=4,803\%$; $\%RMSE<7,1\%$.) sin embargo se usaron un número elevado de factores (5). En cualquier caso siempre se obtienen modelos más exactos usando la transformación CR que usando PSL sin ningún tipo de transformación. Por otro lado, PLS produjo modelos más exactos que SVM para los datos no transformados en todos los subconjuntos espectrales (VNIR, VNIR+SWIR1 y VNIR+SWIR1+SWIR2).

En la Figura 4.8 se muestra la idoneidad de los modelos PLS y SVM más precisos de acuerdo con los resultados de validación cruzada.

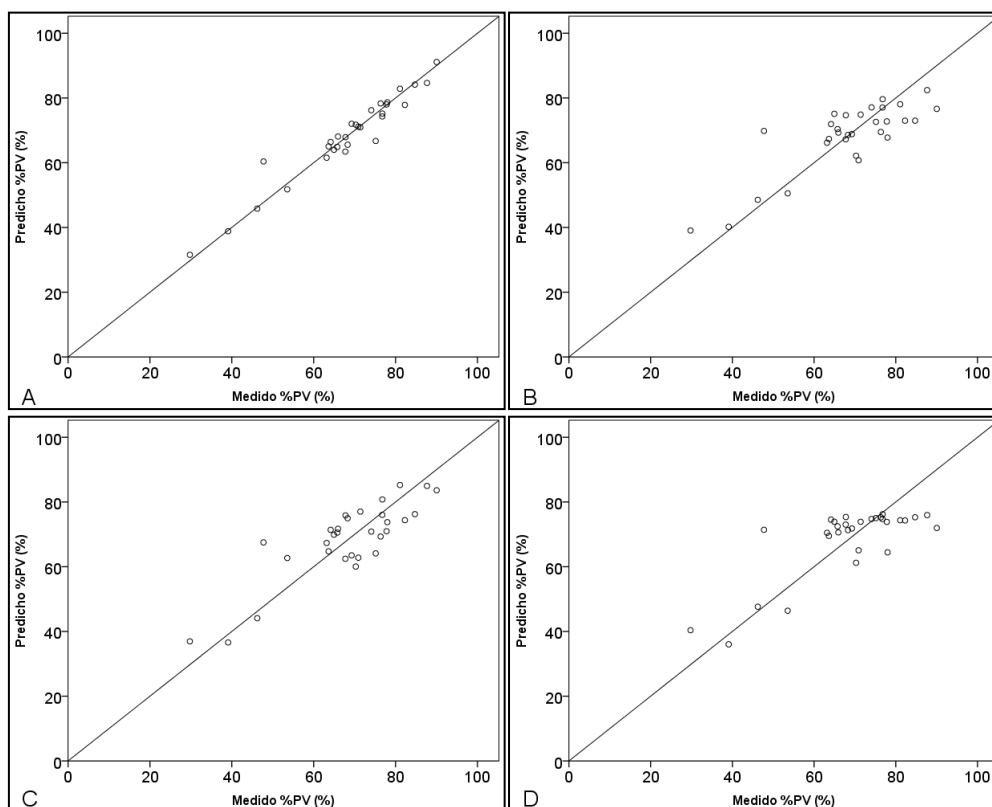


Figura 4.8. Resultados de la validación cruzada en la predicción del %PV usando (A) Regresión PLS tras la transformación SG en la zona VNIR+SWIR1+SWIR2), (B) SVM basado en los datos no transformados en la región del VNIR, (C) Regresión PLS sin transformación aplicado en el subconjunto espectral VNIR+SWIR1+SWIR2 y (D) Regresión OLS a partir del MBD en la zona Z4. Se muestra la línea 1:1

La regresión OLS produjo modelos menos exactos que la regresión PLS y SVM, como se demostró, por el hecho de que tanto el RMSE como el %RMSE correspondiente al mejor modelo OLS (AOM en la característica de absorción Z5).

4.5. Discusión

Se ha demostrado que ha sido posible la estimación de biomasa aérea (PV, PT y %PV) a partir de datos de Espectro-radiometría de campo. Se han obtenido modelos de predicción adecuados para las 3 formas de medir la biomasa aérea (PT, PV, %PV), siendo los resultados más exactos en las tres formas de medir, el uso de la regresión PLS.

Al igual que *Cho et al.* (2007), *Adjorlolo et al.* (2012), *Mutanga et al.* (2012) y *Ren y Zhou* (2014) la medida de referencia en este trabajo fue el PV, obteniéndose los modelos de predicción más exactos frente al PT teniendo en cuenta el criterio AIC, debido al bajo número de factores, sin embargo si se tiene en cuenta el R^2 , RMSE y %RMSE. Los modelos más exactos en la estimación de biomasa aérea se obtuvieron mediante PT.

El modelo más exacto en la estimación de biomasa aérea se consiguió aplicando la regresión PLS a la zona VNIR del espectro tras la transformación *Savitzky y Golay* ($R^2=0,95$; %RMSE=9,1% para el PV). Los resultados para PV aquí presentados mejoran los de *Cho et al.* (2007), que obtuvo un RMSE equivalente al 19% del valor medio de la biomasa, con un modelo PLS más sencillo (2 factores).

Teniendo en cuenta la estimación de biomasa aérea referida al PT, el modelo más exacto se obtuvo con PLS en la zona VNIR+SWIR1 tras una transformación MSCO ($R^2=0,97$; %RMSE<6,2%). A pesar de tener un error menor y un R^2 mayor que el modelo para la estimación de PV, se considera menos adecuado por los 4 factores necesarios para aplicarlo (siguiendo el criterio de AIC). Este resultado es más exacto que el obtenido por *Álvarez et al.* (2010b) donde la correlación entre los datos del espectro-radiómetro y la biomasa seca total era de valores $R^2 < 45$ debido a no usar posiblemente unos tratamientos adecuados de los espectros.

Los métodos de ajuste PLS y OLS resultaron adecuados para estimar biomasa aérea empleando datos espectrales transformados mediante CR. El empleo de CR y PLS en zonas del espectro como Z3 ([916-1120] nm) o Z4 ([1079-1297] nm) simplificó los modelos de estimación de biomasa aérea, tal y como demuestra que el número de

factores latentes se redujeran cuando se utilizaron estas zonas en lugar del espectro completo sin CR. Este resultado concuerda con los obtenidos por Axelsson (2013) para la estimación de Nitrógeno, y los de Cho *et al.* (2007) para la estimación de biomasa.

La zona del espectro más adecuada para la estimación de PV y PT se correspondió con las bandas de absorción de 1079 nm a 1297 nm (Z4), corroborando los resultados de Curran (2001), Cho (2007), Clevers (2008) y Mutanga (2010). Se ha identificado una nueva zona (de 1265 a 1676 nm) como relevante para la estimación de biomasa aérea, lo que supone una novedad en este tipo de trabajos. Dentro de esa zona entre 1400-1690 nm, Hadi (2015) estimó biomasa a partir de césped, obteniendo un resultado menos exacto que en esta tesis ($R^2=0,76$; $RMSE=0,20$ g/m²; %RMSE=32,1%). Esta zona está relacionada sobre todo con la lignina y agua, lo que según Hadi (2015) confirma que sea una zona sensible para la estimación de biomasa.

Respecto al empleo de los índices MBD y AOM, los resultados de este trabajo mostraron que los modelos más exactos para la estimación de PV y PT se obtuvieron empleando los índices derivados de Z4, al igual que ocurría al emplear PLS. Este resultado confirma que la selección óptima de las zonas a las que aplicar la transformación CR es clave para lograr modelos más exactos. Clevers *et al.* (2008) lograron resultados similares a los de este trabajo al estimar el contenido de agua de una cubierta de *Lolium perenne* y *Trifolium repens* empleando MDB y AOM en una región del espectro entre 1115 y 1270 nm, muy similar a Z4, corroborando la idoneidad de estas longitudes de onda para la estimación de PV y PT.

Respecto a la comparación entre los métodos de regresión, si se emplean como predictores los datos de Z4 (con CR) no existen diferencias significativas entre los R^2 obtenidos empleando la regresión PLS y los obtenidos con MBD y AOM. Además las diferencias entre los RMSE son menores del 2%, por lo que no se puede considerar que un procedimiento sea más exacto que otro (Kooistra *et al.*, 2006; Cho *et al.*, 2007; Clevers *et al.*, 2008). Se recomienda el empleo de los índices MBD y AOM y la regresión lineal simple para estimar la cantidad de biomasa aérea (PV o PT) debido a la simplicidad del modelo y a la facilidad para su interpretación, en comparación con la complejidad de los factores latentes de la regresión PLS.

Empleando los mismos datos de partida y el método SVM, el espectro transformado también proporcionó estimaciones más exactas de PV, PT y %PV que el espectro sin transformar (Marabel y Álvarez, 2013). Los resultados para PV aquí presentados mejoran los de Cho *et al.* (2007), que obtuvo un RMSE equivalente al 19%

del valor medio de la biomasa, mientras que en este trabajo el RMSE fue menor (%RMSE<12% del PV) y se obtuvo con un modelo PLS más sencillo (con un menor número de factores).

CAPÍTULO 5

5

CALIBRACIÓN RADIOMÉTRICA DE IMÁGENES MULTIESPECTRALES DE CÁMARA FOTOGRAMÉTRICA DIGITAL DE GRAN FORMATO

5.1. Introducción y objetivos

Hoy en día la explotación de las magnitudes físicas no está generalizada en aplicaciones temáticas de imágenes aéreas captadas mediante técnicas fotogramétricas. Sin embargo, siempre y cuando el sensor está calibrado correctamente, es posible obtener valores absolutos de luminosidad o reflectancia, y por lo tanto, estos sensores se

pueden utilizar para la clasificación multiespectral de cubiertas del suelo o la estimación de variables biofísicas, proporcionando la ventaja sobre los satélites de ofrecer imágenes de muy alta resolución espacial (Honkavaara y Markelin, 2007).

Las cámaras aéreas digitales de gran formato permiten obtener imágenes multiespectrales de elevada precisión/exactitud geométrica e información radiométrica, requiriéndose su calibración para poder extraer información temática cualitativa y cuantitativa comparable (Honkavaara *et al.*, 2004).

Se puede definir como calibración el proceso de caracterizar cuantitativamente la respuesta de un sensor a una señal de entrada conocida y controlada (Cramer, 2007). Esta calibración debe ir más allá de las propiedades geométricas y constituirse como un sistema integral que aborde la parte geométrica, espacial, espectral y radiométrica (Cramer, 2004; Stensaas *et al.*, 2007). Schowengerdt (2007) expuso que era evidente que los datos obtenidos en la teledetección deben tener una corrección topográfica y atmosférica absoluta si se desean establecer comparaciones con firmas espectrales, y una corrección atmosférica relativa si se van a utilizar series temporales (imágenes de diferentes fechas).

En los últimos años se han realizado numerosos trabajos respecto a la calibración geométrica de cámaras aéreas digitales de gran formato (Cramer, 2004, 2005; Cramer y Stallman, 2002; Heipke *et al.*, 2002; Jacobsen, 2003; Honkavaara, 2004; Merchant *et al.*, 2004; Honkavaara *et al.*, 2005; Arias y Gómez, 2009), que tienen la finalidad de ajustar la imagen a sistema de coordenadas geográficas y corregir las distorsiones de tipo geométrico derivadas de la captura de la misma. Sin embargo, las calibraciones radiométricas han sido más escasas, centrándose en la calibración en laboratorio de la cabeza del sensor y de la plataforma (e.g. Heier *et al.*, 2002; Beisl, 2006; Hefele, 2006; Fricker, 2006) así como otras más recientes empleando campos de calibración (e.g. Markelin *et al.*, 2005, Beisl y Woodhouse, 2006; Honkavaara y Markelin, 2007; Hernández-López *et al.*, 2012; Markelin, 2013). Es por ello necesario investigar sobre los métodos adecuados para la corrección radiométrica de imágenes tomadas con sensores fotogramétricos aerotransportados multiespectrales (Honkavaara *et al.*, 2009).

Es necesario integrar el procesamiento radiométrico en las líneas de producción fotogramétrica para aprovechar las propiedades radiométricas de estos sensores (e.g. linealidad de la respuesta radiométrica, amplitud del rango dinámico, elevada

resolución, bajo nivel de ruido, imágenes multispectrales y multiangulares) (Boland *et al.*, 2004) y para asegurar su utilidad en series temporales de imágenes, capturadas en diferentes condiciones de vuelo (Fricker, 2006). La información resultante de este proceso de calibración y corrección podrá emplearse en las tareas fotogramétricas convencionales (e.g. medición automática de *tie points*, extracción de elementos, medición de modelos digitales de elevaciones, generación de ortofotografías) (Beisl y Woodhouse, 2006; Honkavaara *et al.*, 2006) o para aplicaciones que emplean técnicas de teledetección y más relacionadas con la clasificación automática de imágenes (e.g. mapas de cubiertas, detección de cambios, sistemas de monitorización) (Perko, 2005; LeberL y Gruber, 2005; Honkavaara y Markelin, 2007; Hajèk, 2007).

Las condiciones de vuelo (e.g. condiciones atmosféricas, características de la exposición, altitud solar) y las propiedades del sensor (calidad de las lentes y los filtros) son factores que afectan a la radiometría de las imágenes, así como los efectos del post-proceso, tales como la calibración basada en correcciones radiométricas o la cuantización de los niveles digitales (ND) a la escala de grises final (e.g. conversión de 16-bit a 8-bit) (Markelin *et al.*, 2005).

El procesamiento radiométrico óptimo depende de la aplicación, según sea de tipo visual, de teledetección clásica (empleando datos normalizados de la imagen) o de teledetección empleando las propiedades de reflectancia anisotrópica de los objetos (función de distribución de la reflectancia bidireccional, BRDF) (Honkavaara y Markelin, 2007). Estas dos últimas aplicaciones relacionadas con la extracción automática de información requieren métodos de procesamiento rigurosos, que se encuentran bien desarrollados para imágenes de satélite (e.g. Schowengerdt, 1997; Pellikka, 1998, Liang, 2004), pero que todavía están en fase de desarrollo para sensores fotogramétricos (e.g. Papaprotis *et al.*, 2006; Beisl, 2006; Hernández-López *et al.*, 2012; Honkavaara y Markelin, 2007; Markelin, 2013).

Las condiciones de vuelo (e.g. condiciones atmosféricas, características de la exposición, altitud solar) y las propiedades del sensor (calidad de las lentes y los filtros) son factores que afectan a la radiometría de las imágenes, así como los efectos del post-proceso, tales como la calibración basada en correcciones radiométricas o la cuantización de los niveles digitales (ND) a la escala de grises final (e.g. conversión de 16-bit a 8-bit) (Markelin *et al.*, 2005). Las correcciones radiométricas involucran el arreglo de los ND de tal forma que todas las áreas de la imagen tengan una respuesta

lineal de los ND con la radiación reflejada. La consecuencia práctica de estos fenómenos es que el mismo objeto genera ND diferentes en diferentes localizaciones de una misma imagen y en diferentes imágenes; para poder emplear de forma cuantitativa esta información radiométrica es necesario referenciarla radiométricamente de una forma relativa o absoluta. En este contexto, la reflectancia es una variable cuyos valores son comparables para distintos lugares y distintas fechas, esto hace más sólida la interpretación de los datos y el análisis integrado entre imágenes de distintos sensores (Chuvieco, 1996).

La conversión de ND a reflectancias usando métodos atmosféricos es un procedimiento bien conocido en imágenes de satélites (Chavez, 1996; Schowengerdt, 2007; Richter y Schläpfer, 2011; Immitzer *et al.*, 2012). Sin embargo los métodos de corrección radiométrica son pocos frecuentes cuando se usa imágenes de fotografía aérea, debido a las características especiales a la hora de adquirir los datos fotogramétricos, como son el amplio campo de visión para distintas alturas de vuelo, el formato del fotograma de la imagen, la exposición del sensor variando su configuración (Read y Graham, 2002; Ryan y Pagnutti, 2009; Beisl, 2012; Martínez, 2015).

Según Dinguirard y Slater (1999), los métodos de calibración radiométrica pueden clasificarse en tres tipos:

- (i) Calibración en laboratorio, antes del vuelo (*preflight calibration*). Se trata de la calibración rigurosa de los sensores. Se emplean esferas integradoras con las cuales se obtienen diferentes niveles de radiación conocida, permitiendo conocer la relación lineal entre niveles digitales y radiancia.
- (ii) Calibración a bordo de la plataforma (*On-board calibration*), obteniendo comprobaciones durante la adquisición de las imágenes, para lo que se utilizan lámparas o paneles difusores que reflejan la luz solar.
- (iii) Calibración mediante campañas de medidas in situ (*vicarious calibration*), la cual supone hacer una calibración radiométrica absoluta en condiciones de vuelo (y de atmósfera) distintas a las de laboratorio. En la actualidad los diferentes diseños de los sistemas de captura y su actuación conjunta con sensores IMU y GPS (que proporcionan localizaciones espaciales de las imágenes muy exactas)

han propiciado el giro hacia este tipo de calibraciones (Cramer, 2005).

Dentro del grupo de calibraciones vicarias se encuentra el método de corrección atmosférica absoluta mediante calibración empírica, que permite obtener reflectancias en superficie (reflectancias aparentes, puesto que no se tiene en cuenta el efecto topográfico).

Este método relaciona los niveles digitales de las imágenes con los valores de reflectancia en superficie medidos en campo para una serie de puntos de calibración, denominados blancos, que se identifican en la imagen y en el terreno. Para ello cada uno de los blancos de calibración debe cubrir un área de al menos 3 x 3 píxeles de la imagen, deben ser homogéneos y lambertianos, sin bandas de absorción fuerte en la región del espectro considerada, y deben abarcar una amplia gama de niveles de albedo (de mucha a poca reflectancia).

Los blancos de calibración pueden ser fijos y "pseudo-invariantes" (Haest *et al.*, 2009) o móviles (situados específicamente en la zona de estudio) (Álvarez *et al.*, 2010a). Ejemplos de objetivos de calibración fijos y pseudo-invariante son: asfalto, hormigón, sal, arena, grava, cal y superficies pintadas. Idealmente, la vegetación y el agua no se deben emplear como blancos de calibración, por sus condiciones cambiantes. El agua profunda también se puede utilizar si se quiere calibrar imágenes con bandas de infrarrojo y se requieren referencias con reflectancia baja en el NIR y en el SWIR. Para la calibración con blancos móviles se suelen usar blancos de calibración de lona (con diferentes reflectancias nominales) para apoyar campañas de campo de calibración radiométrica (Hernández-López *et al.*, 2012; Del Pozo *et al.*, 2014).

En el caso de los blancos fijos no se puede elegir la ubicación de los mismos, pero en el caso de los móviles estos deberían estar en el centro de las líneas de vuelo (nadir), sobre una superficie plana, para minimizar los efectos de la reflectancia bidireccional y de la topografía. Si no es posible encontrar un sitio llano, se debe estimar la pendiente y su dirección, para realizarlas correcciones necesarias (Smith y Milton, 1999; Che y Price, 1992; Karpouzli y Malthus, 2003). La ubicación y disposición del campo de calibración radiométrica se debe hacer antes de la campaña aérea. Haest *et al.* (2009) realizó una calibración radiométrica en la cámara UltraCam D usando blancos de calibración pseudoinvariantes (asfalto, gravillas, pastos, baldosas

rojas o grises entre otros) y ajustando un modelo (*Kernel*) para corregir la reflectancia bidireccional de los blancos.

Se han realizado en los últimos años estudios para la validación de los procesos radiométricos (Markelin *et al.*, 2010) y para la calibración de sensores fotogramétricos como la cámara ADS40 (Beisl y Adigüezel, 2010). Para el sensor ADS40 se ha descrito de forma detallada su radiometría (Gomez-Molina, 2010) y su calibración (Beisl, 2006, Honkavaara y Markelin, 2007; Hernández-López *et al.*, 2012), mientras que para las cámaras DMC, UltraCam-D y ADS40 no se dispone de información tan exhaustiva. Markelin *et al.* (2005) realizó la comparación radiométrica de las imágenes de cámara analógica y de la UltraCam-D, con el objetivo de emplear esa información radiométrica en métodos avanzados de clasificación, realizando para ello calibraciones radiométricas absolutas con escalas de grises y empleando correcciones atmosféricas e información de las BRDF. Honkavaara y Markelin (2007) caracterizaron y compararon la radiometría de las imágenes capturadas con los sensores ADS40, DMC, UltraCam-D y DSS (cámara de medio formato), determinando la respuesta radiométrica del sensor, el rango dinámico, la calibración absoluta y la sensibilidad, empleando un campo de calibración con una escala de grises. En este ámbito también se realizaron evaluaciones y comparaciones de los sensores ADS40, ADS40- SH52, UltraCam-D, y DMC en el norte de Alemania para la realización de mapas biotipos (Rosso *et al.*, 2008). Haest *et al.* (2009) también realizaron una calibración radiométrica de este tipo, a partir de reflectancias de las imágenes usando las mediciones realizadas cuatro años antes del sensor UltraCam-D. Martínez *et al.* (2008) realizaron calibraciones radiométricas y colorimétricas del sensor DMC y lo comparó con imágenes del sensor CASI. Dentro de otro proyecto DGPF's "*Evaluation of digital photogrammetric aerial cameras systems*" (Cramer, 2010) se realizan calibraciones in situ, en un campo de prueba de varios sensores fotogramétricos de gran formato, pero sin éxito debido a las condiciones climáticas desfavorables y diferentes problemas en las mediciones sobre el terreno (Schönermark, 2010). En el mismo proyecto Hanusch y Baltsavias (2009) realizan un análisis de los histogramas, de la linealidad del sensor así como un análisis del ruido para los sensores DMC, ADS40, y la UltraCam-X. Rosso *et al.* (2008) Álvarez *et al.* (2010) realizaron una caracterización radiométrica y evaluación de los sensores UltraCam-X y UltraCam-Xp a partir de una calibración radiométrica empírica de tipo línea con el fin de evaluar la usabilidad de las imágenes en el Plan Nacional de

Ortofotografía Aérea (PNOA) en España. Posteriormente también se evaluó la calidad radiométrica de la DMC-II y de la UltraCam Eagle (Jacobsen y Neumann, 2010; Passini *et al.*, 2012). Recientemente se han llevado a cabo varias calibraciones en sensores de medio formato como la cámara Mini-MCA de la casa Tetracam© la cual Herrero-Huerta (2013) llevó a cabo en un vuelo con paramotor o Del Pozo *et al.* (2014) y Murillo-Sandoval *et al.* (2014), usando como plataforma un vehículo aéreo no tripulado.

En este contexto se presenta la posibilidad de explorar diferentes opciones para calibración radiométrica absoluta de imágenes de la cámara aérea fotogramétrica multiespectral para obtener imágenes de reflectancia en superficie (reflectancia aparente) a partir de medidas en campo.

El objetivo principal de este capítulo fue desarrollar un método para la calibración radiométrica absoluta de imágenes multiespectrales de la cámara aérea digital fotogramétrica de gran formato UltraCam-Xp WA, y comprobar si la calibración obtenida para una imagen se puede emplear para imágenes adyacentes de la misma pasada.

El objetivo global se desglosó en los siguientes objetivos específicos:

1. Desarrollar un método para calibrar radiométricamente las imágenes de la cámara aérea digital fotogramétrica para obtener imágenes de reflectancia en superficie.
2. Determinar la influencia del conjunto de muestras empleado como referencia en la calibración radiométrica de imágenes de UltraCam-Xp.
3. Determinar la idoneidad de emplear la calibración radiométrica de una imagen de este sensor a imágenes de la misma pasada. .

Por lo tanto, se compararon los siguientes enfoques: (i) empleo de blancos móviles rígidos (ii) empleo de blancos móviles flexibles, (iii) empleo de blancos móviles rígidos y móvil flexible (iiii) empleo de blancos móviles rígidos y fijos (iiii) empleo de blancos móviles flexibles y fijos, y (iiii) empleo de blancos móviles rígidos, flexibles y fijos. Para testar la robustez del método de calibración radiométrica se determinaron las diferencias entre utilizar las ecuaciones de calibración ajustadas para una imagen o las de una imagen adyacente. .

5.2. Material

5.2.1. Datos de teledetección

En este trabajo se realizó la calibración radiométrica de imágenes multiespectrales tomadas durante un vuelo fotogramétrico realizado con el sensor aerotransportado UltraCam-Xp WA (Wide Angle). El sensor, el vuelo y las imágenes se describen a continuación.

5.2.1.1. Características del sensor

El sensor utilizado fue la cámara aérea fotogramétrica UltraCam-Xp Wide Angle, denominada de forma abreviada UltraCam-Xp WA, fabricado por Microsoft-Vexcel. Es un sensor de tipo CCD (*Charge Coupled Devide*) matricial, multiespectral aerotransportado que comenzó a comercializarse en el año 2012 aunque su primera imagen fue tomada en 2010. Las características principales de esta cámara se muestran en la Tabla 5.1 (Microsoft Vexcel, 2011).

Tabla 5.1. Características del sensor UltraCam-Xp WA (Microsoft Vexcel, 2011).

Características	Datos técnicos
Tipo de sensor CCD	Matricial
Color	4 Canales : RGB+NIR
Tamaño de imagen (color)	5770×3770 pixeles
Tamaño de pixel (imagen de color)	6 µm
Distancia focal (color)	23 mm
Apertura de lente (color)	f = 1/4,0
Tamaño de imagen pancromático	17310×11310 pixeles
Ángulo de campo	73°(sentido transversal a la traza) 52° (sentido de la traza)
Tamaño de pixel (pancromático)	6 µm
Distancia focal (pancromático)	70 mm
Apertura de lente (pancromático)	f = 1/5,6
Resolución radiométrica	>12bits (7400 valores)
Almacenamiento	Unidades DX 4,2Tb
Plataforma giroestabilizada	Ultramount GSM 3000
Sistema navegación	Applanix POSTrack510
GPS	Doble frecuencia + Glonass
IMU	POSAV 510
Frecuencia registro IMU	200_Hz
Precisión roll/pitch	0,005°

Precisión kappa	0,008°
-----------------	--------

Está formada por 4 objetivos pancromáticos (B/N) compuesto cada uno por 17310×11310 píxeles y por otros 4 objetivos matriciales multiespectrales (R, G, B, NIR) (rojo, verde, azul e infrarrojo cercano) de 5770×3770 píxeles cada uno (Figura 5.1), con una distancia focal de 23 mm, un tamaño de píxel en el CCD de $6 \times 6 \mu\text{m}$, y una resolución radiométrica de 12 bits para las lentes de color. Los 4 módulos pancromáticos se encuentran dispuestos formando haces convergentes de forma que adquieren cuatro imágenes del terreno distintas pero con unas zonas comunes para unir todas en una imagen global.



Figura 5.1. Imagen de la UltraCam-Xp WA (Microsoft Vexcel, 2011).

La formación de las imágenes se realiza formando un mosaico de las imágenes a partir de los citados módulos pancromáticos, a partir de ahí se forman las combinaciones a color natural o falso color, mediante los otros cuatro objetivos color (*pan-sharpening*) (Santos-Pérez, 2006). Para la mejora de la imagen dispone de un sistema de retardo de la imagen (TDI) con un valor máximo de 50 píxeles.

La formación de la imagen más detallada se explica a continuación en tres pasos: En primer lugar entra en funcionamiento el cono principal o maestro con 4 matrices de imagen. En el segundo paso el primer cono “esclavo” introduce dos imágenes de forma vertical en el centro de las primeras, creando cuatro áreas de solape. En el tercer paso, el segundo cono “esclavo” coloca otras dos imágenes en horizontal creando nuevas áreas

de solape y por último el tercer como “esclavo” coloca una nueva y última imagen uniendo y solapando todas las anteriores (Figura 5.2) (Santos-Pérez, 2006).

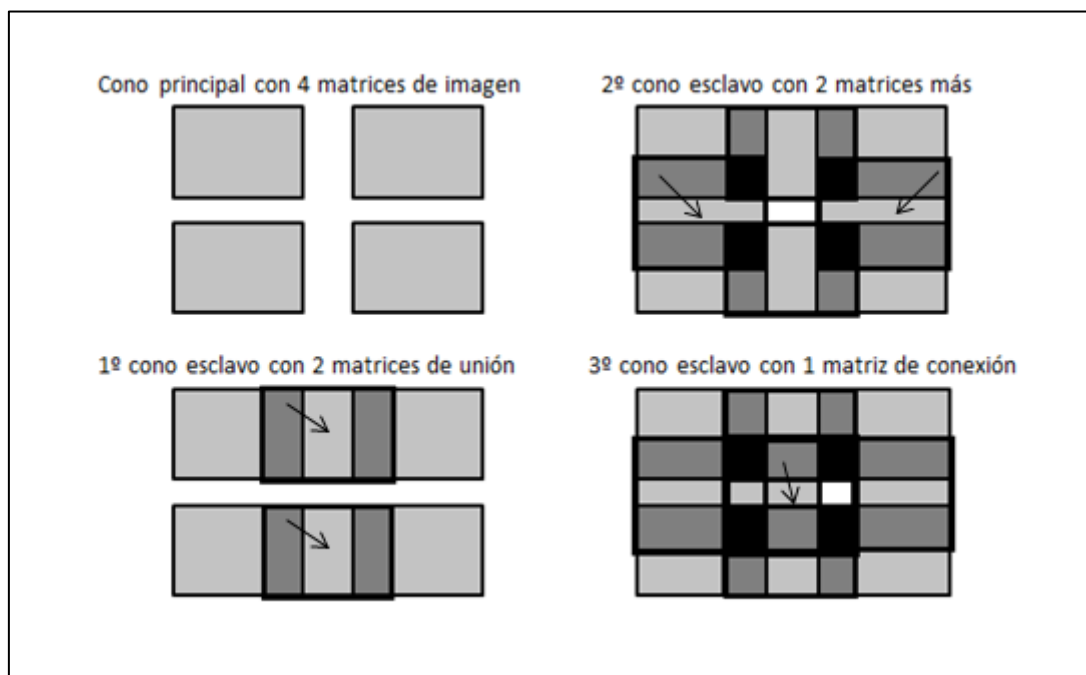


Figura 5.2. Pasos para la formación de una imagen (adaptación de Santos-Pérez, 2006)

Esta cámara se caracteriza por un ángulo de campo mayor que el de otras cámaras de gran formato, de modo que puede abarcar extensiones de terreno mayores en una pasada (un 25% mayor que la cámara de gran formato DMC y un 44% mayor que la ASD40 y la ASD80).

En las características radiométricas de la cámara UltraCam-Xp WA se describen las longitudes de onda a las que son sensibles las diferentes bandas: así la banda azul abarca desde los 380 nm hasta los 600 nm, la banda verde desde los 480 nm hasta los 680, la banda roja está limitada desde los 580 nm hasta los 720 nm y el Infrarrojo cercano desde los 680 nm hasta los 1000 nm (Figura 5.3). Las curvas de sensibilidad espectral se muestran en la Figura 5.3, donde se aprecia la existencia de solapamiento entre algunas bandas. La banda azul se representa mediante la letra “B” (Blue), la banda verde mediante la letra “G” (Green), la banda roja mediante la letra “R” (Red) y la banda del infrarrojo cercano “NIR” (Near Infrared). La cámara UltraCam-Xp WA con la que se realizó el trabajo presentaba un certificado de calibración realizado en Marzo del 2012, 4 meses antes del vuelo realizado en este trabajo.

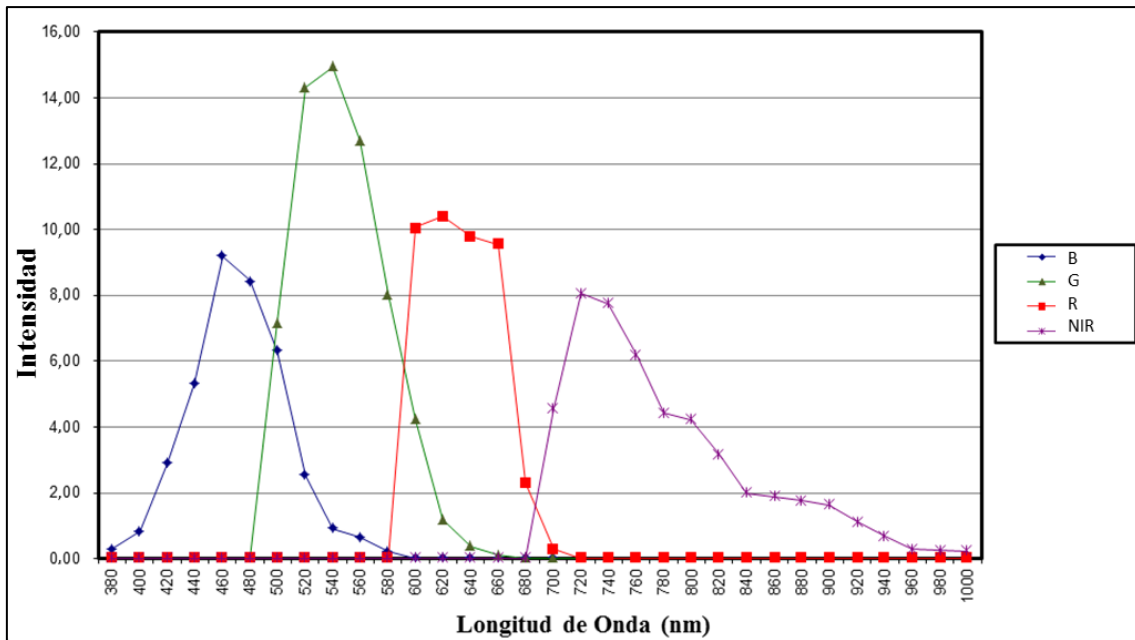


Figura 5.3. Respuesta espectral de la UltraCam-Xp WA (Microsoft Vexcel, 2011).

5.2.1.2. Captura de datos (vuelo fotogramétrico)

El vuelo con la UltraCam-Xp WA lo realizó la compañía Servicios Politécnicos Aéreos S.A. (SPASA) el 23 de julio de 2012, y se tomaron 7 fotogramas consecutivos de oeste a este. Para este trabajo se usaron los tres fotogramas correspondientes a la zona de calibración (en morado en la Figura 5.4) (fotogramas 3, 4 y 5). Se observan los centros de estas imágenes y su situación de solape máximo. Se trató de que el centro geométrico de cada imagen estuviese lo más próximo posible a los blancos de calibración radiométrica y que las tomas fuesen lo más nadiral posible al campo de calibración (Figura 5.4), para minimizar los efectos de reflectancia bidireccional. Para poder realizar una calibración vicaria, dos superficies de igual reflectancia deben tener el mismo ND. Para ello las zonas deben tener una misma iluminación solar, un mismo ángulo de observación y verse afectadas por las mismas condiciones atmosféricas (De Miguel *et al.*, 2001) u otros aspectos derivados de la situación geográfica como la pendiente, orientación, asociación con otras especies, reflectividad del sustrato, geometría de plantación (Chuvienco, 2008; Roman-González y Vargas-Cuentas, 2013).

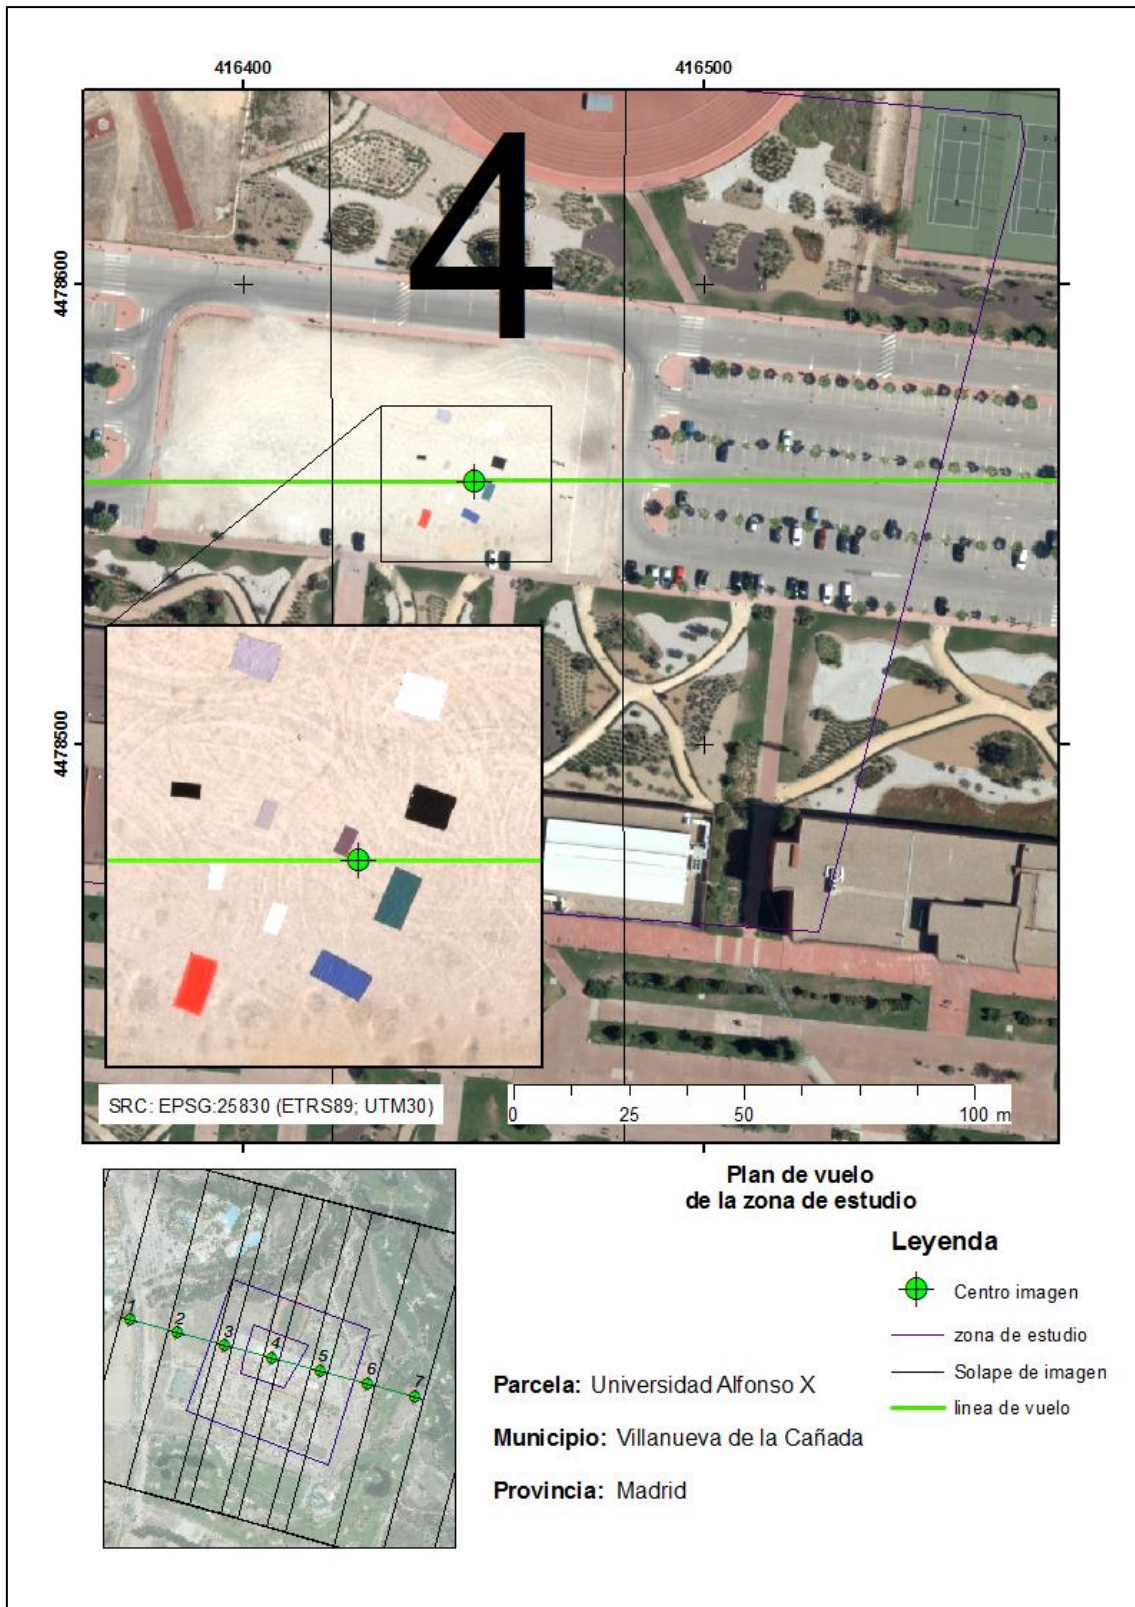


Figura 5.4. Representación cartográfica del plan de vuelo. Los límites de color negro representan las 7 imágenes con sus centros tomados de oeste a este de color verde. La zona en morado representa la zona objetivo.

Características de las imágenes

Se emplearon 3 imágenes multispectrales (R, G, B, NIR) de la cámara aérea fotogramétrica UltraCam-Xp WA, con una resolución espacial (GSD) de 18 cm y una resolución radiométrica de 16 bits, en formato TIFF. Las imágenes se obtuvieron en nivel 2, que proporciona imágenes multispectrales con los canales R, G, B y NIR separados a la máxima resolución posible para los sensores de color. Este nivel almacena los valores de color con el menor nivel de procesamiento radiométrico posible, mientras que los datos de nivel 3 son el resultado de una fusión con los datos de pancromático por *pan-sharpening*. Como se ha indicado anteriormente, para este trabajo se usaron los tres fotogramas centrales del vuelo (fotogramas 3, 4 y 5 en la Figura 5.4), asignándoles las letras A, B y C respectivamente.

5.2.2. Campo de calibración: establecimiento y caracterización radiométrica

El campo de calibración estuvo formado por tres tipos de superficies de referencia (denominados “blancos”) (Figura 5.5): (i) Escala de grises (blancos móviles rígidos), (ii) Filtros (blancos móviles flexibles), y (iii) Zonas de referencia (no móviles). La escala de grises estaba formada por 10 blancos móviles rígidos de 1 m × 1 m, 2 de cada una de las siguientes reflectancias nominales: 100% (BL), 75% (GR25), 50% (GR50), 25% (GR75) y 0% (NG), realizados en *Alocubond®* y recubiertos de vinilo. En cuanto a los filtros, se colocaron 6 de distintos colores (blanco, gris, negro, azul, rojo y verde), los tres primeros de 3 m × 3 m y el resto de 4 m × 2 m. Las superficies de referencia fijas consistieron en zonas homogéneas de 3,5 m × 3 m formadas por diferentes cubiertas: césped artificial, dos tipos de pista de atletismo, superficie de asfalto. En todos los casos los blancos fueron mayores de 3 × 3 píxeles, que es el mínimo requerido para una calibración radiométrica vicaria.




Figura 5.5. Detalle de los blancos de calibración (Elaboración propia)

La posición de todos estos blancos de calibración se determinó mediante un levantamiento con un receptor GNSS Topcon Hiper II, determinándose su localización planimétrica con precisión de 0,01 m. La información se procesó para referir las coordenadas al sistema de referencia de coordenadas ETRS 89 UTM30.

La caracterización radiométrica de los blancos de referencia se realizó con un espectro-radiómetro de campo ASD Fieldspec®4, (Analytical Spectral Devices, Inc., Boulder, Colorado, USA), con un FOV de 25° a 1,5 m, con una resolución espectral de 3 nm ($\pm 1,0$ nm de precisión) con un ruido máximo en radiancia de $1,4 \times 10^{-9}$ W/cm²/sr y un rango de medición entre 350 y 2500 nm. En este sensor la luz entrante es codificada en 16 bits y separada en tres espectrómetros: Visible/Infrarrojo cercano (VNIR) [350–1000] nm, Infrarrojo de onda corta 1 (SWIR1) [1000–1800] nm e Infrarrojo de onda corta 2 (SWIR2) [1800–2500] nm.

Se siguió una metodología basada en un protocolo de medición uniforme y sistemático metódico, según Yuste-Martín *et al.* (2013). Antes de cada medición se calibró el instrumento empleando un blanco estándar de referencia (*Spectralon Labsphere®*), lo que permitió obtener reflectancias absolutas en superficie. Al utilizar un blanco de referencia antes de cada medida no es necesario que la posición solar fuera la misma que la correspondiente a las imágenes siempre que las superficies muestreadas sean suficientemente lambertianas (De Miguel *et al.*, 2001). En cada uno de los blancos de calibración móviles rígidos (10) se realizaron 15 mediciones de la reflectancia en

superficie por cada panel individual de 1 m × 1 m, obteniendo con el espectroradiómetro un total de 30 espectros para cada nivel de reflectancia nominal. En los blancos móviles flexibles (fieltros) también se tomaron un total de 30 mediciones en cada uno. En cuanto a los blancos fijos, en cada uno de los cuatro tipos se realizaron un total de 30 mediciones mediante transectos (15 espectros por diagonal) para cada zona. Las reflectancias de los blancos se midieron inmediatamente antes e inmediatamente después del vuelo (Figura 5.6), para minimizar los errores en la calibración debidos a una variación en las condiciones de la atmósfera.

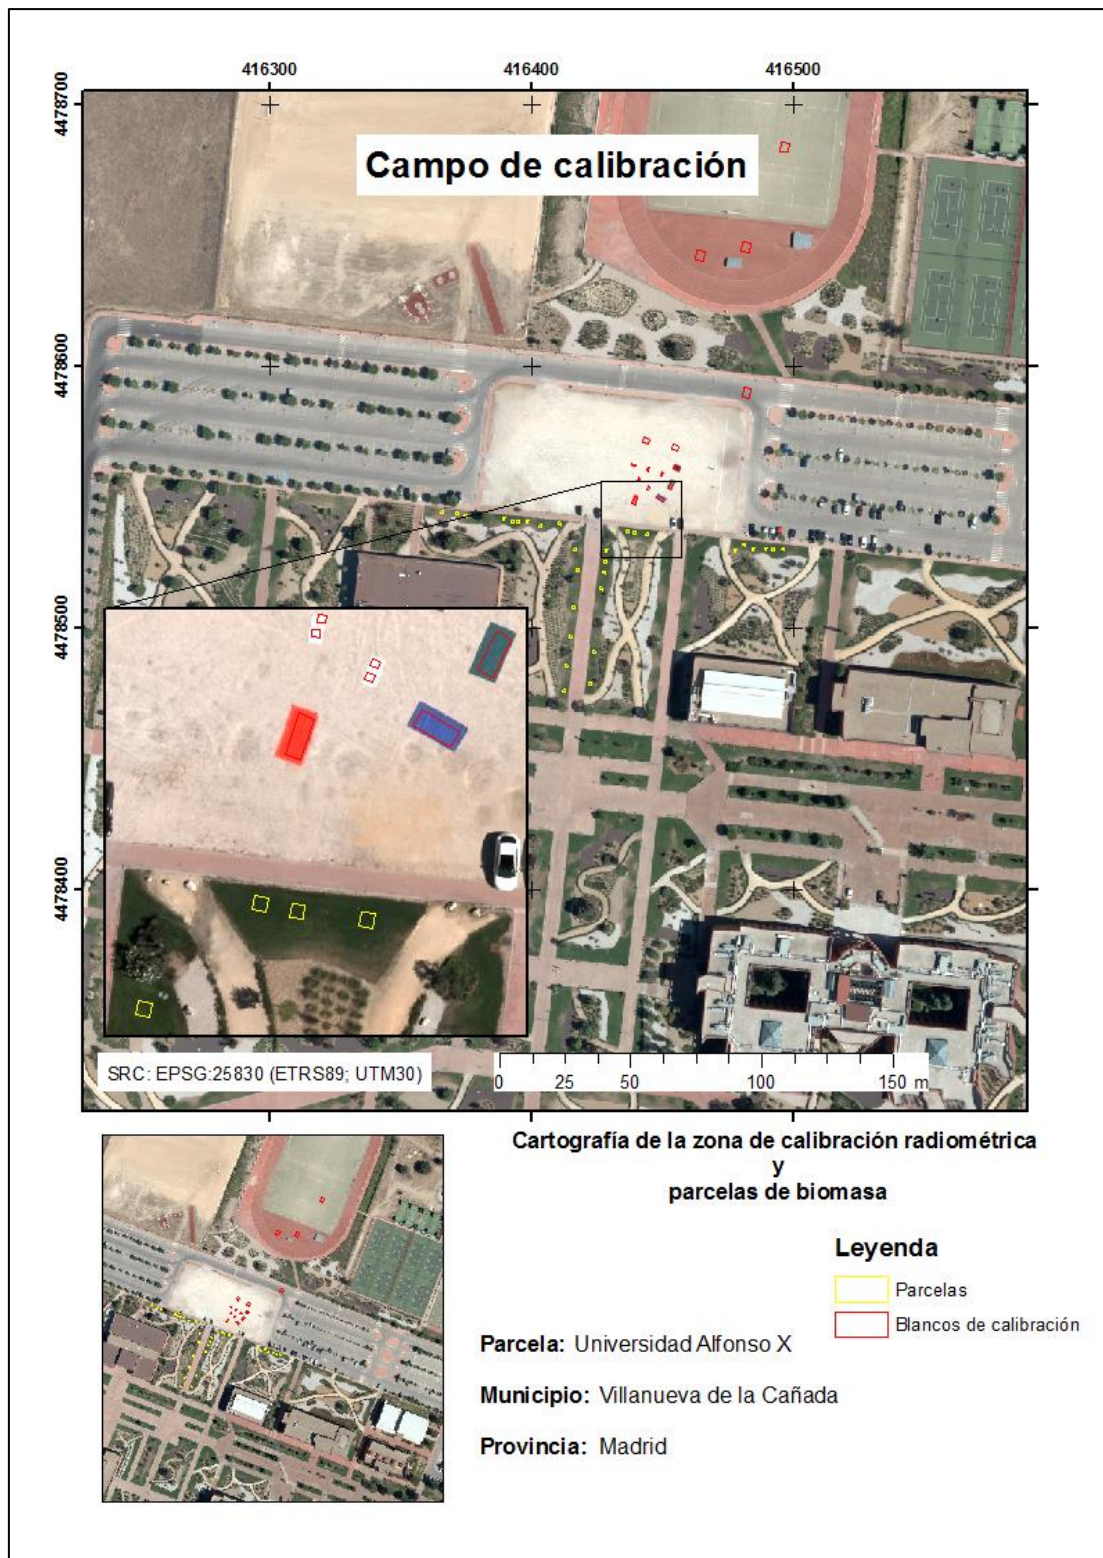


Figura 5.6. Localización del campo de calibración. Los rectángulos rojos representan los blancos de calibración y los amarillos las parcelas con vegetación de la validación.

