

Estimación de variables biofísicas del pastizal en un ecosistema de dehesa a partir de espectro-radiometría de campo e imágenes hiperespectrales aeroportadas

Melendo-Vega, J.R.*; Martín, M.P., Vilar del Hoyo, L., Pacheco-Labrador, J., Echavarría, P., Martínez-Vega, J.

Laboratorio de Espectro-radiometría y Teledetección Ambiental (SpecLab), Instituto de Economía, Geografía y Demografía, Consejo Superior de Investigaciones Científicas (CSIC).

Resumen: Este trabajo aborda la estimación de variables biofísicas de un pastizal de dehesa a partir de información óptica generada por sensores próximos y remotos. Las variables de contenido de humedad del combustible (*FMC*), contenido de agua del dosel (*CWC*), índice de área foliar (*LAI*), materia seca (*Cm*) y biomasa superficial (*AGB*) fueron estimadas en laboratorio a partir de muestras de vegetación tomadas simultáneamente a la adquisición de datos hiperespectrales del sensor *Compact Airbone Spectrographic Imager* (CASI) y del espectro-radiómetro de campo ASD FieldSpec® 3. A partir de la información espectral se han calculado diversos índices extraídos de la literatura y se han analizado las relaciones lineales existentes con las variables biofísicas medidas en campo. Los resultados muestran relaciones consistentes entre las variables biofísicas y los índices espectrales, especialmente en el caso de los índices basados en bandas del infrarrojo medio de onda corta (SWIR) y del *red-edge*, poniendo de manifiesto la importancia de estas regiones en la estimación de variables biofísicas en cubiertas de pastizal. Se han obtenido coeficientes de determinación (R^2) superiores a 0,91 y un error cuadrático medio relativo (*RRMSE*) de 21,4%, para los índices espectrales calculados con datos ASD; y R^2 de 0,91 y *RRMSE* de 15,5% para los índices espectrales calculados con datos CASI.

Palabras clave: espectro-radiometría de campo, imágenes hiperespectrales aeroportadas, variables biofísicas, pastizal, CASI, índices espectrales.

Estimation of grassland biophysical parameters in a “dehesa” ecosystem from field spectroscopy and airborne hyperspectral imagery

Abstract: The aim of this paper is the estimation of biophysical vegetation parameters from its optical properties. The variables Fuel Moisture Content (*FMC*), Canopy Water Content (*CWC*), Leaf Area Index (*LAI*), dry matter (*Cm*) and Above-Ground Biomass (*AGB*) were estimated in the laboratory from vegetation samples collected simultaneously with the acquisition of spectral data from the Compact Airborne Spectrographic Imager (CASI) sensor and the field spectroradiometer ASD FieldSpec® 3. Spectral vegetation indices found in the literature were computed from hyperspectral data. Their linear relationships with the biophysical variables measured in the field were analysed. Results show consistent relationships between analysed biophysical parameters and spectral indices, mainly those using SWIR and red-edge

To cite this article: Melendo-Vega, J.R., Martín, M.P., Vilar del Hoyo, L., Pacheco-Labrador, J., Echavarría, P., Martínez-Vega, J. 2017. Estimation of grassland biophysical parameters in a “dehesa” ecosystem from field spectroscopy and airborne hyperspectral imagery. *Revista de Teledetección*, 48, 13-28. <https://doi.org/10.4995/raet.2017.7481>

* Autor para la correspondencia: joseramon.melendo@cchs.csic.es

bands which reveal the importance of these spectral regions for the estimation of biophysical variables in herbaceous covers. Determination coefficients (R^2) above 0.91 and $RRMSE$ of 21.4% have been obtained for the spectral indexes calculated whit ASD data, and 0.91 R^2 and $RRMSE$ of 15.5% for the spectral indexes calculated whit CASI data.

Keywords: field spectroscopy, airborne hyperspectral imagery, biophysical parameters, grassland, CASI, spectral indices.

1. Introducción

La estimación de variables biofísicas de la vegetación es fundamental para conocer el papel que ésta juega en las funciones ecofisiológicas y para evaluar el impacto que el cambio climático y la actividad humana tienen sobre el medio natural. La relación existente entre la respuesta espectral de la vegetación y su estado ha permitido que la teledetección se consolide como una herramienta útil a la hora de realizar estas estimaciones.

Una de las variables biofísicas de la vegetación de mayor relevancia por su interés en aplicaciones del ámbito agrícola y forestal es el contenido de humedad de la vegetación (Gao, 1996; Zarco-Tejada et al., 1999). Esta variable se cuantifica utilizando diversas métricas, como el contenido de humedad del combustible (FMC) o el contenido de agua del dosel (CWC). El FMC es un parámetro ampliamente empleado en estudios de prevención de incendios por afectar directamente a factores como la ignición o la propagación del fuego pero también en otras aplicaciones como en estudios relacionados con la agricultura de precisión (Chuvieco et al., 2002; Stagakis et al., 2012). Se define como la proporción de peso fresco respecto del peso seco de la muestra vegetal y se calcula a partir de la siguiente expresión:

$$FMC(\%) = \frac{W_f - W_d}{W_d} \times 100 \quad (1)$$

Donde W_f es el peso fresco de la muestra y W_d el peso seco de la misma. Por su parte, CWC es un indicador del estrés hídrico de la cubierta vegetal a nivel de dosel y se ha utilizado en diversas aplicaciones ambientales relacionadas con estudios ecofisiológicos (Ustin et al., 2004), agricultura de precisión (Yi et al., 2014), estudios de variabilidad intra-diaria de la cubierta vegetal (Cheng et al., 2013; Cheng et al., 2014) y estudios forestales de diversa índole (Gao, 1996; Ustin et al., 1998). Este parámetro biofísico se define como el peso del agua por unidad de área de hoja y por unidad

de superficie de suelo muestreada (A_{plot}). De forma simplificada se puede calcular como:

$$CWC(g/cm^2) = \frac{W_f - W_d}{A_{plot}} \quad (2)$$

Otra variable biofísica de gran relevancia en estudios de vegetación es el índice de área foliar (LAI). Su importancia reside en su relación con un gran número de procesos biológicos y físicos de la vegetación como la fotosíntesis, la transpiración o el ciclo del agua, nutrientes y carbono (Chen y Cihlar, 1996; Demarty et al., 2007; Reichstein et al., 2003). Se calcula mediante la siguiente fórmula:

$$LAI(cm^2/cm^2) = \frac{A_{Leaf}}{A_{plot}} \quad (3)$$

Donde A_{Leaf} es el área foliar y A_{plot} es la superficie de suelo muestreada. Finalmente, la materia seca (Cm) y la biomasa superficial (AGB) son variables biofísicas ampliamente utilizadas en estudios ambientales y socioeconómicos como los aprovechamientos agropecuarios y forestales (Li et al., 2015; Schucknecht et al., 2015). Su estimación resulta clave a la hora de estudiar los factores climáticos globales, especialmente los relacionados con las reservas de carbono existentes en los suelos (Li et al., 2015). Las fórmulas de ambas variables son las siguientes:

$$Cm(g/cm^2) = \frac{W_d}{A_{Leaf}} \quad (4)$$

$$AGB(g/cm^2) = \frac{W_d}{A_{plot}} \quad (5)$$

La estimación directa de estas variables está asociada a la realización de campañas de muestreo en terreno que suponen un elevado coste humano y económico. En este contexto, la teledetección plantea una alternativa viable que proporciona datos exhaustivos espacialmente explícitos a una resolución temporal suficiente para el estudio de la evolución y características de las cubiertas vegetales (Chen, 1996; Cheng et al., 2014; Chuvieco et al., 2004; Li et al., 2015; Stagakis et al., 2012;

Yebra *et al.*, 2008; Zarco-Tejada *et al.*, 1999). La existencia de ciertas zonas en el espectro, como el *red-edge* o el infrarrojo medio de onda corta (SWIR), que son especialmente sensibles a los cambios de estado de la vegetación, ha permitido estimar con éxito variables biofísicas (Pacheco-Labrador *et al.*, 2014; Richter *et al.*, 2012; Zarco-Tejada *et al.*, 2003). En los últimos años el desarrollo de sensores con mejores capacidades espectrales (mayor número de bandas y regiones espectrales) ha contribuido al descubrimiento de nuevas regiones de interés que son claves en procesos como la fotosíntesis y en variables clave como la producción primaria bruta (GPP) (Cogliati *et al.*, 2015; Wieneke *et al.*, 2016).