5.2.3. Datos radiométricos auxiliares para la validación

Para determinar la idoneidad de la calibración radiométrica de las imágenes en zonas con vegetación, se realizó una validación independiente con los datos de reflectancia en superficie de 30 parcelas de cultivos herbáceos, localizadas en la zona de estudio. Los datos espectrales se tomaron en 30 unidades de muestreo, definidas como parcelas homogéneas de 1 m × 1 m, divididas en subparcelas de 0,5 m × 0,5 m, compuestas fundamentalmente por *Lolium perenne*, *Poa pratense* y *Trifolium repens*. Para evitar la contaminación espectral de la señal, cada una de las parcelas se localizó dentro de un área homogénea de 2 m × 2 m. Se registraron 15 espectros fijos para cada subparcela de 0,5 × 0,5 m, inmediatamente después del vuelo. Los 60 espectros por parcela, se emplearon para caracterizar cada unidad de muestreo de 1 × 1 m a través de un espectro promedio. Antes de cada toma de datos, se realizó una medición de referencia en un blanco estándar de referencia (*Spectralon Labsphere*®) para calibrar el instrumento y obtener reflectancias absolutas en superficie. Las medidas se tomaron de manera uniforme en rectángulos concéntricos intentando abarcar toda la superficie y heterogeneidad de cada subparcela.

La posición de cada parcela en el sistema de referencia de coordenadas ETRS 89 UTM30 se determinó empleando un receptor GNSS Topcon Hiper II.

5.3. Métodos

5.3.1. Flujo de trabajo

El flujo de trabajo seguido para la calibración a reflectancia en superficie de las imágenes tomadas con la cámara aérea digital se resume en la figura 5.7. Por una parte se capturaron las imágenes y se pre-procesaron geométrica y radiométricamente para obtener los niveles digitales correspondientes con los blancos del campo de calibración. La campaña de campo se realizó lo más próxima posible al momento de adquisición de las imágenes y bajo condiciones atmosféricas equivalentes. Por otra parte se determinó la reflectancia en superficie de cada uno de los blancos de calibración mediante el espectro-radiómetro. Finalmente se realizó una calibración empírica de línea a partir de las medidas de superficie y los niveles digitales de la imagen, para cada uno de los conjuntos de blancos (sets de calibración) definidos. Este proceso se realizó para las tres imágenes y se validó para muestras independientes con cubierta de herbáceas.

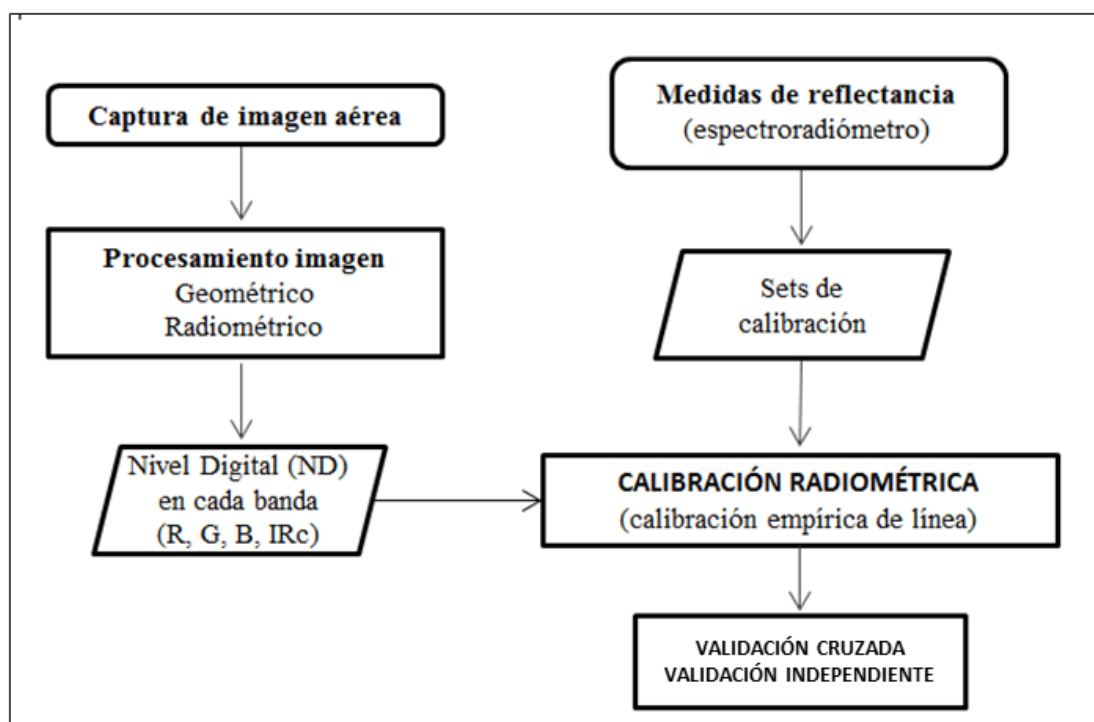


Figura 5.7. Diagrama de flujo de trabajo para realizar la calibración de las imágenes a reflectancia en superficie (Elaboración propia).

5.3.2. Pre-procesamiento de las imágenes

Las correcciones geométricas realizadas consistieron en una ortorrectificación de los fotogramas, con el fin de corregir las distorsiones geométricas de los mismos y referirlos al sistema de referencia de coordenadas ETRS89 UTM30. Esta ortorrectificación fue de tipo estadística, empleando los parámetros de orientación directa del vuelo y puntos de apoyo medidos por el receptor GNSS Topcon Hiper II. Estos puntos fueron tomados a distintas alturas y cubriendo toda la zona de calibración y en lugares estables y fácilmente localizables a partir de las imágenes tomadas del sensor aerotransportado. Las imágenes se obtuvieron a nivel 2 sin ningún tipo de ajuste radiométrico, para lo que se mantuvo un fichero de 16 bit (con un valor máximo de 65535 y un valor mínimo de 0, gradación de tipo lineal y parámetro gamma 1.0). Los niveles digitales de cada una de las bandas espectrales se remuestrearon usando el método del vecino más próximo, de modo que no se modificasen los niveles digitales originales. De este modo se obtuvieron 3 ortofotos para el campo de calibración (A, B y C, de Oeste a Este). En los tres casos se determinó mediante un test de comparación de medianas que no había diferencias significativas entre los niveles digitales de los

blancos de referencia en las ortofotos y en los fotogramas (i.e. $p < 0,05$ al $\alpha = 0,05$).

5.3.3. Procesamiento de los datos auxiliares de campo

5.3.3.1. Blancos de calibración

Para caracterizar espectralmente cada superficie de referencia se usó el espectro promedio de las 30 mediciones tomadas sobre cada blanco con el espectro-radiómetro, antes y después del vuelo. Se determinó mediante un test de comparación de medianas que no había diferencias significativas entre las reflectancias de los blancos de referencia antes y después del vuelo (i.e. $p < 0,05$ al $\alpha = 0,05$) por lo que se decidió emplear las reflectancias después del vuelo.

Una vez en laboratorio se obtuvo el espectro promedio (media) de reflectancia para caracterizar cada uno de los bancos de calibración mediante el software ViewSpecPro™ de ASD (ASD, 2008) a partir de los 30 espectros por blanco (Figura 5.8). Sólo se empleó el espectro desde los 350 nm hasta los 1000 nm para realizar posteriormente la calibración radiométrica de las imágenes, debido a que la cámara fotogramétrica empleada sólo capta el espectro electromagnético entre esas dos longitudes de onda. De esta forma se descartaron también las zonas de ruido del espectro presentes en torno a los 1400 nm y a los 1900 nm.




Figura 5.8. Reflectancias del blanco de calibración azul (en negro) y su espectro promedio (media) (en azul).

5.3.3.2. Parcelas de validación

Una vez en laboratorio se procedió a la depuración de los espectros medidos en campo mediante el software ViewSpecPro™ (ASD, 2008), de forma análoga a cómo se hizo para los blancos de calibración. Se calculó la media de los 15 espectros de reflectancia en superficie de cada subparcela y se estimó el espectro promedio por parcela. Se visualizaron los 30 espectros promedios, para localizar y excluir las zonas con irregularidades debido al ruido atmosférico. De este modo se obtuvo un espectro depurado entre [350-1000] nm, que se empleó como base para los análisis estadísticos posteriores.

5.3.4. Calibración empírica de línea: ajuste

La calibración empírica de línea se encuadra dentro del método de calibración mediante campañas de medidas in situ (calibración vicaria) mencionado anteriormente (Herrero-Huerta, 2013). Este método supone hacer una calibración radiométrica absoluta en las condiciones de vuelo distintas a las de laboratorio, relacionando los niveles digitales (ND) de un conjunto de blancos de referencia ubicados en la imagen con sus correspondientes reflectancias medidas en superficie (Álvarez *et al.*, 2010a; Hernández-López *et al.*, 2012). Este método se basa en determinar las relaciones lineales entre los ND y las reflectancias de los blancos de calibración para cada una de las bandas y en cada imagen, con el fin de obtener una ecuación lineal con una ganancia y un desplazamiento (“gain” y “offset”) para cada una de las bandas (Ecuación 5.1) (Jensen, 2005).

$$\rho_k = ND_k a_k + b_k \quad (\text{Ec. 5.1})$$

donde ρ_k es la reflectancia escalada de superficie del material en el ángulo de visión instantánea (IFOV) para la banda k , ND_k es el nivel digital para un píxel en la banda k , a_k es la ganancia y b_k el desplazamiento.

Para la realización de este método es necesario usar superficies de referencia con reflectancias muy diferenciadas, las cuales cubran un rango con reflectancias muy elevadas (muy brillantes) y con reflectancias muy bajas (muy oscuros) (Hall *et al.*, 1991). Este método de corrección atmosférica se ha aplicado en numerosos estudios, como los de Conel y Alley (1987) para imágenes del sensor AVIRIS, Roberts *et al.*

(1997) para el sensor AIS (*The Airborne Imaging Spectrometer*). Conel *et al.* (1987) para el sensor AIS2, Farrand *et al.* (1994) para datos procedentes del AVIRIS, Hadley (2005) y Haest *et al.* (2009) para la UltraCam-D, Hernández-López *et al.* (2012) para imágenes procedentes del sensor Leica ADS40, Herrero-Huerta (2013) para imágenes procedentes de una cámara Mini-MCA, Markelin (2013) en imágenes de diferentes sensores (DMC, ASD40, UltraCam-D) y Wang *et al.* (2015) para imágenes procedentes del sensor Canon EOS Rebel T4 acoplado a un sUAS (*Small Unmanned Aircraft Systems*). Este fue el método el elegido en este trabajo para realizar la calibración radiométrica absoluta de las imágenes de cámara aérea digital.

Para determinar el conjunto de blancos de referencia más adecuado para hacer la corrección radiométrica mediante calibración empírica de línea, las superficies de referencia se agruparon en sets (Tabla 5.2). Se realizaron 27 combinaciones entre los blancos de calibración (identificadas con letras en la Tabla 5.2), obteniéndose por ello 27 modelos de regresión en cada una de las cuatro bandas espectrales de la imagen.

Al hacer las combinaciones se usó de manera independiente la escala de grises formada por 10 blancos móviles rígidos. Cada uno de los blancos formados por dos paneles, se nombró como panel 1 y panel 2 (Figura 5.9), usándose de manera independiente sus reflectancias. También se usó el promedio de la reflectancia de los dos paneles adyacentes (panel 1+panel 2) como un blanco independiente.



Figura 5.9. Blancos móviles rígidos

Tabla 5.2. Combinaciones (a-T) de los blancos (1-25) testados para calibrar las imágenes (Sets). T=todos los blancos. Las superficies de referencia se han identificado con números, de la siguiente forma: 1-6: Filtro azul, filtro blanco, filtro gris, filtro negro, filtro rojo, filtro verde; 7-21: blancos móviles rígidos con las siguientes reflectancias nominales en la escala de escala de grises (panel 1, panel 2, panel 1+2): 0%, 25%, 50%, 75%, 100%); 22-25: blancos fijos: pista de atletismo I, pista de atletismo II, asfalto, césped artificial. Las “x” en la tabla indican que ese blanco se empleó en el set.

	a	b	c	d	e	f	g	h	I	j	K	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	T	
1				x							X	x			x		x	x	x	x	x			x			X	
2					x						X	x	x	x	x	x			x	x			x	x	x	x	x	X
3						x					X	x	x	x	x	x			x	x			x	x	x	x	x	X
4							x				X	x	x	x	x	x			x	x			x	x	x	x	x	X
5								X			X	x			x	x			x	x	x				x		X	
6									x	X	x				x	x	x	x	x	x						x	X	
7	x	x	x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
8	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
9	x	x		x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
10	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
11	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
12	x	x		x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
13	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
14	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
15	x	x		x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
16	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
17	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
18	x	x		x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
19	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
20	x		x	x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
21	x	x		x	x	x	x	x	x	X	x	X	x	x	x	x	x	x				x			x	x	x	X
22																											X	
23																											X	
24				x							X		x														X	
25																											X	

Los Sets “a, b y c” están formados por los blancos móviles rígidos buscando diferencias al usar todos los paneles (panel 1, panel 2 y panel 1+2), al usar solo los dos paneles como si fuera uno sólo (paneles 1+2) y usando los paneles independientes (panel 1 y panel 2). El set “d” es igual que el “a” pero añadiendo el blanco fijo de asfalto. Los sets “e, f, g, h, i, j” están compuestos por los paneles móviles rígidos más un blanco móvil flexible (filtro) demostrando la interacción de cada blanco móvil flexible por separado en las diferentes bandas. Los sets “k y l” están compuestos por todos los blancos móviles (rígidos y flexibles) comprobando el efecto del uso del blanco fijo “asfalto”. Dentro de las comparativas se usa el asfalto dentro de los blancos fijos debido a que es el blanco que más afecta en los resultados. La misma operación se realizó con los sets “m” y “n” compuestos por los blancos móviles blancos, grises y negros. Dentro de los sets compuestos por los blancos móviles también se buscó el efecto en los resultados al usar la combinación de dos de los filtros (azul, rojo y verde)

manteniendo los blancos móviles grises, negros, blancos (rígidos y flexibles) como son los sets “o, p y q”. Los sets “r y u” se buscó el efecto del asfalto usando los blancos rígidos y flexibles excepto los fieltros gris, blanco y negro. La misma comparativa del asfalto se realizó usando sólo los blancos móviles flexibles (sets “s” y “t”). Los sets “v” y “w” también se compararon interaccionando el asfalto pero tan sólo usando los blancos móviles flexibles blanco, gris y negro. Los sets “x” “y” y “z” están compuestos por los blancos móviles rígidos, los móviles flexibles blanco, gris, negro y manteniendo estos blancos se añadió otro flexible (azul, rojo o verde respectivamente) para comprobar su efecto independientemente. Por último el set “total” está formado por todos los blancos de calibración, móviles y fijos.

Para comparar las medidas de reflectancia realizadas con el espectro-radiómetro con los ND de la imagen, se ha de tener en consideración que la reflectancia se midió en un rango de 350-2500 nm (con una anchura de banda de 1 nm), mientras que la UltraCam-Xp WA registra únicamente los niveles digitales en cuatro canales (R, G, B, NIR), cuyas curvas de respuesta espectral se muestran en la Figura 5.3 (Microsoft Vexcel, 2011). Para hacer comparables las mediciones radiométricas del espectro-radiómetro con las de la cámara se calculó el área relativa bajo las curvas de sensibilidad espectral de las diferentes bandas (R, G, B, NIR), obteniéndose el porcentaje de superficie correspondiente con cada intervalo de 20 nm (Figura 5.3). Por otro lado se calculó el promedio de las reflectancias tomadas con el espectro-radiómetro correspondiente a cada intervalo de 20 nm definido para las bandas de la cámara y se multiplicó por los porcentajes de superficie calculados anteriormente, obteniéndose la reflectancia ponderada correspondiente a cada banda de la cámara (De Miguel, 2001; Hernández-López, 2011; Del Pozo *et al.*, 2014).

Una vez obtenidos los valores de reflectancia de cada blanco para cada banda y los ND asociados, se realizó el ajuste estadístico empleando la técnica de regresión lineal simple (OLS) para cada uno de los sets. La técnica OLS se ha explicado en el capítulo 4 (apartado 4.3.5.3). Este ajuste se realizó entre las reflectancias de los blancos de calibración, medidas con el espectro-radiómetro de campo (variable dependiente) y los ND de los blancos en la imagen a calibrar (variable predictora), para cada una de las bandas de la imagen, siguiendo la metodología utilizada por Hernández-López *et al.* (2011), Herrero-Huerta (2013) y Del Pozo *et al.* (2014), entre otros. La relación lineal se evaluó buscando siempre la recta con un coeficiente de determinación del ajuste R^2 más

alto (con un nivel de significación del 5%) y el error medio cuadrático RMSE representado como valor absoluto y cómo %RMSE (porcentaje del valor de la variable que supone el RMSE) más bajo para cada una de las bandas (R, G, B, NIR). También se tuvo en cuenta el RMSE promedio resultante de promediar los diferentes errores de cada banda (R, G, B, NIR). Con el fin de comprobar la estabilidad de los modelos de calibración resultantes y de los sets, los ajustes se realizaron de forma independiente para las tres imágenes (A, B y C), y además se determinaron los errores cometidos al aplicar las ecuaciones obtenidas para la imagen A y C en la imagen B.

5.3.5. Validación

La validación de los modelos de calibración fue realizada de dos formas: mediante una validación cruzada completa (Geladi y Kowalski, 1986) y mediante un conjunto de datos independiente. Los datos independientes se correspondieron con las reflectancias en superficie medidas para las 30 muestras de vegetación herbácea, que no se emplearon en el ajuste de los modelos. Para hacer comparables las mediciones radiométricas del espectro-radiómetro con las de la cámara, las reflectancias en superficie de estas parcelas también fue necesario adaptar y normalizar las mediciones radiométricas a la resolución espectral de la cámara mediante el cálculo de las reflectancias ponderadas, teniendo en cuenta las curvas de sensibilidad espectral de la cámara (de forma análoga a como se hizo para los blancos de calibración). Esta última validación se consideró muy relevante, puesto que el objetivo final de la calibración de las imágenes fue el estimar biomasa aérea en zonas con vegetación, y por lo tanto el comportamiento de las ecuaciones de calibración y los sets en zonas con vegetación es crítico. Como criterios para la comparación y elección de los mejores sets de calibración, se usó el %RMSE y el coeficiente de determinación R^2 de la validación.

5.4. Resultados

5.4.1. Caracterización radiométrica de los blancos de calibración y validación

En la Figura 5.10, se muestran los espectros promedios de los blancos rígidos móviles, desde el negro hasta el blanco pasando por los diferentes reflectancias nominales de grises. Se representan las reflectancias promedio de los dos paneles (panel 1 y panel 2) de cada color. Se puede observar el amplio rango que abarcan las diferentes

reflectancias absolutas radiométricas en la zona del espectro visible e infrarrojo cercano (350-1000 nm). Este rango de valores de reflectancia en superficie es necesario para obtener una calibración radiométrica de las imágenes de la cámara aérea más precisa empleando la calibración empírica de línea. El panel blanco tiene una reflectancia alta en el visible, aunque en el infrarrojo cercano (750-1000 nm) se observa una reflectancia menor que la de los paneles grises. Estos paneles grises presentan una reflectancia decreciente según desciende su reflectancia nominal, mientras que el negro presenta una reflectancia mínima a lo largo de todo el espectro electromagnético.




Figura 5.10. Espectros promedio de los diferentes paneles móviles rígidos.

En la Figura 5.11, se muestran los espectros promedios de los blancos móviles flexibles, desde el fieltro negro (con una baja reflectancia) hasta el fieltro blanco (con reflectancias muy elevadas en el espectro visible). Entre estas reflectancias se observan las correspondientes con los fieltros rojo, gris, azul y verde.

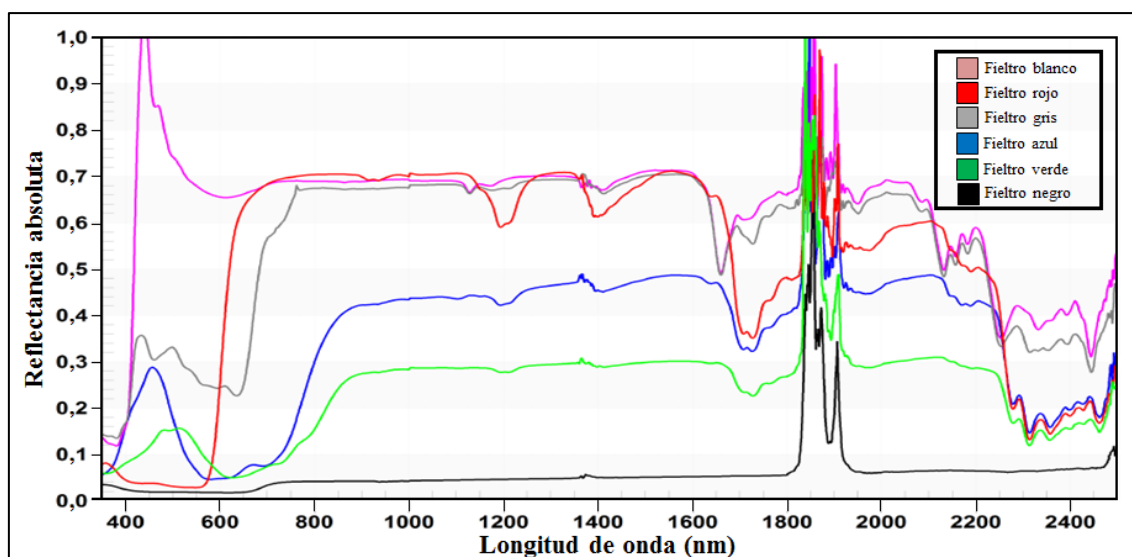


Figura 5.11. Espectros promedio de los diferentes blancos móviles flexibles.

En la Figura 5.12, se muestran los 4 espectros promedios de los blancos de calibración fijos. Las pistas 1 y 2 de atletismo se observan muy similares con reflectividad alta en la zona del rojo en el espectro visible, observándose baja reflectancia en la zona del azul y del verde. El espectro correspondiente al césped artificial presenta un pico de reflectancia en la zona correspondiente al color verde presentando una elevada reflectancia en el NIR. El asfalto representa una reflectancia baja y progresiva a lo largo del espectro electromagnético.

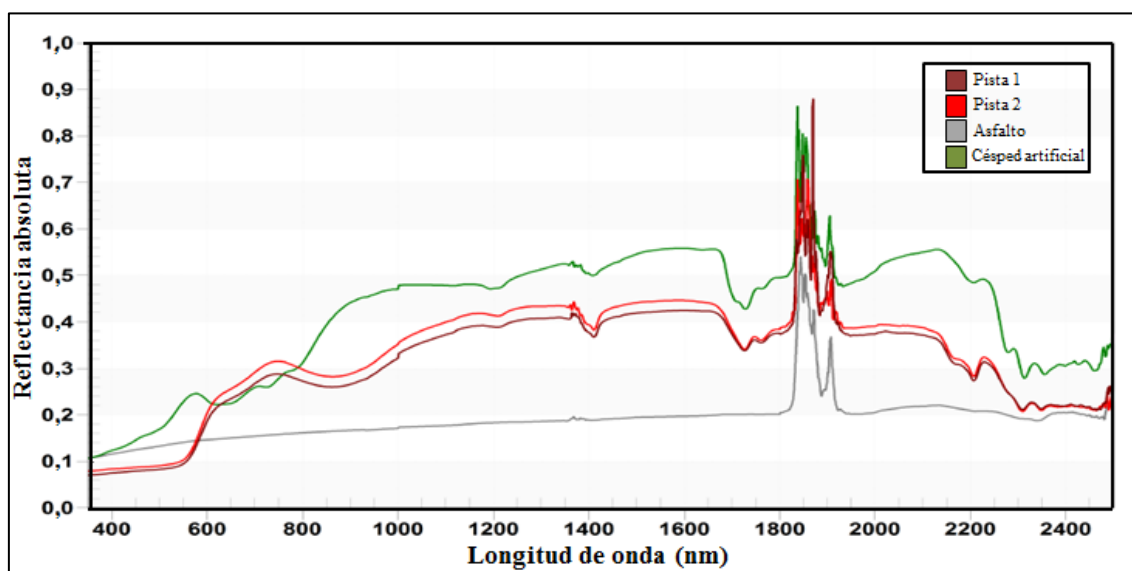


Figura 5.12. Espectros promedio de los diferentes blancos fijos.

En la siguiente Tabla 5.3 se presenta la caracterización radiométrica de los diferentes blancos a partir de los que se formaron los diferentes sets, también se

representan en la Tabla 5.3 los niveles digitales promedios correspondientes a cada blanco de calibración de la imagen B de la cámara multispectral UltraCam-Xp WA.

Tabla 5.3. Caracterización radiométrica de los blancos utilizados en los sets de calibración: Ref: Reflectancias ponderadas para cada banda (B, G, R, NIR) de la cámara y ND: Nivel digital promedio.

Blancos de calibración	B		G		R		NIR	
	Ref	ND	Ref	ND	Ref	ND	Ref	ND
Panel 1 blanco	0,769	2646,00	0,775	4601,10	0,733	4776,40	0,674	2956,00
Panel 2 blanco	0,778	2663,08	0,785	4646,50	0,744	4824,42	0,686	2984,50
Panel blanco medio	0,773	2654,54	0,780	4623,80	0,738	4800,41	0,680	2970,25
Panel 1 gris 25%	0,480	1816,00	0,501	3128,60	0,470	3389,50	0,623	2844,20
Panel 2 gris 25%	0,480	1810,27	0,502	3119,55	0,471	3368,82	0,625	2820,09
Panel gris 25% medio	0,480	1813,14	0,501	3124,07	0,471	3379,16	0,624	2832,15
Panel 1 gris 50 %	0,279	1049,78	0,290	1794,56	0,308	2239,22	0,542	2474,33
Panel 2 gris 50%	0,278	1047,75	0,289	1791,58	0,305	2236,17	0,542	2441,50
Panel gris 50% medio	0,279	1048,76	0,290	1793,07	0,307	2237,69	0,542	2457,92
Panel 1 gris 75%	0,123	521,17	0,121	810,25	0,162	1287,50	0,431	1946,50
Panel 2 gris 75%	0,121	516,17	0,119	791,83	0,161	1282,42	0,428	1950,67
Panel gris 75% medio	0,122	518,67	0,120	801,04	0,161	1284,96	0,430	1948,58
Panel 1 negro	0,021	154,13	0,018	252,00	0,015	295,50	0,013	360,75
Panel 2 negro	0,020	148,22	0,017	233,11	0,015	273,44	0,014	353,33
Panel negro medio	0,021	151,17	0,018	242,56	0,015	284,47	0,014	357,04
Filtro azul	0,230	775,89	0,102	609,31	0,056	495,42	0,204	1007,44
Filtro blanco	0,791	2844,92	0,700	4294,96	0,659	4520,33	0,688	3107,96
Filtro gris	0,312	1121,10	0,284	1767,78	0,258	2143,65	0,629	2876,01
Filtro negro	0,020	135,32	0,018	216,69	0,018	259,20	0,039	361,08
Filtro rojo	0,036	182,59	0,052	451,65	0,453	3541,32	0,696	3096,23
Filtro verde	0,127	518,29	0,128	831,97	0,057	490,92	0,134	742,00
Asfalto	0,127	480,85	0,139	908,20	0,148	1066,93	0,159	832,83
Césped artificial	0,153	596,46	0,206	1366,68	0,229	1651,86	0,306	1515,49
Pista 1	0,088	299,38	0,110	654,63	0,229	1517,88	0,301	1319,29
Pista 2	0,080	320,15	0,101	695,88	0,210	1615,44	0,275	1397,81

A partir de la Tabla 5.3 se representaron las reflectancias ponderadas de los diferentes blancos de calibración en cada banda (Figura 5.13).

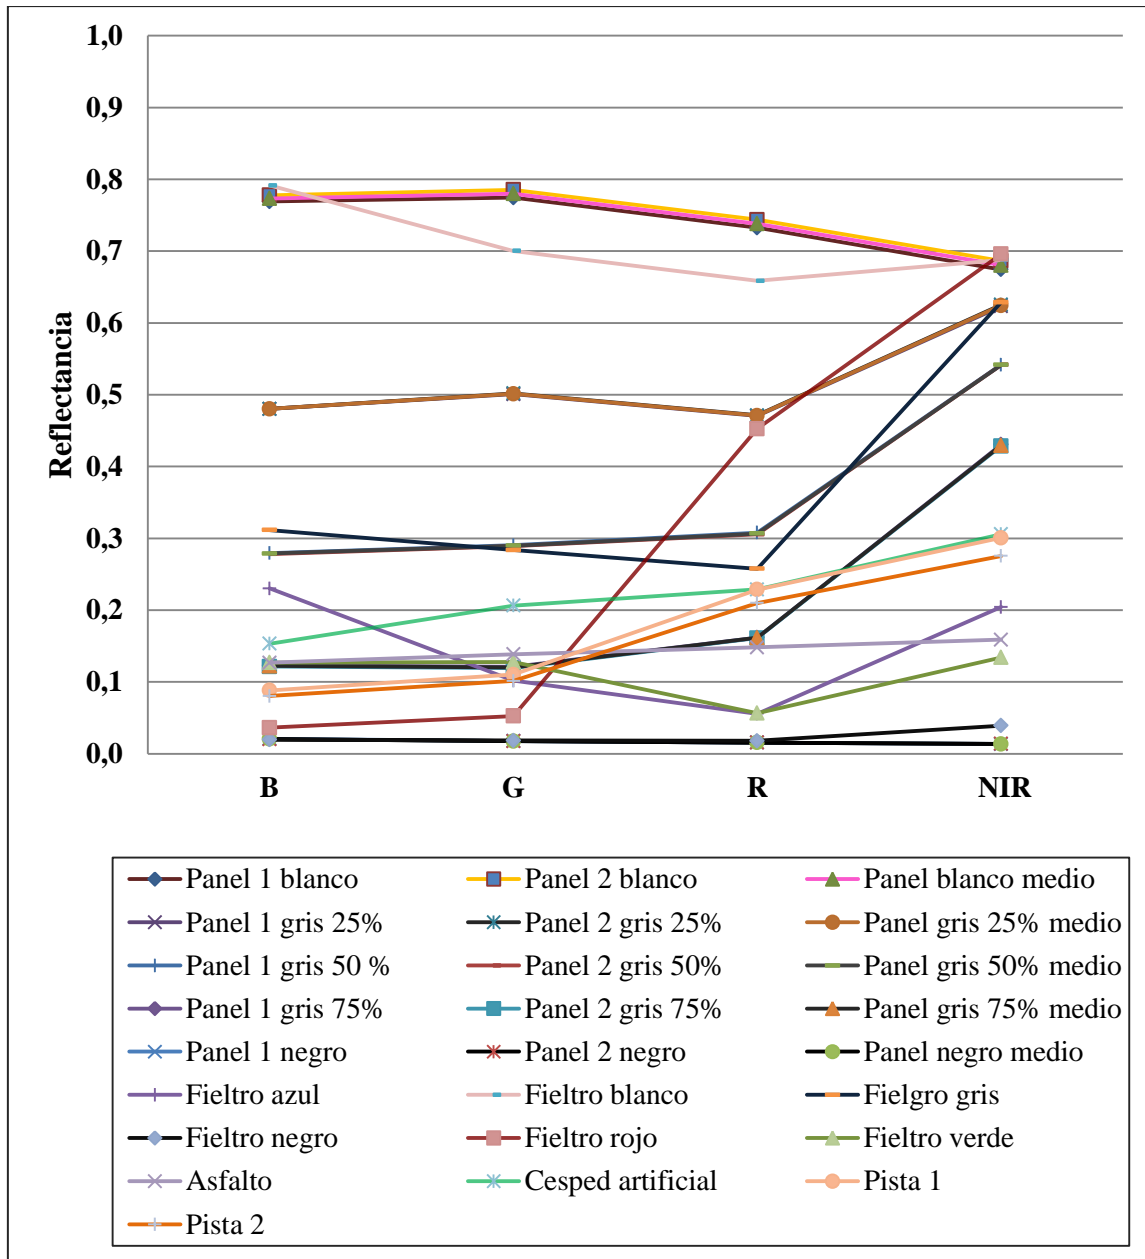


Figura 5.13. Reflectancias ponderadas de los diferentes blancos de calibración.

En la siguiente Figura 5.14, se representaron las reflectancias ponderadas simuladas de las diferentes parcelas de validación en cada banda (Figura 5.14). Se aprecia en la banda verde como las parcelas con más biomasa verde presentan reflectancias más elevadas y en la banda del NIR reflectancias menores debido a la absorción de la energía electromagnética por la concentración de agua en las plantas (e.g. parcelas 18 y 20). Por el contrario las parcelas con menos biomasa verde presentan en el NIR reflectancias más elevadas (e.g. parcelas 10 y 4).




Figura 5.14. Reflectancias promedio de las diferentes parcelas de validación (vegetación) simuladas para la cámara a partir de los datos del espectro-radiómetro.

5.4.2. Calibración radiométrica (validación cruzada)

A continuación se muestra en la Tabla 5.4, la exactitud de la validación cruzada completa en los resultados de la calibración empírica de la imagen B empleando los diferentes sets de calibración usando un nivel de significación del 0,05%. Se usó la imagen B debido a que su centro está más próximo al campo de calibración donde se encuentran los blancos. Tras analizar los resultados de los sets en la Tabla 5.4, se observa que todos los resultados son muy similares, por lo que para evaluar la exactitud se empleó el RMSE promedio de las 4 bandas. En el primer grupo (set “a”, “b” y “c”) la opción más exacta fue el set “a” compuesto por todos los blancos móviles rígidos. Al añadir el blanco fijo “asfalto” al set “a” no mejora los resultados frente al set “a”. Al analizar el siguiente grupo de estudio (Sets “e”, “f”, “g”, “h”, “i” y “j”) compuesto por los paneles móviles rígidos más un blanco móvil flexible (fieltro) se observa que el set “f” es el más exacto en la estimación de la banda roja y el set “g” en la banda verde. Los 6 sets son muy similares pero observando el RMSE promedio se observa que el set “j”

provoca la estimación más exacta mediante el uso del fieltro verde. Si comparamos el “k” y “l” fijándonos en el RMSE promedio se observa que es más exacto no usar el blanco fijo “asfalto” al igual que al comparar el set “m” y “n”. Si comparamos el siguiente grupo “o”, “p” y “q” se observa que el set “p” proporciona la estimación más exacta en la banda del verde y se deduce que el set más exacto para el estudio dentro de este grupo teniendo en cuenta el RMSE promedio, es el set “q” usando todos los blancos móviles excepto el fieltro rojo. Buscando el efecto del blanco fijo asfalto en los sets “r” y “u” se observa que el resultado es más exacto usando el blanco fijo (set u). Del mismo modo ocurre al comprar los sets “s” y “t” y los sets del siguiente grupo “v” y “w”. El set “v” resultó ser el más exacto en la banda NIR. Finalmente el grupo de sets “x”, “y”, “z” se observa que el set más exacto es el “z” usando el blanco móvil flexible verde. El set “total” usado de manera comparativa, ha mejorado los resultados de diferentes sets (“b”, “o”, “r”, “s”, “t”, “v”, “w”).

Tabla 5.4. Exactitud de la validación en la calibración empírica de línea para cada banda (B, G, R, NIR). RMSE: (%). Dentro de cada banda se destaca los resultados más exactos. Se destacan los resultados más exactos de cada banda así como el RMSE promedio más exacto.

Set	B		G		R		NIR		RMSE
	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	Promedio
Set a	0,996	0,01685	0,999	0,00861	0,995	0,01736	0,998	0,01082	0,01341
Set b	0,987	0,03068	0,997	0,01416	0,984	0,03145	0,993	0,01989	0,02405
Set c	0,995	0,01861	0,999	0,00940	0,994	0,01928	0,998	0,01173	0,01476
Set d	0,996	0,01686	0,999	0,00841	0,995	0,01753	0,997	0,01225	0,01376
Set e	0,995	0,01824	0,999	0,00986	0,995	0,01743	0,997	0,01248	0,01450
Set f	0,996	0,01712	0,999	0,00943	0,995	0,01716	0,998	0,01168	0,01385
Set g	0,996	0,01644	0,999	0,00832	0,993	0,02006	0,997	0,01174	0,01414
Set h	0,996	0,01662	0,999	0,00838	0,995	0,01741	0,998	0,01210	0,01363
Set i	0,996	0,01677	0,999	0,00834	0,990	0,02477	0,998	0,01065	0,01513
Set j	0,996	0,01635	0,999	0,00853	0,995	0,01756	0,998	0,01199	0,01361
Set k	0,996	0,01653	0,999	0,00921	0,991	0,02376	0,997	0,01319	0,01567
Set l	0,996	0,01675	0,999	0,00942	0,991	0,02399	0,997	0,01317	0,01583
Set m	0,996	0,01635	0,999	0,00871	0,994	0,01960	0,997	0,01336	0,01450
Set n	0,996	0,01646	0,999	0,00889	0,994	0,01959	0,997	0,01298	0,01448
Set o	0,996	0,01719	0,999	0,00959	0,991	0,02427	0,997	0,01319	0,01606
Set p	0,997	0,01581	0,999	0,00860	0,990	0,02434	0,997	0,01279	0,01538
Set q	0,996	0,01707	0,999	0,00959	0,994	0,01936	0,997	0,01353	0,01489
Set r	0,995	0,01739	0,999	0,00939	0,990	0,02417	0,997	0,01260	0,01589
Set s	0,992	0,02306	0,998	0,01161	0,969	0,04178	0,999	0,00893	0,02135
Set t	0,993	0,02114	0,998	0,01037	0,969	0,03893	0,999	0,00812	0,01964
Set u	0,995	0,01717	0,999	0,00914	0,990	0,02387	0,997	0,01284	0,01576
Set v	0,997	0,01691	0,999	0,00893	0,948	0,05442	0,999	0,00752	0,02194
Set w	0,995	0,02135	0,998	0,01100	0,915	0,07711	0,990	0,02913	0,03465
Set x	0,996	0,01754	0,999	0,00979	0,994	0,01947	0,997	0,01358	0,01509
Set y	0,997	0,01623	0,999	0,00868	0,990	0,02457	0,997	0,01259	0,01552
Set z	0,997	0,01602	0,999	0,00879	0,994	0,01956	0,997	0,01316	0,01438
Set T	0,996	0,01640	0,999	0,00952	0,990	0,02302	0,996	0,01459	0,01588

A nivel general el set más exacto en cada banda es diferente por lo que se elaboró tres estudios diferentes: el primero usando el set más exacto en cada banda (Tabla 5.4), el segundo eligiendo el set con el estadístico de validación RMSE promedio menor de las 4 bandas) y el tercero usando el set T compuesto por todos los blancos de calibración.

A continuación se muestran las Tablas 5.5, 5.7 y 5.9 para las tres imágenes (A, B y C) así como los parámetros obtenidos en sus modelos en las tablas correspondientes (5.6, 5.8, 5.10). Se usó una validación cruzada y un nivel de significación del 0,05%. Con el fin de comparar la exactitud de los modelos se usaron los estadísticos R^2 : coeficiente de determinación; RMSE: error cuadrático medio de la validación (valor absoluto y porcentaje de la media de la variable (%). Para un uso comparativo también se realizó el estudio usando el set “total” compuesto por todos los blancos de calibración.

En la Tabla 5.5, se muestran los estadísticos de validación de las calibraciones empíricas de línea en la imagen B y el set “a”, compuesto por los paneles en la escala de grises (panel 1, panel 2, panel 1+2) con un $R^2=0,99$ y un RMSE promedio $\leq 0,014$ % correspondiente a un %RMSE = 3,64%. En el segundo estudio se muestran los estadísticos de validación de las calibraciones empíricas de línea en la imagen B y el set “mixto” que proporcionaron las estimaciones más exactas en cada banda (Set “p”, Set “g”, Set “f” y Set “v”) En los cuatro sets se obtuvieron resultados semejantes y de elevada exactitud ($R^2=0,99$ y RMSE promedio $< 0,013\%$ correspondiente a un %RMSE=3,51%) respecto a las reflectancias medidas en los blancos de calibración. En un último estudio se realizó usando el set “total” en la imagen B, compuesto por todos los paneles de calibración obteniendo una exactitud elevada y un %RMSE $< 5,1\%$ sobre las reflectancias. Por tanto según estos resultados el set “mixto” demuestra ser el más exacto en esta imagen.

Tabla 5.5. Exactitud de la validación en la calibración empírica de línea para la imagen B en cada banda. RMSE:(%), %RMSE: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R^2	RMSE	%RMSE	R^2	RMSE	%RMSE	R^2	RMSE	%RMSE
B	0,996	0,0169	5,0309	0,997	0,0158	5,0115	0,996	0,0164	5,8654
G	0,999	0,0086	2,5195	0,999	0,0083	2,4608	0,999	0,0095	3,4161
R	0,995	0,0174	5,1300	0,995	0,0172	4,7877	0,990	0,0230	7,7851
NIR	0,998	0,0108	2,3631	0,999	0,0075	1,9861	0,996	0,0146	3,5415
MEDIA	0,997	0,0134	3,6417	0,998	0,0122	3,5099	0,995	0,0159	5,0176

En la Tabla 5.5 se observan resultados más exactos al usar un set independiente para cada banda (set “mixto”) que usar un mismo set para todas las bandas. Al usar el set “mixto” el resultado más exacto se alcanza en la banda infrarrojo cercano ($R^2=0,999$ y $RMSE=0,00752$ siendo un $\%RMSE<2\%$) y al usar el set “a” la estimación más exacta se consigue en la banda del verde ($R^2=0,9999$ y $RMSE=0,00861$ representando un $\%RMSE<2,6\%$ sobre las reflectancias). En la siguiente Tabla 5.6, se muestran los parámetros de calibración para la imagen B en cada banda.

Tabla 5.6. Parámetros del modelo de calibración según los diferentes sets (a, mixto y total).

Gain: término a y Offset: término b en la ecuación: Reflectancia= $aND+b$.

Banda	Set	Gain	Offset
B	a	0,0003	-0,0327
G	a	0,0002	-0,0223
R	a	0,0002	-0,0413
NIR	a	0,0003	-0,0721
B	p	0,0003	-0,0271
G	g	0,0002	-0,0222
R	f	0,0002	-0,0403
NIR	v	0,0002	-0,0412
B	total	0,0003	-0,0211
G	total	0,0002	-0,0178
R	total	0,0002	-0,0317
NIR	total	0,0002	-0,0552

A continuación en la Tabla 5.7, se muestran los valores de la exactitud de los modelos de validación obtenidos en la imagen A

Tabla 5.7. Exactitud de la validación en la calibración empírica de línea para la imagen A en cada banda. RMSE: (%), $\%RMSE$: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R^2	RMSE	$\%RMSE$	R^2	RMSE	$\%RMSE$	R^2	RMSE	$\%RMSE$
B	0,9956	0,0178	5,31	0,9964	0,0164	5,21	0,9958	0,0167	5,95
G	0,9989	0,0092	2,69	0,9989	0,0089	2,62	0,9985	0,0097	3,48
R	0,9966	0,0146	4,33	0,9968	0,0145	4,05	0,9929	0,0197	6,65
NIR	0,9980	0,0107	2,34	0,9995	0,0063	1,67	0,9964	0,0144	3,49
MEDIA	0,9973	0,0131	3,55	0,9979	0,0115	3,32	0,9959	0,0151	4,77

En la imagen A se obtienen resultados semejantes al usar los mismos sets que en la imagen B. Mediante el set “a” el modelo nos muestra un $\%RMSE<3,6\%$ sobre las reflectancias, mediante el set “mixto” un $\%RMSE<3,4\%$ resultando ser el más exacto y el set “total” un $\%RMSE<4,8\%$. El resultado más exacto se obtiene en la banda NIR ($R^2=0,9995$ y $RMSE=0,0063\%$) del set “mixto” y si observamos el set “a” la banda más exacta es la verde de nuevo obteniendo un $RMSE=0,0092\%$. En la siguiente Tabla 5.8, se muestran los parámetros de calibración para la imagen B en cada banda.

Tabla 5.8. Resultados de los parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia= $aND+b$

Banda	Set	Gain	Offset
B	a	0,0003	-0,0309
G	a	0,0002	-0,0205
R	a	0,0002	-0,0381
NIR	a	0,0002	-0,0657
B	p	0,0003	-0,0254
G	g	0,0002	-0,0206
R	f	0,0002	-0,0373
NIR	v	0,0002	-0,0378
B	total	0,0003	-0,0201
G	total	0,0002	-0,0172
R	total	0,0002	-0,0293
NIR	total	0,0002	-0,0519

A continuación en la Tabla 5.9, se muestran los valores de la exactitud de los modelos de validación obtenidos en la imagen C

Tabla 5.9. Exactitud de la validación en la calibración empírica de línea para la imagen C en cada banda. RMSE: (%), %RMSE: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE
B	0,996	0,0169	5,03	0,996	0,0175	5,56	0,995	0,0177	6,31
G	0,999	0,0084	2,478	0,999	0,0084	2,47	0,998	0,0108	3,88
R	0,996	0,0150	4,42	0,996	0,0164	4,58	0,991	0,0215	7,28
NIR	0,997	0,0121	2,64	0,999	0,0063	1,67	0,995	0,0144	3,49
MEDIA	0,9970	0,0131	3,55	0,9975	0,0122	3,49	0,99475	0,0161	5,08

En la imagen C el set que presenta un %RMSE promedio más bajo vuelve a ser el set “mixto” (%RMSE promedio=3,49%) ya que se escoge el set con menos error en cada banda. Por otro lado analizando las bandas de manera independiente en el set “mixto” se obtienen los resultados más exactos en la banda del NIR ($R^2=0,999$ y $RMSE<0,007\%$). Si nos fijamos en el set “a” de nuevo la banda del verde obtiene los resultados más exactos ($R^2=0,999$, $RMSE<0,009\%$). En la siguiente Tabla 5.10 se muestran los parámetros de calibración para la imagen B en cada banda.

Tabla 5.10. Resultados de los parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia= $aND+b$.

Banda	Set	Gain	Offset
B	a	0,0003	-0,0313
G	a	0,0002	-0,0196
R	a	0,0002	-0,0355
NIR	a	0,0002	-0,0643
B	p	0,0003	-0,0260
G	g	0,0002	-0,0202

R	f	0,0002	-0,0338
NIR	v	0,0002	-0,0370
B	total	0,0003	-0,0196
G	total	0,0002	-0,0162
R	total	0,0002	-0,0267
NIR	total	0,0002	-0,0480

En la Figura 5.15, se muestran tres imágenes en reflectancias. La imagen 1 de la izquierda es la imagen formada por las ecuaciones de la imagen A sobre la imagen B. La imagen central 2, es la imagen en reflectancias formada por las ecuaciones de su propia imagen B y la imagen de la derecha 3 es la imagen formada con las ecuaciones óptimas de la imagen C. En las tres imágenes se usó el set “mixto” al presentarse como el más exacto o con menor error medio. Son imágenes (R, G, B, NIR) en falso color (4, 3, 2) en la imagen central se aprecia un *display* donde aparecen las reflectancias (R, G, B) en las tres imágenes (1, 2, 3). El R: representa la banda del NIR donde en esa imagen está situada sobre un arbusto y representa en las tres imágenes reflectancias similares (0,42%) y muy superior a las otras dos bandas.

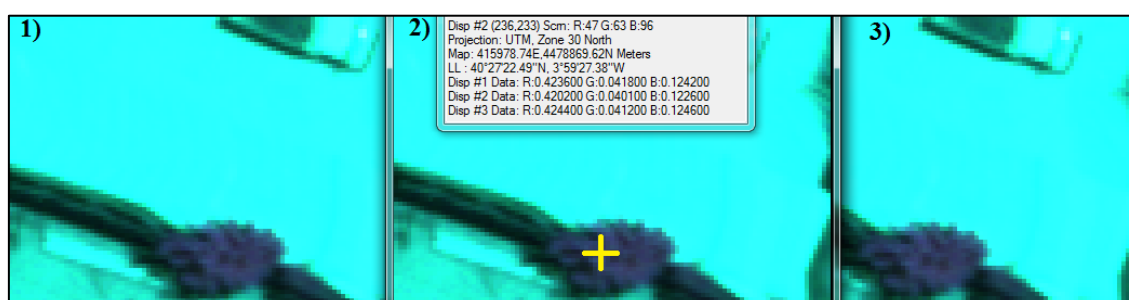


Figura 5.15. Imágenes en reflectancia de la imagen B. La imagen 1 está formada por las ecuaciones de la imagen A sobre la imagen B. La imagen 2, es la imagen formada por las ecuaciones de su propia imagen B y la imagen 3 es la imagen formada con las ecuaciones de la imagen C.

Con el fin de evaluar la robustez de los modelos se aplicaron las ecuaciones de los sets (a, mixto y total) de la imagen A y C en la imagen B obteniéndose en ambos casos los mismos modelos (Tabla 5.11). Se usó una validación cruzada y un nivel de significación del 0,05%.

Tabla 5.11. Exactitud de la validación en la calibración empírica de línea usando los modelos de los sets de las imágenes A y C en la imagen B para cada banda. RMSE: (%), %RMSE: % sobre las reflectancias.

SET A	SET MIXTO	SET TOTAL
-------	-----------	-----------

BANDAS	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE
B	0,996	0,0169	5,0338	0,997	0,0158	5,0115	0,996	0,0164	5,8654
G	0,999	0,0086	2,5195	0,999	0,0083	2,4608	0,999	0,0095	3,4161
R	0,995	0,0174	5,1300	0,995	0,0172	4,7877	0,990	0,0230	7,7851
NIR	0,998	0,0108	2,3631	0,999	0,0063	1,6666	0,996	0,0144	3,4905
MEDIA	0,9970	0,0134	3,6424	0,9975	0,0119	3,4229	0,99525	0,0158	5,0018

En la Tabla 5.11, se observaron resultados similares que aplicando los modelos propios de la imagen B, incluso una mayor exactitud en %RMSE sobre las reflectancias de los blancos de calibración usando los set “mixto” (%RMSE=3,42% promedio) y el set “total” (%RMSE<5,1% promedio) pero con diferentes parámetros a y b como se observa en la siguiente Tabla 5.12. El valor del termino independiente es cero ya que en la validación el nivel de significación fue >0,05, por lo que se rechazó ese término por no ser significativo. En la siguiente Tabla 5.12, se muestran los parámetros de calibración de cada banda para la imagen B (obtenidos a partir de los modelos de los sets de las imágenes A y C).

Tabla 5.12. Resultados de los parámetros del modelo de calibración según los diferentes sets (a, mixto y total). Gain: término a y Offset: término b en la ecuación: Reflectancia=aND+b.

Banda	Set	Gain	Offset
B	a	0,9907	0
G	a	0,8599	0
R	a	0,7921	0
NIR	a	1,2541	0
B	p	0,9780	0
G	g	0,8598	0
R	f	0,7883	0
NIR	v	1,1698	0
B	total	0,9700	0
G	total	0,8511	0
R	total	0,7683	0
NIR	total	1,2177	0

5.4.3. Calibración radiométrica (validación independiente)

Con el fin de completar la determinación de la robustez de los modelos se realizó una validación independiente, empleando parcelas con vegetación como puntos de comprobación de las reflectancias obtenidas.

La validación independiente se realizó en las parcelas de vegetación usando como variable dependiente o respuesta las reflectancias medidas con el espectro-radiómetro y como variables predictoras o independientes las imágenes de reflectancia obtenidas con

los sets de calibración más exactos (set “a”, set “mixto” y set “total”) para los fotogramas A, B y C. Los resultados de la validación se muestran en las Tablas (5.13, 5.14 y 5.15).

Tabla 5.13. Exactitud de la validación independiente de la calibración radiométrica en la imagen A. RMSE:(%), %RMSE: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE
B	0,995	0,0131	3,92	0,999	0,0085	2,68	0,999	0,0041	1,48
G	0,999	0,0060	1,76	0,999	0,0060	1,79	0,999	0,0045	1,63
R	0,974	0,0285	8,43	0,977	0,0280	7,82	0,989	0,0217	7,35
NIR	0,988	0,0188	4,10	0,961	0,0204	5,39	0,991	0,0204	4,94
MEDIA	0,989	0,0166	4,51	0,984	0,0157	4,52	0,995	0,0127	4,01

Tabla 5.14. Exactitud de la validación independiente de la calibración radiométrica en la imagen B. RMSE: (%), %RMSE: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE
B	0,993	0,0164	4,90	0,997	0,0116	3,68	0,999	0,0063	2,25
G	0,997	0,0103	3,01	0,997	0,0102	3,02	0,999	0,0071	2,55
R	0,965	0,0330	9,75	0,970	0,0324	9,04	0,986	0,0255	8,62
NIR	0,989	0,0175	3,82	0,975	0,0164	4,33	0,995	0,0163	3,96
MEDIA	0,986	0,0193	5,24	0,985	0,0177	5,08	0,995	0,0138	4,36

Tabla 5.15. Exactitud de la validación independiente de la calibración radiométrica en la imagen C. RMSE:(%), %RMSE: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE
B	0,991	0,0176	5,26	0,997	0,0132	4,19	0,999	0,0075	2,68
G	0,997	0,0099	2,90	0,997	0,0104	3,08	0,999	0,0078	2,81
R	0,968	0,0316	9,33	0,973	0,0304	8,49	0,986	0,0247	8,37
NIR	0,989	0,0177	3,86	0,970	0,0180	4,75	0,994	0,0174	4,21
MEDIA	0,986	0,0192	5,21	0,984	0,0180	5,18	0,995	0,0143	4,53

En las Tablas 5.13, 5.14 y 5.15) se observa cómo se mantiene la parsimonia de los modelos al validar en las parcelas. El uso del set “total” es el más adecuado en esta validación independiente en las tres imágenes, siendo la diferencia en las tres imágenes <1% y obteniéndose en el mejor de los casos un %RMSE<4,1% promedio de las cuatros bandas (R, G, B, NIR) en la imagen A (R²=0,995, RMSE promedio=0,0127%). La diferencia del set “total” respecto a los otros sets (a y mixto) vuelve a ser <1%, en las tres imágenes. El uso de los otros sets también dio resultados %RMSE<5% sobre las

reflectancias. La estimación más exacta en la validación de las parcelas se consigue en la banda azul del set “total” ($R^2=0,0999$; $RMSE=0,0041$). Por tanto en las tres imágenes se aprecian resultados en la validación muy semejantes ya sea usando el set “a”, el set “mixto” o el set “total”, siendo este último el que presenta en las tres imágenes los resultados más exactos.

Por otro lado se utilizaron las ecuaciones usadas en la calibración de los set de las imágenes A y C en la imagen B y las reflectancias obtenidas se compararon con las medidas en las parcelas con vegetación. En los dos casos se obtuvieron los mismos resultados, mostrados en la Tabla 5.16. Se aprecia cómo se sigue manteniendo la exactitud de los modelos, siendo el set “total” el más exacto $\%RMSE=4,37\%$ independientemente de que las ecuaciones de calibración sean las de las imágenes adyacentes y no las de la propia imagen B.

Tabla 5.16. Exactitud de la validación independiente de la calibración radiométrica en la imagen B usando las ecuaciones de calibración de la imagen A y C. RMSE: (%), $\%RMSE$: % sobre las reflectancias.

BANDAS	SET A			SET MIXTO			SET TOTAL		
	R^2	RMSE	$\%RMSE$	R^2	RMSE	$\%RMSE$	R^2	RMSE	$\%RMSE$
B	0,993	0,0164	4,91	0,997	0,0116	3,69	0,999	0,0063	2,26
G	0,997	0,0103	3,03	0,997	0,0102	3,02	0,999	0,0071	2,56
R	0,965	0,0330	9,76	0,970	0,0324	9,04	0,986	0,0255	8,64
NIR	0,989	0,0175	3,82	0,975	0,0164	4,32	0,995	0,0163	3,96
MEDIA	0,986	0,0193	5,25	0,985	0,0177	5,08	0,995	0,0138	4,37

5.5. Discusión

Este trabajo se ha basado en una corrección atmosférica absoluta mediante una calibración vicaria. Los modelos obtenidos pueden ser usados para el procesamiento de imágenes derivadas de la cámara multispectral UltraCam-Xp WA.

Este trabajo ha demostrado que es posible calibrar radiométricamente una imagen ($\%RMSE<4\%$) mediante el uso de datos de radiometría de campo adquiridos en condiciones equivalentes sobre la superficie observada. Dentro de los diferentes tipos de calibración radiométrica, se ha demostrado que la calibración empírica de línea es un procedimiento adecuado para hacer una calibración absoluta de las imágenes de cámara aérea fotogramétrica UltraCam-Xp WA, empleando imágenes con el mínimo nivel de procesamiento posible (nivel 2). El error mínimo que se cometió promediando las

cuatro bandas en la calibración fue de 3,3% (%RMSE) (%RMSE_{RGB} entre el 2-5%, según banda y %RMSE_{NIR}<2%). Estos errores cometidos en la calibración de las cuatro bandas (%RMSE=3,3%) son menores que los obtenidos por Markelin *et al.* (2010) y Beisl (2010), que obtuvieron errores en la calibración de las bandas menores del 5%. Resultados similares se obtuvieron en el trabajo de Hernández-López *et al.* (2012), donde obtuvieron un %RMSE<3,5% al usar la calibración empírica de línea (%RMSE_{RGB} entre 2% y 2,6% y %RMSE_{NIR} 3,5%) frente a la calibración radiométrica de laboratorio de la ADS40-SH5 (RMSE_{RGB} entre 2,6-4% según la banda y un RMSE_{NIR}=5,5 % en el NIR), obteniendo por tanto una mejora sobre todo en la banda del NIR de un 2%. Duan *et al.* (2013) realizó de igual modo una calibración empírica de línea en un sensor hiperespectral (UAV-HYPER) obteniendo errores relativos en las bandas entre aproximadamente 4% y 10%. El mayor error lo obtuvieron en las primeras y últimas bandas del sensor. A la inversa, errores más pequeños se produjeron en el rango visible. En este trabajo el mayor error se comete en la banda del rojo aunque el error relativo también está por debajo del 8%, consiguiendo mayores exactitudes que en el trabajo de Duan *et al.* (2013) (<2%,)

En la misma línea de los resultados de este trabajo están los obtenidos por Secker *et al.* (2001) para una calibración vicaria de los coeficientes radiométricos procedentes de la cámara CASI a partir de espectro-radiometría, usando como blanco de calibración una pista de gravilla, obteniendo errores de $3,9 \pm 5,6\%$.

La mayoría de los trabajos de calibración radiométrica usan diferentes blancos de referencia aunque pocos realizan estudios independientes según el conjunto de blancos de calibración usados. En este trabajo, se compararon los resultados de realizar la calibración con 27 sets diferentes, obteniéndose un RMSE promedio de las cuatro bandas (R, G, B, NIR) entre 0,013% (set “a”) y 0,034% (set “w”). El error relativo promedio en la estimación de las reflectancias varió entre 3,3% y 5,1%, cometiéndose el menor error usando los set “mixtos” en las tres imágenes y el mayor error con el set “total”. Las diferencias al usar el set óptimo para cada banda o usar todos los set (set “total”) puede deberse a que algunas de las superficies no móviles muestreadas (asfalto, césped artificial, pistas de atletismo) no sean totalmente homogéneas ni representen valores extremos de reflectancia (muy alta o muy baja). Este aspecto fue recogido por De Miguel (2001), que no consiguió bajar de un error absoluto del 10% debido a que las

superficies artificiales empleadas eran poco lambertianas y las como las naturales eran poco homogéneas (tierra de campo de futbol, tierra de lodos, pista artificial verde etc.).

Por tanto se recomienda el uso del set “a” (Paneles móviles de escala de grises (panel 1, panel 2, panel 1+2) debido a su simplicidad, y a su respuesta lambertiana, aunque el uso de otros sets es factible ya que no presentan diferencias significativas. Álvarez *et al.* (2010a) también obtuvo elevadas exactitudes ($R^2 > 95\%$) usando únicamente la escala de grises de referencia, al igual que Honkavaara y Markelin (2007), que evaluaron la idoneidad de un patrón con 8 niveles de gris en la calibración de diferentes sensores (ADS40, DMC, UltraCam-D y DSS).

El uso de fieltros de distintos colores y otros blancos pseudoinvariantes ha sido también testado por otros autores como Del Pozo *et al.* (2014), que en la calibración vicaria basada en métodos de radiancias, obtuvieron un error %RMSE entre el 2,5 % y 8% usando 6 lonas con diferentes tonos de grises, y 6 lonas de vinilo de diferentes colores. En esta línea Hernández-López *et al.* (2012), obtuvieron un %RMSE entre el 2% y el 14% según la superficie y banda contrastada donde usaron una escala de grises y lonas con los mismos colores que en este trabajo. No obstante, demostraron que la solución basada en la calibración vicaria con la aplicación de la corrección atmosférica supera ligeramente la exactitud en todas las bandas sobre la base de la calibración propuesta por el fabricante del sensor ADS40. Sin embargo, las reflectancias terrestres obtenidas en la calibración vicaria y la calibración de laboratorio proporcionado por el fabricante son válidas ya que en los dos casos los RMSE obtenidos estaban por debajo del 6%. Hernández-López *et al.* (2012), demostró que los blancos más exactos se obtienen en las lonas de color granate y verde para los cuatro canales del espectro (RMSE promedio de las cuatro bandas menor del 3% y desviaciones estándar menor del 1%) mientras que las superficies más variables como la arena o la vegetación obtuvieron errores más elevados (RMSE promedio de las cuatro bandas menor del 4% y desviaciones estándar entorno al 3%) debido a que estas superficies son anisotrópicas, es decir son superficies donde los ángulos de reflexión cambian y existe por tanto una cantidad de energía que no es recogida por el sensor, situación que provoca un ligero aumento en su error. En trabajos futuros sería de interés considerar superficies con un comportamiento anisotrópico y a continuación, analizar los efectos bidireccionales empleando, por ejemplo, modelos de núcleo-conducido (Hernández-López *et al.*, 2011).

Por otra parte, cabe destacar que en este trabajo teniendo en cuenta las tres

imágenes, la calibración más exacta se consigue en la banda del NIR (set “mixto”, con un %RMSE<1,7%), al contrario que los resultados obtenidos por Hernández-López *et al.* (2012), donde las bandas más uniformes en términos de similitud de error, fueron la azul y la verde, y la banda más variable era la NIR, donde el error promedio para esta banda de todos los blancos fue mayor (RMSE=2,45%), debido principalmente al uso de muestras con vegetación donde el RMSE era de 6,44% para la hierba y 4,54% para los arbustos, aumentando por tanto la media del error de la banda NIR.

Al usar los fieltros no se mejoró el %RMSE promedio de las 4 bandas respecto a la escala de grises (set “a”) sin embargo usar el set “f” (set “a” +fieltro blanco) se obtiene el modelo más exacto en la banda del rojo (RMSE=0,0172) frente al set “a” (RMSE=0,0174). Al usar el set “g” (set “a” +fieltro gris) se obtiene la mayor exactitud en la banda verde (RMSE=0,0083) respecto al set “a” (RMSE=0,0086). El uso del set “p” (set “a”+ fieltros blanco, negro, gris, rojo y verde) se obtiene el menor error en la banda azul (RMSE=0,0158 frente al set “a” (RMSE= 0,0169) y usando el set “s” o “t” es decir usando todos los fieltros mejora la banda del NIR (RMSE=0,008%) frente al set “a” (RMSE=0,011%). No obstante, el método menos exacto (set “w”, usando solo 3 fieltros) obtuvo un R^2 promedio >0,97 (RMSE promedio <0,035%).

Herrero-Huerta (2013) demostró la posibilidad de realizar una calibración radiométrica de la cámara Mini-MCA de la casa Tetracam© en paramotor con materiales “*low cost*” mediante el método vicario, usando de igual modo lonas de distintos colores para la calibración de las 6 bandas con $R^2=0,96$ en todas las bandas, demostrando el buen funcionamiento en el uso de lonas como se hizo en este trabajo mediante el uso de fieltros. Murillo-Sandoval *et al.* (2014) realizó un trabajo similar a partir de 5 lonas plásticas opacas de diferentes colores de tamaño 20 cm × 15 cm como referencia, obteniendo una exactitud de la calibración mínima de 0,965 (R^2), inferior a lo obtenido en este trabajo ($R^2=0,99$). Esto se puede deber a que la resolución radiométrica (16 bits) de las imágenes de la cámara Ultracam-Xp WA es el doble que las imágenes que se pueden obtener con la cámara Mini-MCA (8 bits).

Otras cámaras se están testando para su uso en los UAVs a partir de modificaciones en filtros o en las lentes. Un ejemplo de ello es el trabajo de Wang *et al.* (2015), usando una cámara digital single-lens reflex (DSLR) Canon modificada y una escala de grises con reflectancias nominales (20%, 30%, 40%, 50%, 60%, 70%, 80%, y 90%) para la calibración de las imágenes, obteniendo un ajuste bastante exacto

$R^2=99\%$. El resultado de ese ajuste no es lineal pero mediante funciones logarítmicas estiman la ecuación lineal para la calibración. Otro trabajo como el que realizaron Hunt *et al.* (2010) de igual modo usaron una cámara modificada de tres bandas (Fuji FinePix S3 Pro UVIR) donde obtuvo una correlación en las bandas más acorde con este trabajo ($R^2=0,967$) usando una calibración radiométrica a partir de lonas de colores (rojo, verde, negro, gris, azul).

Con el fin de evaluar la robustez de los modelos se aplicaron las ecuaciones de los sets (a, mixto y total) de la imagen A y C en la imagen B obteniéndose en ambos casos, los mismos modelos en los cuales los errores obtenidos varían entre 3,4% y un 5% de las reflectancias (%RMSE), dependiendo del set. Las estimaciones más exactas con las ecuaciones de la imagen A o C en la imagen B se obtuvieron para la banda del NIR (%RMSE<1,7%), manteniendo la exactitud del modelo ajustado propiamente para la imagen B. Esto puede ser debido al uso de los filtros ya que cuando se usan independientemente (set “s”, “t”, “v”) al resto de blancos de calibración, presentan un error muy bajo en la calibración de la banda del NIR. Se demostró por tanto el uso de la misma calibración para imágenes adyacentes sí es posible, debido a la estabilidad de las condiciones atmosféricas y la elevada resolución radiométrica de la cámara así como el uso de filtros para la calibración radiométrica.

La validación independiente realizada en las zonas de vegetación obtuvo un %RMSE un promedio para las tres imágenes muy similar, independientemente según el set usado. Así para el set “a” se obtuvo un %RMSE=4,99%, para el set “mixto” un %RMSE=4,93% y para el set “total” un %RMSE=4,30%. La diferencia fue menor del 1%, por lo que no se considera que un set sea superior al resto. Los errores del promedio de las cuatro bandas %RMSE variaron entre un 4 y un 4,5%, siendo la calibración más exacta la realizada en la imagen A. Por otra parte la banda azul es la que se corrige de una forma más exacta en las tres imágenes, con errores entre el 1,5% y el 2,6%, así como un $R^2=0,999$ en las tres imágenes. Por otro lado la banda que arroja una peor exactitud es la roja, con un %RMSE entre 7,4% y 8,6%. Del Pozo *et al.* (2014) también realizaron una validación independiente sobre plántulas de pino obteniendo un error del 1,8% con la cámara Mini-MCA para imágenes de 10 bit. Este error tan pequeño puede deberse a la baja altura de vuelo (30 m), lo que permite obtener píxeles muy homogéneos espacialmente.

Los resultados obtenidos en este capítulo indican que a partir de los valores de reflectancia obtenidos para estas imágenes se pueden estimar variables biofísicas como la biomasa aérea o la cantidad de carbono secuestrado por esa biomasa.

CAPÍTULO 6

6 ESTIMACIÓN DE BIOMASA AÉREA CON IMÁGENES MULTIESPECTRALES DE CÁMARA AÉREA DIGITAL

6.1. Introducción y objetivos

La estimación de variables biofísicas como la cantidad de carbono o de biomasa a partir de métodos empíricos e imágenes requiere una calibración radiométrica absoluta de dichas imágenes, de modo que se obtengan valores de reflectancia escalada en superficie (Jensen, 2005). En el caso de sensores fotogramétricos, las calibraciones más habituales son mediante calibración empírica de línea y campos de calibración permanentes o móviles (Álvarez *et al.*, 2010a, Markelin, 2013; Pérez-Aragües *et al.*, 2013; Del Pozo *et al.*, 2014). La posibilidad de estimar la cantidad de biomasa y su

modelización facilita la toma de decisiones en cuanto al manejo de cultivos (Pordesimo *et al.*, 2004), siendo interesante su estimación en una determinada zona, por su relación directa con el carbono (Barrio *et al.*, 2006). Las mediciones directas de biomasa son destructivas y costosas (Reese *et al.*, 1980) por lo que la aplicación un método basado en imágenes multiespectrales de sensores fotogramétricos y la regresión por mínimos cuadrados parciales (PLSR, *Partial Least Squares Regression*) (Mutanga *et al.*, 2012; Axelsson *et al.*, 2013; Marabel y Álvarez, 2014), se plantea como una oportunidad para mejorar los modelos de estimación biomasa aérea usados en la bibliografía científica a partir de diferentes índices de vegetación (Hansen y Schjoerring, 2003; Hernán *et al.*, 2007; Hongrui y Guangsheng, 2014).

El objetivo principal de este capítulo fue desarrollar, comparar y validar diferentes métodos para la estimación de biomasa aérea de herbáceas con imágenes multiespectrales de Ultracam-Xp WA corregidas radiométricamente. Se compararon los siguientes enfoques: (i) estimación a partir de los índices de vegetación y regresión por mínimos cuadrados (OLS), y (ii) estimación a partir de las bandas de reflectancia (R, G, B, NIR) y regresión por mínimos cuadrados parciales (PLS).

Además se establecieron los siguientes objetivos específicos:

1. Testar la idoneidad del índice de vegetación MARAVI propuesto en este trabajo para la estimación de biomasa.
2. Analizar la robustez de los modelos de calibración radiométrica de imágenes cuando estas se emplean para la estimación de biomasa aérea.

6.2. Material

6.2.1. Datos de teledetección

El sensor utilizado fue la cámara aérea fotogramétrica UltraCam-Xp Wide Angle (Ultracam-Xp WA), fabricado por Microsoft-Vexcel. Es un sensor multiespectral aerotransportado de tipo matricial, con captura de imágenes en las bandas del azul, verde, rojo e infrarrojo cercano (R, G, B, NIR) (Microsoft Vexcel, 2011). La descripción completa del sensor y sus características técnicas se pueden consultar en el capítulo 5 (apartado 5.2.1.1.), puesto que se empleó la misma cámara.

El vuelo con la UltraCam-Xp WA lo realizó la compañía Servicios Politécnicos

Aéreos S.A. (SPASA) el 23 de julio de 2012, y se tomaron 7 fotogramas consecutivos de oeste a este. Para una descripción completa de las características del vuelo, véase el capítulo 5 (apartado 5.2.1.2).

Se emplearon las 3 imágenes multispectrales (R, G, B, NIR) ortorectificadas de la cámara aérea fotogramétrica Ultracam-Xp WA, con una resolución espacial (GSD) de 18 cm y una resolución radiométrica de 16 bits, en formato TIFF y con un nivel 2 de procesamiento. Para este trabajo se usaron los tres fotogramas centrales del vuelo (fotogramas A, B y C). Las características detalladas de las imágenes se pueden observar en el capítulo 5 (apartado 5.2.1.3). Los sets de calibración empleados para hacer las correcciones radiométricas de las imágenes se describen en el capítulo 5 (apartado 5.3.4).

6.2.2. Datos de biomasa aérea

Se establecieron 30 unidades de muestreo homogéneas con herbáceas, fundamentalmente *Trifolium repens*, *Lolium perenne* y *Poa pratense*, sometidas a riego y sembradas en la misma época. Cada una de estas unidades fue una parcela de 1 m × 1 m, dividida en 4 subparcelas de 0,5 m × 0,5 m. El trabajo de campo se llevó a cabo el 22 de julio de 2012 y la posición de las parcelas se determinó utilizando el receptor GNSS Topcon Hiper II. Los datos GPS fueron post-procesados utilizando estaciones de referencia con el fin de obtener las coordenadas en el sistema ETRS89 UTM huso 30. La localización de las mismas y su distribución se representan en la Figura 6.1. El dispositivo de parcelas para la toma de datos de biomasa se explica en detalle en el capítulo 4 (apartado 4.2.3).

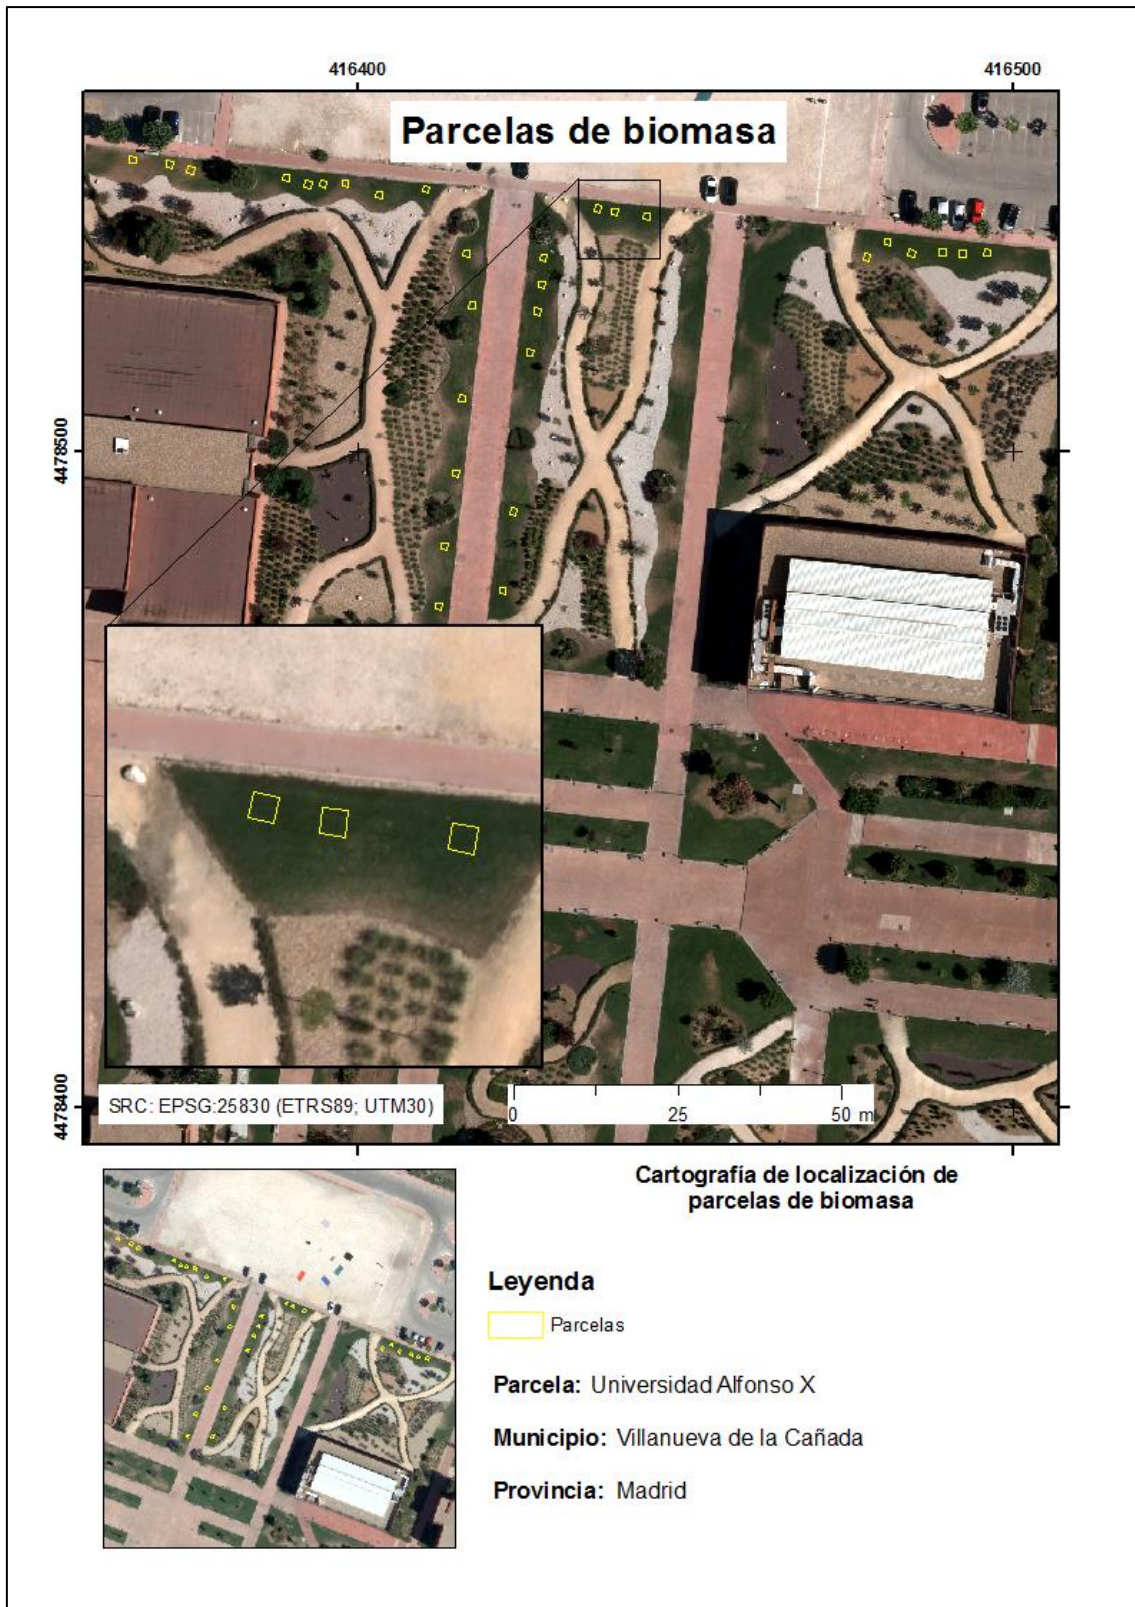


Figura 6.1. Localización de las parcelas de biomasa de herbáceas (Elaboración propia).

Para llevar a cabo la cuantificación de la biomasa aérea medida como peso seco de la fracción verde en g/m^2 , (PV), en cada unidad de muestreo se cortó la biomasa aérea de la subparcela noroeste de cada parcela de $1 \text{ m} \times 1 \text{ m}$ y se tomó como muestra representativa (Figura 6.2). Las muestras se introdujeron en bolsas herméticas con el fin de evitar la pérdida de humedad y fueron transportadas al laboratorio en neveras frigoríficas.

En el laboratorio se procedió a su pesado y a su separación en biomasa seca y biomasa verde. A posteriori se procedió al secado en una estufa, obteniendo por separado, el peso de la biomasa aérea verde (PV) el peso total (PT) y el porcentaje de PV respecto al total (%PV).

El peso de la biomasa se expresó en g/m^2 al dividir su peso entre el área de las parcelas. El procedimiento se describe en detalle en Marabel y Álvarez-Taboada (2013, 2014).



Figura 6.2. Representación de la parcela ($1 \text{ m} \times 1 \text{ m}$) y la cosecha de biomasa aérea en la subparcela ($0,5 \text{ m} \times 0,5 \text{ m}$)

6.3. Métodos

6.3.1. Flujo de trabajo

El flujo de trabajo seguido para la estimación de biomasa con imágenes tomadas con la cámara aérea digital se resume en la Figura 6.3. Se partió de los fotogramas del vuelo, que se corrigieron geométricamente y se corrigieron radiométricamente mediante calibración empírica de línea empleando los sets de calibración y la metodología detallada en el Capítulo 5. Una vez obtenidas las imágenes de reflectancia en superficie, se derivaron índices de vegetación de las mismas y los valores de reflectancia para cada una de las cuatro bandas de la imagen.

Por otro lado se calculó la biomasa aérea medida como PV, PT y %PV a partir de los datos de las parcelas de campo. Posteriormente se ajustaron dos modelos de estimación de biomasa aérea en herbáceas para cada imagen (A, B, C): (i) mediante regresión PLS a partir de la reflectancias de cada banda de la imagen de reflectancia en superficie y (ii) mediante regresión OLS a partir de los índices de vegetación obtenidos de la imagen de reflectancia en superficie (NDVI, SR, SAVI, NLI y un nuevo índice aportado en este trabajo denominado MARAVI). Finalmente se validaron los modelos obtenidos. Además se evaluó el efecto en la estimación de biomasa al emplear el mismo modelo de corrección radiométrica para imágenes adyacentes. Finalmente se testó la posibilidad de emplear el mismo modelo de estimación de biomasa aérea para imágenes adyacentes.

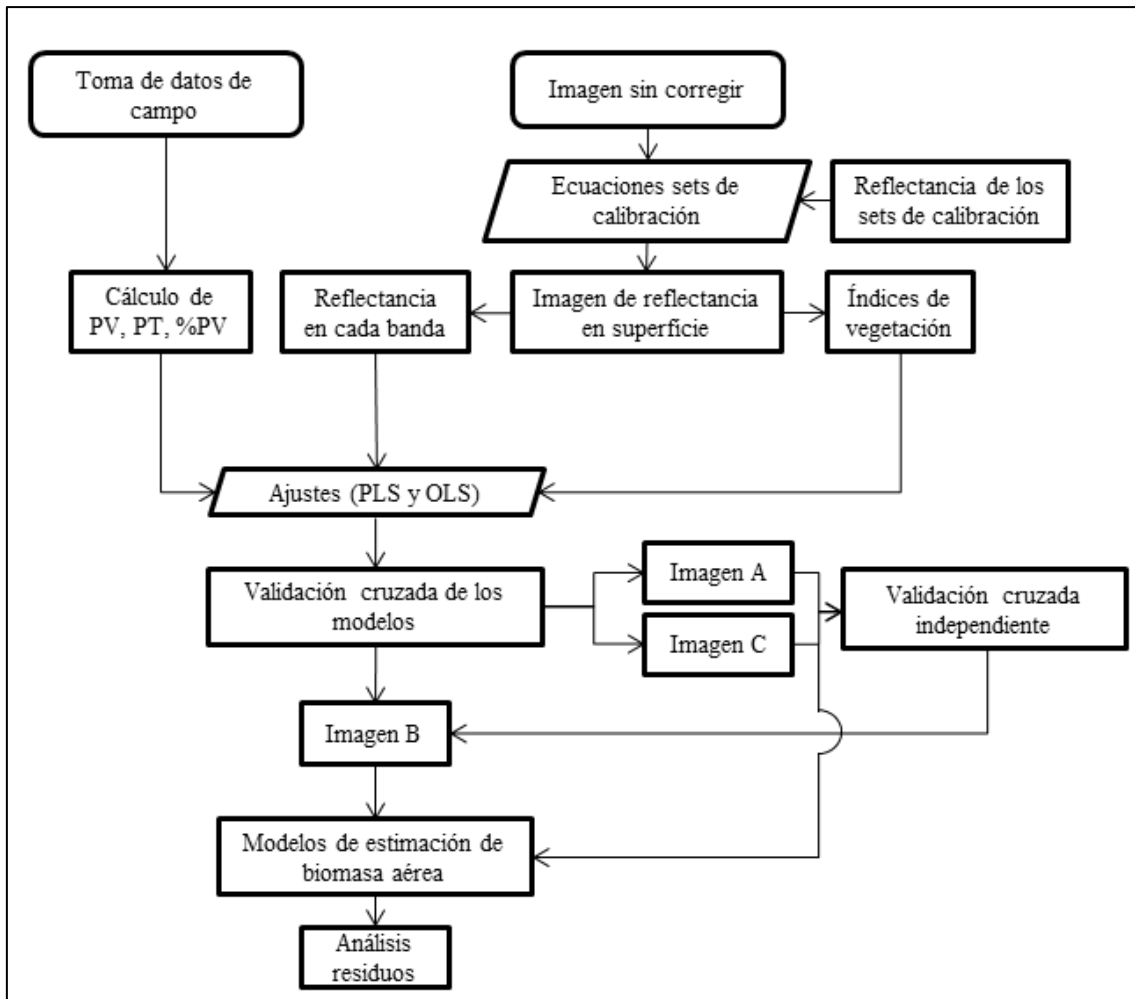


Figura 6.3. Diagrama de flujo de trabajo seguido en el Capítulo 6. (Elaboración propia).

6.3.2. Pre-procesamiento de las imágenes

Las imágenes A, B y C se ortorrectificaron empleando los parámetros de orientación directa del vuelo y los puntos de apoyo medidos con el receptor GNSS.

Los niveles digitales de cada imagen se corrigieron a reflectancia en superficie (reflectancia aparente) mediante una calibración empírica de línea siguiendo la metodología y los sets de calibración descritos en el Capítulo 5 (apartado 5.4.2). Para cada una de las imágenes se emplearon las ecuaciones de calibración radiométrica ajustadas para la propia imagen, siendo los set usados finalmente para la calibración los siguientes: (i) set “a”: que se corresponde con el estadístico de validación RMSE promedio menor para las 4 bandas, (ii) set “mixto”, “p”, “g”, “f”, “v”: que se corresponde con el set más exacto para cada banda (B, G, R e NIR, respectivamente) y (iii) el set “total”, que incluye todos los blancos de calibración y él cual se empleó como referencia.

6.3.3. Modelos de ajuste para la estimación de biomasa

Los modelos de ajuste estadístico empleados en la estimación de biomasa aérea emplearon como variables respuesta el PV, el PT y el %PV y como variables predictoras las reflectancias de las bandas (R, G, B, NIR) o bien los siguientes índices de vegetación: el ratio simple (*Simple ratio*, SR) (Birth y McVey, 1968) (Ec. 6.1) el índice de vegetación de diferencia normalizada (*Normalized Difference Vegetation Index*, NDVI) (Rouse *et al.*, 1974) (Ec. 6.2), el índice de vegetación ajustado al suelo (*Soil Adjusted Vegetation Index*, SAVI) (Huete, 1988) (Ec. 6.3), el índice de vegetación no lineal (*Non-Linear vegetation Index*, NLI) (Goel y Qin, 1994) (Ec. 6.4), así como un índice de vegetación definido en esta tesis (Ec. 6.5) (*Marabel Vegetation Index*, MARAVI).

Estas variables predictoras se obtuvieron a partir de las imágenes A, B y C, calibradas a reflectancias, tal y como se ha descrito en el apartado anterior.

$$SR = \frac{NIR}{R} \quad (\text{Ec. 6.1})$$

$$NDVI = \frac{NIR-R}{NIR+R} \quad (\text{Ec. 6.2})$$

$$SAVI = \frac{NIR-R}{NIR+R+L} \times (1+L) \quad (\text{Ec. 6.3})$$

$$NLI = \frac{NIR^2 - R}{NIR^2 + R} \quad (\text{Ec. 6.4})$$

$$MARAVI = (NIR - R^2) \sqrt{\frac{NIR}{R}} \quad (\text{Ec. 6.5})$$

Dónde: NIR y R son los valores de las reflectancias en las bandas del infrarrojo cercano y del rojo, respectivamente, L: constante para ajustar la línea vegetación-suelo al origen= 0,5.

Para ajustar los modelos basados en la reflectancia de las bandas (R, G, B, NIR) se usó la regresión por mínimos cuadrados parciales (PLS), explicada en el capítulo 4 (apartado 4.3.5.1) debido a los posibles fenómenos de multicolinealidad (Marabel y Álvarez-Taboada, 2013). Por otro lado en el ajuste de los modelos basados en los índices SR, NDVI, SAVI, NLI y MARAVI se usó la regresión de mínimos cuadrados ordinarios (OLS), explicada en el capítulo 4 (apartado 4.3.5.3).

Para analizar la robustez de los modelos de calibración radiométrica cuando las imágenes se emplean en la estimación de biomasa aérea, se compararon las estimaciones de biomasa obtenidas a partir de la imagen de reflectancia B (corregida radiométricamente con su set óptimo) y los valores de biomasa estimados en la imagen de reflectancia B (corregida con las correcciones radiométricas ajustadas para las imágenes adyacentes A y C). En el caso de que las diferencias en biomasa no fuesen significativas, se podría utilizar el mismo modelo de calibración radiométrica para las imágenes adyacentes de una misma pasada.

6.3.4. Validación

Para los modelos ajustados con PLS, se realizó una validación cruzada de tipo *Leave-One-Out* (LOOCV) la cual implica separar los datos de forma que para cada iteración se emplee un solo dato de prueba y todo el resto de los datos se utilicen para entrenamiento. Se usó este tipo de validación debido a que la estimación del error es más estable y no tiende a sobrestimarlo (Geladi y Kowalski, 1986; Huang *et al.*, 2004; Clevers *et al.*, 2008; Atzberger *et al.*, 2010). Para la comparación de los modelos se emplearon como criterios el RMSE, el %RMSE, el coeficiente de determinación R^2 y el criterio de información de Akaike de la validación. Con el fin de elegir el modelo ajustado con PLS óptimo con un error aceptable y mantener la parsimonia del modelo, se usó el criterio de información de Akaike (AIC) (Akaike, 1969). La ventaja de AIC frente a otros posibles indicadores como R^2 o RMSE es que éste tiene en cuenta además del RMSE, el número de factores utilizados en el modelo penalizando la inclusión de factores que no mejoran significativamente el modelo. Minimizando este criterio se obtienen modelos más adecuados para la predicción (Akaike, 1969). El cálculo de estos estadísticos se ha descrito en el capítulo 4 (apartado 4.3.6.).

Para el modelo elegido se realizó un análisis de residuos de la validación cruzada entre valores de referencia y los valores predichos que consistió en verificar que no se violaran las hipótesis sobre las que se estiman los modelos (la normalidad de residuos, la no autocorrelación, la homocedasticidad o la falta de linealidad). Esta verificación se llevó a cabo de manera gráfica y mediante test de significación, en los cuales se contrastaron dos hipótesis: la nula y la alternativa. La hipótesis nula es aquella que se presupone inicialmente y los datos deben comprobar si se rechaza o no hay argumentos suficientes para ello. La hipótesis alternativa es la que tienen valor probatorio en el

sentido de que dice que los datos rechazan claramente la hipótesis nula. Indica cual es la línea de fallo de la hipótesis nula y por consiguiente la que le da capacidad de discriminación al test (Shapiro y Wilk, 1965).

Para realizar los contrastes a posteriori de las hipótesis de los modelos se realizó un análisis de residuos, definiendo como residuos la diferencia entre el valor observado y el valor predicho por el modelo (en la validación).

Para verificar si los residuos estaban normalmente distribuidos se usaron tres gráficos (el histograma, el diagrama de proporciones acumuladas (P-P) y el diagrama de posiciones (Q-Q)) y el contraste de *Shapiro-Wilk* (Shapiro y Wilk, 1965).

El histograma de residuos con la curva de distribución normal de media cero ajustada superpuesta permitió ver la distribución de los residuos y verificar cualquier desviación de la normalidad.

En el gráfico P-P se compararon la frecuencia acumulada por los residuos tipificados y la probabilidad esperada bajo la hipótesis de normalidad. Si la variable residuos coincidía con la distribución normal, los puntos se concentraban en torno a una línea recta.

Los gráficos Q-Q también permitieron observar si existía alguna desviación de la normalidad de los residuos. Su interpretación se basó en que si los puntos de la gráfica Q-Q estaban ajustados a la línea diagonal de la gráfica, los cuantiles de los residuos coincidían con los cuantiles de una normal. Las desviaciones de los puntos con respecto a la línea indicaban desviaciones de la normalidad en los residuos.

El Contraste de normalidad se llevó a cabo mediante el Test de *Shapiro-Wilk*, utilizado para determinar cuál es la distribución que sigue una variable aleatoria continua en una población a partir de los datos obtenidos en una muestra. Es adecuado para el contraste de normalidad en muestras en las cuales el tamaño máximo es 50.

1. H_0 : La variable residuo tiene una distribución normal
2. H_1 : La variable residuo no tiene una distribución normal

El contraste se lleva a cabo rechazando la hipótesis nula de normalidad si el estadístico W es menor que el valor crítico proporcionado por la tabla elaborada por los autores para el tamaño de la muestra y el nivel de significación dado (Shapiro y Wilk, 1965). Se tomó como valor crítico 0,05 (5% de nivel de significación) de modo que si el estadístico fue inferior a ese valor, se rechazó la hipótesis de normalidad, concluyendo

que la variable residuos no se ajustaba a una distribución normal, y si era mayor de 0,05 la distribución sí se ajustaba a una normal.

Para analizar la homocedasticidad (que indica que la varianza del error es constante y que no aumenta al aumentar el valor del error), se usó el diagrama de dispersión de residuos tipificados frente al de valores pronosticados tipificados. A parte de usarlo para detectar problemas de heterocedasticidad también se usó para comprobar la dependencia entre las variables predictoras y los errores (hipótesis de linealidad). Si en el gráfico se observó alguna tendencia, ésta puede ser indicio de autocorrelación, de heterocedasticidad o falta de linealidad. Una característica que se tuvo en cuenta fue observar en estos casos si el tamaño de los residuos aumentaba o disminuía de forma sistemática para algunos valores ajustados de la otra variable, es decir si el gráfico mostraba forma de embudo, indicio de que el modelo propuesto no describía adecuadamente los datos. Si por el contrario los residuos no presentaban patrón alguno, entonces no se rechazó la hipótesis de igualdad de varianzas. Se trazó una línea horizontal a la altura de 0 para comprobar la variación de los residuos sobre esta línea.

Para la no autocorrelación (relacionada con la no independencia entre los residuos) se usó el estadístico de *Durbin-Watson*. Éste estadístico oscila entre 0 y 4 y si los residuos varían aleatoriamente, este valor debería ser cercano a 2. Los valores mayores de 2 indican autocorrelación positiva y los menores de 2 autocorrelación negativa. Un p-valor pequeño indica un patrón no aleatorio en los residuales. Si están correlacionadas, entonces la regresión de cuadrados mínimos subestima el error estándar de los coeficientes y sus predictores pueden parecer significativos sin serlo realmente.