Por otro lado, la heterogeneidad espacial supone una dificultad para la estimación remota del estado y función de la vegetación, especialmente a partir de sensores multispectrales localizados en plataformas satelitales. El seguimiento del estado de la vegetación requiere una alta frecuencia temporal pero ésta limita habitualmente la resolución espacial. Esto provoca que los diferentes elementos de una escena localizada en un ecosistema heterogéneo como la dehesa, donde se mezclan tipos de vegetación con un comportamiento espectral muy dispar (árboles, pasto, agua, suelo, etc), no puedan ser discriminados por sensores de media y baja resolución espacial, produciéndose problemas derivados de la mezcla de la respuesta espectral de distintas cubiertas dentro del pixel (Hill *et al.*, 2011).

Los datos hiperespectrales procedentes de radiómetros de campo y de sensores aeroportados se han empleado en un buen número de estudios para diversas aplicaciones. Sin embargo, en muchos trabajos estos datos hiperespectrales han estado limitados a una sola fecha de adquisición por el elevado coste que requiere su obtención, especialmente en el caso de sensores aeroportados. Algunos autores como Fernández *et al.* (2015) y Serrano *et al.* (2002) que han realizado estimaciones de variables biofísicas de la vegetación como el contenido de humedad, el nitrógeno o la lignina en un ecosistema mediterráneo, manifiestan el interés de incluir la dimensión temporal, especialmente en ecosistemas con alta variabilidad fenológica. Otros estudios como el de Schmidlein y Sassín (2004), en el que se modelizaron y cartografiaron gradientes florísticos a partir de

datos hiperespectrales, muestran la importancia de utilizar una serie multitemporal de imágenes hiperespectrales para validar la metodología utilizada en su investigación.

En el presente estudio se plantea la estimación de las variables *FMC*, *CWC*, *LAI*, *Cm* y *AGB* de una cubierta de pastizal en una zona de dehesa a partir de datos hiperespectrales adquiridos en dos momentos del ciclo fenológico y a dos escalas espaciales: imágenes aeroportadas obtenidas con el sensor CASI y espectros medidos en terreno mediante un espectro-radiómetro de campo ASD Fieldspec 3® (ASD Inc., Boulder, Colorado, Estados Unidos). A partir de estos datos se han calculado una serie de índices de vegetación usando la información espectral original así como datos espectrales remuestreados a la resolución del sensor *Multispectral Instrument* (MSI) a bordo del Sentinel-2. Los índices hiperespectrales y multispectrales derivados se han correlacionado mediante técnicas de regresión lineal, con los datos de campo obtenidos a partir de distintos muestreos realizados en el área de estudio de forma simultánea a la adquisición de datos ópticos. Los modelos generados han permitido derivar mapas de las variables analizadas a partir de la serie de imágenes CASI disponible.

2. Metodología

2.1. Área de estudio

El área de estudio se localiza en el término municipal de Majadas del Tiétar, en el noreste de la provincia de Cáceres. Se trata de un ecosistema de dehesa con un uso ganadero extensivo de ganado bovino. El clima en la zona es mediterráneo con una temperatura media anual de 16,7°C y una precipitación media anual de 572 mm (González-Cascón *et al.*, 2016). La vegetación se organiza en dos estratos con características biofísicas y fenológicas muy diferenciadas. El estrato arbóreo, compuesto principalmente por encinas (*Quercus Ilex* ssp. *Ballota* (L)), cubre el 16% de la superficie. El estrato herbáceo cubre la mayor parte del área y se caracteriza por tener un ciclo fenológico muy dinámico. La zona de estudio seleccionada para el trabajo se sitúa en torno a una torre de medición de flujos de agua y de carbono mediante el método *Eddy covariance* que opera en la zona

desde el año 2003 y que está incluida en las redes CARBORED (<http://www.ceam.es/carboredes/>) y FLUXNET (<http://fluxnet.ornl.gov/>).

2.2. Variables biofísicas

Con objeto de obtener los datos necesarios para la calibración y validación de los modelos propuestos en este estudio se muestrearon en campo un total de 11 parcelas de 25×25 m localizadas en un radio máximo de 600 m en torno a la torre de medición de flujos (Figura 1).

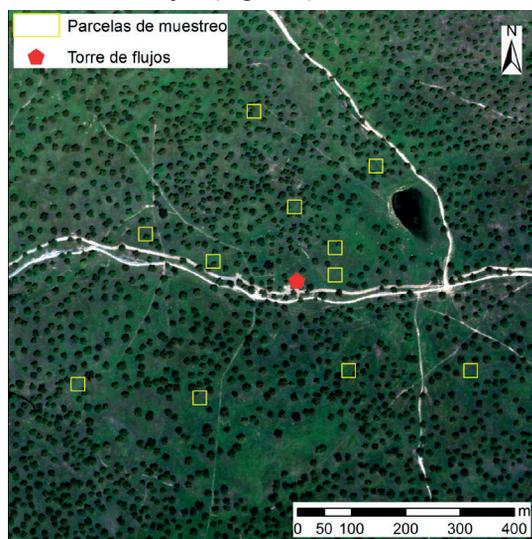


Figura 1. Distribución de las parcelas de muestreo en el área de estudio

Estas parcelas se distribuyeron de forma aleatoria de acuerdo al protocolo propuesto en el proyecto Biospec (<http://www.lineas.cchs.csic.es/biospec/>). En estas parcelas se realizaron muestreos destructivos del pasto entre los años 2009 y 2016, que coincidieron con la obtención de datos espectrales a partir de sensores terrestres y aeroportados. En cada parcela se tomaron muestras de pasto sobre 3 cuadrantes de 25×25 cm localizados de forma semi-aleatoria en aquellas zonas identificadas visualmente por el operador como representativas del conjunto de la parcela de 25×25 m. Si en la parcela había uno o más árboles, al menos uno de los 3 cuadrantes se localizó bajo el área de influencia de la copa del árbol donde el pasto suele tener características distintas debido al efecto del sombreado y al aporte de materia seca muerta.

El procesamiento de las muestras vegetales en el laboratorio comenzó con la separación manual de

una submuestra representativa de la muestra total. La cantidad de submuestra seleccionada varió en función del peso de la muestra total siendo en cualquier caso superior al 18% de la misma. Cada una de las submuestras fue escaneada (Epson Perfection V30 color scanner) con el fin de realizar el cálculo del área foliar. Para ello se obtuvieron clasificaciones no supervisadas de las imágenes escaneadas utilizando el algoritmo ISOCLUS con 16 iteraciones empleándose tanto el software PCI (<http://www.pcigeomatics.com>) como Matlab® (Mathworks, Batick, Massachusetts, USA). Posteriormente, las muestras se secaron en una estufa a 60°C durante 48 horas obteniéndose su peso seco. Con los datos obtenidos en el procesamiento del laboratorio se procedió a calcular las variables biofísicas del estudio. El tamaño de la muestra (n) y su distribución (Tabla 1) varió en función del parámetro estimado: FMC , $n=31$; CWC , $n=33$; LAI , $n=28$; Cm , $n=28$; AGB , $n=33$.

Tabla 1. Estadísticas de las variables medidas en campo para este estudio.

Variable	Min	Max	Rango	Promedio
FMC (%)	31,04	427,84	396,80	269,41
CWC (g/cm ²)	0,0004	0,73	0,07	0,03
LAI (cm ² /cm ²)	0,04	3,09	3,05	1,73
Cm (g/cm ²)	0,004	0,02	0,01	0,007
AGB (g/cm ²)	0,0005	0,02	0,02	0,01

2.3. Datos hiperespectrales

2.3.1. Imágenes aeroportadas

En este trabajo se han utilizado 3 imágenes adquiridas por el sensor hiperespectral aeroportado CASI (*Compact Airborne Spectrographic Imager*) los días 5 de mayo de 2011, 4 de octubre de 2012 y 8 de abril de 2014. CASI fue configurado para adquirir información en 144 bandas repartidas entre 350 nm y 1050 nm aproximadamente, con un ancho de banda (*Full Width at Half Maximum* - FWHM) de 7,5 nm y una resolución espacial que oscila entre 0,5 y 1,5 m (de Miguel *et al.*, 2014). Todos los vuelos fueron realizados en torno a las 12:00 horas solares en condiciones de cielo descubierta. Las imágenes utilizadas en este estudio pueden considerarse representativas de los dos extremos del ciclo fenológico del ecosistema, caracterizados por un fuerte contraste entre un pasto verde y desarrollado en primavera, y seco y prácticamente carente de actividad fotosintética al final

Tabla 2. Índices espectrales utilizados para la estimación de variables biofísicas de la vegetación.