Para los modelos ajustados mediante OLS se empleó una validación cruzada completa, que es análoga a la LOOCV descrita anteriormente. Para la comparación de los modelos se emplearon como criterios el RMSE, el %RMSE y el coeficiente de determinación R^2 de la validación. El cálculo de estos estadísticos se ha descrito en el capítulo 4 (apartado 4.3.6). El criterio para elegir el modelo OLS óptimo fue el menor valor de RMSE, al igual que al comparar estos modelos con los obtenidos por regresión PLS. También se realizó un análisis de la varianza y de los residuos de la validación cruzada entre valores de referencia y los valores predichos para verificar que no se violaran las de partida.

Estos modelos se validaron de forma análoga a lo indicado en los párrafos

anteriores. Tanto el ajuste estadístico como la validación se realizaron con el software Unscrambler® X10.2 (CAMO Software Inc., Woodbridge).

6.4. Resultados

6.4.1. Modelos de estimación de biomasa aérea

En la Tabla 6.1 se muestra la exactitud en la validación cruzada (R^2 , RMSE, %RMSE y AIC) de los diferentes modelos de estimación de la biomasa aérea (PV, PT y %PV) ajustados con regresión PLS a partir de reflectancias empleando los diferentes sets (a, mixto y total). Se resaltan en negrita los resultados más exactos en cada imagen.

Tabla 6.1. Resultados de la validación cruzada de los modelos de estimación de biomasa aérea (PV, PT y %PV) en las imágenes A, B y C, empleando regresión PLS, las reflectancias de las cuatro bandas y los diferentes sets de calibración (a, mixto y total). F: número de factores latentes; R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m²; $RMSE_{PT}$: g/m²; y $RMSE_{\%PV}$: %; AIC: criterio de información de Akaike, %RMSE: %.

	Biomasa	SET	R^2	RMSE	F	AIC	%RMSE
Imagen A	PV	a	0,873	4,5741	2	49,6125	14,42
		mixto	0,867	4,6906	2	50,3667	14,79
		total	0,873	4,5741	2	49,6125	14,42
	PT	a	0,714	8,5224	2	68,2809	18,92
		mixto	0,701	8,7045	2	68,9152	19,32
		total	0,714	8,5224	2	68,2810	18,92
	%PV	a	0,661	7,8743	3	67,9080	11,52
		mixto	0,689	7,8339	3	67,7537	11,46
		total	0,666	8,8915	3	71,5529	13,01
Imagen B	PV	a	0,878	4,4842	2	49,0166	14,14
		mixto	0,878	4,4842	2	49,0166	14,14
		total	0,878	4,4841	2	49,0166	14,14
	PT	a	0,696	8,7784	2	69,1690	19,49
		mixto	0,696	8,7784	2	69,1690	19,49
		total	0,720	8,8354	2	69,3628	19,61
	%PV	a	0,693	7,7828	3	67,5576	11,39
		mixto	0,693	7,7829	3	67,5580	11,39
		total	0,714	7,8145	3	67,6794	11,43
Imagen C	PV	a	0,898	4,0958	2	46,2987	12,92

		mixto	0,898	4,0958	2	46,2987	12,92
		total	0,901	4,1038	2	46,3574	12,94
	PT	a	0,700	8,7202	2	68,9693	19,36
		mixto	0,700	8,7202	2	68,9693	19,36
		total	0,721	8,7568	2	69,0950	19,44
	%PV	a	0,711	7,5450	3	66,6266	11,04
		mixto	0,711	7,5450	3	66,6266	11,04
		total	0,733	7,5471	3	66,6347	11,04

En el anexo II se muestran los coeficientes obtenidos de los modelos en la estimación a partir de la tabla anterior Tabla 6.1.

En la estimación de biomasa aérea, los resultados más exactos (AIC menor) se obtuvieron para la biomasa aérea medida como peso seco de la fracción verde (PV), utilizando la imagen C y el set de calibración radiométrica “a” ($R^2=0,90$; $RMSE=4,096 \text{ g/m}^2$ y $AIC=46,299$; $\%RMSE=12,92\%$). A este modelo se le denominó Modelo 1 (Imagen C, Set “a”, PV) (Ec. 6.6):

$$PV = -38,72652 - 42,16429 \cdot R_B - 50,54102 \cdot R_G - 111,4273 \cdot R_R + 327,8595 \cdot R_{NIR}$$

Ec.6.6

Siendo PV: Biomasa aérea (peso verde) (g/m^2); R_B, G, R, NIR : Reflectancias en superficie de cada banda (en tanto por uno).

Los resultados fueron muy similares en la estimación de biomasa aérea referida al PV en las tres imágenes, obteniendo los resultados más exactos (AIC menor) al usar el set “a” y el set “total”. De las tres imágenes destaca la imagen C por obtenerse el AIC menor independientemente del set usado respecto a las otras dos imágenes. Las estimaciones de biomasa aérea como PT también mostraron resultados similares para las tres imágenes. El set “a” de nuevo proporcionó el resultado más exacto para la imagen A ($R^2=0,714$; $RMSE=8,522 \text{ g/m}^2$; $AIC=68,281$; $\%RMSE=18,92\%$) y para la imagen B se obtiene el mismo resultado para set “a” y set “mixto” ($R^2=0,696$; $RMSE=8,7784 \text{ g/m}^2$; $AIC=69,169$; $\%RMSE=19,49\%$). Para la imagen C se obtiene de igual modo un resultado igual tanto el set “a” como para el “mixto”. Respecto a las estimaciones de la biomasa aérea como %PV, en las tres imágenes, el set “a” y “mixto” proporcionan los modelos más exacto destacando la imagen C ($R^2=0,711$;

RMSE=7,545%; AIC=66,627; %RMSE=11,04%), aunque en las tres imágenes se obtienen resultados semejantes.

Las diferencias en la exactitud de la estimación de biomasa aérea (PV, PT, %PV) según el set de calibración empleado oscilaron entre 0,1% y un 2% (%RMSE) independientemente de la imagen. Por otro lado, si se tuvo en cuenta una misma imagen, las diferencias entre usar los diferentes sets de calibración oscilaron en un rango entre 0,1% a 1,6% para el %RMSE. Este resultado corrobora los resultados del capítulo 5, donde se comprobó que el empleo de los sets de calibración “a” y “mixto”, proporcionaban estimaciones de reflectancia en superficie, tan exactos como el uso del set con todos los blancos. El resultado obtenido para la estimación de biomasa muestra que las diferencias en las reflectancias estimadas no tienen un impacto en las estimaciones de PV, PT o %PV cuando se emplean esos sets.

A continuación se muestra el análisis de residuos del ajuste entre los valores de referencia y los valores predichos en la validación cruzada por el Modelo 1 (Imagen C, Set “a”, estimación de biomasa como PV).

Para comprobar las hipótesis de independencia, normalidad y homocedasticidad de residuos del Modelo 1 se emplearon los gráficos de la Figura 6.4 y los resultados de los test de *Shapiro-Wilk* y de *Durbin-Watson*. En el gráfico A de la Figura 6.4, los residuos siguen una distribución normal ya que las barras del histograma representan un aspecto similar al de dicha curva. En el gráfico B se muestra que la variación de los residuos sobre esta línea 0 no sigue ninguna tendencia o forma de embudo por lo que no se puede rechazar la hipótesis de homocedasticidad, es decir los residuos tienen una varianza constante y son independientes de los valores ajustados. En el gráfico C (P-P), se aprecia que los puntos se ajustan a una línea recta por lo que los datos probablemente tienen una distribución normal. En el gráfico D se observa que los puntos se aproximan bien a la diagonal, lo que confirma la hipótesis de normalidad. El estudio analítico de la normalidad de los residuos mediante el contraste no-paramétrico de *Shapiro-Wilk*, indicó que no se puede rechazar la hipótesis de normalidad de los residuos a un nivel de significación del 95%, puesto que se obtuvo un *p*-valor de 0,354.

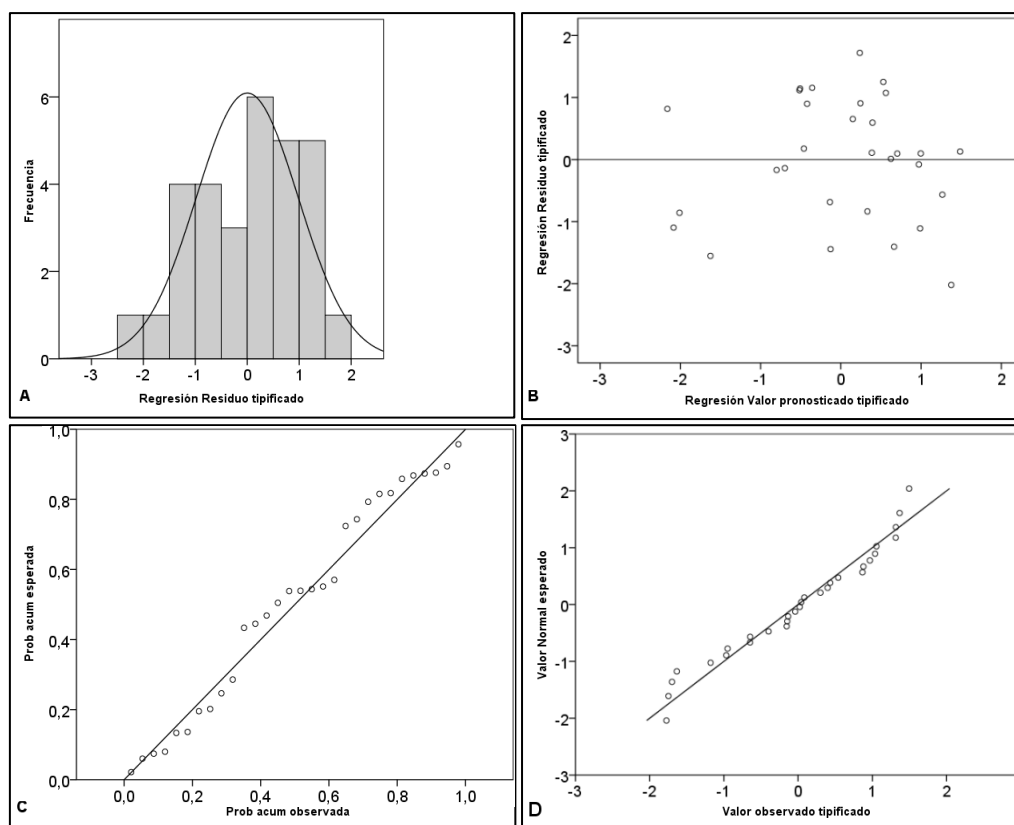


Figura 6.4. Análisis de los residuos en el modelo 1. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q.

El contraste de *Durbin-Watson* indicó la incorrelación de los residuos, puesto que el valor obtenido (2,115) está próximo a 2, lo que indica que los residuos están incorrelados.

Por lo tanto, los resultados de los diagramas de dispersión y de los test realizados indican que el que el modelo lineal ajustado (Modelo 1) cumple las hipótesis de partida y se puede emplear para la estimación de la biomasa aérea medida como peso seco de la fracción verde (PV).

En la Tabla 6.2 se muestra la exactitud en la validación cruzada (R^2 , RMSE, %RMSE) de los diferentes modelos de estimación de biomasa aérea (PV, PT y %PV) ajustados con regresión OLS empleando los diferentes sets (a, mixto y total). Se resaltan en negrita los resultados más exactos de cada índice independientemente de la imagen. En el Anexo II se muestran en la Tabla 2 los coeficientes obtenidos de los modelos en la estimación a partir de la Tabla 6.

Tabla 6.2. Resultados de la validación cruzada de los modelos de estimación de biomasa aérea (PV, PT y %PV) en la imagen A, B y C, empleando la regresión OLS, índices de

vegetación y los diferentes sets de calibración (a, mixto y total). R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m²; $RMSE_{PT}$: g/m²; $RMSE_{\%PV}$: %; %RMSE: %.

Biomasa	SET	NDVI			SR			NLI			SAVI			MARAVI			
		R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	
Imagen A	PV	a	0,793	5,6500	17,82	0,725	6,5181	20,56	0,851	4,7869	15,10	0,843	4,9163	15,50	0,830	5,1266	16,17
		MIXTO	0,780	5,8225	18,36	0,727	6,4912	20,47	0,839	4,9862	15,72	0,832	5,0860	16,04	0,828	5,1540	16,25
		TOTAL	0,797	5,5930	17,64	0,777	5,8636	18,49	0,857	4,6937	14,80	0,843	4,9191	15,51	0,852	4,7741	15,06
	PT	a	0,664	9,9223	22,02	0,526	10,5948	23,52	0,708	8,3170	18,46	0,694	8,5181	18,91	0,635	9,3019	20,65
		MIXTO	0,647	9,1510	20,31	0,526	10,6027	23,54	0,691	8,5542	18,99	0,678	8,7413	19,40	0,628	9,3916	20,85
		TOTAL	0,666	8,8915	19,74	0,595	9,8010	21,76	0,712	8,2628	18,34	0,694	8,5220	18,92	0,667	8,8904	19,73
	%PV	a	0,498	9,6190	14,08	0,311	11,2657	16,48	0,429	10,2577	15,01	0,517	9,4338	13,80	0,374	10,7347	15,71
		MIXTO	0,514	9,4609	13,84	0,336	11,0622	16,19	0,464	9,9353	14,54	0,536	9,2406	13,52	0,404	10,4795	15,33
		TOTAL	0,501	9,5901	14,03	0,340	11,0245	16,13	0,439	10,1598	14,87	0,517	9,4299	13,80	0,393	10,5708	15,47
Imagen B	PV	a	0,767	5,9964	18,91	0,710	6,6939	21,11	0,830	5,1158	16,13	0,830	5,1163	16,13	0,823	5,2221	16,47
		MIXTO	0,767	5,9966	18,91	0,710	6,6939	21,11	0,830	5,1158	16,13	0,830	5,1163	16,13	0,823	5,2221	16,47
		TOTAL	0,779	5,8980	18,60	0,765	6,0183	18,98	0,847	4,8648	15,34	0,835	5,0532	15,94	0,851	4,7899	15,11
	PT	a	0,640	9,2397	20,51	0,517	10,7028	23,76	0,686	8,6319	19,16	0,671	8,8356	19,61	0,617	9,5340	21,16
		MIXTO	0,640	9,2397	20,51	0,517	10,7028	23,76	0,696	8,6319	19,16	0,671	8,8356	19,61	0,617	9,5340	21,16
		TOTAL	0,648	9,1341	20,28	0,582	9,9528	22,09	0,692	8,5497	18,98	0,673	8,8026	19,54	0,647	9,1499	20,31
	%PV	a	0,510	9,4982	13,90	0,325	11,1495	16,31	0,466	9,9127	14,50	0,556	9,0444	13,23	0,416	10,3726	15,18
		MIXTO	0,511	9,4982	13,90	0,325	11,1495	16,31	0,466	9,9127	14,50	0,556	9,0444	13,23	0,416	10,3726	15,18
		TOTAL	0,514	9,4574	13,84	0,361	10,8441	15,87	0,472	9,8560	14,42	0,556	9,0394	13,23	0,442	10,1347	14,83
Imagen C	PV	a	0,797	5,9635	18,81	0,701	6,7929	21,42	0,839	4,9887	15,73	0,841	4,9541	15,62	0,824	5,2038	16,41
		MIXTO	0,765	6,0242	19,00	0,714	6,6383	20,93	0,833	5,0810	16,02	0,837	5,0196	15,83	0,830	5,1169	16,14
		TOTAL	0,775	5,8904	18,58	0,761	6,0738	19,15	0,848	4,8446	15,28	0,840	4,9629	15,65	0,855	4,7276	14,91
	PT	a	0,646	9,1618	20,34	0,509	10,7924	23,96	0,692	8,5457	18,97	0,676	8,7672	19,46	0,609	9,6257	21,37
		MIXTO	0,641	9,2207	20,47	0,529	10,5627	23,45	0,690	8,5691	19,02	0,673	8,8007	19,54	0,621	9,4730	21,03
		TOTAL	0,648	9,1356	20,28	0,582	9,9568	22,10	0,695	8,4965	18,86	0,675	8,7741	19,48	0,646	9,1631	20,34
	%P V	a	0,503	9,5669	14,00	0,315	11,2305	16,43	0,457	10,0043	14,64	0,560	8,9996	13,17	0,416	10,3684	15,17

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

	MIXTO	0,505	9,5485	13,97	0,322	11,1750	16,35	0,468	9,8987	14,48	0,560	9,0051	13,18	0,421	10,3238	15,11
	TOTAL	0,509	9,5045	13,91	0,354	10,9094	15,96	0,475	9,8320	14,39	0,561	8,9960	13,16	0,445	10,1063	14,79

En la estimación de biomasa aérea a partir de regresión OLS, los resultados más exactos (RMSE menor) se obtuvieron para la biomasa aérea medida como peso seco de la fracción verde (PV). Destacar la que se obtuvo mediante el índice NLI, utilizando la imagen A y el set de calibración radiométrica “total” ($R^2=0,857$; $RMSE=4,6937 \text{ g/m}^2$; $\%RMSE=14,80\%$). A este modelo se le denominó Modelo 2 (índice NLI, Imagen A, Set “total”, PV) (Ec. 6.7):

$$PV=40,804 \cdot NLI - 26,1578 \quad (\text{Ec. 6.7})$$

Siendo PV: Biomasa aérea (peso verde) (g/m^2); NLI: valor del índice NLI

Los resultados fueron muy similares en la estimación de biomasa aérea referida al PV en las tres imágenes, obteniendo el resultado más exacto (RMSE menor) al usar el set “total” generalmente. Las diferencias entre los sets de calibración para el PV son $<2,3\%$ para el $\%RMSE$ independientemente de la imagen y el índice de vegetación. El índice SAVI fue el más estable a la variación de error ($\%RMSE$) al tipo de set de calibración usado (set “a”, “mixto”, “total”) obteniendo una media en las tres imágenes de la diferencia $<0,5\%$ en el índice NDVI y $<0,4\%$ en el índice SAVI mientras que el índice SR varió hasta un $2,3\%$ dependiendo del set de calibración empleado.

Las estimaciones de biomasa aérea como PT también mostraron resultados similares para las tres imágenes. El set “total” de nuevo proporcionó el resultado más exacto para la imagen A y usando el índice NLI ($R^2=0,712$; $RMSE=8,263 \text{ g/m}^2$ y un $\%RMSE=18,34\%$). Tanto en la imagen B como C, de nuevo el índice NLI proporcionó el resultado más exacto usando el set “total”

Respecto a las estimaciones de la biomasa aérea como $\%PV$, la estimación más exacta en las tres imágenes se alcanza con el índice SAVI, destacando la imagen C, set “total” ($R^2=0,561$, $RMSE=8,996\%$ y un $\%RMSE=13,16\%$). Tanto la imagen A como B, proporcionaron modelos similares y estables al uso indistinto del set.

Teniendo en cuenta todos los índices y set de calibración el error relativo varió entre un $5,76\%$ en la imagen A y un $6,51\%$ en la imagen C para el PV, entre un $4,78\%$ en la imagen B y un $5,20\%$ en la imagen A para el PT y entre un $2,68\%$ en la imagen A y un $3,27\%$ en la imagen C para $\%PV$, siendo las diferencias de error entre imágenes $<0,8\%$ en la estimación de biomasa aérea (PV, PT, $\%PV$).

A continuación se muestra el análisis de residuos del ajuste del Modelo 2 (índice NLI, Imagen A, Set “total”, PV)

Para comprobar las hipótesis de independencia, normalidad y homocedasticidad de residuos del Modelo 1 se emplearon los gráficos de la Figura 6.5 y los resultados de los test de *Shapiro-Wilk* y de *Durbin-Watson*. En el gráfico A de la Figura 6.5 los residuos siguen una distribución normal ya que las barras del histograma representan un aspecto similar al de dicha curva. En el gráfico B se muestra que la variación de los residuos sobre esta línea 0 no sigue ninguna tendencia o forma de embudo por lo que no se puede rechazar la hipótesis de homocedasticidad, es decir los residuos tienen una varianza constante y son independientes de los valores ajustados. En el gráfico C (P-P), se aprecia que los puntos se ajustan a una línea recta por lo que los datos probablemente tienen una distribución normal. En el gráfico D se observa que los puntos se aproximan bien a la diagonal, lo que confirma la hipótesis de normalidad. El estudio analítico de la normalidad de los residuos mediante el contraste no-paramétrico de Shapiro-Wilk, indicó que no se puede rechazar la hipótesis de normalidad de los residuos a un nivel de significación del 95%, puesto que se obtuvo un *p*-valor de 0,369

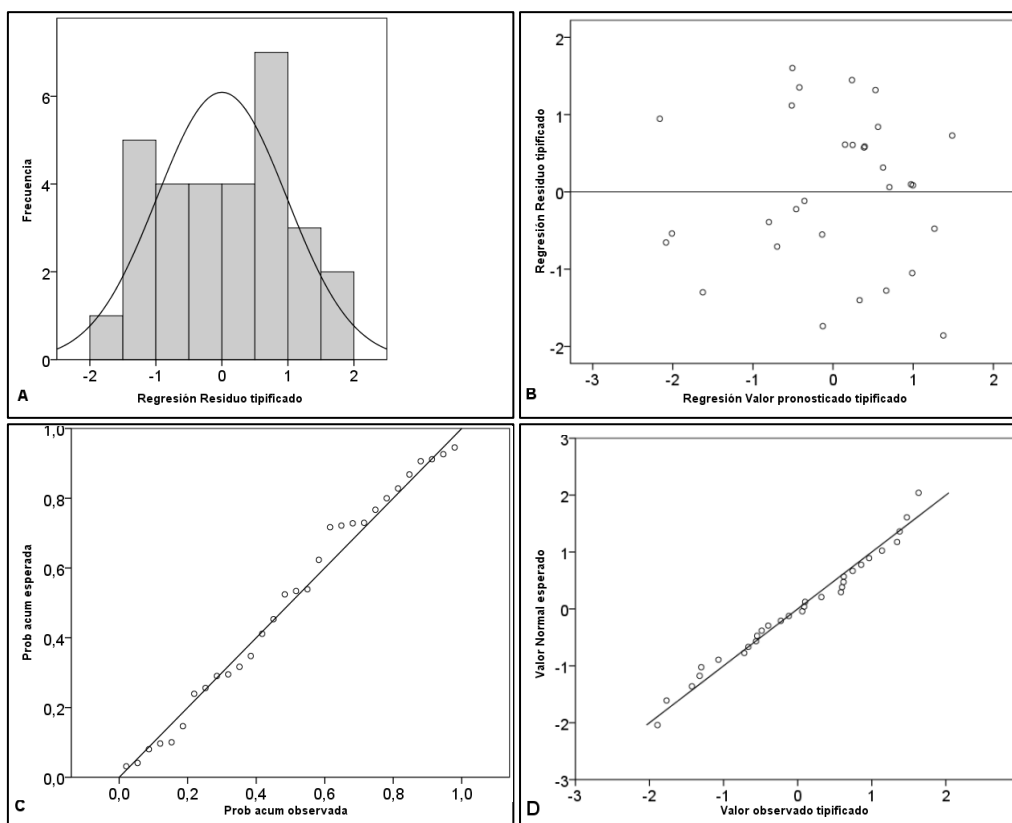


Figura. 6.5. Análisis de los residuos en el modelo 2. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q.

El contraste de *Durbin-Watson* indicó la incorrelación de los residuos, puesto que el valor obtenido (1,529) está próximo a 2, fuera de los límites de incertidumbre, ([1,134 - 1,264] para $k=1$ y $n=30$) lo que indica que los residuos están incorrelados.

Por lo tanto, los resultados de los diagramas de dispersión y de los test realizados indican que el que el modelo lineal ajustado (Modelo 2) cumple las hipótesis de partida y se puede emplear para la estimación de la biomasa aérea medida como peso seco de la fracción verde (PV).

6.4.2. Robustez del modelo de calibración radiométrica para la estimación biomasa aérea

Para analizar la robustez de los modelos de calibración radiométrica cuando las imágenes se emplean en la estimación de biomasa aérea, se compararon las estimaciones de biomasa obtenidas a partir de la imagen de reflectancia B (corregida radiométricamente con su set óptimo) y los valores de biomasa estimados en la imagen de reflectancia B (corregida con las correcciones radiométricas ajustadas para las imágenes adyacentes A y C). En el caso de que las diferencias en biomasa no fuesen significativas, se podría utilizar el mismo modelo de calibración radiométrica para las imágenes adyacentes de una misma pasada. .

Los resultados en la estimación de biomasa a partir de PLS en la imagen de reflectancia B corregida con las correcciones radiométricas ajustadas para las imágenes adyacentes A y C se muestran en la Tabla 6.3. Estos indican que la calibración radiométrica de una imagen se puede aplicar a imágenes contiguas, puesto que la exactitud en la estimación de biomasa fue muy similar a la obtenida empleando las ecuaciones de calibración radiométrica propias de B, puesto que las diferencias en la estimación fueron menores del 1% (%RMSE) (tanto para PV, PT y %PV). Por lo tanto, la calibración radiométrica de una imagen puede ser utilizada con éxito para la estimación de biomasa en imágenes adyacentes. En el Anexo II se muestran en la Tabla 3 los coeficientes obtenidos de los modelos en la estimación a partir de la Tabla 6.2.

Tabla 6.3. Resultados de la validación cruzada de los modelos de estimación de biomasa aérea (PV, PT y %PT) en la imagen B empleando las correcciones radiométricas ajustadas para las

imágenes adyacentes A y C, usando regresión PLS y las reflectancias de las cuatro bandas (Roja, verde, azul e IRc). F: número de factores latentes (PLS); R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; $RMSE_{\%PV}$: %; %RMSE: %; AIC: Criterio de Información de Akaike.

	Biomasa	SET	R^2	RMSE	F	AIC	%RMSE
Ecuaciones B en Imagen B	PV	a	0,878	4,4796	2	48,98590	14,13
		mixto	0,878	4,4842	2	49,01656	14,14
		total	0,878	4,4841	2	49,01613	14,14
	PT	a	0,704	8,6640	2	68,77513	19,23
		mixto	0,696	8,7784	2	69,16895	19,49
		total	0,720	8,8354	2	69,36282	19,61
	%PV	a	0,693	7,7828	3	67,55762	11,39
		mixto	0,693	7,7829	3	67,55796	11,39
		total	0,714	7,8145	3	67,67939	11,43
Ecuaciones A en Imagen B	PV	a	0,884	4,4938	2	49,08076	14,17
		mixto	0,884	4,4938	2	49,08078	14,17
		total	0,884	4,4938	2	49,08079	14,17
	PT	a	0,720	8,8354	2	69,36283	19,61
		mixto	0,720	8,8354	2	69,36283	19,61
		total	0,720	8,8354	2	69,36283	19,61
	%PV	a	0,714	7,8145	3	67,67939	11,43
		mixto	0,714	7,8145	3	67,67938	11,43
		total	0,714	7,8145	3	67,67938	11,43
Ecuaciones C en Imagen B	PV	a	0,884	4,4938	2	49,08079	14,17
		mixto	0,884	4,4938	2	49,08078	14,17
		total	0,884	4,4938	2	49,08078	14,17
	PT	a	0,720	8,8354	2	69,36283	19,61
		mixto	0,720	8,8354	2	69,36283	19,61
		total	0,720	8,8354	2	69,36283	19,61
	%PV	a	0,714	7,8145	3	67,67939	11,43
		mixto	0,714	7,8145	3	67,67938	11,43
		total	0,714	7,8145	3	67,67938	11,43

En la estimación de biomasa aérea, los resultados más exactos (AIC menor) se obtuvieron para la biomasa aérea medida como peso seco de la fracción verde (PV), utilizando el set de calibración radiométrica “a” ($R^2=0,884$; $RMSE=4,494 g/m^2$ y $AIC=49,081$: %RMSE=14,17%). A estos modelos se les denominó Modelo 3a (Imagen B, ecuaciones de calibración del set “a” de la imagen A, estimación de biomasa como

PV) (Ec. 6.8) y Modelo 3b (Imagen B, ecuaciones de calibración del set “a” de la imagen C, estimación de biomasa como PV) (Ec. 6.9).

$$PV = -30,42574 - 41,33503 \cdot R_B - 57,34773 \cdot R_G - 121,929 \cdot R_R + 302,5378 \cdot R_{NIR} \quad \text{Ec.6.8}$$

$$PV = -30,49722 - 41,33503 \cdot R_B - 57,34771 \cdot R_G - 121,9289 \cdot R_R + 302,5378 \cdot R_{NIR} \quad \text{Ec.6.9}$$

Siendo PV: Biomasa aérea (peso verde) (g/m^2); R_B, G, R, NIR : Reflectancias en superficie de cada banda en la imagen de reflectancias (en tanto por uno).

Las estimaciones de biomasa aérea como PT también mostraron resultados similares para las tres imágenes, obteniéndose el mismo resultado cuando se emplearon las ecuaciones de calibración de la imagen A sobre B que cuando se usaron las de C sobre B. Por otro lado los tres sets (“a”, “mixto” y “total”) arrojaron el mismo resultado ($R^2=0,720$; $\text{RMSE}=8,835\%$, $\text{AIC}=69,363$ y $\% \text{RMSE}=19,61\%$).

Respecto a las estimaciones de la biomasa aérea como %PV tanto si se usan las ecuaciones de calibración de la imagen A sobre B o la ecuaciones de calibración de la imagen C sobre B, los resultados son idénticos ($R^2=0,714$; $\text{RMSE}=7,815\%$; $\text{AIC}=67,679$; $\% \text{RMSE}=11,43\%$) independientemente del set usado (“a”, “mixto” o “total”).

A continuación se muestra el análisis de residuos del ajuste entre los valores de referencia y los valores predichos en la validación cruzada por el Modelo 3 (Imagen B, Set “a”, estimación de biomasa como PV).

Para comprobar las hipótesis de independencia, normalidad y homocedasticidad de residuos del Modelo 3 se emplearon los gráficos de la Figura 6.6 y los resultados de los test de *Shapiro-Wilk* y de *Durbin-Watson*. En el gráfico A de la Figura 6.6 los residuos siguen una distribución normal ya que las barras del histograma representan un aspecto similar al de dicha curva. En el gráfico B se muestra que la variación de los residuos sobre esta línea 0 no sigue ninguna tendencia o forma de embudo por lo que no se puede rechazar la hipótesis de homocedasticidad, es decir los residuos tienen una varianza constante y son independientes de los valores ajustados. En el gráfico C (P-P), se aprecia que los puntos se ajustan a una línea recta por lo que los datos probablemente tienen una distribución normal. En el gráfico D se observa que los puntos se aproximan

bien a la diagonal, lo que confirma la hipótesis de normalidad. El estudio analítico de la normalidad de los residuos mediante el contraste no-paramétrico de Shapiro-Wilk, indicó que no se puede rechazar la hipótesis de normalidad de los residuos a un nivel de significación del 95%, puesto que se obtuvo un p -valor de 0,570.

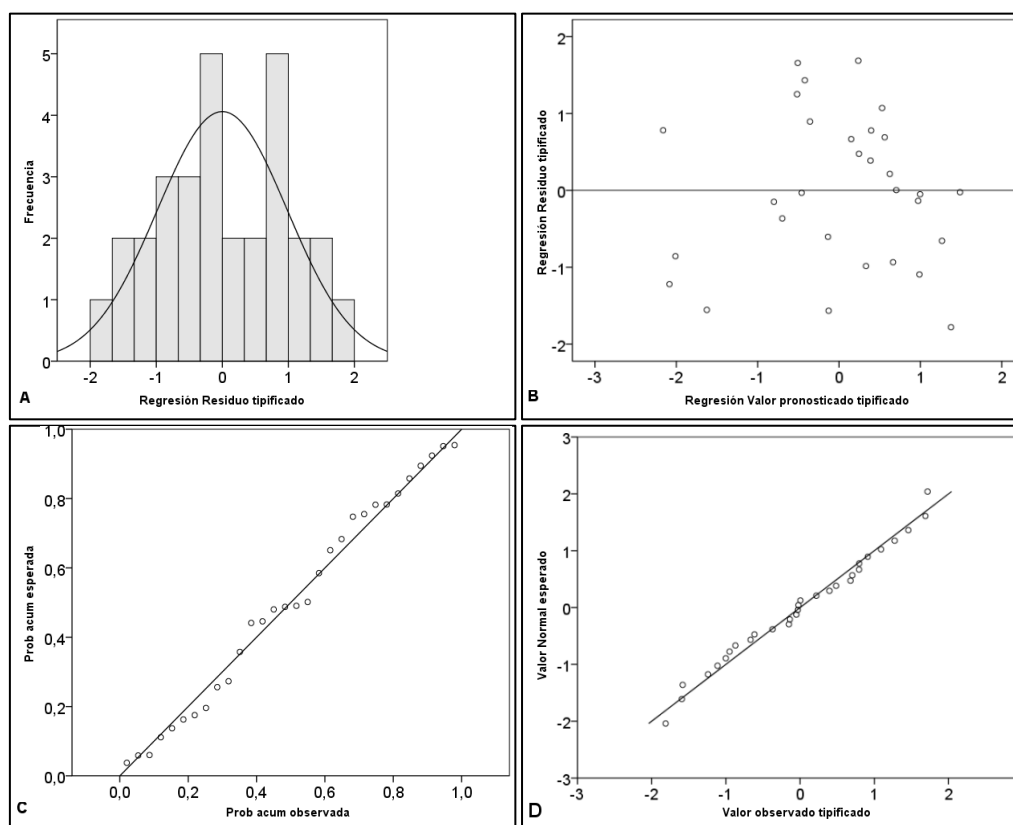


Figura 6.6. Análisis de los residuos del ajuste entre los valores medidos y predichos por el modelo 3 en la validación cruzada. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q.

El contraste de *Durbin-Watson* indicó la incorrelación de los residuos, puesto que el valor obtenido (1,976) está próximo a 2, lo que indica que los residuos están incorrelados. Por lo tanto, los resultados de los diagramas de dispersión y de los test realizados indican que el que el modelo lineal ajustado (Modelo 3) cumple las hipótesis de partida y se puede emplear para la estimación de la biomasa aérea medida como peso seco de la fracción verde (PV).

A continuación en la Tabla 6.4 se realiza la misma validación independiente para los modelos obtenidos a partir de índices de vegetación. En el anexo II se muestran en la Tabla 4 los coeficientes obtenidos de los modelos en la estimación a partir de la Tabla

6.4. Estos resultados indican que la calibración radiométrica de una imagen se puede aplicar a imágenes contiguas para estimar biomasa aérea, puesto que la exactitud en la estimación fue muy similar a la obtenida empleando las ecuaciones de calibración radiométrica propias de B y siendo las diferencias en la estimación menores del 1% (%RMSE) en las tres formas elegidas para estimar biomasa aérea (PV, PT y %PV). Por lo tanto, la calibración radiométrica de una imagen puede ser utilizada con éxito para la estimación de biomasa en imágenes adyacentes.

Tabla 6.4. Resultados de la validación cruzada independiente de los modelos de biomasa aérea (PV, PT y %PV) en la imagen B empleando las ecuaciones de los modelos obtenidos en los diferentes sets de calibración (set “a”, set “mixto” y set “total”), de la imagen A, B y C, regresión OLS, índices de vegetación. R^2 : coeficiente de determinación; $RMSE_{PV}$: g/m^2 ; $RMSE_{PT}$: g/m^2 ; y $RMSE_{\%PV}$: %; %RMSE: %.

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

Biomasa	SET	NDVI			SR			NLI			SAVI			MARAVI			
		R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	R ²	RMSE	%RMSE	
Ecuaciones B en Imagen B	PV	A	0,767	5,9964	18,91	0,710	6,6939	21,11	0,830	5,1158	16,13	0,830	5,1163	16,13	0,823	5,2221	16,47
		mixto	0,767	5,9966	18,91	0,710	6,6939	21,11	0,830	5,1158	16,13	0,830	5,1163	16,13	0,823	5,2221	16,47
		total	0,779	5,8980	18,60	0,765	6,0183	18,98	0,847	4,8648	15,34	0,835	5,0532	15,94	0,851	4,7899	15,11
	PT	A	0,640	9,2397	20,51	0,517	10,7028	23,76	0,686	8,6319	19,16	0,671	8,8356	19,61	0,617	9,5340	21,16
		mixto	0,640	9,2397	20,51	0,517	10,7028	23,76	0,696	8,6319	19,16	0,671	8,8356	19,61	0,617	9,5340	21,16
		total	0,648	9,1341	20,28	0,582	9,9528	22,09	0,692	8,5497	18,98	0,673	8,8026	19,54	0,647	9,1499	20,31
	%PV	A	0,510	9,4982	13,90	0,325	11,1495	16,31	0,466	9,9127	14,50	0,556	9,0444	13,23	0,416	10,3726	15,18
		mixto	0,511	9,4982	13,90	0,325	11,1495	16,31	0,466	9,9127	14,50	0,556	9,0444	13,23	0,416	10,3726	15,18
		total	0,514	9,4574	13,84	0,361	10,8441	15,87	0,472	9,8560	14,42	0,556	9,0394	13,23	0,442	10,1347	14,83
Ecuaciones A en Imagen B	PV	A	0,775	5,8883	18,47	0,729	6,4613	20,38	0,841	4,9582	15,64	0,835	5,0497	15,92	0,834	5,0632	15,97
		mixto	0,769	5,9680	18,69	0,733	6,4223	20,25	0,834	5,0624	15,96	0,831	5,1137	16,13	0,835	5,0469	15,92
		total	0,780	5,8210	18,30	0,775	5,8944	18,59	0,849	4,8337	15,24	0,835	5,0529	15,93	0,856	4,7163	14,87
	PT	A	0,646	9,1546	20,28	0,537	10,4724	23,25	0,689	8,5926	19,07	0,673	8,7991	19,53	0,625	9,4313	20,94
		mixto	0,641	9,2246	20,42	0,545	10,3799	23,04	0,687	8,6122	19,12	0,671	8,8349	19,61	0,631	9,3538	20,76
		total	0,649	9,1255	20,24	0,594	9,8107	21,78	0,692	8,5374	18,95	0,673	8,8031	19,54	0,652	9,0764	20,15
	%PV	A	0,510	9,4957	13,87	0,337	11,0521	16,17	0,461	9,9613	14,58	0,556	9,0424	13,23	0,424	10,2975	15,07
		mixto	0,512	9,4810	13,85	0,339	11,0349	16,15	0,472	9,8618	14,43	0,556	9,0429	13,23	0,426	10,2792	15,04
		total	0,516	9,4444	13,80	0,369	10,7775	15,77	0,476	9,8232	14,37	0,556	9,0382	13,23	0,448	10,0841	14,76
Ecuaciones C en Imagen B	PV	A	0,778	5,8575	18,47	0,747	6,2529	19,72	0,844	4,9044	15,47	0,835	5,0441	15,91	0,842	4,9331	15,56
		mixto	0,772	5,9267	18,69	0,753	6,1715	19,46	0,839	4,9915	15,74	0,831	5,1034	16,09	0,845	4,8867	15,41
		total	0,782	5,8028	18,30	0,784	5,7788	18,22	0,850	4,8048	15,15	0,834	5,0534	15,94	0,860	4,6493	14,66
	PT	A	0,648	9,1373	20,28	0,558	10,2324	22,71	0,690	8,5719	19,03	0,674	8,7967	19,53	0,635	9,3034	20,65
		mixto	0,643	9,2000	20,42	0,570	10,0909	22,40	0,689	8,5851	19,06	0,671	8,8300	19,60	0,643	9,1995	20,42
		total	0,649	9,1176	20,24	0,605	9,6786	21,48	0,693	8,5262	18,93	0,673	8,8040	19,54	0,658	9,0092	20,00
	%PV	A	0,512	9,4806	13,87	0,348	10,9599	16,04	0,465	9,9257	14,52	0,556	9,0411	13,23	0,432	10,2255	14,96
		mixto	0,514	9,4628	13,85	0,353	10,9173	15,97	0,476	9,8230	14,37	0,556	9,0410	13,23	0,437	10,1855	14,90
		total	0,517	9,4309	13,80	0,377	10,7108	15,67	0,480	9,7891	14,32	0,557	9,0370	13,22	0,453	10,0341	14,68

En la estimación de biomasa aérea, los resultados más exactos se obtuvieron para la biomasa aérea medida como peso seco de la fracción verde (PV). La estimación más exacta (RMSE menor) se obtuvo mediante el índice MARAVI, utilizando las ecuaciones de calibración radiométrica (set “total”) de la imagen C aplicadas a la imagen B ($R^2=0,860$; $RMSE=4,6493 \text{ g/m}^2$; $\%RMSE=14,66 \%$). Existe una diferencia $<1\%$ entre usar estas ecuaciones de calibración radiométrica de la imagen C sobre B o las de la imagen A sobre B. A este modelo se le denominó Modelo 4 (índice MARAVI, Imagen B, Set “mixto” de la imagen C, PV) (Ec. 6.10):

$$PV=66,399 \cdot M - 7,0912 \quad (\text{Ec.6.10})$$

Siendo PV: Biomasa aérea (g/m^2); M: Valores del índice MARAVI calculados a partir de la imagen de reflectancia en superficie.

Las estimaciones de biomasa aérea como PT también mostraron resultados similares al usar las ecuaciones de calibración de la imagen A en la imagen B así como las ecuaciones de calibración de la imagen C en la imagen B, siendo las diferencias en error relativo menores de 1%, independientemente de los set usados (“a”, “mixto” y “total”). El índice más exacto para la estimación de biomasa aérea como PT fue el NLI, que proporcionó un $\%RMSE < 19,2\%$, independientemente del set usado e independiente de las ecuaciones de calibración (A y C) aplicadas a la imagen B. El índice SAVI arrojó un error relativo similar ($\%RMSE < 19,7\%$). Es índice menos exacto fue el SR ($\%RMSE < 23,3$), siendo también el menos estable al cambio de sets en las tres imágenes.

Respecto a las estimaciones de la biomasa aérea como $\%PV$ se obtuvieron , resultados similares tanto al usar las ecuaciones de calibración de la imagen A en la imagen B así como las ecuaciones de calibración de la imagen C en la imagen B. La estimación más exacta se alcanzó con el índice SAVI ($R^2=0,556$, $RMSE=9,037\%$ y un $\%RMSE=13,22\%$), siendo las diferencia en error relativo inferiores al 1%, independientemente de los set usados (“a”, “mixto” y “total”).

A continuación se muestra el análisis de residuos del ajuste entre los valores de referencia y los valores predichos en la validación cruzada por el Modelo 4 (índice MARAVI, Imagen B, Set “mixto” de la imagen C, PV).

Para comprobar las hipótesis de independencia, normalidad y homocedasticidad de residuos del Modelo 4 se emplearon los gráficos de la Figura 6.7 y los resultados de los test de *Shapiro-Wilk* y de *Durbin-Watson*. En el gráfico A de la Figura 6.7, los residuos siguen una distribución normal ya que las barras del histograma representan un aspecto similar al de dicha curva. En el gráfico B se muestra que la variación de los residuos sobre esta línea 0 no sigue ninguna tendencia o forma de embudo por lo que no se puede rechazar la hipótesis de homocedasticidad, es decir los residuos tienen una varianza constante y son independientes de los valores ajustados. En el gráfico C (P-P), se aprecia que los puntos se ajustan a una línea recta por lo que los datos probablemente tienen una distribución normal. En el gráfico D se observa que los puntos se aproximan bien a la diagonal, lo que confirma la hipótesis de normalidad. El estudio analítico de la normalidad de los residuos mediante el contraste no-paramétrico de Shapiro-Wilk, indicó que no se puede rechazar la hipótesis de normalidad de los residuos a un nivel de significación del 95%, puesto que se obtuvo un p -valor de 0,122.

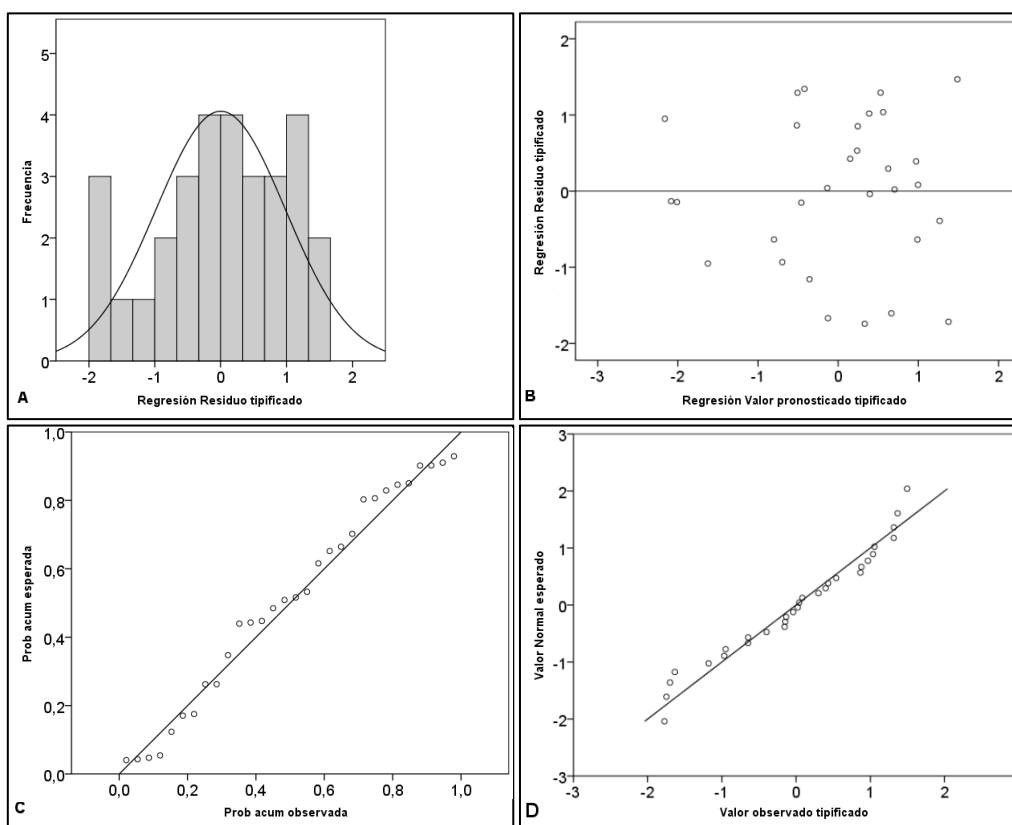


Figura 6.7. Análisis de los residuos del ajuste entre los valores medidos y predichos por el modelo 4 en la validación cruzada. A: Histograma, B: Distribución de residuos, C: Gráficos P-P, D: Gráficos Q-Q

El contraste de *Durbin-Watson* indicó que no era concluyente la incorrelación de los residuos, puesto que el valor obtenido (1,374), estaba entre 1,352 y 1,489 ($n=30$; $k=1$). El Diagrama de dispersión y el valor de R^2 (0,86), nos muestra que el ajuste lineal es satisfactorio.

A continuación se muestra en los gráficos para los cuatro modelos más exactos en la estimación de biomasa aérea (PV) de valores de referencia frente a los valores predichos en las validaciones cruzadas. En la Figura 6.8 se representa el diagrama de dispersión de los valores medidos frente a los valores predichos en las validaciones cruzadas, siendo el ajuste bastante exacto ya que se distribuyen los valores a lo largo de la recta 1:1 y próximos a ella. La reducción en la validación cruzada en los cuatro modelos es $<0,02$ por lo que los cuatro modelos son muy fiables, siendo el modelo 1 el más exacto y fiable (reducción en la validación cruzada 0,01) en la estimación de biomasa aérea medida como peso seco de la fracción verde (PV).

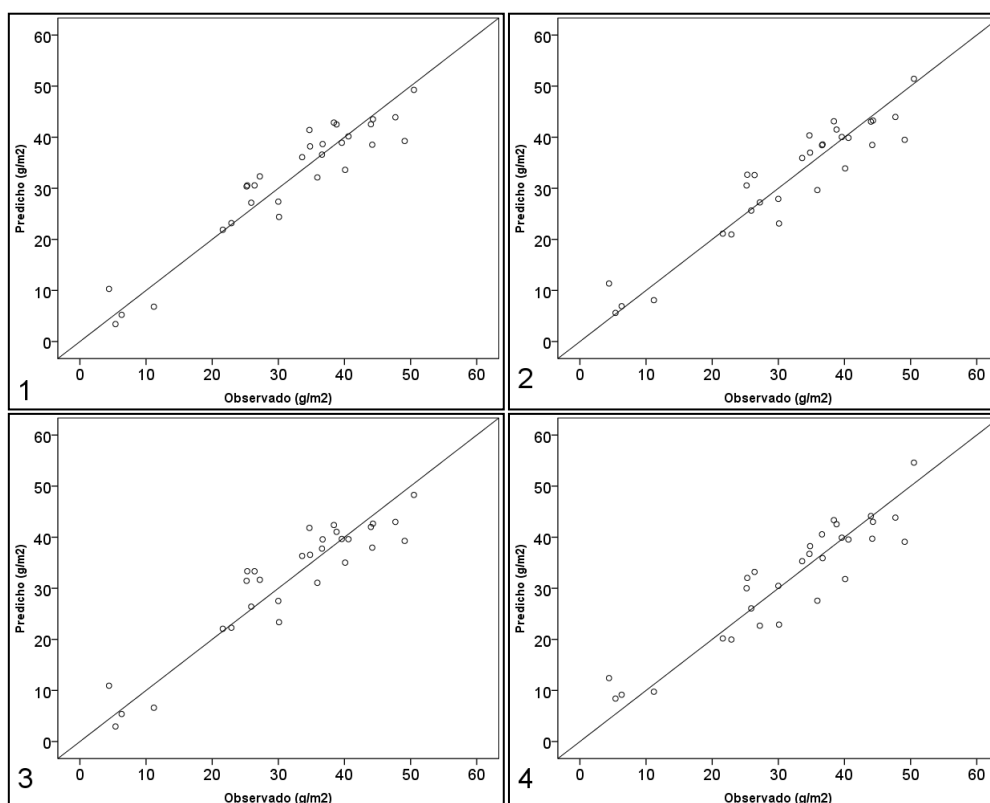


Figura 6.8. Resultados de la validación cruzada en la estimación de biomasa aérea a partir de PV en los 4 modelos más exactos. Regresión PLS: 1 y 3; Regresión OLS: 2 y 4.

6.5. Discusión Los resultados obtenidos indican que las imágenes multiespectrales de la cámara Ultracam-Xp WA una vez calibradas radiométricamente son adecuadas para la estimación de variables biofísicas como la biomasa aérea. Los modelos más exactos para estimar biomasa aérea se obtuvieron a partir de la reflectancia de las 4 bandas (R, G, B, IRc) ajustadas mediante regresión PLS, que resultaron superiores a los modelos lineales basados en índices de vegetación (NDVI, SR, NLI, SAVI y MARAVI). No obstante en el modelo 1 al usar la regresión PLS sólo tuvo un %RMSE un 1,88% menor que usando el modelo 2 (OLS) para PV. Respecto al modelo 3 (PLS) con este se obtuvo un %RMSE un 0,49% menor que usando el modelo 4 (OLS). La diferencia en exactitud entre los 4 modelos fue menor del 2%, obteniendo resultados más exactos usando la información espectral de las banda que usando índices de vegetación, sin embargo el uso de índices de vegetación como el NLI el SAVI o el MARAVI se puede recomendar si lo que se desea es simplificar el modelo de estimación de biomasa aérea.

Los cuatro modelos propuestos resultaron más exactos que obtenidos por Cho *et al.* (2007) para la estimación de biomasa aérea a partir de imágenes aéreas hiperespectrales. Los modelos predictivos de Cho *et al.* (2007) basados en reflectancias en superficie y regresión PLS también tuvieron mayores precisiones ($R^2=0,83$; $RMSE=263 \text{ g/m}^2$; $\%RMSE=19\%$) que los que emplearon índices de vegetación (NDVI: $R^2=0,70$; $RMSE=214 \text{ g/m}^2$, $\%RMSE=34\%$) al igual que en este trabajo. Estos resultados también corroboran los obtenidos por Hansen y Schjoerring (2003), que en su estudio experimental sobre el trigo, reportaron un mejor rendimiento predictivo de biomasa en PV usando PLS ($R^2=0,89$ y $RMSE=250 \text{ g/m}^2$) respecto al empleo del índice NDVI ($RMSE=304 \text{ g/m}^2$), lo que supone una mejora del modelo en un 22%. Para llevar a cabo la calibración, Hansen y Schjoerring (2003) necesitaron 6 factores, tres más que en el Modelo 1 obtenido en este trabajo ($R^2=0,90$; $RMSE=4,096 \text{ g/m}^2$; $\%RMSE=12,92\%$).

En cuanto al empleo de índices de vegetación, se recomienda el uso del índice NLI y el índice MARAVI para la estimación de biomasa como PV, debido a su reducido error en las estimaciones ($\%RMSE<14\%$), que es sólo un 1,88% mayor que el del modelo 1 ($\%RMSE=12,92\%$). En la misma línea están los resultados proporcionados por el índice SAVI, que se recomienda para la estimación de biomasa aérea para PT, resultando más adecuados que el NDVI y el SR. Para la estimación de biomasa aérea en %PV se

recomienda el índice SAVI que proporciona la estimación más exacta en las tres imágenes independientemente del set usado, destacando positivamente el resultado de la imagen C, set “total” ($R^2=0,56$; $RMSE=9,996\%$; $\%RMSE=13,16$). Estos resultados son coherentes con los obtenidos por Hongrui y Guangsheng (2014), que demostraron que mediante el índice SAVI se obtiene mayor exactitud ($\%RMSE=23,5\%$) y robustez que usando el índice NDVI ($\%RMSE=24,8\%$) en la estimación de biomasa aérea verde en pastos localizados en zonas áridas, mejorando el $\%RMSE$ en un 2% cuando usa el índice L-SAVI, el cual era más exacto para zonas donde existe escasa cobertura vegetal verde en zonas áridas. La menor idoneidad del NDVI y SR también se puso de manifiesto en Vila *et al.* (2007), que estimaron la biomasa en viñedos a partir del peso de poda y estos índices de vegetación derivados del sensor DMSC MK II, obteniendo valores de correlación de Pearson $<0,42$ ($NDVI=0,417$; $SR=0,411$). Hernán *et al.* (2007), en su estudio mediante el sensor y usando los índices de vegetación NDVI y SR demostraron que los valores de correlación de Pearson fueron bajos, demostrando que son apropiados para discriminar zonas de viñedos con distinta producción de biomasa pero no buenos estimadores de biomasa. Trabajos más recientes como el de Wang *et al.* (2014), donde se emplearon cámaras multispectrales de pequeño formato acopladas a UAVs para la estimación de biomasa aérea en pastos, obtuvieron resultados con una correlación mayor ($R^2>0,87$) a la obtenida en esta tesis a partir del índice NDVI ($R^2=0,80$), probablemente debido a usar un ajuste exponencial en vez de lineal y con alturas de vuelo más bajas (5, 10 y 50 m), lo que implica una mayor resolución espacial y mayor homogeneidad en los píxeles. En la misma línea, el trabajo de Boschetti *et al.* (2007) muestra como el índice SAVI fue más exacto ($R^2>0,60$) que los índices SR y NDVI ($R^2<0,50$) en la estimación de producción de biomasa en pastizales.

García y Herrera (2015) demostraron que las imágenes obtenidas de la cámara ADC son útiles para generar mosaicos infrarrojos para estimar biomasa en cultivos de caña de azúcar en una edad temprana a partir de los índices de vegetación NDVI y SAVI, con un ajuste en la estimación de biomasa de $R^2=0,70$. El NLI, al igual que en este trabajo, proporcionó algunos de los resultados más exactos, donde el error relativo en la estimación de biomasa referida en PV mediante este índice en el mejor de los casos fue $<13,5\%$, dependiendo del set de calibración usado en la imagen. De igual modo Aguado *et al.* (2008), usaron el índice NLI en la estimación de biomasa indirectamente a partir del LAI (Keane y Burgan., 2001) y el contenido de materia seca foliar (Cm) a mediante los sensores ATM, TM y MODIS, obteniendo unos errores

relativos más elevados ($\%RMSE_{ATM}=20\%$; $\%RMSE_{TM}=40,6\%$; $\%RMSE_{MODIS}=36,5\%$). Estas diferencias entre sensores pudieron deberse a las diferentes resoluciones espaciales de los mismos (ATM=2 m; TM=30 m y MODIS=500 m). Los sensores con menos resolución espacial posiblemente no recogieron de forma adecuada la heterogeneidad que mostró la zona respecto al contenido de materia seca foliar a diferencia de esta tesis donde se realizó con una resolución espacial de 18 cm. De igual modo Gong *et al.* (2003) demuestra la correlación entre el índice NLI y el LAI para la estimación de biomasa en entornos semiáridos obteniendo en el mejor de los casos un coeficiente $R^2=0,75$ aunque las estimaciones de biomasa en esta tesis muestran soluciones más exactas ($R^2=0,88$).

Los resultados más exactos de estimación de biomasa se obtuvieron (en general) al usar el set “a” cuando la regresión usada es PLS; por otro lado, al usar índices de vegetación y regresión OLS, el set “total” es el que aporta modelos más exactos. De todas formas, las estimaciones de biomasa aérea (PV, PT o %PV) fueron muy similares independientemente del set de calibración radiométrica usado. Esta similitud de los resultados, independientemente de la imagen considerada, pone de manifiesto la indiferencia del set de calibración empleado en el método de estimación de la biomasa; por tanto, se recomienda el uso del set “a” (Paneles móviles de escala de grises (panel 1, panel 2, panel 1+2) para obtener imágenes en reflectancias debido a su simplicidad, al igual que Álvarez *et al.* (2010b) donde obtuvieron ajustes lineales para el índice NDVI y el SR con unos coeficientes de determinación $R^2=0,61$ y $R^2=0,64$ respectivamente usando únicamente la escala de grises. La mejora en esta tesis respecto al de Álvarez *et al.* (2010b), se debe fundamentalmente al uso de las 4 bandas (R, G, B, NIR) mediante PLS así como el uso de otros índices que aportaron estimaciones más exactas ($R^2_{NLI}=0,86$, $RMSE=4,693$ g/m²; $R^2_{SAVI}=0,84$, $RMSE=4,916$ g/m²). Otro factor muy importante en las estimaciones de biomasa aérea fue la separación antes de su secado en biomasa verde y biomasa seca optimizando los resultados del error relativo hasta un 6% en una misma imagen mediante el uso de PLS ($\%RMSE_{PV}=13\%$ frente a ($\%RMSE_{PT}=20\%$) y en un 2% y un 6% en el uso de los índices de vegetación, siendo el índice NDVI el que presenta de media menos diferencias en dicha separación (entorno a un 2%) por lo que se demostró la idoneidad de la separación de la biomasa antes del secado.

CAPÍTULO 7

7

DISCUSIÓN GENERAL

A través de los capítulos de esta tesis doctoral se muestra una forma de aplicar técnicas de teledetección cuantitativa, a partir de espectro-radiometría de campo usando un espectro-radiómetro ASD FieldSpec4 y mediante imágenes tomadas con una cámara aerotransportada Ultracam-Xp WA una vez calibradas radiométricamente a través de una calibración vicaria. Este tipo de sensores permiten la obtención de firmas espectrales e imágenes de alta resolución espacial.

Gracias al preprocesamiento, tratamiento, configuración y diferentes métodos estadísticos usados tanto en las firmas espectrales como en las imágenes a través de las bandas espectrales (R, G, B, NIR) o el cálculo de índices de vegetación adecuados, posibilitan la estimación de parámetros biofísicos como es la biomasa aérea.

La potencia de cálculo de los ordenadores actuales, así como los softwares usados hace pensar que el tiempo de entrega de resultados sea bastante corto. Sin embargo, la clave del éxito de este tipo de aplicaciones es la capacidad de generar resultados basados en la estimación de biomasa aérea que tengan interés en el manejo de cultivos y que puedan ser validados y contrastados. Eso sólo será posible mediante el uso de metodologías cuantitativas para considerar y minimizar los efectos que sobre la energía reflejada o emitida por la vegetación tengan el suelo, la atmósfera etc.

La investigación realizada en la primera parte de la tesis tuvo como objetivo buscar la relación lineal entre la Espectro-radiometría de campo y la biomasa aérea, con el fin de poder relacionarla con las imágenes aéreas calibradas radiométricamente.

En la primera parte de esta tesis se ha prestado especial atención a la estimación de biomasa mediante espectro-radiometría, usando un espectro-radiómetro de campo. Se ha demostrado la posibilidad de estimar biomasa aérea (PV, PT y %PV) a partir esta técnica. El uso de métodos para el pretratamiento y procesado de los datos espectrales fue necesario para mejorar la exactitud de los modelos matemáticos. Entre estos métodos destacan el CR (Continuum Removal), derivadas, SG (Savitzky y Golay.), CyE (Centrado y escalado), normalizaciones y MSCO (corrección de dispersión multiplicativa), entre otros. El uso posterior de herramientas estadísticas adecuadas ha sido clave en este estudio, demostrándose que métodos estadísticos como PLS, SVM y OLS son adecuados para estimar biomasa aérea empleando datos espectrales.

El estudio del espectro usando zonas características del mismo simplifica los modelos de estimación de biomasa aérea, tal y como demuestra la disminución de número de factores latentes cuando se utilizan estas zonas en lugar del espectro completo sin CR al usar el método PLS. Este resultado concuerda con los obtenidos por Axelsson (2013) para la estimación de Nitrógeno, y los de Cho et al. (2007) para la estimación de biomasa. Empleando los mismos datos de partida y máquinas de soporte vectorial (Support Vector Machine, SVM), el espectro transformado también proporcionó estimaciones más exactas de PV, PT y %PV que el espectro sin transformar.

Los modelos más exactos se obtuvieron usando la regresión PLS y la transformación SG en PV ($R^2=0,95$ con el uso de 2 factores y un %RMSE=9,1%), y permitieron predecir la biomasa aérea a partir de las regiones del visible y del NIR. Al usar este método en los modelos de estimación de biomasa en PT y %PV también se obtuvieron resultados muy exactos, aunque destaca el uso de la transformación MSCO

para estimar PT, obteniendo un $R^2=0,97$ con 4 factores y un $\%RMSE=6,1\%$. Este modelo fue el más exacto, pero al usar el criterio de AIC, este modelo fue penalizado por su número de factores. Estas exactitudes abren la posibilidad de establecer modelos de estimación de biomasa aérea a partir de sensores que lleven radiómetros que capten el espectro electromagnético del rango visible y NIR, como las cámaras aéreas digitales.

Considerando la transformación CR, la zona del espectro más adecuada para la estimación de PV y PT se corresponde con las bandas de absorción de 1079 nm a 1297 nm (Z4), corroborando los resultados de Curran (2001), Cho (2007), Clevers (2008) y Mutanga (2010), Axelsson (2013) y Hadi (2015). También en este trabajo se ha identificado una nueva zona (de 1265 a 1676 nm) relevante para la estimación de biomasa; esta es una zona característica donde existe relación sobre todo con la lignina y el agua. Hadi (2015) en su trabajo reciente lo corrobora usando la zona 1400-1690 nm y obteniendo un $R^2=0,76$ y un $\%RMSE=32,1\%$.

A partir de la transformación CR, la derivación de índices favorece el estudio del modelado en las diferentes zonas de estudio del espectro. Respecto al empleo de los índices MBD y AOM, los resultados de este trabajo mostraron que los modelos más exactos para la estimación de PV y PT se obtuvieron empleando los índices derivados de Z4, al igual que ocurría al emplear PLS y al igual que los resultados de Clevers et al. (2008) empleando MDB y AOM en una región del espectro entre 1115 y 1270 nm, muy similar a Z4, corroborando la idoneidad de estas longitudes de onda para la estimación de PV y PT. Al realizar las estimaciones en Z4 (con CR) usando los distintos métodos estadísticos, se observó que no existían diferencias significativas entre los R^2 obtenidos empleando PLSR y los obtenidos con MBD y AOM. Por otro lado las diferencias en los RMSE fueron menores del 2% por lo que se puede considerar que un procedimiento sea más exacto que otro (Kooistra et al., 2006; Cho et al., 2007; Clevers et al., 2008). Se recomienda el empleo de los índices MBD y AOM y la regresión lineal simple para estimar la cantidad de biomasa aérea (PV o PT) debido a la simplicidad del modelo y a la facilidad para su interpretación, en comparación con la complejidad de los factores latentes de PLS.

En la segunda parte de esta tesis se ha prestado especial atención a la calibración empírica de línea desde un punto de vista radiométrico, así como a la necesidad de realizar las correcciones atmosféricas para llegar a obtener reflectancia de superficie. La metodología empleada ha sido similar a las utilizadas con otras cámaras a bordo de aviones tripulados, como es el caso de los trabajos de Honkavaara y Markelin, (2007)

usando diferentes sensores (ADS40, DMC, UltraCam-D y DSS) o Álvarez et al. (2010) mediante la Ultracam-X y Ultracam-Xp, o más recientemente Hernández-López et al. (2012) usando el sensor ADS40-SH5.

Los resultados obtenidos en la validación muestran que es posible estimar la reflectancia con un error medio cuadrático (%RMSE) de sólo 3,32%, respecto a las medidas realizadas con espectrorradiómetro en campo, es decir, que fue posible calibrar radiométricamente una imagen de teledetección mediante el uso de datos de radiometría de campo adquiridos en condiciones equivalentes sobre la superficie observada (Roberts, 1985; Slater, 1987; Milton 1995). Esta calibración empírica de línea es un procedimiento adecuado para hacer una calibración absoluta de las imágenes de cámara aérea fotogramétrica Ultracam-Xp WA, empleando imágenes con el mínimo nivel de procesamiento posible (nivel 2).

Dentro de los sets evaluados a partir de las diferentes combinaciones de blancos de calibración el más exacto fue el set “mixto” aunque se recomienda el uso del set “a” (Paneles móviles de escala de grises (panel 1, panel 2, panel 1+2) debido a su simplicidad, al igual que Álvarez et al. (2010) y que Honkavaara y Markelin, (2007), aunque el uso de otros sets es factible ya que no presentan diferencias significativas.

En sintonía con este resultado también se presenta el trabajo de Hernández-Lopez et al. (2012), donde también se demostró la estabilidad de la calibración radiométrica de la ADS40-SH5 usando la escala de grises y lonas con los mismos colores que en este trabajo en la calibración empírica. También presentó un error mayor en la validación de la banda del NIR de un 3,5% frente a un 2,6 % en las bandas del visible. No obstante se demostró que la solución basada en la calibración vicaria supera ligeramente la exactitud en todas las bandas sobre la base de la calibración propuesta por el fabricante del sensor ADS40. Sin embargo, las reflectancias terrestres obtenidos en la calibración vicaria y la calibración de laboratorio proporcionado por el fabricante son válidas ya que en los dos casos los %RMSE alcanzados por la validación estaban por debajo del 6%. Los resultados son consistentes con Markelin et al. (2010) y Beisl (2010), siendo los %RMSE de las superficies de reflectancias menores al 5%.

Hay que destacar el uso de blancos de calibración fijos, existentes en el terreno, al igual que en trabajos como el de Haest et al. (2009), donde se realizó una calibración radiométrica en la cámara UltraCam-D usando blancos de calibración fijos como el asfalto, gravillas, pastos, baldosas rojas o grises entre otros, teniendo en cuenta la reflectancia bidireccional de los mismos y usando diferentes modelos matemáticos para

su corrección. Estas imágenes fueron estudiadas tiempo después de su realización demostrando la posibilidad de calibrar imágenes existentes permitiendo la fusión de datos procedentes de diferentes sensores.

Queda demostrado finalmente que el uso de las ecuaciones de calibración obtenidas mediante la calibración empírica de línea es una manera idónea para obtener imágenes de reflectancias así como el uso de estas ecuaciones en imágenes de la misma pasada del vuelo para poder obtener posteriormente variables biofísicas como la biomasa aérea. Pon algo de las imágenes adyacentes.

En la tercera parte de esta tesis se ha demostrado la adecuación de emplear imágenes corregidas radiométricamente a partir de una calibración empírica de línea para la estimación de biomasa aérea. Estas estimaciones de biomasa aérea, obtenidas a partir de las imágenes de reflectancia en superficie, muestran unos los resultados con una exactitud igual o mayor a las obtenidas con sensores instalados a bordo de aviones tripulados. Así, los modelos más exactos para estimar biomasa aérea se obtuvieron a partir de la reflectancia de las 4 bandas (R, G, B, NIR) ajustadas con PLS. Estos modelos alcanzaron coeficientes de determinación de $R^2=0,90$ para PV, $R^2=0,72$ para PT o $R^2=0,73$ para %PT, mostrando una buena correlación con la biomasa aérea. Por otro lado, usando los índices de vegetación y regresión OLS, para la estimación de biomasa aérea (PV) se ha obtenido un $R^2=0,86$ (índices NLI y MARAVI). Por otra parte, los índices de vegetación NDVI y SR alcanzaron un $R^2=0,80$ y $R^2=0,78$, respectivamente. En cuanto al PT, el resultado más exacto se alcanzó mediante el índice NLI ($R^2=0,71$ y un %RMSE<18,50%), mientras que el índice MARAVI presenta una estimación más exacta para %PV ($R^2=0,57$; RMSE=10,06%).

Por lo tanto fue posible establecer una relación entre los datos radiométricos capturados con la Ultracam-XP WA y el peso de la biomasa referente a PV, PT o %PV, por lo que se pudo estimar biomasa aérea a partir de imágenes multiespectrales de cámara aérea digital una vez calibradas radiométricamente, obteniéndose resultados más exactos al utilizar todas las bandas que usando los índices de vegetación.

Queda demostrado que los índices más comunes y destacados (NDVI y SR) utilizados en trabajos enfocados a la estimación de parámetros de cubierta vegetal (Lu et al., 2004; Mutanga y Skidmore, 2004; Hernán et al. 2007) como la biomasa dieron resultados menos exactos que el usando las reflectancias ajustadas por PLS. Por tanto se ha demostrado que mediante el método PLS se obtienen unos resultados más exactos al igual que en estudios como los realizados por Cho et al. (2007), en los que de igual

modo los modelos predictivos basados en PLS produjeron mayores precisiones en comparación con los índices de vegetación (NDVI). Estos resultados están en coherencia con los resultados de Hansen y Schjoerring (2003).

En otros estudios el uso de índices como el SAVI (Huete, 1998; Hongrui y Guangsheng, 2014), obtuvieron resultados acordes con este trabajo obteniéndose resultados más exactos que usando el NDVI o el SR. En la misma línea Aguado et al. (2008) respecto al índice NLI.

La similitud de los resultados obtenidos, independientemente de la imagen considerada, pone de manifiesto la poca diferencia que existe al usar los diferentes sets de calibración. Finalmente se ha demostrado la robustez de los modelos de calibración radiométrica de imágenes cuando se emplean para la estimación de biomasa aérea (PV, PT y %PV), obteniendo resultados similares independientemente del uso de las ecuaciones de calibración de una imagen en las imágenes contiguas.

CAPÍTULO 8

8

CONCLUSIONES

En este apartado se exponen las conclusiones más notables derivadas de este trabajo. Están temáticamente organizadas en tres subapartados: (i) conclusiones sobre la estimación de biomasa aérea a partir de espectro-radiometría, (ii) conclusiones sobre la calibración radiométrica de imágenes de cámara aérea digital, (iii) conclusiones sobre la estimación de biomasa aérea a partir de imágenes de cámara aérea digital. De forma general, en esta tesis doctoral se ha demostrado la viabilidad de generar productos de teledetección cuantitativa mediante sensores como el espectro-radiómetro de campo o sensores aéreos multiespectrales como la cámara Ultracam-XP WA.

Conclusiones sobre la estimación de biomasa aérea a partir de Espectro-radiometría

Se ha demostrado que la biomasa aérea de herbáceas (estimada como peso seco de la fracción verde (PV), fracción del peso verde (%PV) o peso total seco (PT)) se puede estimar con exactitud a partir de datos del espectrómetro de campo utilizando regresión PLS y los índices derivados de la transformación CR de ciertas regiones del espectro (440-567; 554-762; 916-1120; 1079-1297; 1265-1676). La identificación de esas regiones resultó crucial para incrementar la exactitud de los modelos.

Los modelos para estimar el peso verde de la biomasa aérea produjeron errores más pequeños que los que predicen la biomasa aérea total, por lo que se recomienda la separación de la fracción verde y seca para calibrar estos modelos.

Se recomienda el empleo del método de ajuste SVM en el caso de no realizar transformaciones de los datos de reflectancia, puesto que proporcionan las estimaciones de biomasa más exactas (PV, %PV, PT). En caso contrario se recomienda el empleo de regresión PLS y las transformaciones del espectro de Savitzky-Golay, Multiplicative Scatter Correction y Continuum Removal.

La obtención de modelos de estimación de biomasa aérea (PV y PT) con errores relativos inferiores a 9,1% y 6,2%, respectivamente, pone de manifiesto la elevada correlación entre la información espectral y la cantidad de biomasa aérea en herbáceas. Las estimaciones así obtenidas mediante técnicas no destructivas pueden ser transformadas en cantidad CO₂ capturado de la atmósfera y utilizadas en estudios de cambio climático y de seguimiento de la capacidad de secuestro de carbono de los sistemas silvopastorales.

Conclusiones sobre la calibración radiométrica de imágenes de cámara aérea digital

Se ha demostrado que es posible realizar una calibración radiométrica de imágenes de la cámara aérea fotogramétrica digital multiespectral Ultracam-Xp WA mediante el uso de mediciones de reflectancia para obtener imágenes de reflectancia en superficie, empleando para ello el método de calibración empírica de línea e imágenes con el mínimo nivel de procesamiento posible (nivel 2).

A la hora de elegir las superficies de referencia para medir reflectancias se recomienda el uso del “set a” (paneles móviles de 1 m × 1 m con una escala de grises de reflectancia nominal de 0%, 25%, 50%, 75% y 100%) debido a su simplicidad y exactitud, aunque son equipamientos caros. El uso de otros sets alternativos es factible, si bien deben representar amplios rangos de reflectancia para obtener estimaciones adecuadas. Así, se

demonstró que el uso de filtros así como blancos fijos, son una alternativa adecuada ya que por ejemplo en el set “mixto” formado por los sets que proporcionaron las estimaciones más exactas en cada banda (Set p, Set g, Set f y Set v) donde las ecuaciones de calibración para la banda del NIR (set “v”) se realizó únicamente con filtros ofreciendo los resultados más exactos en esa banda. Al usar los filtros los rangos de reflectancia son más pronunciados en el NIR lo que proporciona exactitudes más exactas en varios sets (e.g. set “mixto” %RMSE<1,7%). Con respecto al uso de blancos fijos destacar el asfalto como un blanco idóneo ya que ha mejorado el resultado de diferentes sets al añadirlo en las calibraciones. El césped artificial y las pistas de atletismo no presentaron mejoras debido posiblemente a su reflectancia bidireccional. La banda que presentó una exactitud mayor fue la banda del NIR, con rangos de error relativo entre el 1,67% y el 3,54% dependiendo del set (set “a”, set “mixto”, set “total”). Sin embargo, al realizar la validación independiente, se observó que la banda verde fue la que presentó los resultados más exactos, con errores relativos entre el 1,63% y 3,01% dependiendo del set de calibración y la imagen.

Al aplicar las ecuaciones de los sets (“a”, “mixto” y “total”) de la imagen A y C en la imagen B se obtuvieron en ambos casos los mismos modelos, confirmando de este modo la robustez de las calibraciones y con unos errores menores al 5%. La estabilidad de las condiciones atmosféricas y la elevada resolución radiométrica de la cámara seguro que también influyeron en los bajos errores cometidos.

En la validación independiente, empleando parcelas con vegetación como puntos de comprobación de las reflectancias, se obtuvo un %RMSE promedio para las tres imágenes muy similar (diferencia en las tres imágenes <1%), independientemente del set usado.

Estas validaciones confirman la robustez del método de calibración radiométrica, siendo los valores de reflectancia obtenidos para estas imágenes, idóneos para estimar variables biofísicas como la biomasa aérea o la cantidad de carbono secuestrado por esa biomasa.

Conclusiones sobre la estimación de biomasa aérea a partir de imágenes de cámara aérea digital

En este estudio se ha demostrado la idoneidad de las imágenes de cámara aérea multiespectral Ultracam-Xp WA para la estimación de la biomasa aérea de herbáceas (PV, PT, %PV), empleando imágenes corregidas a reflectancia en superficie mediante una calibración empírica de línea.

Los resultados más exactos se han obtenido empleando todas las bandas de reflectancia (R, G, B, NIR) y regresión PLS. En este caso las diferencias en la exactitud de la estimación de biomasa aérea (PV, PT, %PV) según el set de calibración empleado oscilaron entre 0,1% y un 2% (%RMSE) independientemente de la imagen. Al usar los índices de vegetación en las tres imágenes independientemente del set usado y del tipo de medición de biomasa (PV, PT, %PV) los errores relativos están entre 0,24% y 2,93%, siendo los índices NDVI y SR los que más varían en la estimación de biomasa de una imagen a otra y por otro lado destacar el índice SAVI como el más estable. En la misma imagen el rango de error relativo entre usar un índice u otro fue menor al 6,6%, siendo las mayores diferencias al estimar la biomasa aérea en PV y siendo la que menor al estimar en %PV. Los rangos fueron entre 5,76% y 6,51% en la estimación de biomasa aérea referida a PV, entre un 4,78% y un 5,20% referida a PT y entre 2,68% y un 3,27 referida a %PV

Se ha demostrado que, de entre los índices de vegetación testados, los que están más correlacionados con la biomasa aérea son el MARAVI, el NLI y el SAVI, frente a otros más comunes en estudios científicos como el NDVI o el SR. Por otro lado, el NDVI y SAVI fueron los menos sensibles a los cambios en la calibración (<5% de diferencia), mientras que SR fue el más afectado (10%).

Las ecuaciones de calibración radiométrica de una imagen pueden ser utilizadas con éxito para calcular las reflectancias de las imágenes adyacentes, puesto que las diferencias en la estimación de biomasa después de utilizar dichas calibraciones o la calibración obtenida específicamente para cada imagen resultaron inferiores al 1% (%RMSE).

Por lo tanto, los modelos de calibración radiométrica empleados resultaron robustos en su empleo para la estimación de biomasa, puesto que se obtuvieron resultados muy similares independientemente de la imagen considerada y los set de calibración empleados.

Fue posible establecer una relación entre los datos radiométricos capturados con la Ultracam-XP WA y la cantidad de biomasa, por lo que se demostró que es posible estimar biomasa aérea a partir de imágenes multiespectrales de cámara aérea digital una vez calibradas radiométricamente. Como la biomasa aérea está relacionada directamente con la función de la vegetación como sumidero de carbono, esta técnica permite generar cartografía continua de esta variable e integrarla en trabajos relacionados con su seguimiento y gestión.

CAPÍTULO 9

9

LÍNEAS DE TRABAJO FUTURO

Las líneas de trabajo futuras van encaminadas a la obtención de modelos matemáticos para la obtención de biomasa en matorral y para zonas arboladas. En estas formaciones vegetales la complejidad deriva, por un lado, de la gran heterogeneidad espacial de la biomasa y, por otro, de la realización de las labores de estimación de la biomasa existente en campo.

Otra línea sería aplicar este trabajo a una zona más extensa, que permitiese emplear los resultados de estimación de la biomasa para la gestión de recursos pascícolas y de las cabañas ganaderas.

En esta misma línea, se sugiere, en trabajos futuros, hacer aproximaciones a la variación de la biomasa basados en el seguimiento de los procesos fotosintéticos. Estos

productos podrían ofrecer una aproximación cuantitativa a la variación intra-anual de biomasa.

Las estimaciones podrán ser mejoradas con el empleo de sensores hiperespectrales como EAGLE y HAWK, así como el uso de datos LIDAR. Por otro lado, resultaría adecuado explorar el uso de RTM (Modelos de transferencia radiactiva) geométricos o mixtos como GORT o Geosailh, ya que los supuestos de partida de dichos modelos concuerdan más con cubiertas forestales heterogéneas.

Por último, otra posible línea de investigación es el empleo de datos obtenidos con UAVs y sensores aerotransportados hiperespectrales, así como de los datos proporcionados por el satélite Biomass, que realizará una misión en el año 2021 para evaluar la biomasa a través de mediciones de la cantidad de carbono terrestre almacenado y sus fluctuaciones.

CAPÍTULO 10

10 BIBLIOGRAFÍA

- Abdel-Rahman, E.M., Ahmed, F.B., Ismail, R., 2013. Random forest regression and spectral band selection for estimating sugarcane leaf nitrogen concentration using EO-1 Hyperion hyperspectral data. *International Journal of Remote Sensing*, 34(2), 712-728.
- Adams, M.L., Philpot, W.D., Norvell, W.A., 1999. Yellowness index: an application of spectral second derivatives to estimate chlorosis of leaves in stressed vegetation. *International Journal of Remote Sensing*, 20(18), 3663-3675.
- Adams, M.L., Norvell, W.A., Philpot, W.D., Peverly, J.H., 2000. Toward the discrimination of manganese, zinc, copper, and iron deficiency in 'bragg' soybean using spectral detection methods. *Agronomy Journal*, 92(2), 268-274.

- Adjorlolo, C., Cho, M.A., Mutanga, O., Ismail, R., 2012. Optimizing spectral resolutions for the classification of C 3 and C 4 grass species, using wavelengths of known absorption features. *Journal of Applied Remote Sensing*, 6(1), 1-15.
- Adjorlolo, C., Cho, M.A., Mutanga, O., 2015. Predicting C3 and C4 grass nutrient variability using in situ canopy reflectance and partial least squares regression. *International Journal of Remote Sensing* 36(6), 1743-1761.
- Aguado, I., Romero, A., Yebra, M., Prado, E., García, M., 2008. Estimación de parámetros forestales a partir de índices normalizados en imágenes ATM, TM y MODIS. En: Hernández, L. y Parreño, J. M. (Eds.), *Tecnologías de la Información Geográfica para el Desarrollo Territorial*. Servicio de Publicaciones y Difusión Científica de la ULPGC. Las Palmas de Gran Canaria, 447-461.
- Akaike, H., 1969. Fitting autoregressive models for prediction. *Annals of the institute of statistical mathematics*, 21(2), 243–247.
- Alcaraz-Segura, D., Liras, E., Tabik, S., Paruelo, J., Cabello, J., 2010. Evaluating the Consistency of the 1982-1999 NDVI trends in the Iberian Peninsula across four time-series derived from the AVHRR Sensor: LTDR, GIMMS, FASIR, and PAL-II. *Sensors*, 10, 1291-1314.
- Alspaugh, D., 2004. A brief history of photogrammetry. In: McGlone, J.C. (ed.) *Manual of Photogrammetry, Fifth Edition*. American Society for Photogrammetry and Remote Sensing, USA, 1-12.
- Álvarez, F., Catanzarite, T., Rodríguez-Pérez, J.R., Nafría, D., 2010a. Radiometric Calibration and Evaluation of the Ultracam Xp using Portable Reflectance Targets and Spectroradiometer Data. Application: to Extract Thematic Data from the Imagery Gathered by the National Plan of Aerial Orthophotography (PNOA). En: Colomina, I.
- Álvarez, F., Catanzarite, T., Castellanos, J. y Blanco-Medina, V., 2010b. Biomass Estimation using Digital Photogrammetric Cameras. En: Colomina, I., Skaloud, J. & Cramer, M. (eds.), 2010. *Proceedings of the joint EuroSDR/ISPRS 'International Calibration and Orientation Workshop EuroCOW 2010' held from 10th to 12th February 2010 in Castelldefels, Spain*.
- Álvarez, F., Catanzarite, T., Rodríguez-Pérez, J.R., Nafria, D., 2010. Radiometric calibration and evaluation of UltraCamX and XP using portable reflectance targets and spectrometer data. Application to extract thematic data from imagery gathered by the national plan of aerial orthophotography (PNOA). *Proceedings of the Calibration and*

Orientation workshop Workshop EuroCOW, 10-12 February 2010, Castelldefels, Spain, 6p.

- Ambrosia, V., Wegener, S., Sullivan, D., Buechel, S., Dunagan, S., Brass, J., et al., 2003. Demonstrating UAV-acquired real-time thermal data over fires. *Photogrammetric Engineering and Remote Sensing*, 69(4), 391-402.
- An, N., Price, K.P., Blair, J.M., 2013. Estimating above-ground net primary productivity of the tallgrass prairie ecosystem of the Central Great Plains using AVHRR NDVI. *International Journal of Remote Sensing*, 34, 3717-3735.
- Anaya, J.A., Chuvieco, E., Palacios, A., 2008. Estimación de biomasa aérea en Colombia a partir de imágenes MODIS. *Revista de Teledetección*. ISSN: 1988-8740, 30, 5-22.
- Anderson, D.M., Swanton, C.J., Hall, J.C., Mersey, B.G., 1993. The influence of soil moisture, simulated rainfall and time of application on the efficacy of glufosinate-ammonium. *Weed Res.*, 33, 149-160.
- Antic, B., Culibrk, D., Crnojevic, V., Minic, V., 2009. An efficient UAV based remote sensing solution for precision farming. In: *BioSense - The First International Workshop on ICT and Sensing Technologies in Agriculture, Forestry and Environment*, Novi Sad, Serbia.
- Arias, B., Gómez, J., 2009. Testing the stereoscopic precision of a large-format digital camera. *The Photogrammetric Record*, 24 (126), 157-170.
- Arngren, M., Hansen, P.W., Eriksen, B., Larsen, J., Larsen, R., 2011. Analysis of pregerminated barley using hyperspectral image analysis *Journal of Agriculture and Food Chemistry*, 59, 11385-11394.
- ASD Inc. ViewSpec Pro User's Guide: ViewSpec Pro™, 2008. User Manual, ASD Document 600555 Rev. A
- Atzberger, C., Guérif, M., Baret, F., Werner, W., 2010. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. *Computers and Electronics in Agriculture*, 73, 165-173.
- Audain-Martínez, E., 2014. Estimación del punto isoeléctrico de péptidos empleando descriptores moleculares y máquinas de soporte vectorial. Tesis doctoral. Ciencias en Tendencias de la Biotecnología Contemporánea. Mención Investigación de Nuevos Productos. Centro de Inmunología Molecular, La Habana.
- Axelsson, C., Skidmore, A.K., Schlerf, M., Fauzi, A., Verhoef, W., 2013. Hyperspectral analysis of mangrove foliar chemistry using PLSR and Hyperspectral analysis of mangrove foliar chemistry using PLSR and support vector regression. *International Journal of Remote Sensing*, 34, 1724-1743.

- Barnes, R.J., Dhanoa, M.S., Lister, S.J., 1989. Standard normal variate transformation and detrending of near-infrared diffuse reflectance spectra. *Applied Spectroscopy*, 43, 772-777.
- Barrio, A.M., Balboa, M.M.A., Castedo, D.F., Diéguez, A.U.y Álvarez, G.J.A., 2006. An ecoregional model for estimating volume, biomass and carbon pools in maritime pine stands in Galicia (northwestern Spain). *For. Ecol. Manage*, 223, 24-34.
- Bauer, M., Mroczynski, R., MacDonald, R., Hoffer, R., 1971. Detection of southern corn leaf blight using color infrared aerial photography. In *Proc. Third Biennial Workshop on color Aerial Photography in the Plant Sciences*, Gainesville Florida, 114-126.
- Bauer, M., 1985. Spectral inputs to crop identification and condition assessment. *Proceedings of the IEEE*, 73(6), 1071-1085.
- Bautista-Zúñiga, F., Delfín-González, H., Delgado, C., Palacio, J.L., 2004. Técnicas de muestreo para manejadores de recursos naturales. Universidad Nacional Autónoma de México, Instituto Nacional de Ecología y Universidad Autónoma de Yucatán. D.F., México. ISBN 970-32-1778-8. Tiraje de 1000 ejemplares.
- Beisl, U., 2006. Absolute spectroradiometric calibration of the ADS40 Sensor. *ISPRS Comm I*, WGI/I, Paris.
- Beisl, U.Y., Woodhouse, N., 2006. Correction of atmospheric and bidirectional effects in multispectral ADS40 images for mapping purposes. *Proc. XXth Congress of the ISPRS*, Istanbul, Turkey, 12-23 July, 5p.
- Beisl, U., Adiguel, M., 2010. Validation of the reflectance calibration of the ADS40 airborne sensor using ground reflectance measurements. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(7B), 80-85.
- Beisl, U., 2012. Reflectance calibration scheme for airborne frame camera images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39(7B), 1-5.
- Ben-Hur, A., Weston, J., 2010. A user's guide to support vector machines. *Methods Mol. Biol.*
- Bhardwaj, S., Warbhe, A., Kumar, B.R., 2015. Sensor system implementation for unmanned aerial vehicles. *Indian Journal of Science and Technology*, 8(S2), 7-11.
- Birth, G.S., McVey, G., 1968. Measuring the color of growing turf with a reflectance spectroradiometer, *Agronomy Journal*, 60, 640-643.
- Blackmer, T.M., Schepers, J.S., Varvel, G.E., 1994. Light reflectance with other nitrogen stress measurements in corn leaves. *Agron. J.*, 86, 934-938.

- Blackmer, T.M., Schepers, J.S., Varvel, G.E., Meyer, G.E., 1996. Analysis of aerial photography for nitrogen stress within corn fields. *Agron. J.*, 88, 729-733.
- Blanco, M., Maspoch, S., 2007. Calibración multivariable. In M. Blanco, & V. Cerdá (Eds.), *Temas avanzados de quimiometría: Advanced topics in chemometrics* (pp. 233 - 280). Barcelona: Ediciones UIB.
- Boissard, P., Huet, P., Pointel, J.G., 1993. Reflectance, green leaf area index, and ear hydric status of wheat from anthesis until maturity. In: *Crop Structure and Light Microclimate* (Varlet-Grancher C, Bonhomme R, eds), Inra, Paris, 491-498.
- Boland, J.T., Ager, E., Edwards, E., Frey, P., Jones, R.K., 2004. Jungquist, A.G. Lareau, J. Lebaron, C.S. King, K. Komazaki, C. Toth, S. Walker, E. Whittaker, P. Zavattoni and H. Zuegge. Cameras and sensing systems, *ASPRS Manual of Photogrammetry*, 5th Edition, (J. C. McGlone, E. Mikhail, J. Bethel, editors), American Society for Photogrammetry and Remote Sensing, 581-676.
- Botero-Herrera, J.M., Parra-Sánchez, L.N., Cabrera-Torres, K.R., 2009. Determinación del nivel de nutrición foliar en banano por espectrometría de reflectancia. *Revista Fac. Nac. Agron. Medellín*, 62,5089-5098.
- Boschetti M., Bocchi, S., Brivio, P.A., 2007. Assessment of pasture production in the Italian Alps using spectrometric and remote sensing information. *Agriculture, Ecosystems and Environment*, 118, 267-272.
- Brereton, R.G., 2007. In calibration; applied chemometrics for scientists; John Wiley & Sons, Ltd, 193-220.
- Burger, J., 2006. Hyperspectral NIR image analysis: data exploration, correction, and regression. Ph.D. Dissertation. Swedish University of Agricultural Sciences; Uppsala, Sweden.
- Calera, A., González-Piqueras, J., Melia, J., 2004. "Monitoring barley and corn growth from remote sensing data at field scale". *International Journal of Remote Sensing*, 25(1), 97-109.
- Camps-Valls, G., Bruzzone, L., Rojo-Álvarez, J.L., Melgani, F., 2006. Robust support vector regression for biophysical variable estimation from remotely sensed images. *IEEE Geosci. Remote Sens. Lett.*, 3,339-343.
- CAMO, Technologies Inc., 2013. The Unscrambler appendices: method references. PDFdocument. Available at: <http://www.camo.com/TheUnscrambler/Appendices/The%20Unscrambler%20Method%20References.pdf> (09/09/2016).

- Carmona-Suarez, E.J., 2013. Tutorial sobre Máquinas de Vectores Soporte (SVM). Dpto. de Inteligencia Artificial, ETS de Ingeniería Informática, Universidad Nacional de Educación a distancia (UNED). Madrid.
- Chavez, R., 1996. Image-based atmospheric corrections - revisited and improved. *Photogrammetric Engineering & Remote Sensing*, 62(9), 1025-1036.
- Che, N., Price, J.C., 1992. Survey of radiometric calibration results and methods for visible and near infrared channels of NOAA 7, 9 and 11 AVHRR. *Remote Sensing of Environment*, 41, 19-27.
- Cherkassky, V., Ma, Y., 2004. Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Netw.*, 17,113-126.
- Cheng, Y.B., Riano, D., Zarco-Tejada, P.J., Ustin, S.L., 2006. Canopy water content estimates with AVIRIS imagery and MODIS reflectance products art. n°. 629809, 6298, 29809-29809.
- Cho, M., Skidmore, A.K., Corsi, F., Van Wieren, S.E. y Sobhan, I., 2007. Estimation of green grass - herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression. *International Journal of Applied Earth Observation and Geoinformation*, 9, 414-424.
- Chuvienco-Salineró, E., 1993. Itegration of linear programming and GIS for land-use modeling. *International Journal of Geographical Information System* 7(I), 71-83.
- Chuvienco-Salineró, E., 1996. *Fundamentos de teledetección espacial*, Madrid: Ed. Rialp, 568 p.
- Chuvienco-Salineró, E., 2000. *Fundamentos de teledetección espacial*. RIALP, 568 p.
- Chuvienco-Salineró, E., 2002. *Teledetección ambiental*, Ariel, 584 p.
- Chuvienco-Salineró, E., 2008. *Earth observation of global change. The role of satellite remote sensing in monitoring the global environment*. Springer Berlín Heidelberg New York.
- Chuvienco-Salineró, E., Huete, A., 2010. *Fundamentals of satellite remote sensing*. Boca Raton (FL), CRC Press. Boca Raton (USA), 302-310.
- Clark, R.N., Roush, T.L., 1984. Reflectance spectroscopy: quantitative analysis techniques for remote sensing applications. *Journal of Geophysical Research*, 89(7), 6329-6340.
- Clevers, J.G.P.W., 1988. The derivation of a simplified reflectance model for the estimation of leaf area index. *Remote Sensing of Environment*, 25, 53-69.
- Clevers, J.G.P.W., Büker, C., Leeuwen, H., Bouman, B., 1994. A framework for monitoring crop growth by combining directional and spectral remote sensing information. *Remote Sens. Environ.* 50, 161-170.

- Clevers, J., 1997. A simplified approach for yield prediction of sugar beet based on optical remote sensing data. *Remote Sens. Environ.*, 61, 221-228.
- Clevers, J.G.P.W., Vonder, O.W., Jongschaap, R.F.E., Desprats, J.F., King, C., Pre´vot, L., Brugier, N., 2002. Using SPOT data for calibrating a wheat growth model under Mediterranean conditions. *Agronomie*, 22, 687-694.
- Clevers, J., van der Heijden, G., Verzakov, S., et al., 2007. Estimating grassland biomass using SVM band shaving of hyperspectral data. *Photogramm Eng Remote Sens*, 73, 1141.
- Clevers, J.G.P.W., Kooistra, L., Schaepman, M.E., 2008. Using spectral information from the NIR water absorption features for the retrieval of canopy water content. *Int. J. Appl. Earth Observ. Geoinf.*, 10, 388-397.
- Colwell, J.E., 1973. Bidirectional spectral reflectance of grass canopies for determination of above ground standing biomass. PhD. Michigan, USA: University of Michigan.
- Comesaña-García, Y., Dago-Morales, A., Talavera-Bustamante, I., Núñez-Cuadra, O., Hernández-González, N., 2010. Modelo de regresión de máquinas de vectores soporte de mínimos cuadrados para la predicción de la cristalinidad de catalizadores de craqueo por espectroscopia infrarroja. *Revista CENIC Ciencias Biológicas*, 41(1), 43-48,
- Conel, J.E., Green, R.O., Vane, G., Bruegge, C.J., Alley, R.E., Curtiss B.J., 1987. Airborne Imaging Spectrometer-2: Radiometric and spectral characteristics and comparison of ways to compensate for the atmosphere, in press, SPIE Proceedings.
- Conel, J.E., Alley, R.E., 1985. Lisbon Valley, Utah, Uranium Test Site Report, Joint NASA / Geosat Test Case Project (H. N. Paley, Ed.).
- Corral, A.J., Fenlon, J.S., 1978. A comparative method for describing the seasonal distribution of production from grasses. *Journal of Agricultural Science, Cambridge* 91, 61-67.
- Cozzolino, D., Cynkar, W.U., Shah, N., Smith, P.A., 2011d. Multivariate data analysis applied to Spectroscopy: Potential application to juice and fruit quality. *Food Research International*, 44(7), 1888-1896.
- Cozzolino, D., Cynkar, W.U., Shah, N., Smith, P.A., 2011c. Technical solutions for analysis of grape juice, must, and wine: The role of Infrared Spectroscopy and chemometrics. *Analytical and Bioanalytical Chemistry*, 401(5), 1475-1484.
- Cramer, M., Stallman, D., 2002. System calibration for direct georeferencing. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 34 (Part 3A), 79-84.
- Cramer, M., 2004. EuroSDR network on digital camera calibration. Report Phase I (Status Oct 26, 2004)..