Índices	Sensor	Fórmula	Referencia
Índices multiespectrales calculados con bandas remuestreadas al sensor MSI (Sentinel-2)			
NDVI	CASI/ASD	$\frac{R_{NIR} - R_R}{R_{NIR} + R_R}$	(Rouse <i>et al.</i> , 1974)
NDII	ASD	$\frac{R_{NIR} - R_{SWIR}}{R_{NIR} + R_{SWIR}}$	(Hardisky <i>et al.</i> , 1983)
EVI	CASI/ASD	$2,5 \left(\frac{R_{NIR} - R_R}{R_{NIR} + 6R_R - 7,5R_B} + 1 \right)$	(Huete <i>et al.</i> , 2002)
NDWII	ASD	$\frac{R_{NIR} - R_{SWIR}}{R_{NIR} + R_{SWIR}}$	(Gao 1996)
SRWI	ASD	$\frac{R_{NIR}}{R_{SWIR}}$	(Zarco-Tejada y Ustin 2001)
GVMi	ASD	$\frac{(R_{NIR} + 0,1) - (R_{SWIR} - 0,002)}{(R_{NIR} + 0,1) + (R_{SWIR} - 0,002)}$	(Ceccato <i>et al.</i> , 2002)
RDVI	CASI/ASD	$\frac{(R_{800} - R_{670})}{\sqrt{(R_{800} + R_{670})}}$	(Roujean y Breon 1995)
MSR	CASI/ASD	$\frac{\left(\frac{R_{800}}{R_{670}} - 1 \right)}{\sqrt{\left(\frac{R_{800}}{R_{670}} + 1 \right)}}$	(Chen 1996)
SAVI	CASI/ASD	$\frac{(1 + L) \times (R_{800} - R_{670})}{(R_{800} + R_{670} + L)}$	(Huete 1988)
MSAVI	CASI/ASD	$0,5 \cdot [2 \cdot R_{800} + 1 - \sqrt{(2 \cdot R_{800} + 1)^2 - 8 \cdot (R_{800} - R_{670})}]$	(Qi <i>et al.</i> , 1994)
MCARI	CASI/ASD	$[(R_{700} - R_{670}) - 0,2 \cdot (R_{700} - R_{550})] \cdot \left(\frac{R_{700}}{R_{670}} \right)$	(Daughtry <i>et al.</i> , 2000)
MCARI1	CASI/ASD	$1,2 \cdot [2,5 \cdot (R_{800} - R_{670}) - 1,3 \cdot (R_{800} - R_{550})]$	(Haboudane <i>et al.</i> , 2004)
MCARI2	CASI/ASD	$\frac{1,5[(R_{800} - R_{550}) - 2,5(R_{670} - R_{550})]}{\sqrt{(2R_{800} + 1)^2 - (6R_{800} - 5\sqrt{R_{670}}) - 0,5}}$	(Haboudane <i>et al.</i> , 2004)
GEMI	CASI/ASD	$[\eta \cdot (1 - 0,25 \cdot \eta)] - \frac{R_R - 0,125}{1 - R_R}$	(Pinty y Verstraete 1992)
VARI	CASI/ASD	$\frac{R_G - R_R}{R_G + R_R - R_B}$	(Gitelson <i>et al.</i> , 2002)
SARVI	CASI/ASD	$\frac{(1 + L)(R_{800} - R_{rb})}{R_{800} + R_{rb} + L}$	(Haboudane <i>et al.</i> , 2004)
PRI	CASI/ASD	$\frac{R_{531} - R_{570}}{R_{531} + R_{570}}$	(Gamon <i>et al.</i> , 1992)
Índices hiperespectrales calculados con bandas CASI y ASD originales			
TVI	CASI/ASD	$[120 \cdot (R_{750} - R_{550}) - 200 \cdot (R_{670} - R_{550})]$	(Broge y Leblanc, 2001)
MTVI1	CASI/ASD	$1,2 \cdot [1,2 \cdot (R_{800} - R_{550}) - 2,5 \cdot (R_{670} - R_{550})]$	(Haboudane <i>et al.</i> , 2004)
MTVI2	CASI/ASD	$\frac{1,5 \cdot [2,5 \cdot (R_{800} - R_{550}) - 2,5 \cdot (R_{670} - R_{550})]}{\sqrt{(2 \cdot R_{800} + 1)^2 - (6 \cdot R_{800} - 5 \cdot \sqrt{R_{670}}) - 0,5}}$	(Haboudane <i>et al.</i> , 2004)
CAI	ASD	$100 \cdot (0,5 \cdot (R_{2030} + R_{2210}) - R_{2100})$	(Nagler <i>et al.</i> , 2000)
NDBLeaf	ASD	$\frac{R_{2160} - R_{1540}}{R_{2160} + R_{1540}}$	(le Maire <i>et al.</i> , 2004)

del verano (Mendiguren *et al.*, 2015; Migliavacca *et al.*, 2017; Perez-Priego *et al.*, 2015). En cada campaña se realizaron varias pasadas para cubrir completamente y con distintas geometrías de observación la zona de interés, si bien en este trabajo se ha utilizado una única imagen por fecha. Para las campañas de 2011 y 2012 se seleccionó la pasada correspondiente al plano solar para minimizar el efecto de las sombras. En la campaña de 2014 se modificó la configuración del vuelo y no se adquirió pasada en el plano solar por lo que, en su lugar, se seleccionó para este estudio una pasada con un rumbo de 253°. Las imágenes fueron corregidas geoméricamente y atmosféricamente por el Instituto Nacional de Técnica Aeroespacial (INTA) tal y como se describe en de Miguel *et al.* (2014). La corrección atmosférica fue realizada con el software ATCOR4 (<http://www.rese.ch/products/atcor/atcor4/>), y fue refinada mediante el método de *Empirical Line correction* (Ferrier y Trahair, 1995; Smith y Milton, 1999) empleando superficies de referencia medidas con el espectroradiómetro ASD Fieldspec® 3 simultáneamente a la adquisición de las imágenes.

Con objeto de aislar en las imágenes CASI las zonas de pasto de otras cubiertas como encinas, sombras, suelos y láminas de agua, se realizó una clasificación supervisada de cada imagen utilizando el método de la distancia de Mahalanobis (Mahalanobis, 1936). Después se procedió a extraer los valores de reflectividad de los píxeles clasificados como pasto incluidos en las 11 parcelas de muestreo para todas las bandas de cada imagen calculándose el valor medio para cada parcela. A partir de estas clasificaciones se obtuvo además la cobertura arbórea del área de estudio.

A continuación, se remuestrearon los datos CASI a las bandas del sensor MSI, a bordo del Sentinel-2, utilizando para ello el *software* ENVI (<http://www.exelisvis.com/ProductsServices/ENVIProducts.aspx>) que utiliza una función gaussiana como respuesta espectral de cada una de las bandas del sensor. En este caso, sólo pudieron ser remuestreadas aquellas bandas del MSI que se encontraban dentro del rango espectral del sensor CASI (bandas 1 a 9).

A partir de las bandas originales y remuestreadas se calcularon una serie de índices espectrales seleccionados de entre los propuestos en la literatura para estimar cada una de las variables biofísicas

estudiadas (Tabla 2). Los índices hiperespectrales se calcularon a partir de las bandas originales del sensor CASI utilizando la banda más próxima a la propuesta por el índice. Para los índices multiespectrales se utilizaron los datos remuestreados al sensor MSI escogiendo las bandas correspondientes a las regiones espectrales requeridas en cada caso. La ausencia, en el sensor CASI, de bandas en la región del SWIR impidió el cálculo de índices que utilizan información en esa región espectral.

2.3.2. Radiometría de campo

De forma simultánea a la adquisición de las imágenes CASI y a los muestreos de vegetación, se tomaron datos espectrales en campo utilizando para ello un espectro-radiómetro ASD Fieldspec® 3, que trabaja con un rango espectral entre 400 y 2500 nm y una resolución entre 3 y 10 nm (remuestreada a 1 nm). En cada una de las 11 parcelas de muestreo se midieron dos transectos con direcciones NW-SE y NE-SW. Las mediciones se realizaron colocando la fibra del sensor aproximadamente a 1,2 m de altura, lo que supone un área observada en cada medición de unos 50 cm de diámetro. Al principio de cada uno de los transectos se realizó una medida sobre un panel calibrado de Spectralon® para medir el flujo incidente de radiación en las parcelas de muestreo.

Los datos ASD fueron igualmente remuestreados a las bandas del sensor MSI tal y como se ha descrito para las imágenes CASI. Posteriormente, se calcularon los mismos índices espectrales seleccionados añadiendo, en este caso, los que incluían la región del SWIR para su cálculo (Tabla 2). Para el cálculo de los índices hiperespectrales se utilizaron las bandas ASD originales.

2.4. Análisis estadístico

2.4.1. Análisis exploratorio

Las variables biofísicas obtenidas en los muestreos de campo fueron sometidas a un primer análisis exploratorio mediante diagramas de cajas lo que permitió determinar su variabilidad espacial y temporal.

Tras realizar la prueba de normalidad de Shapiro-Wilk (Shapiro y Wilk, 1965) se realizó un test estadístico de diferencia de medias entre valores estimados a partir de muestras recogidas dentro y

fuera de la influencia de las copas de los árboles con objeto de comprobar si las interacciones existentes entre pasto y arbolado (Scholes y Archer, 1997) producían diferencias estadísticamente significativas para las variables analizadas.

Para entender cómo funciona el ecosistema a nivel espectral se calculó el NDVI en cada una de las parcelas con los datos CASI y ASD y se realizó también un primer análisis mediante un diagrama de cajas.

2.4.2. Modelos de regresión lineal

Se utilizaron técnicas de regresión lineal para analizar las relaciones entre los índices espectrales calculados, tanto con CASI como con ASD, y las variables biofísicas medidas en terreno. La consistencia de cada uno de estos modelos de regresión fue verificada aplicando técnicas de *bootstrapping* (Efron, 1979). Posteriormente se calculó el error relativo (*RRMSE*) con objeto de hacer más comparables los errores calculados para cada variable.

2.5. Cartografía de variables biofísicas a partir de imágenes CASI

Los modelos de regresión con los *RRMSE* más bajos obtenidos para cada variable biofísica se aplicaron a los píxeles de pasto de las 3 imágenes CASI, lo que permitió obtener la distribución espacial de cada variable en el momento de adquisición de las imágenes dentro del área de estudio.

3. Resultados

3.1. Análisis Exploratorio

Como se observa en la Figura 2, las variables biofísicas presentan una considerable dispersión en todos los muestreos que se explica por la elevada variabilidad espacial del pasto a nivel intra e inter-parcelario. Este fenómeno es especialmente notable en los muestreos de primavera y con ciertas variables biofísicas como *CWC*, *LAI* y *AGB*.

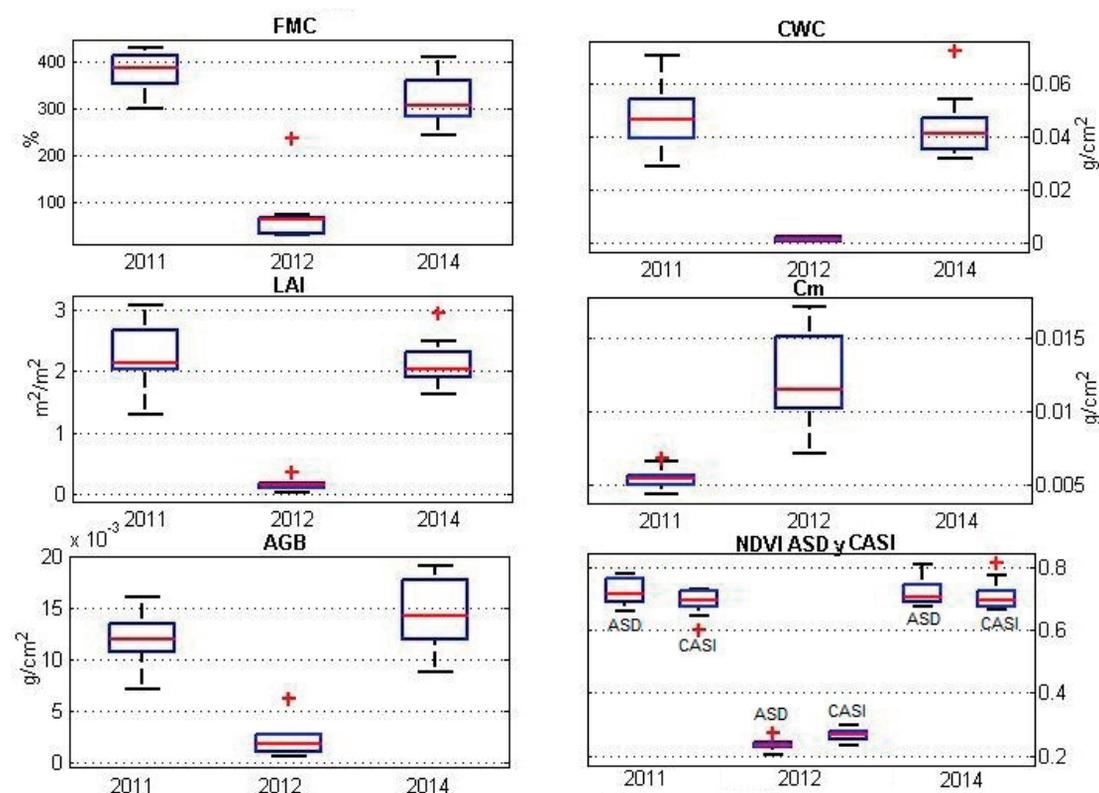


Figura 2. Diagramas de cajas de las variables biofísicas muestreadas en campo los días 5 de mayo de 2011, 4 de octubre de 2012 y 8 de abril de 2014 y de los datos espectrales ASD y CASI tomados en las mismas fechas.

En el caso del *FMC*, la dispersión es baja en todas las fechas excepto en abril de 2014; mientras que para *Cm* la dispersión es baja en primavera pero aumenta considerablemente en el muestreo de otoño. Por el contrario, las variables espectrales presentan una dispersión considerablemente menor.

Los resultados del test de normalidad de Shapiro-Wilk indicaron que las variables biofísicas medidas en campo no presentaban una distribución normal por lo que se aplicó un test de diferencia de medias no paramétrico, el test de Wilcoxon (Wilcoxon, 1945). Los resultados del test (Tabla 3) permitieron aceptar la hipótesis nula confirmando que no existían diferencias estadísticamente significativas entre las variables estimadas con muestras de pasto recogidas dentro y fuera del área de influencia de la copa de las encinas.

Tabla 3. Resultados del test Wilcoxon

Variable	Significación
<i>FMC</i>	0,117
<i>CWC</i>	0,411
<i>LAI</i>	0,650
<i>Cm</i>	0,087
<i>AGB</i>	0,502

3.2. Modelos de regresión lineal

Como se puede apreciar en la Tabla 4, los índices calculados con CASI que mejores resultados han presentado a la hora de estimar *FMC* y *CWC* fueron el RDVI y el MSR con un error relativo (*RRMSE*) del 15,5% y 24,4% y un coeficiente de determinación (R^2) de 0,91 y 0,90 respectivamente. El NDVI ofreció los mejores ajustes para *LAI* (*RRMSE* de 22,6% y R^2 de 0,84) y *AGB* (*RRMSE* de 30,0% y R^2 de 0,77). Para *Cm* el índice que presentó los mejores ajustes fue el RDVI con un *RRMSE* del 23,7% y un R^2 de 0,69.

En lo que respecta a los índices calculados a partir de los datos de espectro-radiometría de campo, (Tabla 5) el mejor estimador de *FMC* fue el índice NDBLeaf con un *RRMSE* del 15,5% y un R^2 de 0,90. Para *CWC* los índices que presentaron menor error fueron el NDWII y el MSR con un *RRMSE* del 21,4% y un R^2 de 0,92. En el caso del *LAI* los mejores ajustes se obtuvieron con el NDII (*RRMSE* 18,8% y R^2 0,84). Por último, para *Cm* y *AGB* los índices que ofrecieron mejores resultados fueron el GVMI y el VARI con un *RRMSE* del 19,0% y 31,0% y un R^2 de 0,78 y 0,74 respectivamente.

Tabla 4. Resultados de la regresión lineal entre los variables biofísicas y los índices espectrales calculados a partir de los datos CASI.