- Cramer, M., 2005. Digital airborne cameras - status and future. Proceedings of ISPRS Hannover Workshop 2005: High-Resolution Earth Imaging for Geospatial Information. 8 p., on CD-ROM.
- Cramer, M., 2007. Certification of digital Airborne Mapping Products. – EuroDAC², GIM-International, September 2007, 21(9), 21-23.
- Cramer, M., 2008. The EuroSDR Approach on Digital Airborne Camera Calibration and Certification, International Archives of Photogrammetry and Remote Sensing IAPRS 27(B4), 1753-1758, Proceedings 21. ISPRS Congress, Beijing 2008, digitally published on CD, 6 pages.
- Cramer, M., 2010. The DGPF-Test on Digital Camera Evaluation – Overview and Test Design. Photogrammetrie – Fernerkundung - Geoinformation (PFG), 73-82.
- Cramer, M., 2011. Geometry perfect – radiometry unknown? Photogrammetric Week 2011, (Fritsch, D., Ed.), Wichmann Verlag, Heidelberg, Germany, 65-77.
- Curran, P.J., 1989. Remote sensing of foliar chemistry. Remote Sensing of Environment, 30(3), 271-278.
- Curran, P.J., Dungan, J.L., Peterson, D.L., 2001. Estimating the foliar biochemical concentration of leaves with reflectance spectrometry testing the Kokaly and Clark methodologies. Remote Sensing of Environment, 76, 349-359.
- Danson, F.M., Steven, M.D., Malthus, T.J., Jaggard, K.W., 1990. Spectral response of sugar beet to water stress, Proceed. of the 16th Annual Conference of the Remote Sensing Society "Remote Sensing and Global Change", University College of Swansea, 19th-21st September 1990, ed. by M.G. Coulson, 49-58.
- Dhanoa, M.S., Lister, S.J., Sanderson, R., Barnes, R.J., 1994. The link between multiplicative scatter correction (MSC) and standard normal variate (SNV) transform of NIR spectra. J. Near Infrared Spectrosc., 2, 43-47.
- Darvishzadeh, R., Skidmore, A.K., Schlerf, M., Atzberger, C., Corsi, F., Cho, M.A., 2008. LAI and chlorophyll estimated for a heterogeneous grassland using hyperspectral measurements. ISPRS J. Photogramm. Remote Sens., 63, 409-426.
- Darvishzadeh, R., Skidmore, A. K., Mirzaie, M., Atzberger, C. y Schlerf, M., 2014. Fresh Biomass Estimation in Heterogeneous Grassland Using Hyperspectral Measurements and Multivariate Statistical Analysis. InAGU Fall Meeting Abstracts, 1, 7.
- Darvishzadeh, R., Skidmore, A., Mirzaei, M., Atzberger, C., Schlerf, M., 2015. Fresh Biomass Estimation in Heterogeneous Grassland Using Hyperspectral Measurements and

- Multivariate Statistical Analysis. Proceedings of the 2015 annual ASPRS conference, IGTF, Tampa, Florida. 7.
- De Jong, S.M., 1994. Applications of Reflective Remote Sensing for Land Degradation Studies in a Mediterranean, Environment. (Netherlands Geographical Studies (NGS)). Ph.D. Dissertation, Utrecht University, Utrecht, The Netherlands.
- De Miguel, E., Rejas, J.G., Jiménez, M., Fernández, G., 2001. Calibración radiométrica de datos ATM mediante radiometría de campo. *Teledetección, Medio Ambiente y Cambio Global*, 465-468.
- Del Pozo, S., Rodríguez-González, P., Hernández-López, D. y Felipe-García, B., 2014. Vicarious Radiometric Calibration of a Multispectral Camera on Board an Unmanned Aerial System. *Remote Sensing*, 6, 1918-1937.
- Díaz García-Cervignon, J.J., 2015. Estudio de Índices de vegetación a partir de imágenes aéreas tomadas desde UAS/RPAS y aplicaciones de estos a la agricultura de precisión. Trabajo fin de máster en tecnologías de la información geográfica. Universidad Complutense de Madrid, 77.
- Dingirard, M., Slater, P.N., 1999. Calibration of space-multispectral imaging sensors: A review. *Remote Sensing of Environment*, 68(3), 194-205.
- Dong, J., Kaufman, R.K., Minen, R.B., Tucker, C.J., Kauppi, P.E., Liski, J., Buermann, W., Alexeyev, W., y Hughes, M.K., 2003. Remote sensing estimates of boreal and temperate forest woody biomass, carbon pools, sources and links. *Remote Sens. Environ.* 84, 393-410.
- Duan, S.B., Li, Z.L., Tang, B.H., Wu, H., Ma, L., Zhao, E., Li, C., 2013. Land surface reflectance retrieval from hyperspectral data collected by an unmanned aerial vehicle over the baotou test site. *plos one*, 8, 6, 66972 (8), 10.1371/annotation/09d10115-c53d-4d9f-8036-85c476eeef38.
- Dunn, B.W., Beecher, H.G., Batten, G.D. y Ciavarella, S., 2002. The potential of near infrared reflectance spectroscopy for soil analysis, a case study from the Riverine Plain of south-eastern Australia. *Austr. J. Exp. Agric.*, 42, 607-614.
- Durbha, S.S., King, R.L., Younan, N.H., 2007. Support vector machines regression for retrieval of leaf area index from multiangle imaging spectroradiometer. *Remote Sens. Environ.*, 107, 348-361.
- Efron, B., Gong, G., 1983. A Leisurely Look at the Bootstrap, the Jackknife, and Cross-Validation. *The American Statistician*, 37, 36-48.

- Eisfelder, C., Kuenzer, C. y Dech, S., 2012. Derivation of biomass information for semi-arid areas using remote-sensing data. *International Journal of Remote Sensing*, 33, 2937-2984.
- Erol, H., Akdeniz, F., 1996. A multispectral classification algorithm for classifying parcels in an agricultural region. *International Journal of Remote Sensing*, 17, 3357-3371.
- Esposito, F., Rufino, G., Moccia, A., 2007. 1st mini-UAV integrated hyperspectral/thermal electro-optical payload for forest fire risk management. *American Institute of Aeronautics and Astronautics, Infotech@Aerospace*, 1, 653-665.
- Eswaran, H., Lai, R., Reich P.F., 2001. Land degradation: an overview. In responses to land degradation. proceedings of the 2nd international conference on land degradation and desertification, 2001, Bridges, E.M., Hannam, I.D., Oldeman, L.R., Pening de Vries, F.W.T., Scher, S.J., Sompatpanit, S. (Eds.), Khon Kaen, Thailand, 20-35.
- EuroDAC2, 2011. Digital Camera Calibration & Validation. <http://www.ifp.uni-stuttgart.de/euroedr/EuroDAC/index.en.html> (10-06-2016).
- Everitt, J.H., Anderson, G.L., Escobar, D.E., Davis, M.R., Spencer, N.R., Andrascik, R.J., 1995. Use of remote sensing for detecting and mapping leafy spurge (*Euphorbia esula*). *Weed Technology*, 9, 599-609.
- Farrand, W.H., Singer, R.B., Merenyi, E., 1994. "Retrieval of Apparent Surface Reflectance from AVIRIS Data: A Comparison of Empirical Line, Radiative Transfer, and Spectral Mixture Methods." *Remote Sensing of Environment*, 47, 311-321.
- Fazakas, Z., Nilsson, M., y Olsson, H., 1999. Regional forest biomass and wood volume estimation using satellite data and ancillary data. *Agric. For. Meteorol.*, 98-99, 417-425.
- Ferdinant, J., Padmanaban, R., 2013. Development of a Methodology to Estimate Biomass from Tree Height Using Airborne Digital Image. *International Journal Of Advanced Remote Sensing And GIS*, 2(1), 49-58.
- Fernández-Corbis, P., Otero-Vicario, J.M., 2016. Curso "Logística y Gestión del aprovechamiento de biomasa mediante SIG" (3ª edición). Universidad de Cordoba.
- Fernández-Núñez, M., Sanchez, N., Ojeda-Zujar, J., 2009. Aplicaciones de Sensores Aerotransportados (Lidar/Cámara Fotogramétrica Digital) en la Gestión de Espacios Protegidos: el Parque Natural de Dunas de Corrubedo y Lagos de Carregal y Vixan (Galicia, no España). 147-151. En: *Nuevas Contribuciones Sobre Geomorfología Litoral*. Huelva, España. Sociedad Geológica de España.

- Flowers, M., Weisz, R., Heiniger, R., 2003. Quantitative approaches for using color infrared photography for assessing in season nitrogen status in winter wheat. *Agron. J.*, 95, 1189-1200.
- Fourty, T., Baret, F., 1997. Vegetation water and dry matter contents estimated from top of the atmosphere reflectance data: A simulation study. *Remote Sensing of Environment*, 61(1), 34-45.
- Franco-Lopez, H. Alan, Ek, A.R., Bauer, M.E., 2001. Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors method. *Remote Sens. Environ.* 77, 251-274.
- Fricker, P., 2001. ADS40 - progress in digital aerial data collection. In: Fritsch, D., Spiller, R. (Eds.), *Photogrammetric Week*. Wichmann Verlag, 67-76.
- Fricker, P., Gervaix, F., Llorens, F., Delgado, J., Cardenal, J., 2002. Utilización de sensores aerotransportados para la generación de MDT y ortofotografías: LH ADS40 y LH ALS40. *Proceedings of the Fourteenth International Symposium on Graphic Engineering*, 05-07 June, Santander, Spain, 527-536.
- Fricker, P., Rohrbach, A., 2005. Pushbroom scanner provide highest resolution earth imaging information in multispectral bands. *Proceedings of the ISPRS Hannover Workshop*, 17-20 May 2005, CD-ROM, 5 p.
- Fricker, P., 2007. Raising the bar for multi-band, high-resolution airborne imagery. In: *Photogrammetric Week 2007*, Fritsch, D., (Ed). Wichmann Verlag. Heidelberg, Germany, 71-79.
- Fu, Y.Y., Wang, J.H., Yang, G.J., Song, X.Y., Xu, X.G. y Feng, H.K., 2013. Band depth analysis and partial least square regression based winter wheat biomass estimation using hyperspectral measurements. *Guang Pu Xue Yu Guang Pu Fen Xi*. Chinese. 33(5), 1315-9.
- Fu, Y., Yang, G., Wang, J., Song, X., Feng, H., 2014. Winter wheat biomass estimation based on spectral indices, band depth analysis and partial least squares regression using hyperspectral measurements. *Computers and Electronics in Agriculture*, 100, 54-59.
- Gao, X., Huete, A.R., Ni, W., Miura, T., 2000. Optical biophysical relationships of vegetation spectra without background contamination. *Remote Sensing of Environment.*, 74, 609-620.
- Gao, T., Xu, B., Yang, X.C., Jin, Y.X., Ma, H.L., Li, J.Y., Yu, H.D., 2013. Using MODIS time - 2014, 47, 611-625, series data to estimate aboveground biomass and its spatio-

- temporal variation in Inner Mongolia's grassland between 2001 and 2011. *International Journal of Remote Sensing*, 34, 7796-7810.
- García-Ferrer, A., 2013. Potencialidad y nuevas orientaciones en el uso de la teledetección en agricultura y silvicultura. *Ambienta: La revista del Medio Ambiente*, 105, 6-15.
- García, C.E., Herrera, F.A., Erazo, E.O., 2014. Metodología básica para la generación de índices de vegetación mediante imágenes multiespectrales aerotransportadas aplicada en cultivos de caña de azúcar. In: XVI Simposio Internacional Selper 2014, Medellín, Selper, Memorias artículos CD-ROM.
- García, C.E., Herrera, F.A., 2015. Percepción remota en cultivos de caña de azúcar usando una cámara multiespectral en vehículos aéreos no tripulados. *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.
- Geladi, P., MacDougall, D., Martens, H., 1985. *Appl. Spectrosc.* 39, 491-500.
- Geladi, P., Kowalski, B.R., 1986. Partial least-squares regression: a tutorial. *Analytica Chimica Acta*, 185, 1-17.
- Gemperline, P., 2006. *Practical Guide to Chemometrics, Second Edition*, CRC Press, Boca Raton FL.
- Goodenough, D.G., Li, J.Y., Dyk, A., 2006. Combining hyperspectral remote sensing and physical modeling for applications in land ecosystems. *IEEE International Geoscience And Remote Sensing Symposium (IGARSS)*, Denver, Colorado.
- Goel, N.S., Qi, W., 1994. Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. *Remote Sens. Rev.*, 10, 309-347.
- Goetz, A.F.H., Vane, G., Solomon, J.E., y Rock, B.N., 1985. *Imaging spectrometry for earth remote sensing: Science*, 228, 1147-1153.
- Gómez-Molina, A., Arjonilla-Sampedro, F.J., Antolín-Sánchez, R., Pérez-García, J.L., Delgado-García, J., 2010. Aplicaciones medioambientales del sensor fotogramétrico de matriz lineal ADS40. En: Ojeda, J., Pita, M.F. y Vallejo, I. (Eds.), *Tecnologías de la Información Geográfica: La Información Geográfica al servicio de los ciudadanos*. Secretariado de Publicaciones de la Universidad de Sevilla. Sevilla, 135-147.
- González-Calvo, C., 2012. *Procesamiento a bordo de imágenes hiperespectrales de la superficie terrestre mediante hardware reconfigurable*. (Tesis Doctoral).

- Gong, P., Pu, R., Biging, G.S., Larrieu, M.R., 2003. Estimation of forest leaf area index using vegetation indices derived from Hyperion hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing* 41(6), 1355-1362.
- Green, R.O, Eastwood, M.L., Sarture, C.M., Chrien, T.G., Aronsson, M., Chippendale, B.J., Faust, J.A., Pavri, B.E., Chovit, C.J., Solis, M., Olah, M.R., Williams, O., 1998. *Imaging Spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)*. *Remote sens. environ.* 65, 227-248.
- Green, K., Tukman, M., Finkbeiner, M., 2011. Comparison of DMC, UltraCam and ADS40 imagery for benthic habitat and propeller scar mapping. *Photogrammetric Engineering and Remote Sensing*, 77(6), 589-599.
- Grignetti, A., Salvatory, R., Casacchia, R., Manes, F., 1997. Mediterranean Vegetation Analysis by Multi-Temporal Satellite Sensor Data. *International Journal of Remote Sensing*, 18,(6), 1307-1318.
- Grossman, Y.L., Ustin, S.L., Jacquemoud, S., Sanderson, E.W., Schmuck, G., Verdebout, J., 1996. Critique of stepwise multiple linear regression for the extraction of leaf biochemistry information from leaf reflectance data. *remote sens. environ.*, 56, 182-193.
- Haboudane, D., Miller, J., Pattey, E., Zarco-Tejada, P., Strachan, I., 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.
- Hadi, 2015. Multivariate statistical analysis for estimating grassland leaf area index and chlorophyll content using hyperspectral data. Enschede, University of Twente Faculty of Geo-Information and Earth Observation (ITC). Enschede, The Netherlands, June.
- Hadlei, B.C., García-Quijano, M., Jensen, J.R., 2005. Empirical versus model-based atmospheric correction of digital airborne imaging spectrometer hyperspectral data. *Geocarto International*, 20(4), 21-28.
- Haest, B., Biesemans, J., Horsten, W., Everaerts, J., 2009. Radiometric calibration of digital photogrammetric image data. In the proceedings of Annual American Society of Photogrammetry and Remote Sensing Conference, 9-13 March 2009, Baltimore, Maryland, USA, 12p.
- Haitao, X., Lei, T., 2007. An autonomous helicopter system for aerial image collection. In 2007 ASABE Annual International Meeting, Technical Papers, Minneapolis, MN, 2.

- Hajek, F., 2007. Process-based approach to automated classification of forest structures using medium format digital aerial photos and ancillary GIS information. *European Journal of Forest Research*.
- Hall, F.G., Strebel, D.E., Nickeson, J.E., Goetz, S.J., 1991. Radiometric rectification: toward a common radiometric response among multitemporal, multisensor images. *Remote Sensing of Environment*, 35, 11-27
- Hall, R.J., Skakun, R.S., Arsenault, E.J., Case, B.S., 2006. Modeling forest stand structure attributes using Landsat ETM+ data, Application to mapping of aboveground biomass and stand volume. *For. Ecol. Manage.* 225, 378-390.
- Hansen, P.M., Schjoerring, J.K., 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment*, 86, 542-553.
- Hansch, T.H., Baltsavias, E., 2009. Evaluation of digital photogrammetric aerial camera systems - Radiometric Evaluation of DMC, ADS40 and UltracamX. Annual meeting of DGPF, 24-26 March 2009, Jena, Germany. <http://www.ifp.uni-stuttgart.de/dgpf/PDF/JT09-Radiometrie-HANUSCH&BALTSAVIAS.pdf> 11p. (10-07-2013)
- Harald, M., Tormod, N., 1989. *Multivariate Calibration*; Wiley & Sons, Great Britain.
- Haydock, K.P., Shaw, N.H., 1975. Comparative yield method for estimating dry matter yield of pasture. *Australian Journal of Experimental Agriculture and Animal Husbandry*, 15, 663-670.
- Hefele, J., 2006. Calibration experience with the DMC. In the Proceedings of the EuroSDR Commission I and ISPRS Working Group 1/3 Workshop EuroCOW, 25-27 January 2006, Castelldefels, Spain, unpaginated CDROM, 6p.
- Heier H., Kiefner M. y Zeitler W., 2002. Calibration of the Digital Modular Camera DMC; FIG XXII International Congress, Washington, D.C. USA.
- Heikkinen, V., Korpela, I., Tokola, T., Honkavaara, E., Parkkinen, J., 2011. An SVM classification of tree species radiometric signatures based on the Leica ADS40 sensor. *IEEE Transactions on Geoscience and Remote Sensing*. *IEEE Transactions on Geoscience and Remote Sensing*, 49(11), 4539-4551.
- Heipke, C., Jacobsen, K.Y., Wegmann, H., 2002. Analysis of the Results of the OEEPE Test "Integrated Sensor Orientation". In: Heipke, C., Jacobsen, K., Wegmann, H. (Eds.), *OEEPE Official Publication*, 43, 31-49.

- Hengl, T., 2006. Finding the right pixel size. *Computers and Electronics in Agriculture*, 32, 1283-1298.
- Hernán, V., Perez-Peña, J., García, M., Vallone, R., Mastrantonio, L., Olmedo, G., Rodríguez-Plaza, L., Salcedo, C., 2007. Estimación de biomasa en viñedos mediante imágenes satelitales y aéreas en Mendoza, Argentina. *Teledetección - hacia un mejor entendimiento de la dinámica global y regional*. Ed. Martin.
- Hernández, J., 2002. Normativa geodésica Venezolana. *Revista Cartográfica*. Enero 2002. Instituto Panamericano de Geografía e Historia.
- Hernández-López, D., Felipe-García, B., González-Piqueras, J., Villa-Alcázar, G., 2011. An approach to the radiometric aerotriangulation of photogrammetric images. – *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 883-893.
- Hernández-López, D., Felipe García, B., Sánchez, N., González Aguilera, D. y Gómez Lahoz, J., 2012. Testing the Radiometric Performance of Digital Photogrammetric Images: Vicarious vs. Laboratory Calibration on the Leica ADS40, a Study in Spain. *German Society for Photogrammetry, Remote Sensing and Geoinformation*, 5, 557-573.
- Herrera-Arango, M.A., Del Valle, J.I., Orrego, S.A., 2001. Biomasa de la vegetación herbácea y leñosa pequeña y necromasa en bosques tropicales primarios y secundarios de Colombia Valdivia, Chile, 1-18.
- Herrero-Huerta, M., 2013. Calibración vicaria de una cámara multiespectral desde paramotor. Trabajo de Fin de Máster del Máster en Geotecnologías cartográficas en ingeniería y arquitectura. <http://hdl.handle.net/10366/122181> (20-12-2014).
- Hendriks, M.M.W.B., Cruz-Juarez, L., Bont, D.D., Hall, R.D., 2005. Preprocessing and exploratory analysis of chromatographic profiles of plant extracts. *Anal. Chim. Acta*, 545, 53-64.
- Herwitz, S., Dunagan, S., Sullivan, D., Higgins, R., Johnson, L., Zheng, J. et al., 2003. Solar-powered UAV mission for agricultural decision support. In *Proc. 2003 IGARSS: Learning From Earth's Shapes and Colours*, 3, 1692-1694.
- Herwitz, S., Johnson, L., Dunagan, S., Higgins, R., Sullivan, D., Zheng, J. et al., 2004. Imaging from an Unmanned Aerial Vehicle: Agricultural surveillance and decision support. *Computers and Electronics in Agriculture*, 44(1), 49-61.
- Hinz, A., Dröstel, C., Heier, H., 2000. Digital Modular Camera: System Concept and Data Processing Workflow. *Pro-ceedings del XIXth Congress of ISPRS "Geoinformation for All"*, IAPRS, Vol. XXXIII. 16-23 July, Amsterdam, The Nether-lands.

- Hirata, M., Kogab, N., Shinjo, H., Fujita, H., Gintzburger, G., Miyazaki, A., 2001. Vegetation classification by satellite image processing in a dry area of northeastern Syria. *International Journal of Remote Sensing*, 23, 507-516.
- Hofjer, R.M., 1967. Interpretation of remote multispectral imagery of agricultural crops. *Research Bulletin of the Laboratory for Agricultural Remote Sensing*, 1(831), 1-36.
- Holm, R.G., Jackson, R.D., Yuan, B., Moran, M.S., Slater, P.N., Biggar, S.F., 1989. surface reflectance factor retrieval from thematic mapper data, *remote sensing of environment*, 27, 47-57.
- Holmström, H., Franson, J.S.E., 2003. Combining remotely sensed optical and radar data in k-nn estimation of forest variables. *For. Sci.*, 49, 409-418.
- Hongrui, R., Guangsheng, Z., 2014. Determination of green aboveground biomass in desert steppe using litter-soil-adjusted vegetation index. *European Journal of Remote Sensing*, 47, 611-625.
- Honkavaara, E., Ilves, R., Jaakkola, J., 2003. Practical results of GPS/ IMU/Camera-system calibration. *Proceedings of International Workshop: Theory, Technology and Realities of Inertial/GPS Sensor Orientation*, Castelldefels, Spain, 22.-23.9.2003, 10 pp. CD-ROM.
- Honkavaara, E., 2004. In-flight camera calibration for direct georeferencing. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 35 (Part B1), 166-171.
- Honkavaara, E., Markelin, L., Ilves, R., Savolainen, P., Vilhomaa, J., Ahokas, E., Jaakkola, J., Kaartinen, H., 2005. In-flight performance evaluation of digital photogrammetric sensors. *Proceedings of ISPRS Hannover Workshop*, 17-20 May 2005. 6 pp., on CD-ROM.
- Honkavaara, E., Jaakkola, J., Markelin, L., Peltoniemmi, J., Ahokas, E., Becker, S., 2006. Complete photogrammetric system calibration and evaluation in the Sjököulla test field - case study with DMC. *Proceedings del EuroCOW06*. 25-27 Enero, Castelldefels, España.
- Honkavaara, E., Markelin, L., 2007. Radiometric Performance of Digital Image Data Collection - A Comparison of ADS40/DMC/UltraCam and EmergeDSS, *Photogrammetric Week 2007*, (Fritsch, D., Ed.), Wichmann Verlag, Heidelberg, Germany, 117-129.
- Honkavaara, E., Peltoniemi, J., Ahokas, E., Kuittinen, R., Hyypä, J. Jaakkola, J., Kaartinen, H., Markelin, L., Nurminen, K., Suomalainen, J., 2008. A permanent test field for

- digital photogrammetric systems, *Photogrammetric Engineering & Remote Sensing*, In press.
- Honkavaara, E., Arbiol, R., Markelin, L., Martinez, L., Cramer, M., Bovet, S. y Veje, N., 2009. Digital airborne photogrammetry-A new tool for quantitative remote sensing?-A state-of-the-art review on radiometric aspects of digital photogrammetric images. *Remote Sensing*, 1(3), 577-605.
- Honkavaara, E., Saari, H., Kaivosoja, J., Pölönen, I., Hakala, T., Litkey, P., Mäkynen, J., Pesonen, L., 2013. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. *Remote Sens.*, 5, 5006–5039.
- Huang, Z., Turner, B.J., Dury, S.J., Wallis, I.R., Foley, W.J., 2004. Estimating foliage nitrogen concentration from HYMAP data using continuum removal analysis. *Remote Sensing of Environment*, 93, 18-29.
- Huete, A.R., Jackson, R. D., Post, D.F., 1988. Spectral response of a plant canopy with different soil backgrounds. *Remote Sensing of Environment*, 17, 37-53.
- Hunt, E.R., Hively, W.H., Fujikawa, S.J., Linden, D.S., Daughtry, C.S.T., McCarty, G.W., 2010. Acquisition of nir-green-blue digital photographs from unmanned aircraft for crop monitoring. *Remote Sensing*, 2, 290-305.
- Hyypä, J., Hyypä, H., Inkinena, M., Engdahla, M., Linkob, S., 2000. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. *For. Ecol. Manage.*, 128, 109-120.
- Immitzer, M., Atzberger, C., Koukal, T., 2012. Tree species classification with random forest using very high resolution 8-band WorldView-2 Satellite data. *Remote Sensing*, 4(9), 2661-2693.
- Jacquemoud, S., Ustin, S.L., Verdebout, J., Schmuck, G., Andreoli, G., Hosgood, B., 1996. Estimating leaf biochemistry using the PROSPECT leaf optical properties model. *Remote Sens. Environ.*, 56, 194-202.
- Jaakkola, A., Hyypä, J., Kukko, A., Yu, X., Kaartinen, H., Lehtomäki, M., Lin, Y., 2010. A low-cost multi-sensoral mobile mapping system and its feasibility for tree measurements. *ISPRS journal of Photogrammetry and Remote Sensing*, 65(6), 514-522.
- Jacobsen, K., 2003. Issues and Method for In-Flight and On-Orbit Calibration, Workshop on Radiometric and Geometric Calibration, Gulfport, 2003, on CD.

- Jacobsen, K., Cramer, M., Ladstädter, R., Ressler, C., Spreckels, V., 2010. DGPF project: Evaluation of digital photogrammetric camera systems - geometric performance. *Photogrammetrie – Fernerkundung – Geoinformation (PFG)*, 2, 83-97.
- Jacobsen, K. y Neumann, 2012. Property of the large format digital aerial camera DMC II. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XXXIX-B1, 2012 XXII ISPRS Congress, 25 August – 01 September 2012, Melbourne, Australia
- Jensen, J.R., 2000. *Remote sensing of the environment: An earth resource perspective*. Upper Saddle River, N.J: Prentice Hall.
- Jensen, J.R., 2005. *Introductory to Digital Image Processing: A remote sensing perspective* (3rd ed.). Upper Saddle River, NJ, USA, Prentice Hall, 526.
- Jensen, J.R., 2009. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. 2a Edição. São José dos Campos: Parênteses.
- Jin, Y.X., Yang, X.C., Qiu, J.J., Li, J.Y., Gao, T., Wu, Q., Zhao, F., Ma, H.L., Yu, H.D., Xu, B., 2014. Remote sensing-based biomass estimation and its spatio-temporal variations in temperate grassland northern China. *Remote Sensing*, 6, 1496-1513.
- Johnson, L., Herwitz, S., Dunagan, S., Lobitz, B., Sullivan, D., Slye, R., 2003. Collection of ultra-high spatial and spectral resolution image data over California vineyards with a small UAV. In *Int'l Symp. Rem. Sens. Environ.* 10-14 Nov., Honolulu, HI, 10-14.
- Karpouzli, E., Malthus, T., 2003. The empirical line method for the atmospheric correction of IKONOS imagery. *International Journal of Remote Sensing*, 24(5), 1143-1150.
- Kaufman, Y.J., Tanré, D., 1992. Atmospheric resistant vegetation index (ARVI) for EOS-MODIS. *IEEE. Transactions on Geoscience and Remote Sensing*, 30, 261-270.
- Keane, R., Burgan, R., 2001. Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. *International Journal of Wildland FIRE*, 10(3-4), 301-319.
- Keegan, H., Schleter, J., Hall, W., 1956. Spectrophotometric and colorimetric study of diseased and rust resisting cereal crops. *National Bureau of Standards Report*, 4591.
- Kokaly, R.F., Clark, R.N., 1999. Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression. *Remote Sensing of Environment*, 67, 267-287.
- Kokaly, R.F., Despain, D.G., Clark, R.N., Livo, K.E., 2003. Mapping vegetation in Yellowstone National Park using spectral feature analysis of AVIRIS data. *Remote Sens. Environ.*, 84, 437-456.

- Kokaly, R.F., Skidmore, A.K., 2015. Plant phenolics and absorption features in vegetation reflectance spectra near 1.66 μ m. *International Journal of Applied Earth Observation and Geoinformation*.
- Kooistra, L., Wanders, J., Epema, G.F., Leuven, R.S.E.W., Wehrens, R. y Buydens, L.M.C., 2003. The potential of field spectroscopy for the assessment of sediment properties in river floodplains. *Anal. Chim. Acta*, 484, 189-200.
- Kooistra, L., Suarez-Barranco, M.D., van Dobben, H., Schaepman, M.E., 2006. Regional Scale Monitoring of Vegetation Biomass in river Floodplains using Imaging Spectroscopy and Ecological Modeling. En: *Proceedings of the IEEE Geoscience and Remote Sensing Symposium*, Denver, CO, USA, 31 July 2006-4 August 2006, 124-127.
- Korpela, I., Heikkinen, V., Honkavaara, E., Rohrbach, F., Tokola, T., 2011. Variation and directional anisotropy of reflectance at the crown scale - Implications for tree species classification in digital aerial images. *Remote Sensing of Environment*, 115(8), 2062-2074.
- Labrecque, S., Fournier, R., Luther, J., Piercey, D., 2006. A comparison of four methods to map biomass from Landsat-TM and inventory data in western Newfoundland. *For. Ecol. Manage.*, 226, 129-144.
- Laliberte, A.S., Browning, D.M., Rango, A., 2012. A Comparison of three feature selection methods for object-based classification of sub-decimeter resolution UltraCam-L imagery. *International Journal of Applied Earth Observation and Geoinformation*, 15, 70-78.
- Lambers, K., Eisenbeiss, H., Sauerbier, M., Kupferschmidt, D., Gaisecker, T., Sotoodeh, S., et al., 2007. Combining photogrammetry and laser scanning for the recording and modelling of the Late Intermediate Period site of Pinchango Alto, Palpa, Peru. *J. Archaeol. Sci.*, 34(10), 1702-1712.
- Lass, L. W., Callihan, R.H., 1997. The effect of phenological stage on detectability of yellow hawkweed (*hieracium pratense*) and oxeye daisy (*chrysanthemum leucanthemum*) with remote multispectral digital imagery. *Weed Technology*, 248-256.
- Le Toan, T., Beaudoin, A., Riom, J., Guyon, D., 1992. Relating forest biomass to SAR data. *Geoscience and Remote Sensing, IEEE Transactions on*, 30(2), 403-411.
- Le Bris, A., Boldo, D., 2008. Extraction of land cover themes from aerial ortho-images in mountainous area using external information. *The Photogrammetric Record*, 23(124), 387-404.

- Leberl, F., Gruber, M., 2005. UltraCamD: Understanding some noteworthy capabilities. In: Fritsch (ed.), Proceedings of the 50th Photogrammetric Week 2005, Wichmann Verlag, 57-68.
- Lee, K.S., Cohen, W.B., Kennedy, R.E., Maieringer, T.K., Gower, S.T., 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sens. Environ.*, 91, 508-520.
- Lee, K.H., Ehsani, R., Schueller, J.K., 2007. Forward movement synchronization of two vehicles in parallel using a laser scanner. *Applied Engineering in Agriculture*, 23(6), 827-836.
- Lefsky, M.A., Cohen, W.B., Spies, T.A., 2001. An evaluation of alternate remote sensing products for forest inventory, monitoring, and mapping of Douglas-fir forests in western Oregon. *Canadian Journal of Forest Research*, 31(1), 78-87.
- Li, H., Liang, Y., Xu, Q., 2009. Support vector machines and its application in chemistry. *Chemom. Intell. Lab. Syst.*, 95, 188-198.
- Liang, 2004. *Cuantitative Remote Sensing of Land Surfaces*, Wiley-Interscience, Hoboken, New Jersey.
- Lim, K.S., Treitz, P.M., 2004. Estimation of above ground forest biomass from airborne discrete return laser scanner data using canopy-based quantile estimators. *Scandinavian Journal of Forest Research*, 19(6), 558-570.
- Liu, Y., Zha, Y., Gao, J., Ni S., 2004. Assessment of grassland degradation near Lake Qinhai, West China, using Landsat TM and in situ reflectance spectra data. *International Journal of Remote Sensing*, 25, 4177-4189.
- Liu, L.Y., Zhao, J.J., Guan, L.L., 2013. Tracking photosynthetic injury of Paraquat-treated crop using chlorophyll fluorescence from hyperspectral data. *European Journal of Remote Sensing*, 46, 459-473.
- López-Espinoza, D.M., 2014. Elaboración de un manual de operaciones para la captura de “firmas espectrales” en campo, validada en dos granjas experimentales. Tesis previa a la obtención del título de Ingeniero Agrónomo. Universidad de Cuenca facultad de ciencias agropecuarias, Cuenca, Ecuador.
- Lourenco, N.D., Lopes, J.A., Almeida, C.F., Sarraguca, M.C., Pinheiro, H.M., 2012. Bioreactor monitoring with Spectroscopy and chemometrics: A review. *Analytical and Bioanalytical Chemistry*, 404(4), 1211-1237.

- Lu, D., Mausel, P., Brondízio, E., Moran, E., 2004. Relationships between Forest Stand Parameters and Landsat TM Spectral Responses in the Brazilian Amazon Basin, *Forest Ecology and Management* 198(1–3), 149-167.
- Lu, D., Weng., Q., 2009. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28, 823-870.
- Lucio-Gutiérrez, J.R., 2012. Aplicación de métodos quimiométricos para la caracterización y control de calidad de plantas medicinales. PhD thesis, Universidad Autónoma de Barcelona.
- Macho-Aparicio, S., 2002. Metodologías analíticas basadas en espectroscopia de infrarrojo y calibración multivariante. Aplicación a la industria petroquímica. Tesis doctoral, Universitat Rovira I Virgili, departamento de Química Analítica Tarragona.
- Mäkelä, H., Pekkarinen, A., 2004. Estimation of forest stand volumes by Landsat TM imagery and stand-level field-inventory data. *For. Ecol. Manage.*, 9,(196), 245-255.
- Malthus, T.J., Madeira, A.C., 1993. High-resolution spectroradiometry - spectral reflectance of field bean-leaves infected by botrytis-fabae. *Remote Sensing Of Environment*, 45, 107-116.
- Mallinis, G., Koutsias, N., Makras, A., y Karteris, M., 2004. Forest parameters estimation in a european mediterranean landscape using remotely sensed data. *For. Sci.*, 50, 450-460.
- Marabel, M., Álvarez, F., 2013. Spectroscopic Determination of Aboveground Biomass in Grasslands Using Spectral Transformations, Support Vector Machine and Partial Least Squares Regression. *Sensors*, 13(8), 10027-10051.
- Marabel-García, M., Álvarez-Taboada, F., 2014. Estimación de biomasa en herbáceas a partir de datos hiperespectrales, regresión PLS y la transformación continuum removal. *Revista de Teledetección*, 42, 49-60.
- Marino, S., Alvino, A., 2014. Proximal sensing and vegetation indices for site-specific evaluation on an irrigated crop tomato. *European Journal of Remote Sensing*, 47, 271-283.
- Markelin, L., Ahokas, E., Honkavaara, E., Kukko, A., Peltoniemi, J., 2005. Radiometric quality comparison of UltraCamD and analog camera. In proceedings of ISPRS Hannover Workshop: High-Resolution Earth Imaging for Geospatial Information.
- Markelin, L., Ahokas, E., Honkavaara, E., Peltoniemi, J., Kukko, A., Hyypä, J. y Kuittinen, R., 2006. Portable reflectance targets and their use in radiometric evaluation and calibration of digital photogrammetric cameras, submitted to *ISPRS Journal of*

Photogrammetry and Remote Sensing, Special Issue on Digital Photogrammetric Cameras.

- Markelin, L., Honkavaara, E., Beisl, U., Korpela, I., 2010. Validation of the radiometric processing chain of the Leica ADS40 airborne photogrammetric sensor. – ISPRS TC VII Symposium – 100 Years ISPRS, IAPRS, XXXVIII. Vienna, Austria. (7A), 145-150.
- Markelin, L., 2013. Radiometric Calibration, Validation and Correction of Multispectral Photogrammetric Imagery. Dissertation. Publications of the Finnish Geodetic Institute, 148.
- Martelo-Vidal, M.J., 2014. Desarrollo de métodos rápidos basados en espectroscopía uvvis-nir para el análisis de vinos. Tesis, Universidad de Santiago de Compostela, departamento de química analítica, nutrición y bromatología, Lugo.
- Martens, H., Naes, T., 1989. Multivariate Calibration, Chichester: John Wiley and Sons, Great Britain.
- Martin, P., Zarco-Tejada, P., González, M., Berjon, A., 2007. Using hyperspectral remote sensing to map grape quality in 'tempranillo' vineyards affected by iron deficiency chlorosis. VITIS, 46, 7-14.
- Martínez, L., Arbiol, R., 2008. ICC experiences on DMC radiometric calibration. In the proceedings of the Calibration and Orientation workshop Workshop EuroCOW, 30 January - 1 February 2008, Castelldefels, Spain, 7p.
- Martínez, L., Pérez, F., Arbiol, R., Tardà, A., 2010. Radiometric characterisation of VNIR hyperspectral imaging system for accurate atmospheric correction. In the proceedings of 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 14-16 June 2010, Reykjavik, Iceland, 4p.
- Martínez, L., Pérez, F., Arbiol, R., Magarios, A., 2012. Development of NDVI WMS geoservice from reflectance DMC imagery at ICC. In the proceedings of the Calibration and Orientation workshop Workshop EuroCOW, 8-10 February 2012, Castelldefels, Spain, 5 p.
- McCarty, G.W., Reeves, J.B., III, Reeves, V.B., Follet, R.F., Kimble, J.M., 2002. Mid-infrared and near-infrared diffuse reflectance spectroscopy for soil carbon measurement. Soil Sci. Soc. Am., 66, 640-646.
- McRoberts, R.E., Nelson, M.D., Wendt, D.G., 2002. Stratified estimation of forest area using satellite imagery, inventory data, and the k-Nearest Neighbors technique. Remote Sens. Environ. 82, 457-468.

- Meeuwig, R.O., Miller, E.L., 1979. Estimating pinyon and juniper fuel and biomass from aerial photographs (Vol. 274). USDA Forest Service, Intermountain Forest and Range Experiment Station.
- Merchant, D.C., Schenk, A., Habib A., Yoon, T., 2004. USGS/OSU progress with digital camera in situ calibration methods, *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* vol. 35 (Part B2), 19-24.
- Microsoft Vexcel Ultracam XP/WA, 2011. Características. <http://www.microsoft.com/en-us/ultracam> (20-05-2015).
- Middleton, E.M., 1991. Solar zenith angle effects on vegetation indices in tallgrass prairie, *Remote Sensing of Environment*, 38, 45-62.
- Milton, E., 1987. Principles of field spectroscopy. *International Journal of Remote Sensing*, 8, 1807-1827.
- Moleele, N., Ringrose, S., Arnberg, W., Lunden, B., Vanderpost, C., 2001. Assessment of vegetation indexes useful for browse (forage) prediction in semi-arid rangeland. *International Journal of Remote Sensing*, 22, 741-756.
- Molina-Simbaña, P.X., 2016. Geografía del carbono en alta resolución en bosque tropical amazónico del Ecuador mediante sensores aerotransportados. Tesis (Doctoral), E.T.S.I. en Topografía, Geodesia y Cartografía (UPM).
- Mónaco, N., Rosa, M.J., Santa, V., Aufrán, V., Heguiabehere, A., 2015. Utilización de Estimadores para determinación de biomasa a Campo. *European Scientific Journal*, 11(33), 1857-7431.
- Montesinos, S., 2015. Aplicaciones operativas de los drones en Agriculturas de precisión. Lecciones aprendidas. Teledetección: Humedales y Espacios Protegidos. XVI Congreso de la Asociación Española de Teledetección, Sevilla 21-23 octubre 2015. Eds. J. Bustamante, R. Díaz-Delgado, D. Aragonés, I. Afán y D. García, 629-632.
- Moran, M.S., Maas, S.J., Pinter Jr.P.J., 1995. Combining remote sensing and modeling for estimating surface evaporation and biomass production. *Remote Sensing Reviews*, 12, 335-353.
- Moros, J., Garrigues, S., de la Guardia, M., 2010. Vibrational Spectroscopy provides a green tool for multi-component analysis. *Trac-Trends in Analytical Chemistry*, 29(7), 578-591.
- Mota, C., Alcaraz-López, C., Iglesias, M., Martínez-Ballesta, M.C., Carvajal, M., 2010. Investigación sobre la absorción de CO₂ por los cultivos más representativos de la

- Región de Murcia. Dpto. de nutrición vegetal, Consejo. Sup. Invest. Científicas., Murcia, España, 1-43.
- Mulligan, M., 2009. Integrated environmental modelling to characterize processes of land degradation and desertification for policy support. In: *Recent Advances in Remote Sensing and Geoinformation Processing for Land Degradation Assessment*, Roder A., Hill J. (Eds), 45-72.
- Murillo-Sandobal, P.J., Herrera-Rozo, F.A., Pierre-Díaz, J., 2014. Corrección radiométrica de una cámara multispectral para aplicaciones en caña de azúcar. XVI Simposio internacional Selper 2014, la geoinformación al servicio de la sociedad, Medellín Colombia, del 29 de Septiembre al 3 de Octubre.
- Mutanga, O., 2004. *Hyperspectral Remote Sensing of Tropical Grass Quality and Quantity*. International Training Centre (ITC); Enschede, The Netherlands.
- Mutanga, O., Skidmore, A.K., 2004. Narrow band vegetation indices overcome the saturation problem in biomass estimation. *Int. J. Remote Sens.*, 25, 3999-4014.
- Mutanga, O., Ismail, R., 2010. Variation in foliar water content and hyperspectral reflectance of *Pinus patula* trees infested by *Sirex noctilio*. *Southern Forests*, 72, 1-7.
- Mutanga, O., Adam, E., Cho, M.A., 2012. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. *International Journal of Applied Earth Observation and Geoinformation*, 18, 399-406.
- Myneni, R.B., Los, S.O., 1995. Potential gross primary productivity of terrestrial vegetation from 1982-1990. *Geophysical Research Letters*, 22, 2617-2620.
- Myneni, R.B., Maggion, S., Laquinta, J., Privette, J.L., Gobron, N., Pinty, B., Kimes, D.S., Verstraete, M.M., Williams, D.L., 1995. Optical remote sensing of vegetation: modeling, caveats, and algorithms. *Remote Sensing of Environment*, 51, 169-188.
- Myint, S.W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q., 2011. Per-pixel versus object-based classification of urban land cover extraction using high spatial resolution imagery. *En: Remote Sensing of Environment*, 115(5), 1145-1161.
- Naes, T., Isaksson, T., 1994. *NIR news*, 5, 13.
- Naesset, E., 1997. Estimating timber volume of forest stands using airborne laser scanner data. *Remote Sensing of Environment*, 61(2), 246-253.
- NAIP, 2013. NAIP Imagery. <http://www.fsa.usda.gov/index> (accessed 10 June, 2013).
- Nguyen, H.T., Lee, B.W., 2006. Assessment of rice leaf growth and nitrogen status by hyperspectral canopy reflectance and partial least square regression. *European Journal of Agronomy*, 24, 349-356.

- Nicolai, B.M., Beullens, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K.I., Lammertyn, J., 2007. Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest Biology and Technology*, 46(2), 99-118.
- Nitsch, B.B., Meyer, G.E., Mortensen, D.A., 1991. Visible near-infrared plant, soil and crop residue reflectivity for weed sensor design. *ASAE*, 91-3006. (ASAE, St. Joseph, MI, USA).
- Norris, K.H., Williams, P.C., 1984. Optimization of Mathematical Treatments of Raw Near-Infrared Signal in the Measurement of Protein in Hard Red Spring Wheat. I. Influence of Particle Size. *Cereal Chemistry*, 61, 158-165.
- Ota, T., Ogawa, M., Shimizu, K., Kajisa, T., Mizoue, N., Yoshida, S., Takao, G., Hirata, Y., Furuya, N., Sano, T., Sokh, H., Ma, V., Ito, E., Toriyama, J., Monda, Y., Saito, H., Kiyono, Y., Chann, S., Ket, N., 2015. Aboveground biomass estimation using structure from motion approach with aerial photographs in a seasonal tropical forest. *Forests*, 6, 3882-3898.
- Otero-Pastor, I., 1999. Paisaje Teledetección y SIG conceptos y aplicaciones. Editorial Fundación conde de valle de Salazar ISBN 84-86793-50-5.
- Paparoditis, N., Souchon, J.P., Martinoty, G., Pierrot-Deseilligny, M., 2006. High-end digital cameras and their impact on the automation and quality of the production workflow, *ISPRS Journal of Photogrammetry & Remote Sensing*, 60(6), 400-412.
- Pardos, J.A., 2010. Los ecosistemas forestales y el secuestro de carbono ante el calentamiento global (p.253). Madrid, España: Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria Ministerio de Ciencia e Innovación.
- Passini, R., Jacobsen, K., Day, D., 2012. Accuracy and Radiometric Study on Latest Generation Large Format Digital Frame Cameras, *JACIE 2012*, Fairfax, USA.
- Pax-Lenney, M., Woodcock, C.E., 1997. The effect of spatial resolution on the ability to monitor the status of agricultural lands. *Remote Sensing of Environment*, 61, 210-220.
- Paz, F., Reyes M., Medrano, E., 2011. Diseño de índices espectrales de la vegetación usando curvas iso-suelo. *Agrociencia*, 45, 121-134.
- Paz-Pellat, F., Pascual-Ramírez, F., Bolaños-González, M., 2012. Estimación de biomasa aérea en cultivos con sensores remotos. *Terra Latinoamericana*, Enero-Marzo, 17-28.
- Pelikka, P., 1998. Development of correction chain for multispectral airborne video camera data for natural resource assessment. *FENNIA*, 176, 1-110

- Peltoniemi, J., Kaasalainen, S., Näränen, J., Rautiainen, M., Stenberg, P., Smolander, H., Smolander, S., Voipio, P., 2005. BRDF measurement of understory vegetation in pine forests: dwarf shrubs, lichen and moss. *Remote Sensing of Environment*, 94 (3), 343-354.
- 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 Asociación Española de Teledetección (AET)*.
- Pérez-Aragües, F., Tardà, A., Alamús, R., Moré, G., Cea, C., Palà, V., Corbera, J., Pons, X., 2013. Intercalibración de sensores AISA y CASI. XV Congreso de la Asociación Española de Teledetección. INTA, Torrejón de Ardoz (Madrid). 22-24 octubre, 2013.
- Perko, R., 2005. Image Quality: Digital Pansharpening Versus Full Color Film. Manuscript submitted for publication. www.vexcel.com.
- Peña, M.A., 2010. Propiedades del primer sistema de teledetección hiperespectral chileno. *Revista de geografía Norte Grande*, 46, 159-163.
- Pinilla Ruiz, C., 1995. Elementos de teledetección espacial. Editorial Ra-Ma.
- Pordesimo, L.O., Edens, W.C., Sokhansanj, S., 2004. Distribution of aboveground biomass in corn stover. *Biomass and Bioenergy* 26(4), 337-343.
- Potdar, M.B., 1993. Sorghum yield modelling based on crop growth parameters determined from visible and near ir-channel NOAA AVHRR data. *International Journal of Remote Sensing*, 14, 895-905.
- Price, J.C., Bausch, W.C., 1995. Leaf area index estimates from visible and near infrared reflectance data. *Remote Sensing of Environment*, 52, 55-65.
- Pu, R., Ge, S., Kelly, N. M., Gong, P., 2003. Spectral absorption features as indicators of water status in coast live oak (*Quercus agrifolia*) leaves. *International Journal of Remote Sensing*, 24, 1799-1810
- Pucheta, E., Ferrero, E., Heil, L., Schneider, C., 2004. Modelos de regresión para la estimación de la biomasa aérea en un pastizal de montaña de Pampa de Achala (Cordoba, Argentina). *Agriscientia*, 21, 23-30.
- Quilter, M.C., Anderson, V.J., 2001. A proposed method for determining shrub utilization using (LA/LS) imagery. *Journal of Range Management*, 378-381.
- Ramoelo, A., Skidmore, A.K., Schlerf, M., Heitkönig, I.M.A., Mathieu, R., Cho, M.A., 2013. Savanna grass nitrogen to phosphorous ratio estimation using field spectroscopy and the potential for estimation with imaging spectroscopy. *International Journal of Applied Earth Observation and Geoinformation*, 23, 334-343.

- Rasmussen, M.S., 1992. Assessment of millet yields and production in northern Burkina-faso using integrated NDVI from the AVHRR. *International Journal of Remote Sensing*, 13, 3431-3442.
- Rao, Y.S., Deo, R., Nalini, J., Pillai, A.M., Muralikrishnan, S., Dadhwal, V. K., 2014. Quality assessment of TanDEM-X DEMs using airborne LiDAR, photogrammetry and ICESat elevation data. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1, 187-192.
- Raumonen, P., Kaasalainen, M., Åkerblom, M., Kaasalainen, S., Kaartinen, H., Vastaranta, M., Lewis, P., 2013. Fast automatic precision tree models from terrestrial laser scanner data. *Remote Sensing*, 5(2), 491-520.
- Raun, W.R., Solie, J.B., Johnson, G.V., Stone, M.L., Lukina, E.V., Thomason, W.E., Schepers, J.S., 1999. In-season prediction of potential grain yield in winter wheat using canopy reflectance. *Agronomy Journal*, 93(2), 131-138.
- Read, R.E., Graham, R.W., 2002. *Manual of air survey: primary data acquisition*. Whittles Publishing, Chaitness, Scotland, UK, 408p.
- Reese, G.A., Bayn, R.L., West, N.E., 1980. Evaluation of double-sampling estimators of subalpine herbage production. *Journal of Range Management*, 33, 300-306.
- Reese, H., Nilsson, M., Sandström, P., Olsson, H., 2002. Applications using estimates of forest parameters derived from satellite and forest inventory data. *Comput. Electron. Agr.*, 37, 37-55.
- Reese, H., Nilsson, M., Pahlén, T.G., Hagner, O., Joyce, S., Tingelöf, U., Egberth, M., Olsson, H., 2003. Countrywide estimates of forest variables using satellite data and field data from the National Forest Inventory. *Ambio*, 32, 542-54.
- Ren, H.R., Zhou, G.S., Zhang, X.S., 2011. Estimation of green aboveground biomass of desert steppe in Inner Mongolia based on red edge reflectance curve area method. *Biosystems Engineering*, 109, 385-395.
- Ren, H.R., Zhou, G.S., 2012. Estimating senesced biomass of desert steppe in Inner Mongolia using field spectrometric data. *Agricultural and Forest Meteorology*, 161, 66-71.
- Ren, H. y Zhou, G., 2014. Determination of green aboveground biomass in desert steppe using litter-soil-adjusted vegetation index. *European Journal of Remote Sensing*, 47, 611-625.
- Riaño, D., Vaughan, P., Chuvieco, E., Zarco-Tejada, P., Ustin, S., 2005. Estimation of fuel moisture content by inversion of radiative transfer models to simulate equivalent water thickness and dry matter content: Analysis at leaf and canopy level. *IEEE Transactions of Geoscience and Remote Sensing*, 43(4), 821-826.

- Richter, R., Schläpfer, D., 2011. Atmospheric / Topographic Correction for Airborne Imagery (ATCOR-4 User Guide, Version 6.0.2, August 2011). - DLR report DLR-IB 565-02/11, Wessling, Germany, 194p. Available from <http://www.rese.ch/download/>.
- Riesinger, I., 2007. Investigation on DMC (Digital Metric Camera) Auto-Calibration. Diploma thesis at Technical University Munich (TUM). Not published.
- Rinnan, A., Nørgaard, L., Berg, F.V.D., Thygesen, J., Bro, R., Engelsen, S.B., 2009. In Chapter 2, data pre-processing; infrared spectroscopy for food quality analysis and control; academic press: San Diego, 29-50.
- Roberts, D.A., Green, R.O., Adams, J.B., 1997. Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS. *Remote Sensing of Environment*, 62(3), 223-240.
- Royo-Abuín, J.M., 2007. Tutorial. Instituto de Economía y Geografía Madrid, Febrero. http://humanidades.cchs.csic.es/cchs/web_UAE/tutoriales/PDF/Regresion%20lineal%20simple_3.pdf (24-08-2016).
- Rollin, E.M., Milton, E.J., 1998. Processing of high spectral resolution reflectance data for the retrieval of canopy water content information. *Remote Sens. Environ.* 65, 86-92.
- Roman-Gonzalez, A., Vargas-Cuentas, N.I., 2013. Análisis de imágenes hiperespectrales. *Revista Ingeniería & Desarrollo.*, Año 9, 35, 14-17.
- Rosso, P.H., Klonus, S., Ehlers, M., Tschach, E., 2008. Comparative properties of four airborne sensors and their applicability to land surface interpretation. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(1B), 545-550.
- Rouse, J.W., Hass, R.H., Shell, J.A., Deering, D.W., 1974. Monitoring vegetation systems in the Great Plains with ERTS-1. In: *Third Earth Resources Technology Satellite Symposium*, NASA, Washington DC, 309-317.
- Ryan, R.E., Pagnutti, M., 2009. Enhanced Absolute and Relative Radiometric Calibration for Digital Aerial Cameras. *Photogrammetric Week 2009*, (Fritsch, D., Ed.), Wichmann Verlag, Heidelberg, Germany, 81-90.
- Sandau, R., Braunecker, B., Driescher, H., Eckardt, A., Hilbert, S., Hutton, J., Kirchhofer, W., Lithopoulos, E., Reulke, R., Wicki, S., 2000. Design principles of the LH Systems ADS40 airborne digital sensor. *International Archives of Photogrammetry and Remote Sensing*, 33(1B), 258-265.
- Sandau, R., 2010. *Digital airborne camera: introduction and technology*. Springer, 356p. ISBN: 978-1402088773.

- Santos-Pérez, L.J., 2006. Cámaras fotogramétricas aéreas digitales: ventajas e inconvenientes. Influencias en la ejecución de cartografía catastral. Dirección General de Catastro.
- Savitzky, A., Golay, M.J.E. 1964. Anal. Chem. 36, 1267.
- Scarabotti, D.S., Feldman, S. R., Refi, R., 2011. Evaluación de distintos métodos para estimar la biomasa aérea en macollas de *Spartina argentinensis parodi*. Pastos, 32, 69-79.
- Schino, G., Borfecchia, F., Dececco, L., Dibari, C., Iannetta, M., Maritini, S., Pedrotti F., 2003. Satellite estimate of grass biomass in a mountainous range in central Italy. Agroforestry Systems, 59, 157-162.
- Schlerf, M., Atzberger, C., Hill, J., 2005. Remote sensing of forest biophysical variables using HyMap imaging spectrometer data. Remote Sensing of Environment, 95, 177-194.
- Schmidt, K., Skidmore, A., 2003. Spectral discrimination of vegetation types in a coastal wetland. Remote Sensing of Environment, 85(1), 92-108.
- Schönermark, M., 2010. Status report about the evaluation of the radiometric properties of digital photogrammetric airborne cameras. Photogrammetrie – Fernerkundung – Geoinformation (PFG), 2, 131-139.
- Schott, J.R., 2007. Remote Sensing: the Image Chain Approach. Oxford University Press, New York, USA, 2nd ed., 688.
- Schowengerdt, R.A., 1997. Remote Sensing: Models and Methods for Image Processing, 2nd ed. New York: Academic.
- Scurlock, J.M., Hall, D.O., 1998. The global carbon sink: A grassland perspective. Global Change Biology, 4, 229-233.
- Scurlock, J.M.O., Johnson, K., Olson, R.J., 2002. Estimating net primary productivity from grassland biomass dynamics measurements, Global Change Biol., 8, 736-753.
- Secker, J., Staenz, K., Gauthier, R.P., Budkewitsch, P., 2001. Calibration of hyperspectral sensors in operational environments; Remote Sensing of Environments, 76(1), 81-82.
- Sellers, P.J., 1985. Canopy reflectance, photosynthesis, and transpiration. International Journal of Remote Sensing, 6, 1335-1372.
- Sepulcre-Cantó, G., Zarco-Tejada, P., Jiménez-Munoz, J., Sobrino, J., Soriano, M., Fereres, E. et al., 2007. Monitoring yield and fruit quality parameters in open-canopy tree crops under water stress. Implications for ASTER. Remote Sensing of Environment, 107(3), 455-470.
- Sepulcre-Cantó, G., Zarco-Tejada, P., Jiménez-Munoz, J., Sobrino, J., De Miguel, E., Villalobos, F., 2006. Detection of water stress in an olive orchard with thermal remote sensing imagery. Agricultural and Forest Meteorology, 136(1/2), 31-44.

- Sepulcre-Cantó, G., Zarco-Tejada, P.J., Sobrino, J.A., Jimenez-Munoz, J.C., Villalobos, E., 2005. Spatial variability of crop water stress in an olive grove with high-spatial thermal remote sensing imagery. In 5th European Conference on Precision Agriculture (5ECPA), Precision Agriculture '05 - J.V. Stafford (Ed.), Wageningen Academic., 267-272.
- Serrano, L., Filla, I., Peñuelas, J., 2000. Remote Sensing of Biomass and Yield of Winter Wheat. *Crop Sci.*, 40, 723-731.
- Shapiro, S., Wilk, M., 1965. An analysis of variance test for normality (complete samples). *Biometrika*, 52, 591-611.
- Skaloud, J., Cramer, M., 2010. Proceedings of the joint EuroSDR/ISPRS International Calibration and Orientation Workshop EuroCOW 2010 held from 10th to 12th February 2010 in Castelldefels, Spain. ISSN: 9789051797343.
- Smith, G.M., Curran, P.J., 1996. The signal-to-noise required for the estimation of foliar biochemical concentrations. *Int. J. Remote Sens.*, 17, 1031-1058.
- Smith, G.M., Milton, E.J., 1999. The use of the empirical line method to calibrate remotely sensed data to reflectance. *International Journal of Remote Sensing*, 20(13), 2653-2662.
- Sobrino, J.A., 2000. Teledetección Servicio de Publicaciones Universidad de Valencia, 467.
- Solberg, S., Brunner, A., Hanssen, K.H., Lange, H., Næsset, E., Rautiainen, M., Stenberg, P., 2009. Mapping LAI in a Norway spruce forest using airborne laser scanning. *Remote Sensing of environment*, 113(11), 2317-2327.
- Solomon, S., Qin, D., Manning, M., Alley, R.B., Berntsen, T., Bindoff, N.L., Chen, Z., Chidthaisong, A., Gregory, J.M., Hegerl, G.C., Heimann, M., Hewitson, B., Hoskins, B.J., Joos, F., Jouzel, J., Kattsov, V., Lohmann, U., Matsuno, T., Molina, M., Nicholls, N., Overpeck, J., Raga, G., Ramaswamy, V., Ren, J., Rusticucci, M., Somerville, R., Stocker, T.F., Whetton, P., Wood, R.A., Wratt, D., 2007. Technical Summary. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge y New York: Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor y H.L. Miller ed., 1-25.
- Stensaas, G.Y., Lee, G., Christopherson, J., 2007. The USGS Plan for Quality Assurance of Digital Aerial Imagery.
- Stimson, H.C., Breshears, D.D., Ustin, S.L., Kefauver S.C., 2005. Spectral sensing of foliar water conditions in two co-occurring conifer species: *Pinus edulis* and *Juniperus monosperma*. *Remote Sensing of Environment*, 96,108-118.

- Stone, C.H., Coops, N., 2004. Assessment and monitoring of damage from insects in Australian eucalypt forests and commercial plantations. *Aus J Entomol*, 43(3), 283-292.
- Sugiura, R., Noguchi, N., Ishii, K., 2005. Remote-sensing technology for vegetation monitoring using an unmanned helicopter. *Biosystems Engineering*, 90(4), 369-379.
- Sun, Y., Liu, X., Wu, Y., Liao, C., 2008. Identifying hyperspectral characters of wetland species using in situ data. *Int. Arch. Photogram Remote Sens. Sp.a Inf. Sci.*, 107, 459-465.
- Swain, K.C., Thomson, S.J., Jayasuriya, H.P.W., 2010. Adoption of an unmanned helicopter for low-altitude remote sensing to estimate yield and total biomass of a rice crop. *T ASABE*, 53, 21-27.
- Tao, Y., García, J.F., Sun, D., 2013b. Advances in wine ageing technologies for enhancing wine quality and accelerating wine ageing process. *Critical Reviews in Food Science and Nutrition*.
- Thenkabail, P.S., Gumma, M.K., Teluguntla, P.G., Ilyas, M., 2014. Hyperspectral remote sensing of vegetation and agricultural crops *Photogramm. Eng. Remote Sensing*. 80(4), 697-709,
- Temmerman, S., Bouma, J.T., van de Koppel, D., van der Wal, M.B., Vries, H., 2007. Vegetation causes channel erosion in a tidal landscape. *Geology*, 35, 631–634.
- Tomppo, E., 1993. Multi-Source national forest inventory of Finland. In: *Proceedings of Ilvessalo Symposium of National Forest Inventories*, Ed. A. Nyysönen, S. Posso, y J. Rautal, (pp. 53-61). Research papers 444, Helsinki Finland: The Finish Forest Research Institute.
- Tomppo, E., Goulding, C., Katila, M., 1999. Adapting Finnish multi-source inventory techniques to the New Zealand preharvest inventory. *Scand. J. Forest Res.* 14, 182-192.
- Tomppo, E., Nilsson, M., Rosengren M., Aalto, P., Kennedy, P., 2002. Simultaneous use of Landsat-TM and IRS-1C WiFS data in estimating large area stem volume and above ground biomass. *For. Ecol. Manage.* 128, 109-120.
- Tucker, C.J., 1979. Red and photographics infrared linear combination for monitoring vegetation. *Remote Sensing of Environment*, 8, 127-150.
- Tucker, C.J., 1980. Remote sensing of leaf water content in the near infrared. *Remote Sensing of Environment*, 10, 23-32.
- Tucker, C.J., Holben, B.N., Elgin, J.H., McMurtrey, J.E., 1981. Remote sensing of total dry matter accumulation on winter wheat. *Remote Sensing of Environment*, 11, 171-189.

- Thulin, S.M., Hill, M.J., Held, A.H., Jones, S., Woodgate, P., 2012. Hyperspectral Determination of Feed Quality Constituents in Temperate Pastures: Effect of Processing Methods on Predictive Relationships from Partial Least Squares Regression. *International Journal of Applied Earth Observation and Geoinformation*, 19, 322-334.
- Udelhoven, T., Delfosse, P., Bossung, C., Ronellenfitch, F., Mayer, F., Schlerf, M., Machwitz, M., Hoffmann, L., 2013. Retrieving the bioenergy potential from maize crops using hyperspectral remote sensing. *Remote Sens.*, 5, 254-273.
- Ultracam, 2015. <http://www.microsoft.com/en-us/ultracam/default.aspx> (10 03 2016)
- USGS, 2013. Digital Aerial Quality Assurance. http://calval.cr.usgs.gov/pastactivities/digaerial/digital_qa/ (10-07-2016).
- Ustin, S.L., Roberts, D.A., Pinzon, J., Jacquemoud, S., Gardner, M., Scheer, G. et al., 1998. Estimating canopy water content of chaparral shrubs using optical methods. *Remote Sensing of Environment*, 65(3), 280-291.
- Underwood, E., Ustin, S., DiPietro, D., 2003. Mapping nonnative plants using hyperspectral imagery. *Remote Sensing of Environment*, 86, 150-161.
- Vaglio-Laurin, G., Chen, Q., Lindsell, J.A., Coomes, D.A., Frate, F.D., Guerriero, L., Pirotti, F., Valentini, R., 2014. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. *ISPRS J. Photogramm. Remote Sens.*, 89, 49–58.
- Valdés-Calviño, D., 2005. Estudio de la influencia de parámetros físicos en la construcción de modelos de calibración en la Espectroscopia en el Infrarrojo Cercano. Tesis doctoral, Universidad Autónoma de Barcelona, Departamento de Química.
- Valdés, E., Vilanova, M., Sabio, E., Benalte, M.J., 2011. Clarifying agents effect on the nitrogen composition in must and wine during fermentation. *Food Chemistry*, 125(2), 430-437.
- Vapnik, V., 1995. *The Nature of Statistical Learning Theory*. Springer; New York, NY, USA.
- Vapnik, V., Golowich, S., Smola, A., 1997. Support vector method for function approximation, regression estimation, and signal processing. *Advances in Neural Information Processing Systems*, 9.
- Vargas-Patiño, G.E., 2011. Predicción del análisis SARA de fondos de vacío colombianos utilizando espectroscopía foto-acústica en el infrarrojo medio y métodos quimiométricos. Trabajo de grado, Universidad de Santander, facultad de ciencias, escuela de química, Bucaramanga.

- Vasques, G.M., Grunwald, S., Sickman, J.O., 2008. Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra. *Geoderma*, 146, 14-25.
- Verboven, S., Hubert M., Goos, P., 2012. Robust preprocessing and model selection for spectral data. *J. Chemom.*, 26, 282-289.
- Verstraete, M.M., 1986. Defining desertification: a review climatic change, 9, 5-18.
- Vila, H., Pérez Peña, J., García, M., Vallone, R., Mastrantonio, L., Olmedo, G., Rodríguez Plaza, L., y Salcedo, C., 2007. Estimación de la biomasa en viñedos mediante imágenes satelitales aéreas de Mendoza, Argentina. En: *Actas del Congreso Internacional de la AET. "Teledetección hacia un mejor entendimiento de la dinámica global y regional"*, Ed.: Rivas, R Grisotto, y A. Sacido, 51-58.
- Wallerman, J., Joyce, S., Vencatasawmy, C.P., y Olsson, H., 2002. Prediction of forest stem volume using kriging adapted to detected edges. *Can. J. Forest Res.* 32, 509-518.
- Wamunyima, S., 2005. Estimating fresh grass biomass at landscape level using hyperspectral remote sensing. Thesis.
- Wang, C., Price, K.P., Van der Merwe, D., An, N., Wang, H., 2014. Modeling above-ground biomass in tallgrass prairie using ultra-high spatial resolution sUAS imagery. *Photogrammetric Engineering & Remote Sensing*, 80(12), 1151-1159.
- Wang, C., Myint, S. W., Price, K. P., Wang, H., An, N., 2015. A simplified empirical line calibration method for sUAS-based remote sensing. In *Imaging and Geospatial Technology Forum, IGTF 2015 - ASPRS Annual Conference and co-located JACIE Workshop*. American Society for Photogrammetry and Remote Sensing, 219-229.
- Wang, J., Wang, T., Skidmore, A.K., Shi, T. y Wu, G., 2015. Evaluating Different Methods for Grass Nutrient Estimation from Canopy Hyperspectral Reflectance. *Remote Sensing*, 7, 5901-5917.
- Waser, L.T., Klonus, S., Ehlers, M., Khler, M., Jung, A., 2010. Potential of digital sensors for land cover and tree species classifications - a case study in the framework of the DGPF-project. *Photogrammetrie - Fernerkundung - Geoinformation (PFG)*, 2, 141-156.
- Weckler, P.R., Solie, J.B., Stone, M.L., Jayasekara, R., Washmon, C.N., 2002. Airborne collection of ndvi data on winter wheat in oklahoma. Paper No. 021081. *ASAE Annual International Meeting*, at Chicago, IL.
- Wessels, S.D., Prince, S.D., Zambatis, N., Macfadyen, S., Frost, P.E., Van Zyl, D., 2006. Relationship between herbaceous biomass and 1-km² Advanced Very High Resolution

- Radiometer (AVHRR) NDVI in Kruger National Park, South Africa. *International Journal of Remote Sensing*, 27, 951-973.
- Wiegand, C.L., Richardson, A.J., Kanemasu, E.T., 1979. Leaf area index estimates for wheat from landsat and their implications for evapotranspiration and crop modeling. *Agronomy Journal* 74, 677-683.
- Williams, P.C., Norris, K.H., 1987. *Near-Infrared Technology in the Agricultural and Food Industries*. St. Paul, MN, USA: American Association of Cereal Chemists, 143-167.
- Wise, B., Gallagher, N., Bro, R., Shaver, J., Windig, W., Koch, R., 2006. *Chemometrics Tutorial for PLS_Toolbox and Solo*. ISBN: 0-9761184-1-6.
- Wu, S., 1987. Potential application of multipolarization SAR for pine-plantation biomass estimation. *Geoscience and Remote Sensing, IEEE Transactions on*, 3, 403-409.
- Wulder, M.A., White, J.C., Coggins, S., Ortlepp, S.M., Coops, N.C., Heath, J., Mora, B., 2012. Digital high spatial resolution aerial imagery to support forest health monitoring: the mountain pin beetle context. *Journal of Applied Remote Sensing*, 6(1) 1-10.
- Xia, J.Z., Liu, S.G., Liang, S.L., Chen, Y., Xu, W.F., Yuan, W.P., 2014. Spatio-temporal patterns and climate variables controlling of biomass carbon stock of global grassland ecosystems from 1982 to 2006. *Remote Sensing*, 6, 1783-1802.
- Yang, C., Anderson, L.G., 1996. Determining within-field management zones for grain sorghum using aerial videography. Paper read at 26th International Symposium on Remote Sensing of Environment, at Vancouver, BC, Canada.
- Yuste-Martín, R., Vargas-Velasco, N., Moya-Hernández, J., 2013. Teledetección ambiental de alta resolución mediante aplicación de vehículos aéreos no tripulados. *Sociedad española de ciencias forestales*, 1-22.
- Zarco-Tejada, P., Miller, J., Haboudane, D., Tremblay, N., Apostol, S., 2004. Detection of chlorophyll fluorescence in vegetation from airborne hyperspectral CASI imagery in the red edge spectral region. In 2003 International Geoscience and Remote Sensing Symposium, IGARSS'03, Toulouse. France, 598-600.
- Zarco-Tejada, P., Berjon, A., López-Lozano, R., Miller, J., Martin, P., Cachorro, V., et al., 2005. Assessing vineyard condition with hyperspectral indices: leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sensing of Environment*, 99, 271-287.
- Zawadzki, J., Cieszewski, C.J., Zasada, M., Lowe, R.C., 2005. Applying geostatistics for investigations of forest ecosystems using remote sensing imagery. *Silva Fenn.* 17(39), 599-617.

Zebedin, L., Klaus, A., Gruber-Geymayer, B., Karner, K., 2006. Towards 3D map generation from digital aerial images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60, 413-427.

Zeitler, W., Dörstel, C., Jacobsen, K., 2002. Geometric Calibration of the DMC: Method and Results. In : *IntArchPhRs, Com. I, Denver (USA), Vol. XXXIV Part 3b*, 324-333.

Zhao, H., Yan, L., Gou, Z., Zhang, L., 2006. The characteristic analyses of images from the UAV remote sensing system. In *2006 IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2006, Denver, CO.*, 3349-3351.

Zheng, D., Rademacher, J., Chen, J., Crow, T., Bresee, M., Le Moine, J., Ryu, S.R., 2004. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. *Remote Sens. Environ.* 93, 402- 411.

ANEXOS I

MÉTODO ESTADÍSTICO SVM

A continuación se muestran en este apartado las tablas estimadas tanto para los datos de la media como los datos de la mediana usando el método estadístico SVM. $R^2 = g/m^2$, C= Constante, SVS = define el vector soporte calculado.

SVM-MEDIANAS

DATOS DE LA ZONA VNIR

Tabla 1. Malla de los diferentes “C” en la variable PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PV SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
19	0.001	0.800	0.845	5.562	4.915	0.044	0.647
20	0.005	0.819	0.854	5.288	4.754	0.035	0.534
20	0.01	0.809	0.860	5.438	4.666	0.051	0.772
21	0.05	0.819	0.881	5.295	4.333	0.062	0.962
21	0.05	0.819	0.881	5.295	4.333	0.062	0.962
21	0.09	0.827	0.893	5.178	4.110	0.067	1.068
21	0.10	0.831	0.896	5.113	4.071	0.065	1.042
21	0.15	0.845	0.904	4.903	3.93	0.059	0.973
21	0.16	0.846	0.905	4.895	3.905	0.060	0.989
21	0.17	0.845	0.906	4.902	3.88	0.061	1.022
21	0.18	0.844	0.908	4.913	3.855	0.063	1.058
21	0.19	0.844	0.909	4.921	3.830	0.065	1.090
21	0.20	0.843	0.910	4.936	3.805	0.067	1.131
21	0.21	0.842	0.911	4.952	3.779	0.070	1.172
21	0.30	0.829	0.923	5.137	3.517	0.094	1.620
18	0.50	0.828	0.941	5.177	3.036	0.113	2.141
21	1	0.850	0.962	4.853	2.420	0.113	2.433
19	5	0.848	0.958	5.054	2.802	0.110	2.252
19	10	0.848	0.958	5.054	2.802	0.110	2.252
19	50	0.848	0.958	5.054	2.802	0.110	2.252
19	100	0.848	0.958	5.054	2.802	0.110	2.252
19	500	0.848	0.958	5.054	2.802	0.110	2.252

Tabla 2. Malla de los diferentes “C” en la variable PT en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PT SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
18	0.001	0.646	0.708	9.164	8.388	0.062	0.775
20	0.005	0.648	0.729	9.153	8.044	0.080	1.109
20	0.01	0.637	0.750	9.317	7.737	0.113	1.580
20	0.05	0.660	0.797	9.012	7.032	0.137	1.979

22	0.09	0.678	0.806	8.768	6.820	0.128	1.948
21	0.1	0.682	0.808	8.709	6.784	0.126	1.925
21	0.11	0.684	0.810	8.691	6.748	0.126	1.942
21	0.2	0.667	0.823	8.941	6.527	0.156	2.414
21	0.5	0.636	0.856	9.347	5.977	0.220	3.370
20	1.00	0.604	0.891	9.775	5.422	0.287	4.353
20	5	0.513	0.938	11.690	4.027	0.425	7.664
20	10	0.513	0.938	11.690	4.026	0.425	7.664
20	50	0.513	0.938	11.690	4.027	0.425	7.664
20	100	0.513	0.938	11.690	4.026	0.425	7.664
20	500	0.513	0.938	11.690	4.026	0.425	7.664

Tabla 3. Malla de los diferentes “C” en la variable %PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R² lo más elevado posible. (Gama = 1, Epsilon = 0,1)

%PV SVs	C	R ²		RMSE		Resta R ²	Resta RMSE
		Validación	Calibración	Validación	Calibración		
24	0.001	0.579	0.640	8.834	8.167	0.061	0.667
22	0.005	0.643	0.691	8.131	7.607	0.048	0.524
22	0.01	0.658	0.724	7.940	7.157	0.066	0.783
25	0.04	0.681	0.790	7.663	6.247	0.108	1.415
25	0.05	0.695	0.794	7.493	6.168	0.099	1.325
25	0.06	0.700	0.797	7.438	6.119	0.098	1.319
25	0.07	0.699	0.800	7.456	6.081	0.102	1.375
25	0.09	0.691	0.806	7.551	5.995	0.114	1.555
26	0.1	0.690	0.808	7.575	5.953	0.119	1.622
26	0.11	0.686	0.811	7.625	5.911	0.125	1.714
26	0.2	0.661	0.834	7.964	5.556	0.173	2.408
26	0.4	0.677	0.870	7.802	4.931	0.193	2.871
26	0.5	0.694	0.882	7.587	4.684	0.188	2.903
25	0.6	0.709	0.894	7.387	4.437	0.185	2.949
25	0.61	0.711	0.895	7.363	4.418	0.185	2.946
25	0.62	0.712	0.896	7.352	4.404	0.184	2.948
25	0.65	0.716	0.899	7.298	4.350	0.183	2.948
25	0.689	0.719	0.902	7.242	4.276	0.183	2.966
25	0.69	0.720	0.902	7.240	4.279	0.182	2.961
25	0.691	0.720	0.902	7.240	4.277	0.182	2.963
25	0.692	0.719	0.897	7.241	4.374	0.178	2.867
25	0.695	0.720	0.898	7.235	4.369	0.178	2.865
25	0.7	0.720	0.903	7.229	4.261	0.183	2.968
25	0.9	0.727	0.917	7.128	3.961	0.190	3.167
25	1	0.728	0.923	7.115	3.822	0.195	3.293
21	5	0.756	0.962	6.747	2.755	0.206	3.992
21	10	0.756	0.959	6.747	2.868	0.203	3.879
21	50	0.756	0.962	6.747	2.755	0.206	3.992
21	100	0.756	0.962	6.747	2.758	0.206	3.989
21	500	0.756	0.962	6.747	2.758	0.206	3.989

DATOS DE LA ZONA VNIR + SWIR 1

Tabla4. Malla de los diferentes “C” en la variable PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R² lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PV SVs	C	R ²		RMSE		Resta R ²	Resta RMSE
		Validación	Calibración	Validación	Calibración		
18	0.001	0.839	0.882	4.983	4.310	0.042	0.673
21	0.005	0.885	0.917	4.211	3.595	0.032	0.617

20	0.01	0.885	0.928	4.222	3.341	0.043	0.880
20	0.05	0.895	0.953	4.027	2.723	0.057	1.304
20	0.09	0.898	0.957	3.970	2.586	0.059	1.384
20	0.1	0.900	0.958	3.933	2.566	0.058	1.367
21	0.16	0.906	0.960	3.824	2.492	0.055	1.332
21	0.17	0.906	0.961	3.813	2.482	0.054	1.331
21	0.18	0.906	0.961	3.811	2.473	0.055	1.338
21	0.19	0.906	0.961	3.830	2.463	0.056	1.367
21	0.2	0.905	0.962	3.851	2.454	0.057	1.397
21	0.21	0.903	0.962	3.876	2.444	0.059	1.432
21	0.2	0.905	0.962	3.851	2.454	0.057	1.397
20	0.3	0.893	0.964	4.074	2.358	0.071	1.716
19	0.4	0.886	0.967	4.212	2.267	0.081	1.945
19	0.5	0.876	0.969	4.396	2.185	0.093	2.211
19	1	0.865	0.972	4.579	2.134	0.107	2.445
19	5	0.865	0.972	4.578	2.134	0.107	2.444
19	10	0.865	0.972	4.578	2.134	0.107	2.444
19	50	0.865	0.972	4.578	2.134	0.107	2.444
19	100	0.865	0.972	4.578	2.134	0.107	2.444
19	500	0.865	0.972	4.578	2.134	0.107	2.444

Tabla 5. Malla de los diferentes “C” en la variable PT en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R² lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PT SVs	C	R ²		RMSE		Resta R ²	Resta RMSE
		Validación	Calibración	Validación	Calibración		
18	0.001	0.673	0.739	8.828	7.959	0.066	0.868
18	0.005	0.689	0.797	8.618	6.990	0.108	1.628
19	0.01	0.721	0.828	8.139	6.425	0.107	1.714
18	0.019	0.740	0.846	7.860	6.121	0.107	1.739
17	0.02	0.738	0.847	7.878	6.107	0.108	1.771
18	0.03	0.729	0.852	8.017	5.976	0.122	2.042
17	0.04	0.723	0.859	8.138	5.841	0.136	2.298
18	0.05	0.725	0.861	8.113	5.785	0.137	2.328
18	0.06	0.728	0.866	8.112	5.638	0.138	2.474
21	0.07	0.728	0.867	8.119	5.608	0.139	2.512
21	0.08	0.723	0.869	8.205	5.584	0.145	2.621
21	0.1	0.715	0.871	8.339	5.538	0.155	2.802
23	0.5	0.643	0.899	9.447	4.909	0.257	4.538
22	1	0.569	0.910	10.540	4.722	0.341	5.818
22	5	0.403	0.964	12.986	3.062	0.562	9.924
22	10	0.403	0.964	12.986	3.062	0.562	9.924
22	50	0.403	0.964	12.986	3.062	0.562	9.924
22	100	0.403	0.964	12.986	3.062	0.562	9.924
22	500	0.403	0.964	12.986	3.062	0.562	9.924

Tabla 6. Malla de los diferentes “C” en la variable %PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R² lo más elevado posible. (Gama = 1, Epsilon = 0,1)

%PV	R ²	RMSE
-----	----------------	------

SVs	C	Validación	Calibración	Validación	Calibración	Resta R ²	Resta RMSE
21	0.001	0.635	0.676	8.221	7.756	0.042	0.465
20	0.002	0.629	0.710	8.273	7.314	0.081	0.960
21	0.005	0.622	0.738	8.363	6.967	0.116	1.396
24	0.01	0.628	0.783	8.282	6.366	0.155	1.915
24	0.05	0.613	0.824	8.569	5.73	0.211	2.84
25	0.1	0.612	0.836	8.634	5.526	0.225	3.108
26	0.5	0.579	0.922	9.226	3.976	0.344	5.25
25	1	0.619	0.951	8.777	3.124	0.332	5.653
26	5	0.634	0.958	8.477	2.983	0.325	5.494
26	10	0.634	0.958	8.477	2.983	0.325	5.494
26	50	0.634	0.958	8.477	2.983	0.325	5.494
26	100	0.634	0.958	8.477	2.983	0.325	5.494
26	500	0.634	0.958	8.477	2.983	0.325	5.494

DATOS DE LA ZONA VNIR + SWIR 1 + SWIR 2

Tabla 7. Malla de los diferentes “C” en la variable PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R² lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PV SVs	C	R ²		RMSE		Resta R ²	Resta RMSE
		Validación	Calibración	Validación	Calibración		
19	0.001	0.84	0.882	4.971	4.3	0.042	0.671
22	0.005	0.894	0.921	4.039	3.5	0.027	0.54
20	0.01	0.894	0.935	4.043	3.161	0.041	0.883
20	0.05	0.905	0.958	3.844	2.574	0.053	1.269
20	0.09	0.9128	0.9616	3.6981	2.4716	0.0488	1.2265
19	0.1	0.9160	0.9620	3.6430	2.4500	0.0470	1.1930
19	0.11	0.9169	0.9630	3.6220	2.4229	0.0461	1.1991
19	0.12	0.9167	0.9637	3.6283	2.3975	0.0470	1.2308
18	0.2	0.9101	0.9666	3.7780	2.2924	0.0565	1.4857
20	0.5	0.881	0.971	4.339	2.15	0.089	2.189
18	1	0.87	0.973	4.57	2.043	0.104	2.527
18	5	0.87	0.973	4.57	2.043	0.104	2.527
18	10	0.87	0.973	4.57	2.043	0.104	2.527
18	50	0.87	0.973	4.57	2.043	0.104	2.527
18	100	0.87	0.973	4.57	2.043	0.104	2.527
18	500	0.87	0.973	4.57	2.043	0.104	2.527

Tabla 8. Malla de los diferentes “C” en la variable PT en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R² lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PT SVs	C	R ²		RMSE		Resta R ²	Resta RMSE
		Validación	Calibración	Validación	Calibración		
18	0.001	0.673	0.738	8.825	7.974	0.065	0.851
18	0.005	0.68	0.8	8.746	6.937	0.121	1.809
19	0.009	0.707	0.829	8.349	6.414	0.122	1.936
19	0.01	0.714	0.830	8.251	6.400	0.116	1.851
18	0.014	0.721	0.841	8.154	6.188	0.120	1.966
18	0.015	0.722	0.843	8.146	6.123	0.122	2.023

18	0.02	0.724	0.851	8.102	5.991	0.127	2.111
19	0.05	0.712	0.864	8.307	5.757	0.151	2.55
20	0.1	0.681	0.874	8.888	5.462	0.193	3.426
23	0.5	0.586	0.906	10.524	4.778	0.32	5.746
23	1	0.487	0.924	12.244	4.298	0.437	7.946
23	5	0.401	0.954	13.931	3.307	0.553	10.625
23	10	0.401	0.954	13.931	3.307	0.553	10.625
23	50	0.401	0.954	13.931	3.307	0.553	10.625
23	100	0.401	0.954	13.931	3.307	0.553	10.625
23	500	0.401	0.954	13.931	3.307	0.553	10.625

Tabla 9. Malla de los diferentes “C” en la variable %PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

%PV SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
20	0.001	0.637	0.693	8.179	7.529	0.056	0.65
21	0.005	0.615	0.749	8.446	6.818	0.133	1.628
24	0.01	0.641	0.781	8.15	6.384	0.14	1.766
26	0.02	0.655	0.800	7.991	6.084	0.145	1.908
25	0.03	0.633	0.813	8.268	5.893	0.180	2.375
25	0.05	0.64	0.831	8.246	5.596	0.191	2.649
27	0.1	0.63	0.852	8.461	5.259	0.222	3.202
26	0.5	0.566	0.922	9.428	3.909	0.356	5.519
26	1	0.536	0.948	9.866	3.199	0.412	6.667
24	5	0.513	0.961	9.972	2.951	0.447	7.02
24	10	0.513	0.961	9.972	2.951	0.447	7.02
24	50	0.513	0.961	9.972	2.951	0.447	7.02
24	100	0.513	0.961	9.972	2.951	0.447	7.02
24	500	0.513	0.961	9.972	2.951	0.447	7.02

SVM-MEDIANAS

DATOS DE LA ZONA VNIR

Tabla 10. Malla de los diferentes “C” en la variable PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PV SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
21	0.001	0.790	0.841	5.690	4.962	0.050	0.728
21	0.005	0.812	0.849	5.310	4.829	0.038	0.481
21	0.01	0.809	0.854	5.429	4.756	0.045	0.673
21	0.05	0.810	0.877	5.422	4.438	0.067	0.984
21	0.1	0.817	0.891	5.318	4.175	0.073	1.143
19	0.4	0.833	0.929	5.095	3.370	0.097	1.724
19	0.5	0.838	0.935	5.011	3.209	0.097	1.801
19	0.57	0.841	0.939	4.977	3.103	0.098	1.873
19	0.58	0.840	0.939	4.986	3.094	0.099	1.893
20	0.581	0.842	0.940	4.960	3.094	0.098	1.866
20	0.582	0.841	0.939	4.969	3.085	0.098	1.883
20	0.587	0.841	0.940	4.975	3.088	0.100	1.887
20	0.588	0.840	0.940	4.987	3.081	0.100	1.906
20	0.59	0.841	0.940	4.974	3.079	0.099	1.895
20	0.591	0.841	0.940	4.976	3.076	0.099	1.899

20	0.6	0.841	0.940	4.976	3.068	0.100	1.909
20	0.7	0.837	0.944	5.036	2.951	0.107	2.085
20	1	0.829	0.956	5.171	2.619	0.126	2.552
20	5	0.830	0.950	5.372	2.992	0.120	2.380
20	10	0.830	0.950	5.372	2.992	0.120	2.380
20	50	0.830	0.950	5.372	2.992	0.120	2.380
20	100	0.830	0.950	5.372	2.992	0.120	2.380
20	500	0.830	0.950	5.372	2.994	0.120	2.378

Tabla 11. Malla de los diferentes “C” en la variable PT en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PT SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
18	0.001	0.644	0.705	9.202	8.433	0.061	0.769
18	0.005	0.653	0.725	9.091	8.095	0.073	0.996
19	0.01	0.651	0.745	9.112	7.805	0.094	1.307
20	0.05	0.661	0.792	9.013	7.089	0.131	1.924
21	0.08	0.671	0.801	8.880	6.900	0.130	1.980
21	0.09	0.672	0.803	8.867	6.860	0.131	2.008
21	0.1	0.672	0.805	8.862	6.820	0.133	2.042
21	0.11	0.671	0.807	8.879	6.783	0.136	2.096
21	0.2	0.637	0.822	9.374	6.543	0.186	2.831
21	0.5	0.574	0.855	10.249	6.021	0.281	4.228
21	1	0.523	0.887	10.962	5.471	0.363	5.491
21	5	0.473	0.931	12.299	4.234	0.458	8.065
21	10	0.473	0.931	12.300	4.234	0.458	8.066
21	50	0.473	0.931	12.300	4.234	0.458	8.065
21	100	0.473	0.931	12.300	4.234	0.458	8.066
21	500	0.473	0.931	12.300	4.234	0.458	8.066

Tabla 12. Malla de los diferentes “C” en la variable %PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

%PV SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
23	0.001	0.574	0.637	8.889	8.244	0.063	0.645
23	0.005	0.636	0.683	8.209	7.713	0.047	0.496
23	0.01	0.655	0.721	7.980	7.184	0.066	0.796
25	0.04	0.691	0.788	7.552	6.277	0.097	1.275
25	0.05	0.711	0.791	7.294	6.228	0.080	1.067
25	0.06	0.723	0.795	7.148	6.160	0.072	0.988
25	0.07	0.724	0.798	7.134	6.115	0.074	1.019
25	0.08	0.722	0.800	7.159	6.075	0.079	1.084
26	0.1	0.716	0.806	7.227	5.991	0.089	1.236
26	0.5	0.700	0.874	7.502	4.851	0.174	2.651
24	1	0.697	0.911	7.533	4.095	0.214	3.439
22	5	0.684	0.963	7.701	2.818	0.280	4.883
22	10	0.681	0.955	7.943	2.938	0.274	5.005
22	50	0.684	0.963	7.701	2.818	0.280	4.883
22	100	0.684	0.963	7.701	2.814	0.280	4.887
22	500	0.684	0.963	7.701	2.818	0.280	4.883

DATOS DE LA ZONA VNIR + SWIR 1

Tabla 13. Malla de los diferentes “C” en la variable PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PV	SVS	C	R ²		RMSE		Resta R ²	Resta RMSE
			Validación	Calibración	Validación	Calibración		
19	0.001	0.850	0.879	4.810	4.326	0.029	0.484	
18	0.005	0.891	0.915	4.106	3.626	0.024	0.480	
18	0.01	0.890	0.929	4.119	3.307	0.039	0.812	
18	0.05	0.897	0.958	3.993	2.564	0.061	1.430	
17	0.1	0.904	0.962	3.859	2.436	0.058	1.423	
17	0.14	0.909	0.964	3.759	2.363	0.055	1.396	
17	0.19	0.908	0.966	3.791	2.311	0.058	1.480	
17	0.2	0.908	0.966	3.798	2.302	0.058	1.496	
17	0.21	0.907	0.966	3.803	2.294	0.059	1.509	
18	0.3	0.903	0.968	3.889	2.242	0.065	1.648	
19	0.5	0.892	0.971	4.107	2.149	0.079	1.958	
19	1	0.865	0.973	4.593	2.034	0.109	2.560	
19	5	0.865	0.975	4.589	1.997	0.110	2.591	
19	10	0.865	0.975	4.589	1.997	0.110	2.591	
19	50	0.865	0.975	4.589	1.997	0.110	2.591	
19	100	0.865	0.975	4.589	1.997	0.110	2.591	
19	500	0.865	0.975	4.589	1.997	0.110	2.591	

Tabla 14. Malla de los diferentes “C” en la variable PT en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PT	SVs	C	R ²		RMSE		Resta R ²	Resta RMSE
			Validación	Calibración	Validación	Calibración		
18	0.001	0.674	0.738	8.814	7.958	0.065	0.856	
18	0.005	0.700	0.797	8.469	7.028	0.097	1.441	
17	0.01	0.700	0.828	8.458	6.466	0.128	1.992	
17	0.02	0.723	0.862	8.104	5.952	0.139	2.153	
16	0.03	0.745	0.865	7.780	5.783	0.120	1.997	
16	0.04	0.751	0.872	7.684	5.594	0.121	2.090	
16	0.045	0.752	0.873	7.681	5.550	0.121	2.131	
16	0.046	0.751	0.873	7.695	5.542	0.122	2.153	
16	0.047	0.750	0.873	7.713	5.534	0.124	2.179	
16	0.048	0.749	0.873	7.728	5.526	0.125	2.202	
16	0.049	0.748	0.874	7.743	5.519	0.126	2.224	
17	0.05	0.747	0.874	7.764	5.511	0.127	2.252	
17	0.06	0.741	0.875	7.884	5.450	0.134	2.434	
17	0.1	0.734	0.880	8.037	5.330	0.146	2.707	

17	0.5	0.678	0.906	8.950	4.781	0.229	4.168
17	1	0.593	0.924	10.260	4.329	0.331	5.932
17	5	0.427	0.966	12.576	2.891	0.538	9.684
17	10	0.427	0.966	12.576	2.891	0.538	9.684
17	50	0.427	0.966	12.576	2.891	0.538	9.684
17	100	0.427	0.966	12.576	2.891	0.538	9.684
17	500	0.427	0.966	12.576	2.891	0.538	9.684

Tabla 15. Malla de los diferentes “C” en la variable %PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

%PV SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
21	0.001	0.613	0.672	8.456	7.802	0.060	0.654
21	0.005	0.607	0.735	8.541	7.003	0.128	1.538
24	0.01	0.630	0.782	8.265	6.354	0.152	1.911
25	0.02	0.650	0.793	8.047	6.194	0.143	1.854
25	0.03	0.633	0.803	8.262	6.044	0.170	2.218
25	0.05	0.619	0.822	8.475	5.765	0.203	2.710
26	0.1	0.615	0.839	8.587	5.489	0.224	3.099
25	0.5	0.570	0.925	9.408	3.827	0.355	5.581
26	1	0.648	0.951	8.379	3.084	0.304	5.295
26	5	0.645	0.963	8.269	2.913	0.319	5.356
26	10	0.645	0.963	8.269	2.913	0.319	5.356
26	50	0.645	0.963	8.269	2.913	0.319	5.356
26	100	0.645	0.963	8.269	2.913	0.319	5.356
26	500	0.645	0.963	8.269	2.913	0.319	5.356

DATOS DE LA ZONA VNIR + SWIR 1 + SWIR 2

Tabla 16. Malla de los diferentes “C” en la variable PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PV SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
		Validación	Calibración	Validación	Calibración		
18	0.001	0.842	0.882	4.933	4.278	0.040	0.655
18	0.005	0.895	0.920	4.019	3.519	0.025	0.500
18	0.01	0.903	0.940	3.873	3.055	0.037	0.818
17	0.05	0.926	0.965	3.378	2.328	0.039	1.050
16	0.09	0.933	0.969	3.236	2.208	0.036	1.028
16	0.099	0.933	0.969	3.230	2.193	0.036	1.037
16	0.1	0.933	0.969	3.229	2.192	0.036	1.037
17	0.2	0.925	0.971	3.413	2.127	0.046	1.286

17	0.5	0.891	0.974	4.139	2.009	0.083	2.130
18	1	0.878	0.976	4.399	1.923	0.098	2.476
18	5	0.878	0.976	4.399	1.923	0.098	2.476
18	10	0.878	0.976	4.399	1.923	0.098	2.476
18	50	0.878	0.976	4.399	1.923	0.098	2.476
18	100	0.878	0.976	4.399	1.923	0.098	2.476
18	500	0.878	0.976	4.399	1.923	0.098	2.476

Tabla 17. Malla de los diferentes “C” en la variable PT en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

PT	SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
			Validación	Calibración	Validación	Calibración		
18	0.001	0.674	0.739	8.818	7.965	0.065	0.852	
18	0.005	0.691	0.802	8.592	6.939	0.111	1.653	
18	0.01	0.697	0.833	8.490	6.391	0.135	2.099	
18	0.02	0.725	0.866	8.090	5.729	0.141	2.361	
16	0.03	0.745	0.865	7.780	5.783	0.120	1.997	
17	0.04	0.743	0.874	7.845	5.508	0.131	2.337	
19	0.05	0.736	0.877	7.979	5.416	0.141	2.563	
19	0.06	0.731	0.879	8.081	5.356	0.149	2.724	
20	0.1	0.722	0.888	8.247	5.156	0.166	3.090	
23	0.5	0.629	0.916	9.822	4.492	0.287	5.330	
23	1	0.525	0.933	11.496	4.032	0.408	7.464	
23	5	0.365	0.955	14.261	3.284	0.589	10.977	
23	10	0.365	0.955	14.261	3.284	0.589	10.977	
23	50	0.365	0.955	14.261	3.284	0.589	10.977	
23	100	0.365	0.955	14.261	3.284	0.589	10.977	
23	500	0.365	0.955	14.261	3.284	0.589	10.977	

Tabla 18. Malla de los diferentes “C” en la variable %PV en la búsqueda del parámetro “C” óptimo en la estimación, el cual aporte un RMSE inferior al 2% en la diferencia calculada entre la calibración y la validación, estimando el R^2 lo más elevado posible. (Gama = 1, Epsilon = 0,1)

%PV	SVs	C	R^2		RMSE		Resta R^2	Resta RMSE
			Validación	Calibración	Validación	Calibración		
21	0.001	0.614	0.686	8.432	7.614	0.072	0.818	
22	0.005	0.611	0.746	8.487	6.838	0.135	1.649	
24	0.009	0.630	0.777	8.267	6.422	0.147	1.844	
25	0.01	0.635	0.779	8.214	6.389	0.145	1.825	
25	0.02	0.633	0.794	8.257	6.171	0.161	2.086	
26	0.05	0.613	0.826	8.535	5.686	0.213	2.848	

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

25	0.1	0.615	0.839	8.587	5.489	0.224	3.099
26	0.5	0.563	0.928	9.491	3.761	0.365	5.730
26	1	0.559	0.951	9.425	3.281	0.392	6.144
27	5	0.552	0.960	9.396	3.002	0.408	6.394
27	10	0.552	0.960	9.396	3.002	0.408	6.394
27	50	0.552	0.960	9.396	3.002	0.408	6.394
27	100	0.552	0.960	9.396	3.002	0.408	6.394
27	500	0.552	0.960	9.396	3.002	0.408	6.394

➤ MÉTODO ESTADÍSTICO PLSR

TRANSFORMACIONES Y SUAVIZADOS (MEDIAS)

Como resultado del análisis exhaustivo de las relaciones entre PV, PT y %PV de biomasa aérea y los datos espectrales (transformados y no transformados, la tabla 18 muestra los mejores resultados de los diferentes enfoques probados en las distintas zonas del espectro estudiadas.