Índice	<i>FMC</i>		<i>CWC</i>		<i>LAI</i>		<i>Cm</i>		<i>AGB</i>	
	R^2	<i>RRMSE</i>	R^2	<i>RRMSE</i>	R^2	<i>RRMSE</i>	R^2	<i>RRMSE</i>	R^2	<i>RRMSE</i>
NDVI	0,86	19,1	0,89	25,6	0,84	22,6	0,65	25,1	0,77	30,0
GEMI	0,88	17,8	0,82	32,6	0,71	30,0	0,67	24,9	0,55	41,5
EVI	0,81	22,2	0,74	39,1	0,59	35,8	0,58	27,8	0,45	45,8
VARI	0,81	22,2	0,88	26,4	0,79	25,5	0,59	27,4	0,75	30,9
RDVI	0,91	15,5	0,88	26,9	0,80	24,9	0,69	23,7	0,66	36,3
MSR	0,83	21,4	0,90	24,4	0,81	24,5	0,59	27,2	0,75	30,7
SAVI	0,91	15,8	0,87	27,2	0,80	25,3	0,69	23,9	0,65	36,7
MSAVI	0,91	15,8	0,86	28,3	0,76	27,5	0,65	25,3	0,61	38,7
SARVI	0,90	16,0	0,87	27,8	0,78	26,4	0,67	24,6	0,63	37,8
MCARI	0,87	18,2	0,88	26,6	0,79	25,6	0,64	25,5	0,66	36,2
MCARI1	0,89	16,7	0,84	30,2	0,75	27,7	0,68	24,3	0,60	39,4
MCARI2	0,90	16,6	0,88	26,5	0,79	25,5	0,67	24,6	0,66	36,4
TVI	0,90	16,3	0,85	29,2	0,78	26,6	0,68	24,0	0,62	38,2
MTVI1	0,90	16,1	0,86	29,0	0,77	26,7	0,68	24,0	0,62	38,3
MTVI2	0,90	16,5	0,88	26,1	0,80	25,1	0,67	24,5	0,67	35,9
PRI	0,28	43,4	0,52	53,2	0,47	40,7	0,23	37,4	0,52	42,8

Tabla 5. Resultados de la regresión lineal entre los variables biofísicas y los índices espectrales calculados a partir de los datos del espectro-radiómetro de campo.

Índice	FMC		CWC		LAI		Cm		AGB	
	R ²	RRMSE								
NDVI	0,84	19,7	0,86	27,3	0,80	21,0	0,69	22,6	0,70	32,5
GEMI	0,83	20,7	0,85	28,7	0,71	25,5	0,67	23,3	0,58	38,3
NDII	0,84	20,0	0,90	23,3	0,84	18,8	0,76	19,7	0,68	33,5
EVI	0,79	22,6	0,75	36,6	0,56	31,1	0,53	27,8	0,46	43,6
NDWII	0,80	22,0	0,92	21,4	0,81	20,3	0,72	21,6	0,69	32,6
SRWI	0,74	25,1	0,91	21,9	0,75	23,4	0,57	26,5	0,64	35,6
VARI	0,77	23,9	0,90	23,1	0,79	21,3	0,68	23,0	0,74	31,0
GVMÍ	0,84	19,6	0,88	25,5	0,83	19,5	0,78	19,0	0,69	33,1
RDVI	0,87	18,3	0,88	25,7	0,78	22,3	0,74	20,6	0,63	35,8
MSR	0,83	21,0	0,92	21,4	0,83	19,5	0,69	22,5	0,70	32,3
SAVI	0,86	18,2	0,88	25,9	0,77	22,7	0,74	20,6	0,62	36,3
MSAVI	0,85	19,2	0,88	25,2	0,74	23,9	0,69	22,5	0,59	37,7
SARVI	0,86	19,0	0,88	25,1	0,79	21,3	0,75	20,1	0,66	34,2
MCARI	0,84	19,8	0,89	24,3	0,78	22,1	0,72	21,6	0,63	35,7
MCARI1	0,87	18,4	0,87	26,7	0,74	23,9	0,74	20,7	0,60	37,4
MCARI2	0,85	19,1	0,89	24,7	0,77	22,5	0,72	21,3	0,63	35,9
TVI	0,86	18,9	0,88	26,0	0,76	23,0	0,75	20,1	0,62	36,3
MTVI1	0,86	18,6	0,87	26,2	0,76	23,2	0,75	20,2	0,62	36,5
MTVI2	0,86	19,1	0,88	25,1	0,77	22,5	0,74	20,6	0,63	35,8
PRI	0,36	39,5	0,64	44,0	0,41	36,0	0,15	37,4	0,67	34,0
CAI	0,84	19,9	0,71	39,8	0,67	26,8	0,52	28,1	0,56	39,0
NDBLeaf	0,90	15,8	0,85	28,6	0,71	25,2	0,75	20,4	0,53	40,5

El índice espectral que peores ajustes presentó en todos los casos fue el PRI con valores de R² iguales o inferiores a 0,52 para todas las variables en los modelos procedentes de datos CASI; e iguales o inferiores a 0,67 para los derivados de ASD.

3.3. Cartografía de variables biofísicas a partir de imágenes CASI

A partir de las ecuaciones de regresión correspondientes a los mejores RRMSE obtenidos con datos CASI (Tabla 6), se ha estimado la distribución espacial de las variables biofísicas analizadas (FMC, CWC, LAI, Cm y AGB) para todos los píxeles identificados como pastizal en cada una de las imágenes CASI.

Tabla 6. Modelos de regresión utilizados en la estimación de variables biofísicas.

Variable estimada	Ecuación recta de regresión	RRMSE (%)	R ²
FMC	-168,426+1202,938×RDVI	15,5	0,91
CWC	-0,015+0,033×MSR	24,4	0,90
LAI	-1,376+5,088×NDVI	22,6	0,84
Cm	0,017+(-0,026)×RDVI	23,7	0,69
AGB	-0,006+0,027×NDVI	30,0	0,77

En la Figura 3 se observa, como la distribución espacial de la mayor parte de las variables biofísicas analizadas está condicionada por el gradiente de humedad del suelo, siendo sus valores más elevados en zonas próximas a las láminas de agua localizadas en el noreste y en la vaguada del suroeste del área de estudio. Sin embargo, Cm no sigue un patrón tan claro a pesar de que en las imágenes de mayo pueden observarse valores más altos en las áreas en las que el encinar es algo más denso. Existe un fuerte contraste estacional entre los meses de primavera, donde el pastizal se encuentra en el periodo de máximo desarrollo, y el otoño, donde el pastizal aún no se ha recuperado del periodo estival. En estas imágenes también puede analizarse la fuerte interrelación que existe entre las variables biofísicas calculadas. Esto se aprecia más claramente en las zonas en las que el gradiente de humedad difiere del resto del territorio, como en la vaguada del suroeste.

4. Discusión

La utilización de datos hiperespectrales y multiespectrales en este estudio ha permitido comparar su capacidad para estimar variables biofísicas del