Transformaciones: visibles en Tabla 18: Crudo = Espectro sin transformar, CyE = Centrado y Escalado del espectro, SG = Transformación Savitzky y Golay, BL = Transformación Basline, DE-TREN2 = Transformación De-trending usando un polinomio de orden 2, SNV = Transformación variable aleatoria normal, NME = Normalización usando la media, RAB = Transformación de reflectancia en absorbancia, MSCO ($X=X-a$) = Corrección de dispersión multiplicativa. El espectro es la media de los datos, F es el número de factores latentes (PLSR) R^2 es el coeficiente de determinación (cross-validation); RMSE es el error cuadrático medio (validación cruzada), AIC es el criterio de información de Akaike y V representa la variabilidad explicada por el modelo mediante los dos primeros factores en los Scores.

TRANSFORMACIONES Y SUAVIZADOS (MEDIANAS)

Como resultado del análisis exhaustivo de las relaciones entre PV, PT y %PV de biomasa aérea y los datos espectrales (transformados y no transformados, la tabla 19 muestra los mejores resultados de los diferentes enfoques probados en las distintas zonas del espectro estudiadas. Transformaciones visibles en Tabla 19: Crudo = Espectro sin transformar, CyE = Centrado y Escalado del espectro, SG = Transformación Savitzky y Golay, BL = Transformación Basline, DE-TREN2 = Transformación De-trending usando un polinomio de orden 2, SNV = Transformación variable aleatoria normal, NME = Normalización usando la media, RAB = Transformación de reflectancia en absorbancia, MSCO ($X=X-a$) = Corrección de dispersión multiplicativa. El espectro es la media de los datos, F es el número de factores latentes (PLSR) R^2 : Coeficiente de determinación (cross-validation); RMSE es el error cuadrático medio (cross-validation), AIC es el criterio de información de Akaike y V representa la variabilidad explicada por el modelo mediante los dos primeros factores en los Scores

Tabla 19. Resultados de aplicar diferentes transformaciones espectrales y posteriormente aplicar el método estadístico PLSR a las medias para predecir PT, PV y %PV de biomasa aérea.

TRANSFORMACIÓN	ZONA	PV				PT				%PV			
		R ²	RMSE	F	AIC	R ²	RMSE	F	AIC	R ²	RMSE	F	AIC
Crudo	VNIR	0.894	4.193	4	51.002	0.752	7.932	4	70.127	0.737	7.193	2	63.193
	VNIR+SW1	0.938	3.200	6	46.895	0.802	7.080	3	64.718	0.692	7.780	4	69.547
	VNIR+SW1+SW2	0.920	3.651	3	44.850	0.805	7.026	3	64.489	0.727	7.331	2	63.763
CyE	VNIR	0.820	5.455	1	52.896	0.674	9.087	1	68.205	0.750	7.017	3	64.450
	VNIR+SW1	0.905	3.970	3	47.363	0.783	7.421	3	66.129	0.692	7.786	3	67.570
	VNIR+SW1+SW2	0.908	3.886	3	46.721	0.797	7.169	3	65.093	0.668	8.087	2	66.708
SG	VNIR	0.950	2.879	2	35.723	0.925	4.356	2	48.147	0.904	4.360	2	48.174
	VNIR+SW1	0.904	3.979	1	43.431	0.910	4.766	2	50.845	0.901	4.426	2	48.625
	VNIR+SW1+SW2	0.911	3.836	1	42.333	0.923	4.417	2	48.564	0.942	3.367	2	40.421
CyE+SG	VNIR	0.793	5.842	1	54.952	0.614	9.890	1	70.746	0.851	5.417	3	56.686
	VNIR+SW1	0.938	3.187	2	38.772	0.768	7.671	1	63.123	0.869	5.080	3	54.759
	VNIR+SW1+SW2	0.943	3.101	2	37.952	0.768	7.671	1	63.123	0.873	5.002	4	56.295
BL	VNIR	0.891	4.234	4	51.294	0.686	8.926	2	69.669	0.718	7.452	2	64.254
	VNIR+SW1	0.915	3.737	3	45.548	0.782	7.440	3	66.206	0.742	7.127	2	62.917
	VNIR+SW1+SW2	0.910	3.861	3	46.528	0.782	7.436	3	66.190	0.708	7.587	2	64.793
DE-TREN2	VNIR	0.884	4.377	2	48.291	0.775	7.562	2	64.694	0.716	7.486	2	64.391
	VNIR+SW1	0.900	4.129	1	44.541	0.781	7.441	2	64.210	0.664	8.134	1	64.882
	VNIR+SW1+SW2	0.895	4.154	1	44.722	0.784	7.390	2	64.004	0.709	7.570	2	64.726
DE-TREN2 +SNV	VNIR	0.894	4.187	2	46.960	0.713	8.538	2	68.336	0.722	7.400	1	62.044
	VNIR+SW1	0.900	4.187	2	46.960	0.796	7.190	2	63.181	0.685	7.875	1	63.911
	VNIR+SW1+SW2	0.900	4.063	2	46.058	0.781	7.445	2	64.226	0.680	7.944	1	64.173

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

NME	VNIR	0.905	3.958	3	47.272	0.776	7.530	2	64.567	0.722	7.402	2	64.053
	VNIR+SW1	0.920	3.627	5	48.652	0.791	7.287	2	63.583	0.730	7.290	2	63.595
	VNIR+SW1+SW2	0.924	3.545	5	47.966	0.769	7.651	2	65.045	0.742	7.130	2	62.929
RAB	VNIR	0.823	5.411	2	54.653	0.671	9.141	1	68.383	0.701	7.677	3	67.147
	VNIR+SW1	0.902	4.025	4	49.776	0.688	8.898	2	69.575	0.800	6.284	3	61.140
	VNIR+SW1+SW2	0.898	4.103	1	44.352	0.733	8.230	1	65.234	0.764	6.816	3	63.578
MSCO (X=X-a)	VNIR	0.922	3.600	4	46.428	0.895	5.158	6	61.216	0.816	6.127	2	58.381
	VNIR+SW1	0.930	3.435	3	43.0205	0.970	2.753	4	38.381	0.819	5.984	2	57.673
	VNIR+SW1+SW2	0.952	2.805	4	38.942	0.970	2.851	4	39.430	0.818	5.992	2	57.713

Tabla 20. Resultados de aplicar diferentes transformaciones espectrales y posteriormente aplicar el método estadístico PLSR a las medianas para predecir PT, PV y %PV de biomasa aérea

MEDIANAS TRANSFORMACIÓN	ZONA	PV				PT				%pv			
		R ²	RMSE	F	AIC	R ²	RMSE	F	AIC	R ²	RMSE	F	AIC
Crudo	VNIR	0.904	3.971	4	49.371	0.790	7.301	7	73.640	0.739	7.178	2	63.131
	VNIR+SW1	0.901	4.039	3	47.880	0.789	7.311	3	65.681	0.670	8.070	1	64.645
	VNIR+SW1+SW2	0.894	4.181	3	48.917	0.794	7.223	3	65.318	0.742	7.126	2	62.913
CyE	VNIR	0.824	5.386	1	52.514	0.677	9.050	1	68.083	0.734	7.239	2	63.384
	VNIR+SW1	0.918	3.679	3	45.079	0.780	7.474	3	66.343	0.734	7.243	4	67.401
	VNIR+SW1+SW2	0.918	3.670	4	47.006	0.784	7.397	3	66.032	0.670	8.119	2	66.826
SG	VNIR	0.933	3.330	2	40.089	0.614	9.896	1	70.764	0.863	5.196	2	53.437
	VNIR+SW1	0.931	3.384	3	42.572	0.745	8.048	1	64.563	0.893	4.600	3	51.782
	VNIR+SW1+SW2	0.896	4.153	1	44.715	0.735	8.196	4	71.109	0.735	8.196	4	71.109
CyE+SG	VNIR	0.800	5.740	1	54.424	0.617	9.853	1	70.633	0.904	4.345	4	52.071
	VNIR+SW1	0.920	3.593	1	40.370	0.815	6.859	1	59.767	0.670	8.070	1	64.645
	VNIR+SW1+SW2	0.940	3.157	2	38.489	0.815	6.859	1	59.767	0.932	3.650	5	48.842
BL	VNIR	0.857	4.864	3	53.456	0.690	8.872	2	69.487	0.723	7.378	3	65.955
	VNIR+SW1	0.898	4.094	1	44.286	0.773	7.588	3	66.797	0.731	7.284	2	63.570
	VNIR+SW1+SW2	0.891	4.244	2	47.365	0.775	7.546	3	66.631	0.730	7.300	2	63.636
DE-TREN2	VNIR	0.891	4.239	2	47.330	0.770	7.642	2	65.010	0.724	7.379	2	63.959
	VNIR+SW1	0.903	4.007	2	45.641	0.775	7.558	2	64.678	0.708	7.584	2	64.781
	VNIR+SW1+SW2	0.898	4.105	2	46.366	0.763	7.748	1	63.423	0.780	6.581	2	60.526
DE-TREN2+SNV	VNIR	0.907	3.928	2	45.044	0.758	7.834	2	65.754	0.724	7.372	1	61.931
	VNIR+SW1	0.907	3.923	2	45.006	0.795	7.207	2	63.252	0.687	7.857	1	63.842
	VNIR+SW1+SW2	0.903	4.000	2	45.589	0.782	7.432	2	64.174	0.723	7.387	1	61.992
NME	VNIR	0.913	3.783	3	45.916	0.776	7.539	2	64.603	0.775	6.665	5	66.906
	VNIR+SW1	0.914	3.770	4	47.812	0.768	7.671	2	65.123	0.735	7.229	2	63.343
	VNIR+SW1+SW2	0.892	4.225	2	47.231	0.747	8.009	2	66.417	0.804	6.207	6	66.770
RAB	VNIR	0.828	5.336	2	54.234	0.728	8.301	4	71.491	0.918	4.001	6	53.596
	VNIR+SW1	0.908	3.901	4	48.837	0.737	8.171	2	67.018	0.815	6.038	3	59.942
	VNIR+SW1+SW2	0.890	4.255	1	45.443	0.745	8.050	2	66.570	0.729	7.309	2	63.673
MSCO (X=X-a)	VNIR	0.919	3.647	3	44.817	0.788	7.333	3	65.772	0.736	7.210	4	67.264
	VNIR+SW1	0.881	4.426	1	46.625	0.761	7.781	2	65.551	0.728	7.323	2	63.731
	VNIR+SW1+SW2	0.901	4.050	2	45.962	0.718	8.457	1	66.050	0.704	7.633	2	64.974

TRANSFORMACIÓN CR (MEDIAS)

A continuación se muestra la tabla con los resultados de aplicar la transformación CR a diferentes partes del espectro (Z1, Z2, Z3, Z4 y Z5) aplicando posteriormente el método PLSR en la predicción de biomasa aérea (PV, PT, %PV). El espectro es la media de los datos, F es el número de factores latentes (PLSR) R^2 es el coeficiente de determinación (cross-validation); RMSE es el error cuadrático medio (cross-validation), AIC es el criterio de información de Akaike.

Tabla 21. Resultados de aplicar la transformación CR y posteriormente aplicar el método estadístico PLSR a los espectros medios para predecir PT, PV y %PV de biomasa aérea en 5 zonas diferentes del espectro (Z1, Z2, Z3, Z4, Z5).

	Zonas	PV				PT				%PV			
		R ²	RMSE	F	AIC	R ²	RMSE	F	AIC	R ²	RMSE	F	AIC
CR	Z1	0.740	6.550	1	58.384	0.616	9.864	1	70.667	0.666	11.830	2	78.119
	Z2	0.867	4.692	4	54.376	0.654	9.367	1	69.116	0.614	8.724	1	66.982
	Z3	0.880	4.447	1	46.767	0.672	9.117	1	68.304	0.591	8.977	1	67.840
	Z4	0.919	3.656	1	40.891	0.752	7.938	1	64.150	0.558	9.328	1	68.991
	Z5	0.861	4.788	2	50.983	0.698	8.752	1	67.078	0.620	8.656	1	66.748

COMBINACIONES CR (MEDIAS)

Una vez obtenido los resultados de la tabla anterior, a continuación se combinaron las diferentes zonas de estudio donde se aplicó CR obteniéndose la siguiente tabla21. Se realizó combinación de dos, tres, cuatro y cinco zonas.

Tabla 2.2. Resultados de combinar las diferentes zonas donde se aplicó CR en la estimación de biomasa aérea (PV, PT, %PV) y posteriormente aplicar el método PLSR a los espectros medios.

	Zonas	PV				PT				%PV			
		R ²	RMSE	F	AIC	R ²	RMSE	F	AIC	R ²	RMSE	F	AIC
COMBINACIONES	Z12	0.800	5.808	2	56.777	0.606	10.001	1	71.081	0.611	8.745	1	67.054
	Z13	0.882	4.414	1	46.543	0.623	9.779	1	70.407	0.600	8.895	1	67.565
	Z14	0.919	3.654	1	40.875	0.852	6.124	3	60.366	0.577	9.133	1	68.357
	Z15	0.866	4.700	2	50.427	0.693	8.821	1	67.314	0.613	8.729	1	67.000
	Z23	0.878	4.512	1	47.202	0.648	9.452	1	69.387	0.660	8.193	4	71.098
	Z24	0.919	3.650	1	40.842	0.733	8.222	1	65.204	0.615	8.708	1	66.927
	Z25	0.864	4.743	2	50.700	0.703	8.675	2	68.813	0.621	8.647	1	66.716
	Z34	0.934	3.310	2	39.908	0.789	7.309	2	63.673	0.811	6.098	4	62.239
	Z35	0.866	4.696	2	50.401	0.700	8.719	1	66.965	0.749	7.033	3	64.518
	Z45	0.919	3.651	1	40.850	0.710	8.576	1	66.469	0.620	8.656	1	66.748
	Z123	0.882	4.414	1	46.543	0.607	9.987	1	71.039	0.612	8.740	1	67.037
	Z124	0.930	3.412	2	40.819	0.788	7.341	2	63.804	0.613	8.734	1	67.017
	Z125	0.866	4.702	2	50.440	0.713	8.537	1	66.332	0.618	8.676	1	66.817
	Z134	0.935	3.282	2	39.654	0.792	7.271	2	63.517	0.580	9.097	1	68.238
	Z135	0.931	3.393	2	40.651	0.785	7.378	2	63.955	0.614	8.723	1	66.979
	Z145	0.920	3.750	1	41.653	0.882	7.084	5	68.735	0.614	8.727	1	66.993
	Z234	0.920	3.750	1	41.653	0.789	7.321	2	63.722	0.643	8.384	3	69.790

Z235	0.867	4.680	2	50.299	0.713	8.529	1	66.304	0.621	8.644	1	66.706
Z245	0.883	4.401	2	48.455	0.833	6.501	3	62.159	0.621	8.643	1	66.702
Z345	0.890	4.264	2	47.506	0.710	8.577	1	66.473	0.620	8.652	1	66.734
Z1234	0.934	3.304	2	39.854	0.782	7.433	2	64.178	0.661	8.169	4	71.010
Z1235	0.87	4.628	2	49.964	0.694	8.805	1	67.260	0.618	8.673	1	66.806
Z1245	0.922	3.581	1	40.269	0.724	8.366	1	65.725	0.618	8.672	1	66.803
Z1345	0.93	3.393	2	40.651	0.785	7.378	2	63.955	0.614	8.723	1	66.979
Z2345	0.884	4.380	2	48.311	0.750	7.962	1	64.240	0.621	8.64	1	66.692
Z12345	0.940	3.176	2	38.669	0.733	8.233	1	65.245	0.619	8.669	1	66.793

TRANSFORMACIÓN CR (MEDIANAS)

A continuación se muestra la tabla con los resultados de aplicar la transformación CR a diferentes partes del espectro (Z1, Z2, Z3, Z4 y Z5) aplicando posteriormente el método PLSR en la predicción de biomasa aérea (PV, PT, %PV). El espectro es la mediana de los datos, F es el número de factores latentes (PLSR) R^2 es el coeficiente de determinación (cross-validation); RMSE es el error cuadrático medio (cross-validation), AIC es el criterio de información de Akaike.

Tabla 23. Resultados de aplicar la transformación CR y posteriormente aplicar el método estadístico PLSR al espectros medianas para predecir PT, PV y %PV de biomasa aérea en 5 zonas diferentes del espectro (Z1, Z2, Z3, Z4, Z5).

ZONAS	PV				PT				%PV			
	R^2	RMSE	F	AIC	R^2	RMSE	F	AIC	R^2	RMSE	F	AIC
Z1	0.804	5.690	2	56.161	0.604	10.028	1	71.161	0.821	5.940	4	61.451
Z2	0.887	4.322	4	51.912	0.694	8.808	1	67.270	0.621	8.641	1	66.696
Z3	0.888	4.295	1	45.724	0.682	8.988	1	67.877	0.575	9.152	1	68.419
Z4	0.921	3.622	1	40.611	0.735	8.198	1	65.117	0.72	7.432	4	68.174
Z5	0.859	4.821	2	51.189	0.69	8.867	1	67.470	0.625	8.602	1	66.560

COMBINACIONES CR (MEDIANAS)

Una vez obtenido los resultados de la tabla anterior, a continuación se combinaron las diferentes zonas de estudio donde se aplicó CR obteniéndose la siguiente tabla 24. Se realizó combinación de dos, tres, cuatro y cinco zonas.

Tabla 24. Resultados de combinar las diferentes zonas donde se aplicó CR en la estimación de biomasa aérea (PV, PT, %PV) y posteriormente aplicar el método PLSR a los espectros medianas.

Zonas	PV				PT				%pv			
	R^2	RMSE	F	AIC	R^2	RMSE	F	AIC	R^2	RMSE	F	AIC
Z12	0.834	5.233	3	55.650	0.658	9.317	3	72.955	0.859	5.263	5	59.821
Z13	0.889	4.275	1	45.584	0.682	8.987	1	67.873	0.704	7.634	5	70.978
Z14	0.932	3.349	2	40.260	0.835	6.468	4	64.006	0.811	6.109	4	62.293
Z15	0.863	4.748	1	48.732	0.682	8.980	1	67.850	0.621	8.638	1	66.685

Z23	0.891	4.248	1	45.393	0.699	8.734	2	69.017	0.622	8.634	1	66.671
Z24	0.905	3.953	2	45.234	0.726	8.332	1	65.603	0.622	8.626	1	66.643
Z25	0.862	4.776	2	50.908	0.690	8.872	1	67.487	0.627	8.575	1	66.466
Z34	0.916	3.730	1	41.492	0.770	7.645	2	65.022	0.647	8.341	2	67.635
Z35	0.867	4.693	2	50.382	0.693	8.829	1	67.341	0.625	8.600	1	66.553
Z45	0.921	3.621	1	40.603	0.701	8.706	1	66.920	0.624	8.605	1	66.570
Z123	0.890	4.260	1	45.478	0.639	9.563	4	75.737	0.883	4.803	5	57.077
Z124	0.921	3.621	1	40.603	0.724	8.366	2	67.725	0.671	8.052	4	70.578
Z125	0.868	4.676	2	50.273	0.692	8.832	1	67.351	0.626	8.587	1	66.507
Z134	0.939	3.176	3	40.669	0.769	7.661	2	65.084	0.832	5.762	5	62.539
Z135	0.872	4.589	1	47.710	0.683	8.968	1	67.810	0.622	8.635	1	66.675
Z145	0.921	3.621	1	40.603	0.734	8.207	1	65.150	0.621	8.638	1	66.685
Z234	0.906	3.937	2	45.113	0.774	7.565	2	64.706	0.623	8.619	1	66.619
Z235	0.866	4.698	2	50.414	0.712	8.552	1	66.385	0.625	8.602	1	66.560
Z245	0.881	4.424	2	48.611	0.735	8.202	1	65.131	0.627	8.571	1	66.452
Z345	0.891	4.235	2	47.301	0.703	8.680	1	66.831	0.625	8.602	1	66.560
Z1234	0.915	3.736	1	41.540	0.772	7.604	2	64.860	0.708	7.585	4	68.785
Z1235	0.873	4.578	2	49.638	0.697	8.764	1	67.120	0.626	8.585	1	66.500
Z1245	0.890	4.264	2	47.506	0.731	8.258	1	65.335	0.626	8.584	1	66.497
Z1345	0.921	3.620	1	40.594	0.734	8.216	1	65.183	0.622	8.635	1	66.675
Z2345	0.883	4.390	2	48.380	0.734	8.219	1	65.193	0.627	8.569	1	66.445
Z12345	0.892	4.229	2	47.259	0.730	8.282	1	65.423	0.626	8.582	1	66.490

➤ MÉTODO ESTADÍSTICO OLSR

REGRESIONES OLSR (MEDIAS)

A continuación se muestran los resultados en la tabla 25 de la regresión OLS y los índices derivados del CR (MBD y AOM) en el espectro medio de los datos.

Tabla 25. Resultados de la regresión lineal simple (OLSR), para la estimación de biomasa (PV, PT y %PV) en las diferentes zonas del CR (Z1, Z2, Z3, Z4, Z5). Espectro es el promedio de los datos, MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo, R^2 :

Coefficiente de determinación del ajuste; $RMSE_{PV} = g/m^2$; $RMSE_{PT} = g/m^2$; $RMSE_{\%V} = \%$; En

negrita: los modelos más precisos.

		LSR			
		MBD		AOM	
	Zonas	R^2	RMSE	R^2	RMSE
PV	z1	0,720	6,573	0,722	6,546
	z2	0,669	7,142	0,713	6,654
	z3	0,870	4,470	0,866	4,550
	z4	0,908	3,764	0,914	3,646
	z5	0,743	6,293	0,796	5,611
PT	Z1	0,588	9,888	0,594	9,810
	Z2	0,537	10,476	0,575	10,039
	Z3	0,650	9,110	0,641	9,226
	Z4	0,709	8,301	0,720	8,150
	Z5	0,599	9,748	0,642	9,216
%V	Z1	0,544	9,166	0,526	9,343

Z2	0,596	8,621	0,584	8,756
Z3	0,550	9,100	0,552	9,080
Z4	0,525	0,591	0,523	9,370
Z5	0,601	8,568	0,589	8,698

REGRESIONES OLSR (MEDIAS)

A continuación se muestran los resultados de la regresión OLS y los índices derivados del CR (MBD y AOM) en el espectro mediana de los datos.

Tabla 26. Resultados de la regresión lineal simple (OLSR), para la estimación de biomasa (PV, PT y %PV) en las diferentes zonas del CR (Z1, Z2, Z3, Z4, Z5); MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; R²: Coeficiente de determinación, RMSE= g/m². En negrita: los modelos más precisos.

	Zonas	LSR			
		MBD		AOM	
		R ²	RMSE	R ²	RMSE
PV	z1	0,728	6,483	0,722	6,549
	z2	0,669	7,146	0,719	6,587
	z3	0,725	6,517	0,750	6,208
	z4	0,910	3,720	0,915	3,615
	z5	0,742	6,307	0,797	5,593
PT	Z1	0,582	9,950	0,578	9,997
	Z2	0,534	10,510	0,577	10,008
	Z3	0,600	9,743	0,625	9,426
	Z4	0,707	8,328	0,716	8,176
	Z5	0,594	9,810	0,639	9,253
%V	Z1	0,567	8,931	0,554	9,064
	Z2	0,603	8,551	0,591	8,674
	Z3	0,557	9,034	0,541	9,193
	Z4	0,524	9,359	0,522	9,384
	Z5	0,608	8,502	0,594	8,648

MÉTODO DE COMBINATORIA DE ZONAS/ÍNDICES (PLSR)

A continuación se muestran los resultados de la regresión PLS tras aplicar la combinación de las zonas donde los modelos resultantes de los índices derivados del CR (MBD y AOM) fueron más exactos. En la estimación de la biomasa en PV y PT se usó la combinación de la zona 4 con las demás zonas al ser esta zona el resultado más exacto en los resultados tras aplicar la regresión OLS. En la estimación de biomasa en %PV se usó la combinación de la zona 5 con el resto de las zonas.

COMBINATORIA DE ZONAS/ÍNDICES (MEDIA)

En este apartado se muestran los resultados en las tablas 27, 28 y 29 de las regresiones PLS al aplicar la combinatoria de las zonas donde se estimó los índices

derivados del CR (MBD y AOM) en el espectro medio de los datos para la estimación de biomasa aérea (PV, PT y %PV)

Tabla 27. Resultados PLSR en la predicción de biomasa aérea (PV) usando los índices derivados del CR considerando la zona de absorción espectral Z4. MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; F es el número de factores latentes; R^2 : Coeficiente de determinación, $RMSE_{PV} = g/m^2$; $RMSE_{PT} = g/m^2$; $RMSE_{PV} = \%$; AIC: Criterio de información de Akaike.

	Zonas	MBD				AOM			
		R^2	RMSE	F	AIC	R^2	RMSE	F	AIC
PV	Z1,4	0,914	3,762	2	43,747	0,924	3,539	2	41,917
	Z2,4	0,912	3,817	2	44,181	0,918	3,675	2	43,048
	Z3,4	0,919	3,661	2	42,932	0,929	3,433	2	41,002
	Z4,5	0,911	3,826	2	44,252	0,920	3,627	2	42,652
	Z1,2,4	0,914	3,776	3	45,860	0,922	3,587	3	44,323
	Z1,3,4	0,921	3,622	3	44,607	0,939	3,172	3	40,631
	Z1,4,5	0,918	3,689	2	43,160	0,922	3,599	3	44,422
	Z2,3,4	0,915	3,738	3	45,555	0,929	3,432	3	42,997
	Z2,4,5	0,900	4,060	2	46,039	0,916	3,729	3	45,482
	Z3,4,5	0,915	3,755	3	45,691	0,931	3,377	3	42,511
	Z1,2,3,4	0,925	3,518	4	45,741	0,939	3,173	4	42,636
	Z1,2,4,5	0,913	3,782	3	45,904	0,916	3,726	4	47,461
	Z1,3,4,5	0,909	3,873	2	44,620	0,936	3,249	4	43,353
	Z2,3,4,5	0,898	4,098	2	46,313	0,929	3,427	4	44,946
	Z1,2,3,4,5	0,914	3,766	5	49,777	0,931	3,367	5	46,422

Tabla 28. Resultados PLSR en la predicción de biomasa aérea (PT) usando los índices derivados del CR considerando la zona de absorción espectral Z4. MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; F es el número de factores latentes; R^2 : Coeficiente de determinación, $RMSE_{PV} = g/m^2$; $RMSE_{PT} = g/m^2$; $RMSE_{PV} = \%$; AIC: Criterio de información de Akaike.

	Zonas	MBD				AOM			
		R^2	RMSE	F	AIC	R^2	RMSE	F	AIC
PT	Z1,4	0,699	8,733	2	69,013	0,709	8,595	2	68,534
	Z2,4	0,715	8,500	2	68,204	0,724	8,369	2	67,736
	Z3,4	0,772	7,609	2	64,881	0,800	7,120	2	62,889
	Z4,5	0,715	8,500	2	68,204	0,725	8,347	2	67,659
	Z1,2,4	0,675	9,075	2	70,167	0,683	8,971	2	69,819
	Z1,3,4	0,750	7,960	3	68,233	0,786	7,375	3	65,944
	Z1,4,5	0,679	9,026	2	70,004	0,685	8,934	2	69,697
	Z2,3,4	0,762	7,777	3	67,535	0,792	7,270	3	65,513
	Z2,4,5	0,710	8,579	2	68,480	0,699	8,742	3	71,043

Z3,4,5	0,761	7,787	3	67,573	0,794	7,237	3	65,376
Z1,2,3,4	0,730	8,281	4	71,420	0,772	7,599	4	68,842
Z1,2,4,5	0,679	9,025	2	70,001	0,663	9,240	2	70,707
Z1,3,4,5	0,732	8,249	4	71,302	0,772	7,611	4	68,888
Z2,3,4,5	0,723	8,380	4	71,776	0,780	7,473	4	68,339
Z1,2,3,4,5	0,677	9,050	2	70,084	0,758	7,832	5	71,747

Tabla 29. Resultados PLSR en la predicción de biomasa aérea (%PV) usando los índices derivados del CR considerando la zona de absorción espectral Z5. MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; F es el número de factores latentes; R^2 : coeficiente de determinación; $RMSE_{PV} = g/m^2$; $RMSE_{PT} = g/m^2$; $RMSE_{PV} = \%$; AIC: criterio de información de Akaike.

	Zonas	MBD				AOM			
		R^2	RMSE	F	AIC	R^2	RMSE	F	AIC
%PV	Z1,5	0,608	8,794	1	67,223	0,614	8,723	1	66,979
	Z2,5	0,627	8,578	1	66,477	0,620	8,659	1	66,758
	Z3,5	0,629	8,548	1	66,372	0,616	8,697	1	66,889
	Z4,5	0,629	8,552	1	66,385	0,616	8,700	1	66,899
	Z1,2,5	0,619	8,663	1	66,773	0,618	8,673	1	66,807
	Z1,3,5	0,609	8,780	1	67,174	0,614	8,722	1	66,974
	Z1,4,5	0,609	8,775	1	67,157	0,614	8,724	1	66,982
	Z2,3,5	0,628	8,567	1	66,437	0,620	8,658	1	66,754
	Z2,4,5	0,628	8,559	1	66,409	0,620	8,658	1	66,756
	Z3,4,5	0,630	8,539	1	66,339	0,616	8,699	1	66,895
	Z1,2,3,5	0,620	8,655	1	66,743	0,618	8,672	1	66,804
	Z1,2,4,5	0,620	8,649	1	66,724	0,618	8,673	1	66,805
	Z1,3,4,5	0,610	8,763	1	67,117	0,614	8,723	1	66,978
	Z2,3,4,5	0,629	8,549	1	66,374	0,620	8,657	1	66,752
	Z1,2,3,4,5	0,621	8,642	1	66,698	0,618	8,671	1	66,801

COMBINATORIA DE ÍNDICES (MEDIANA)

En este apartado se muestran los resultados en las tablas 30, 31 y 32 de las regresiones PLS al aplicar la combinatoria de las zonas donde se estimó los índices derivados del CR (MBD y AOM) en el espectro mediana de los datos para la estimación de biomasa aérea (PV, PT y %PV).

Tabla 30. Resultados PLSR en la predicción de biomasa aérea (PV) usando los índices derivados del CR considerando la zona de absorción espectral Z4. MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; F es el número de factores latentes; $R^2 =$ coeficiente de determinación, $RMSE = g/m^2$, AIC es el criterio de información de Akaike.

	Zonas	MBD				AOM			
		R^2	RMSE	F	AIC	R^2	RMSE	F	AIC
PV	Z1,4	0,913	3,786	2	43,942	0,924	3,540	2	41,922
	Z2,4	0,913	3,783	2	43,917	0,918	3,676	2	43,054
	Z3,4	0,913	3,795	2	44,012	0,919	3,647	2	42,816
	Z4,5	0,913	3,786	2	43,942	0,921	3,607	2	42,486

Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución

Z1,2,4	0,915	3,745	3	45,616	0,925	3,512	3	43,689
Z1,3,4	0,923	3,566	3	44,144	0,919	3,662	2	42,937
Z1,4,5	0,914	3,764	2	43,767	0,914	3,764	2	43,765
Z2,3,4	0,904	3,988	3	47,499	0,915	3,757	3	45,706
Z2,4,5	0,899	4,077	2	46,159	0,921	3,607	3	44,486
Z3,4,5	0,907	3,908	2	44,893	0,919	3,659	3	44,915
Z1,2,3,4	0,922	3,588	3	44,325	0,921	3,619	3	44,584
Z1,2,4,5	0,912	3,805	3	46,089	0,921	3,618	4	46,578
Z1,3,4,5	0,917	3,703	3	45,274	0,920	3,639	3	44,750
Z2,3,4,5	0,897	4,132	2	46,560	0,916	3,715	4	47,374
Z1,2,3,4,5	0,917	3,702	3	45,262	0,916	3,714	4	47,365

Tabla 31. Resultados PLSR en la predicción de biomasa aérea (PT) usando los índices derivados del CR considerando la zona de absorción espectral Z4. MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; F es el número de factores latentes; El espectro representa el espectro medio o el espectro mediana de los datos; R^2 = coeficiente de determinación, $RMSE= g/m^2$, AIC es el criterio de información de Akaike.

Zonas	MBD				AOM				
	R^2	RMSE	F	AIC	R^2	RMSE	F	AIC	
Z1,4	0,695	8,790	2	69,209	0,708	8,612	2	68,593	
Z2,4	0,713	8,532	2	68,316	0,721	8,406	2	67,870	
Z3,4	0,711	0,741	2	-4,997	0,719	8,436	2	67,974	
Z4,5	0,713	8,538	2	68,336	0,723	8,386	2	67,798	
PT	Z1,2,4	0,670	9,155	2	70,430	0,679	9,023	2	69,993
	Z1,3,4	0,705	8,656	3	70,748	0,727	8,317	3	69,548
	Z1,4,5	0,676	9,070	2	70,148	0,679	9,023	2	69,993
	Z2,3,4	0,736	8,178	2	67,045	0,692	8,838	3	71,371
	Z2,4,5	0,705	8,646	2	68,715	0,700	8,729	3	70,999
	Z3,4,5	0,712	8,547	3	70,368	0,730	8,274	3	69,394
	Z1,2,3,4	0,736	8,180	3	69,052	0,739	8,144	4	70,918
	Z1,2,4,5	0,672	9,121	2	70,318	0,672	9,123	3	72,324
	Z1,3,4,5	0,702	8,700	3	70,899	0,739	8,144	3	68,918
	Z2,3,4,5	0,725	8,347	2	67,656	0,704	8,658	4	72,756
Z1,2,3,4,5	0,724	8,360	2	67,702	0,733	8,234	5	73,250	

Tabla 32. Resultados PLSR en la predicción de biomasa aérea (%PV) usando los índices derivados del CR considerando la zona de absorción espectral Z5. MBD es el índice de profundidad, AOM es el índice del área sobre el mínimo; F es el número de factores latentes; El espectro representa el espectro medio o el espectro mediana de los datos; R^2 :coeficiente de determinación, $RMSE= g/m^2$, AIC es el criterio de información de Akaike.

Zonas	DM				AOM				
	R^2	RMSE	F	AIC	R^2	RMSE	F	AIC	
Z1,5	0,620	8,650	1	66,726	0,619	8,660	1	66,761	
Z2,5	0,633	8,509	1	66,233	0,625	8,592	1	66,526	
Z3,5	0,678	7,972	2	66,278	0,617	8,690	2	68,866	
Z4,5	0,634	8,488	1	66,161	0,620	8,651	1	66,729	
%PV	Z1,2,5	0,629	8,552	1	66,384	0,625	8,599	1	66,551
	Z1,3,5	0,648	8,328	3	69,588	0,612	8,742	2	69,043
	Z1,4,5	0,622	8,637	1	66,680	0,619	8,662	1	66,767
	Z2,3,5	0,675	8,009	3	68,416	0,684	7,897	3	67,994
	Z2,4,5	0,634	8,489	1	66,164	0,625	8,592	1	66,526
	Z3,4,5	0,647	8,341	1	65,637	0,613	8,733	2	69,014
	Z1,2,3,5	0,645	8,368	3	69,731	0,679	7,956	3	68,218
	Z1,2,4,5	0,630	8,539	1	66,339	0,625	8,599	1	66,550
	Z1,3,4,5	0,608	8,785	1	67,191	0,600	8,884	1	67,528
	Z2,3,4,5	0,667	8,105	3	68,774	0,667	8,105	3	68,774
Z1,2,3,4,5	0,646	8,351	3	69,671	0,669	8,080	3	68,684	

ANEXO II

Tabla 2.1. Coeficientes obtenidos de los modelos en la estimación a partir de los diferentes sets (a, mixto y total). Coeficientes=B1, B2, B3, B4 y término independiente= B0 en la ecuación:

$$\text{Biomasa aérea} = B0 + B1_B + B2_G + B3_R + B4_{NIR}$$

	Biomasa	SET	B0	B1	B2	B3	B4
Imagen A	PV	a	18,86883	-65,414	-91,44811	-180,2519	118,5378
		mixto	16,21528	-65,19135	-91,29307	-179,6108	117,5774
		total	19,82748	-65,41383	-91,44811	-180,2519	118,5378
	PT	a	31,39531	-76,07736	-106,83330	-206,3775	132,2333
		mixto	28,76244	-75,59249	-106,5656	-204,973	129,896
		total	32,56079	-76,07736	-106,8333	-206,3775	132,2333
	%PV	a	61,03603	-59,10163	-81,55849	-171,395	91,54601
		mixto	58,2224	-59,51169	-81,60841	-172,6131	94,17311
		total	62,18842	-59,10162	-81,55849	-171,395	91,54601
Imagen B	PV	a	-10,4623	-56,6754	-78,05555	-153,9071	143,0357
		mixto	32,728	-67,8508	-94,0452	-184,2547	11401598
		total	21,88082	-67,85077	-94,04516	-184,2547	114,1598
	PT	a	0,8473812	-65,77183	-92,09697	-176,311	153,62
		mixto	48,5541	-78,5953	-110,053	-210,6862	122,3808
		total	36,05386	-78,5953	-110,053	-210,6862	122,3808
	%PV	a	33,92878	-52,34338	-70,18078	-148,7334	120,7695
		mixto	72,4859	-62,4859	-83,7723	-177,5378	96,1055
		total	61,79214	-62,48044	-83,7723	-177,5378	96,10554
Imagen C	PV	a	17,1593	-71,0051	-97,73140	-183,5821	126,2532
		mixto	13,40581	-71,00507	-97,73143	-183,5821	126,2532
		total	17,87997	-71,00507	-97,73143	-183,5821	126,2532
	PT	a	31,29575	-82,78355	-115,2063	-210,3398	133,5858
		mixto	27,24845	-82,78355	-115,2063	-210,3398	133,5858
		total	32,32957	-82,78355	-115,2063	-210,3397	133,5857
	%PV	a	56,98257	-64,35744	-86,43108	-175,9424	108,0727
		mixto	53,68714	-64,35745	-86,43110	-175,9424	108,0727
		total	57,81612	-64,35744	-86,43108	-175,9424	108,0727

Tabla 2.2. Coeficientes de validación de los diferentes modelos en la estimación de biomasa a partir de los diferentes índices de vegetación usados en la estimación de biomasa aérea (PV, PT y %PV) en las tres imágenes (A, B y C) usando los tres Sests (A, Mixto y Total). B1: Gain; B0:Offset. La ecuación de estimación de biomasa aérea=B1Ref+B0.

Biomasa	SET	NDVI		SR		NLI		SAVI		MARAVI		
		B1	B0	B1	B0	B1	B0	B1	B0	B1	B0	
Imagen A	PV	a	57,3004	0	3,3685	8,7838	35,7888	25,2649	108,0378	-9,0768	51,3435	0
		mixto	61,2875	-10,9515	3,2077	8,045	37,0916	21,9157	110,3832	-13,983	46,478	0
		total	61,7692	-7,846	4,7775	0	40,804	26,1578	110,964	-10,0373	59,7649	0
	PT	a	65,9423	0	3,7045	19,8265	40,9689	37,6612	123,2994	0	57,0973	0
		mixto	70,2295	0	3,5134	19,1193	42,2886	33,8726	125,3936	0	51,4355	0
		total	71,0309	0	5,3209	15,0025	45,8595	38,687	126,631	0	66,8761	0
	%PV	a	51,8737	33,4579	2,677	50,1166	29,9611	62,9401	96,4961	31,9059	41,3005	41,7151
		mixto	56,5623	28,9629	2,6164	49,0329	32,1542	59,845	100,59	26,6962	38,4503	39,6659
		total	55,9024	32,5364	3,8237	46,7507	33,741	63,6621	99,1415	31,036	48,4347	38,3099
Imagen B	PV	a	72,4907	-25,6094	1,7842	9,8008	35,2023	22,2055	111,0142	-13,1952	45,6624	0
		mixto	58,2038	-9,5774	2,7806	9,1995	73,2644	51,3846	126,6457	0	132,1719	-17,3931
		total	58,7248	0	4,4821	0	38,8459	26,732	111,3809	-8,9635	61,6658	0
	PT	a	83,3133	-20,8379	1,9538	21,0481	40,1602	34,1961	125,6596	0	50,2877	0
		mixto	66,8933	0	3,0524	20,3284	81,941	67,044	142,8534	11,8544	146,3991	0
		total	67,3878	0	4,9728	15,7112	44,1103	39,3866	125,981	0	68,1376	0
	%PV	a	68,0752	0	1,4534	50,489	30,743	60,0351	102,6938	26,7957	38,2532	40,2305
		mixto	54,0256	30,0113	2,2675	49,9789	64,1684	85,5675	116,5208	41,2675	115,8068	25,3122
		total	54,322	33,1347	3,6908	46,5682	33,7825	64,0064	102,870	30,7686	52,1366	37,268
Imagen C	PV	a	56,0785	0	2,9262	9,3361	34,5946	24,4882	111,4619	-10,3333	49,9891	0
		mixto	58,1472	-11,6003	1,9113	12,247	33,2271	20,2429	112,816	-15,7314	37,122	0
		total	61,186	-8,852	4,3328	0	39,3341	25,2012	114,7952	-11,8361	59,2838	0
	PT	a	64,6196	0	3,2141	20,464	39,455	36,8028	125,8588	0	54,7977	0
		mixto	67,0888	0	2,0761	23,8979	38,0996	31,8905	127,5182	0	40,5818	11,5961
		total	70,3781	0	4,8192	15,2187	44,7485	37,6344	129,6221	0	65,352	0
	%PV	a	51,6782	32,385	2,3733	50,189	29,8154	62,1115	102,7639	29,5729	41,8324	40,9145
		mixto	53,7921	28,2688	1,5448	52,6043	28,8654	58,3738	104,1858	24,523	40,5818	11,5961
		total	56,4500	30,9129	3,5513	46,3608	34,2066	62,6752	105,8838	28,1696	50,1291	36,7138

Tabla 2.3. Coeficientes para el primer factor, obtenidos de los modelos en la estimación a partir de las ecuaciones de los sets obtenidos en las imágenes A y C sobre la imagen B.

Coeficientes=B1, B2, B3, B4 y B0: Off; Biomasa aérea= $B0+B1_B+B2_G+B3_R+B4_{NIR}$

	Biomasa	SET	B0	B1	B2	B3	B4
Ecuaciones A en Imagen B	PV	a	20,98141	-67,85078	-94,04517	-184,2547	114,1598
		mixto	18,30753	-67,85077	-94,04517	-184,2547	114,1598
		total	22,07059	-67,85078	-94,04517	-184,2547	114,1598
	PT	a	34,9231	-78,59529	-110,053	-210,6862	122,3807
		mixto	32,09849	-78,59528	-110,053	-210,6862	122,3807
		total	36,30029	-78,59529	-110,053	-210,6862	122,3807
	%PV	a	60,82652	-62,48044	-83,77231	-177,5378	96,10552
		mixto	58,62247	-62,48043	-83,77231	-177,5378	96,10554
		total	62,01383	-62,48043	-83,77231	-177,5378	96,10554
Ecuaciones C en Imagen B	PV	a	21,35815	-67,85078	-94,04517	-184,2547	114,1598
		mixto	18,85801	-67,85078	-94,04517	-184,2547	114,1598
		total	22,2324	-67,85078	-94,04517	-184,2547	114,1598
	PT	a	35,36716	-78,59529	-110,053	-210,6862	122,3807
		mixto	32,73485	-78,5953	-110,053	-210,6862	122,3807
		total	36,52013	-78,59529	-110,053	-210,6862	122,3808
	%PV	a	61,20397	-62,48044	-83,77231	-177,5378	96,10552
		mixto	59,16299	-62,48043	-83,77232	-177,5378	96,10552
		total	62,21563	-62,48043	-83,77232	-177,5378	96,10552

Tabla 2.4. Coeficientes de validación de ecuaciones de las imágenes A y C en la imagen B a partir de los índices de vegetación. (B1: Gain, B0:Offset). La ecuación a seguir es Biomasa aérea=B1Ref+B0)

	Biomasa	SET	NDVI		SR		NLI		SAVI		MARABI	
			B1	B0	B1	B0	B1	B0	B1	B0	B1	B0
Ecuaciones A en Imagen B	PV	a	55,2308	0	3,434	8,2549	35,4929	25,9983	109,1597	-8,1603	54,8997	0
		mixto	59,5753	-9,7598	3,2509	7,6325	76,303	22,6559	111,9137	-13,2852	49,3368	0
		total	59,9076	0	4,8838	0	40,0584	27,068	112,1544	-9,1433	64,0598	-6,0402
	PT	a	63,5455	0	3,7786	19,2307	40,3479	38,5462	123,4732	0	60,4316	0
		mixto	68,4379	0	3,5876	18,4679	41,838	34,7184	126,6701	0	54,4620	0
		total	68,7206	0	5,4299	14,5346	45,4669	39,7705	126,8523	0	70,8495	0
	%PV	a	51,1448	33,9436	2,8057	49,1719	30,7024	63,3948	100,7943	31,5204	46,0800	40,0608
		mixto	55,2971	29,8435	2,6601	48,6336	32,1077	60,415	103,5266	26,7121	41,1841	38,7636
		total	55,4218	32,9309	4,0334	45,6767	34,8914	64,2923	103,5931	30,6004	54,2942	36,3403
Ecuaciones C en Imagen B	PV	a	56,2928	0	3,9011	7,0119	36,8202	26,7045	109,7951	-7,9399	58,617	0
		mixto	60,7196	-9,4717	3,8435	6,0038	38,3222	23,586	112,668	-12,7955	54,023	0
		total	61,2344	0	5,3136	0	41,3589	27,3694	113,0225	-9,4001	66,399	-7,0912
	PT	a	64,6327	0	4,3085	17,7622	41,8217	39,3538	124,181	0	64,622	0
		mixto	69,7138	0	4,2604	16,5454	43,6324	35,7895	127,5058	0	59,738	0
		total	70,217	0	5,9193	13,3164	46,9236	40,1146	127,8313	0	73,501	0
	%PV	a	52,0319	34,0487	3,1971	48,095	31,8859	64,0008	101,3719	31,7272	49,346	38,9901
		mixto	56,333	30,1287	3,1585	47,2115	33,5466	61,2239	104,204	27,1731	45,604	37,3164
		total	56,6579	32,6622	4,402	44,7442	36,0862	64,5483	104,4034	30,3602	56,419	35,3661