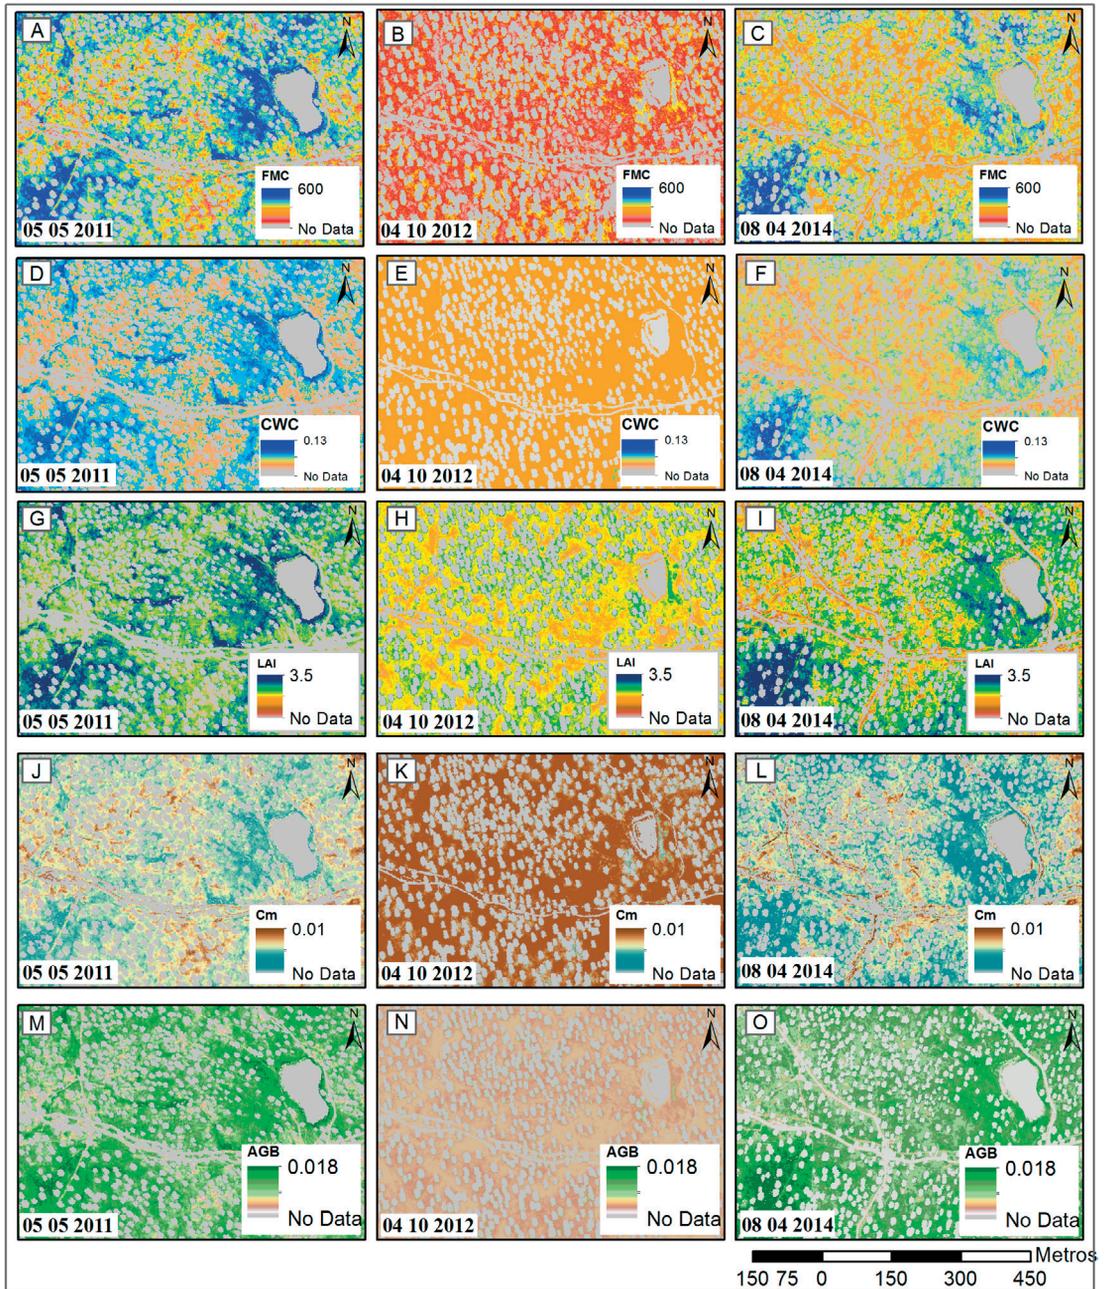


Figura 3. Mapas de estimación de las variables biofísicas estudiadas: *FMC* (A, B, C), *CWC* (D, E, F), *LAI* (G, H, I), *Cm* (J, K, L) y *AGB* (M, N, O) generados a partir de los modelos de la Tabla 6.

pastizal a partir de índices propuestos en la literatura. Los resultados obtenidos indican que los índices espectrales más idóneos son aquellos que utilizan para su cálculo las regiones del SWIR y el *red-edge*, lo que concuerda con los resultados derivados de trabajos previos (Delegido *et al.*,

2011; Herrmann *et al.*, 2011; Lee *et al.*, 2004; Liu *et al.*, 2004). El remuestreo realizado para simular las bandas del sensor MSI ha permitido analizar el interés de este sensor en el cálculo de ciertos índices espectrales que, en el caso de los calculados con datos CASI, han presentado las correlaciones

más altas, lo que demuestra el gran potencial de Sentinel-2 para estimar variables biofísicas de la vegetación (Delegido *et al.*, 2011; Frampton *et al.*, 2013).

Si se comparan los resultados obtenidos con el sensor CASI y con el espectro-radiómetro de campo puede observarse como los ajustes de ambos sensores son similares en aquellos índices que han sido calculados a partir de los datos remuestreados al sensor MSI. Las ligeras diferencias existentes podrían ser debidas a factores como el ratio señal-ruido (*Sensor to Noise Ratio*- SNR), específico de cada sensor, el impacto de la atmósfera o los ángulos de observación. Los índices que se han calculado con las bandas originales de ambos sensores han ofrecido mejor rendimiento con los datos CASI. La mayor capacidad de generalización que poseen los datos CASI frente al ASD en una cobertura que se caracteriza por aumentar su grado de heterogeneidad a medida que disminuye la escala, podría explicar esta diferencia. Además, la tipología de muestreo de campo, en la que la medida espectral tomada con ASD no coincide espacialmente de forma exacta con la medida biofísica, podría ser otro de los motivos que han condicionado los ajustes con este sensor.

Los resultados para *FMC* y *AGB* son ligeramente mejores con los datos CASI mientras que *CWC*, *LAI* y, especialmente, *Cm* presentan mejores ajustes con los datos ASD. En el caso del sensor CASI, los índices que mayor ajuste han presentado son aquellos que basan su formulación en el NDVI, como el RDVI (Roujean y Breon, 1995) o el MSR (Chen, 1996). Respecto a los datos ASD, los índices que, generalmente, han presentado mejores ajustes son aquellos que utilizan la región del SWIR. La utilización en el área de estudio de un sensor aeroportado que proporcione información en la región del SWIR a una escala de detalle similar a CASI, como el sensor AVIRIS, podría dar información sobre el grado de transcendencia que tiene su inclusión en este tipo de análisis con imágenes aeroportadas.

Del conjunto de variables biofísicas analizadas, la que menor ajuste con los datos espectrales ha presentado es *Cm*. Esto podría deberse a la ausencia de características espectrales únicas en las regiones del visible y el infrarrojo cercano; algo que sí ocurre en la región del SWIR (Nagler *et al.*, 2003). Ello explicaría que los índices calculados con el

espectro-radiómetro que utilizan la región del SWIR hayan mostrado mejores ajustes con R^2 muy próximos a 0,8 y un *RRMSE* de 23,7%, lo que demuestra la importancia del SWIR en la estimación de este parámetro. No obstante, la presencia de picos de absorción relacionados con el contenido de agua en esta región del espectro enmascara los picos de absorción de *Cm* limitando la capacidad de estimación como ya se ha comprobado en estudios previos (Casas *et al.*, 2014; Faurtyot y Baret 1997; Feret *et al.*, 2008; Riaño *et al.*, 2005). Por otra parte, índices hiperespectrales como el CAI, que fueron propuestos para estimar esta variable, no han alcanzado el grado de ajuste mostrado en otros estudios como el de HongRui *et al.* (2011) donde se evaluó la capacidad del CAI para estimar *Cm* en la estepa mongola. Este índice utiliza una banda centrada en el pico de absorción a 2,1 μm producido por compuestos estructurales como la celulosa (Elvidge 1990) y está fuertemente afectado por la presencia de vegetación verde debido a la atenuación que el contenido de humedad provoca sobre los picos de absorción de estos componentes. Diversos estudios (Daughtry *et al.*, 2006; Daughtry *et al.*, 2004) han demostrado que el índice no funciona correctamente en ecosistemas en los que la fracción verde sea superior al 30% lo que podría explicar los resultados en nuestro área de estudio donde la fracción verde es muy superior a este porcentaje la mayor parte del año.

La posibilidad de contar con datos espectrales y muestreos de campo en momentos bien diferenciados del ciclo fenológico del pastizal ha aportado información sobre la variabilidad temporal de la cubierta que resulta de gran interés en el análisis de ciertas variables que son clave a la hora de entender los ciclos energéticos del carbono, agua y nitrógeno. Por otra parte, esta información ayuda a interpretar las interrelaciones que se dan entre las variables dentro del ecosistema estudiado tal y como han demostrado otros autores (Casas *et al.*, 2014; Chuvieco *et al.*, 2001; Durá *et al.*, 2013; Privette *et al.*, 2002). En cuanto a la variabilidad espacial del pastizal, los datos revelan una cierta dispersión entre los parámetros calculados a partir de distintos cuadrantes y parcelas. Estos resultados coinciden con los de otros estudios realizados en el mismo área de estudio (Fernández *et al.*, 2015; Mendiguren *et al.*, 2015). En general, se observa mayor dispersión en variables como el *LAI* y el *AGB* lo que puede estar relacionado con el efecto

del pastoreo en la zona. La fuerte influencia de la componente temporal frente a la espacial en este ecosistema justifica la utilización de estrategias de muestreo en las que se prime la frecuencia de recogida de muestras frente al número de parcelas. Mendiguren *et al.* (2015) llegaron a conclusiones similares al estudiar la variabilidad estacional del contenido de humedad de la vegetación en la misma zona.

Cm presenta una dispersión espacial muy baja en primavera y mucho mayor en otoño. Una de las causas podría relacionarse con la presencia de especies como los cardos. Este tipo de vegetación posee un ciclo fenológico distinto al de la mayor parte de las especies de pastizal en la dehesa. Los cardos brotan a finales de la primavera cuando el pasto está prácticamente seco y se mantienen verdes durante todo el verano apareciendo agrupados en rodales y distribuidos de forma irregular en las distintas parcelas de muestreo. En otoño, cuando el pasto rebrota, los cardos se secan pero permanecen enraizados durante buena parte de la primavera. Esta alta variabilidad fenológica y espacial (debida tanto al pastoreo como a la distribución de las especies) limita la aplicación en este ecosistema, de metodologías como la propuesta por Casas *et al.* (2014) donde se proponía asumir un valor constante en *Cm* con el fin de facilitar el proceso de cálculo de las variables relacionadas con el contenido de agua como el *CWC*.

Resulta interesante el resultado obtenido con el índice espectral PRI que ha mostrado los peores ajustes con coeficientes de determinación (R^2) que, en el caso de los datos CASI, han presentado *RRMSE* superiores al 52%. Trabajos anteriores han mostrado la gran dependencia de este índice de la fracción de sombra de la vegetación observada enmascarando su relación con la eficiencia fotosintética, pero también con otras variables (Hernández-Clemente *et al.*, 2016; Hernández-Clemente *et al.*, 2011; Hilker *et al.*, 2008). La unicidad en el ángulo de observación así como el menor impacto de la atmósfera podría explicar que el ajuste haya sido mayor en las estimaciones obtenidas a partir de los datos ASD. Por otro lado, este índice presenta una alta sensibilidad a los efectos direccionales como concluyó Cheng *et al.* (2012) en un estudio donde calculó el PRI a partir de las simulaciones realizadas con el modelo de transferencia radiativa MCRM (Kuusk, 1995)

para analizar diferentes fases de crecimiento de un campo de maíz.

5. Conclusiones

En este estudio se ha analizado la capacidad de estimar variables biofísicas de un pastizal de dehesa a partir de sus propiedades ópticas. Para ello, se han utilizado datos espectrales procedentes de un espectro-radiómetro de campo y del sensor hiperespectral aeroportado CASI adquiridos en distintas fases del ciclo fenológico del pasto. Los resultados sugieren que las regiones espectrales del *red-edge* y el SWIR podrían ser las más relevantes para el estudio de este tipo de vegetación. No obstante, en este estudio se han empleado datos correspondientes a los extremos del ciclo fenológico, y por tanto, próximos a los límites del rango de variabilidad en condiciones naturales de las variables analizadas. Futuros estudios deberían completar la serie temporal añadiendo etapas intermedias del ciclo fenológico para testar la robustez de los modelos ajustados. Sería interesante analizar además la sensibilidad de los modelos al desajuste espacial entre los datos ópticos y las muestras biofísicas, especialmente en pastizales sujetos a pastoreo.

6. Agradecimientos

Este trabajo se ha realizado en el contexto de los proyectos BIOSPEC (CGL2008-02301/CLI) financiado por el Ministerio e Innovación y FLUXPEC (CGL2012-34383) financiado por el Ministerio de Economía y Competitividad. Agradecemos al Ministerio de Educación, Cultura y Deporte la financiación recibida a través del programa de becas FPU del investigador predoctoral José Ramón Melendo. Nuestro agradecimiento al personal de SpecLab-CSIC, Universidad de Alcalá e Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria que ha participado en la recogida y procesamiento de datos.

Referencias

- Casas, A., Riaño, D., Ustin, S.L., Dennison, P., Salas, J. 2014. Estimation of water-related biochemical and biophysical vegetation properties using multitemporal airborne hyperespectral data and its comparison to MODIS spectral response. *Remote Sensing of Environment*, 148, 28-41. <https://doi.org/10.1016/j.rse.2014.03.011>

- Ceccato, P., Flasse, S., Grégoire, J.M. 2002. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. *Remote Sensing of Environment*, 82(2-3), 198-207. [https://doi.org/10.1016/S0034-4257\(02\)00036-6](https://doi.org/10.1016/S0034-4257(02)00036-6)
- Cogliati, S., Rossini, M., Julitta, T., Meroni, M., Schickling, A., Burkart, A., Pinto, F., Rascher, U., Colombo, R. 2015. Continuous and long-term measurements of reflectance and sun-induced chlorophyll fluorescence by using novel automated field spectroscopy systems. *Remote Sensing of Environment*, 164, 270-281. <https://doi.org/10.1016/j.rse.2015.03.027>
- Chen, J.M. 1996. Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. *Canadian Journal of Remote Sensing*, 22(3), 229-242. <https://doi.org/10.1080/07038992.1996.10855178>
- Chen, J.M., Cihlar, J. 1996. Retrieving leaf area index of boreal conifer forests using Landsat TM images. *Remote Sensing of Environment*, 55(2), 153-162. [https://doi.org/10.1016/0034-4257\(95\)00195-6](https://doi.org/10.1016/0034-4257(95)00195-6)
- Cheng, T., Riaño, D., Koltunov, A., Whiting, M.L., Ustin, S.L., Rodriguez, J. 2013. Detection of diurnal variation in orchard canopy water content using MODIS/ASTER airborne simulator (MASTER) data. *Remote Sensing of Environment*, 132, 1-12. <https://doi.org/10.1016/j.rse.2012.12.024>
- Cheng, T., Riaño, D., Ustin, S. 2014. Detecting diurnal and seasonal variation in canopy water content of nut tree orchards from airborne imaging spectroscopy data using continuous wavelet analysis. *Remote Sensing of Environment*, 143, 39-53. <https://doi.org/10.1016/j.rse.2013.11.018>
- Cheng, Y.B., Middleton, E.M., Zhang, Q., Corp, L.A., Dandois, J., Kustas, W.P. 2012. The photochemical reflectance index from directional cornfield reflectances: Observations and simulations. *Remote Sensing of Environment*, 124, 444-453. <https://doi.org/10.1016/j.rse.2012.05.030>
- Chuvieco, E., Cocero, D., Riaño, D., Martín, M.P., Martínez-Vega, J., De la Riva, J., Pérez, F. 2004. Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. *Remote Sensing of Environment*, 92(3), 322-331. <https://doi.org/10.1016/j.rse.2004.01.019>
- Chuvieco, E., Riaño, D., Aguado, I., Cocero, D. 2002. Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: Applications in fire danger assessment. *International Journal of Remote Sensing*, 23(11), 2145-2162. <https://doi.org/10.1080/01431160110069818>
- Chuvieco, E., Salas, J., Aguado, I., Cocero, D., Riaño, D. 2001. Estimación del estado hídrico de la vegetación a partir de sensores de alta y baja resolución. *Geofocus*, 1, 1-16.
- Daughtry, C.S.T., Doraiswamy, P.C., Hunt Jr, E.R., Stern, A.J., McMurtrey III, J.E., Prueger, J.H. 2006. Remote sensing of crop residue cover and soil tillage intensity. *Soil and Tillage Research*, 91(1-2), 101-108. <https://doi.org/10.1016/j.still.2005.11.013>
- Daughtry, C.S.T., Hunt Jr, E.R., McMurtrey III, J.E. 2004. Assessing crop residue cover using shortwave infrared reflectance. *Remote Sensing of Environment*, 90(1), 126-134. <https://doi.org/10.1016/j.rse.2003.10.023>
- Daughtry, C.S.T., Walthall, C.L., Kim, M.S., de Colstoun, E.B., McMurtrey III, J.E. 2000. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sensing of Environment*, 74, 229-239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)
- de Miguel, E., Fernández-Renau, A., Prado, E., Jiménez, M., Gutiérrez de la Cámara, O., Linés, C., Gómez, J.A., Martín, A., Muñoz F. 2014. The processing of CASI-1500I data at INTA PAF. *EARSeL e Proceedings*, 13, 30-37.
- Delegido, J., Verrelst, J., Alonso, L., Moreno, J. 2011. Evaluation of Sentinel-2 red edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors*, 11(7), 7063-7081. <https://doi.org/10.3390/s110707063>
- Demarty, J., Chevallier, F., Friend, A., Viovy, N., Piao, S., Ciais, P. 2007. Assimilation of global MODIS leaf area index retrieval within a terrestrial biosphere model. *Geophysical research letters*, 34(15), 1-6. <https://doi.org/10.1029/2007GL030014>
- Durá, E., Mendiguren, G., Pacheco-Labrador, J., Martín, M.P., Riaño, D., Iturrate, M., Gimeno, C., Carrara, A. 2013. Validación de productos MODIS relacionados con la estimación de flujos de carbono en un ecosistema de dehesa. *Geofocus*, 13, 291-310.
- Efron, B. 1979. Bootstrap Methods: Another Look at the Jackknife. *The annals of statistics*, 7(1), 1-26. <https://doi.org/10.1214/aos/1176344552>
- Elvidge, C.D. 1990. Visible and near infrared reflectance characteristics of dry plant materials. *International Journal of Remote Sensing*, 11(10), 1775-1795. <https://doi.org/10.1080/01431169008955129>
- Faurtyot, 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. [https://doi.org/10.1016/S0034-4257\(96\)00238-6](https://doi.org/10.1016/S0034-4257(96)00238-6)

- Feret, J.B., François, C., Asner, G.P., Gitelson, A.A., Martin, R.E., Bidol, L.P.R., Ustin, S.L., le Maire, G., Jacquemoud, S. 2008. PROSPECT-4 and 5: Advances in the leaf optical properties model separating photosynthetic pigments. *Remote Sensing of Environment*, 112(6), 3030-3043. <https://doi.org/10.1016/j.rse.2008.02.012>
- Fernández, D., Martín, M.P., Vilar, L., Pacheco-Labrador, J. 2015. Estimación del contenido de humedad de la vegetación herbácea en una zona de dehesa a partir de imágenes hiperespectrales adquiridas por el sensor aerportado CASI. *Geofocus*, 16, 177-204.
- Ferrier, G., Trahair, N.S. 1995. Evaluation of apparent surface reflectance estimation methodologies. *International Journal of Remote Sensing*, 16(12), 2291-2297. <https://doi.org/10.1080/01431169508954557>
- Frampton, W.J., Dash, J., Watmough, G., Milton, E.J., 2013. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *Journal of Photogrammetry and Remote Sensing*, 82, 83-92. <https://doi.org/10.1016/j.isprsjprs.2013.04.007>
- Gamon, J.A., Peñuelas, J., Field, C.B. 1992. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of Environment*, 41, 35-44. [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)
- Gao, B. 1996. NDWI-Anormalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58, 257-266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D. 2002. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- González-Cascón, R., Pacheco-Labrador, J., Martín, M.P. 2016. Evolution of spectral behavior and chemical composition in the tree canopy of a dehesa ecosystem. *Revista de Teledetección*, 46, 31-43. <https://doi.org/10.4995/raet.2016.5688>
- Haboudane, D., Miller, J.R., Pattey, E., Zarco-Tejada, P.J., Strachan, I.B. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3), 337-352. <https://doi.org/10.1016/j.rse.2003.12.013>
- Hardisky, M.A., Klemas, V., Smart, R.M. 1983. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. *Photogrammetry Engineering and Remote Sensing*, 49, 77-83
- Hernández-Clemente, R., Kolari, P., Porcar-Castell, A., Korhonen, L., Möttöus, M. 2016. Tracking the Seasonal Dynamics of Boreal Forest Photosynthesis Using EO-1 Hyperion Reflectance: Sensitivity to Structural and Illumination Effects. *IEEE Transactions on Geoscience and Remote Sensing*, 54(9), 5105-5116. <https://doi.org/10.1109/TGRS.2016.2554466>
- Hernández-Clemente, R., Navarro-Cerrillo, R.M., Suárez, L., Morales, F., Zarco-Tejada, P.J. 2011. Assessing structural effects on PRI for stress detection in conifer forests. *Remote Sensing of Environment*, 115(9), 2360-2375. <https://doi.org/10.1016/j.rse.2011.04.036>
- Herrmann, I., Pimstein, A., Karnieli, A., Cogen, Y., Alchanatis, V., Bonfil, D.J. 2011. LAI assessment of wheat and potato crops by Venus and Sentinel-2 bands. *Remote Sensing of Environment*, 115(8), 2141-2151. <https://doi.org/10.1016/j.rse.2011.04.018>
- Hilker, T., Coops, N.C., Hall, F.G., Black, T.A., Wulder, M.A., Nesic, Z., Krishnan, P. 2008. Separating physiologically and directionally induced changes in PRI using BRDF models. *Remote Sensing of Environment*, 112(6), 2777-2788. <https://doi.org/10.1016/j.rse.2008.01.011>
- Hill, M.J., Hanan, N.P., Hoffmann, W., Scholes, R., Prince, S., Ferwerda, J., Lucas, R.M., Baker, I., Armeth, A., Higgings, S.I., Barret, D.J., Disney, M., Hutley, L. 2011. Remote sensing and modeling of savannas: The state of the dis-union. *34th International Symposium on Remote Sensing of Environment*. Sydney, 1-6.
- HongRui, R., GuangSheng, Z., Feng, Z., XinShi, Z. 2011. Evaluating cellulose absorption index (CAI) for non-photosynthetic biomass estimation in the desert steppe of Inner Mongolia. *Chinese Science Bulletin*, 57, 1716-1722.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Huete, A.R. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Kuusk, A. 1995. A fast, invertible canopy reflectance model. *Remote Sensing of Environment*, 51(3), 342-350. [https://doi.org/10.1016/0034-4257\(94\)00059-V](https://doi.org/10.1016/0034-4257(94)00059-V)
- le Maire, G., François, C., Dufrêne, E. 2004. Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. *Remote Sensing of Environment*, 89(1), 1-28. <https://doi.org/10.1016/j.rse.2003.09.004>

- Lee, K.S., Cohen, W., Kennedy, R., Maier-sperger, T., Gower, S. 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sensing of Environment*, 91(3-4), 508-520. <https://doi.org/10.1016/j.rse.2004.04.010>
- Li, W., Niu, Z., Liang, X., Li, Z., Huan, N., Gao, S., Wang, C., Muhammad, S. 2015. Geostatistical modeling using LiDAR-derived prior knowledge with SPOT-6 data to estimate temperate forest canopy cover and above-ground biomass via stratified random sampling. *International Journal of Applied Earth Observation and Geoinformation*, 41, 88-98. <https://doi.org/10.1016/j.jag.2015.04.020>
- Liu, J., Miller, J.R., Haboudane, D., Pattey, E. 2004. Exploring the relationship between red edge parameters and crop variables for precision agriculture. *2004 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, Anchorage, 1276-1279.
- Mahalanobis, P.C. 1936. On the generalised distance in statistics. *Proceedings National Institute of Science, India*, 49-55
- Mendiguren, G., Martín, M.P., Nieto, G., Pacheco-Labrador, J., Jurdao, S. 2015. Seasonal variation in grass water content estimated from proximal sensing and MODIS time series in a Mediterranean Fluxnet site. *Biogeosciences*, 12, 5523-5535. <https://doi.org/10.5194/bg-12-5523-2015>
- Migliavacca, M., Perez-Priego, O., Rossini, M., El-Madany, T., Moreno, G., Van der Tol, C., Rascher, U., Berninger, A., Bessenbacher, V., Burkart, A., Carrara, A., Fava, F., Guan, J., Hammer, T., Henkel, K., Juárez-Alcalde, E., Julitta, T., Kolle, O., Martín, M.P., Musavi, T., Pacheco-Labrador, J., Pérez-Burgueño, A., Wutzler, T., Zaehle, S., Reichstein, M. 2017. Plant functional traits and canopy structure control the relationship between photosynthetic CO₂ uptake and far-red sun induced fluorescence in a Mediterranean grassland under different nutrient availability. *New Phytologist*, 214(3), 1078-1091. <https://doi.org/10.1111/nph.14437>
- Nagler, P.L., Daughtry, C.S.T., Goward, S.N. 2000. Plant Litter and Soil Reflectance. *Remote Sensing of Environment*, 71(2), 207-215. [https://doi.org/10.1016/S0034-4257\(99\)00082-6](https://doi.org/10.1016/S0034-4257(99)00082-6)
- Nagler, P.L., Inoue, Y., Glenn, E.P., Russ, A.L., Daughtry, C.S.T. 2003. Cellulose absorption index (CAI) to quantify mixed soil-plant litter scenes. *Remote Sensing of Environment*, 87(2-3), 310-325. <https://doi.org/10.1016/j.rse.2003.06.001>
- Pacheco-Labrador, J., González-Cascón, R., Martín, M.P., Riaño, D. 2014. Understanding the optical responses of leaf nitrogen in Mediterranean Holm oak (*Quercus ilex*) using field spectroscopy. *International Journal of Applied Earth Observation and Geoinformation*, 26, 105-118. <https://doi.org/10.1016/j.jag.2013.05.013>
- Perez-Priego, O., Guan, J., Rossini, M., Fava, F., Wutzler, T., Moreno, G., Carvalhais, N., Carrara, A., Kolle, O., Julitta, T., Schruppf, M., Reichstein, M., Migliavacca, M. 2015. Sun-induced chlorophyll fluorescence and photochemical reflectance index improve remote-sensing gross primary production estimates under varying nutrient availability in a typical Mediterranean savanna ecosystem. *Biogeosciences*, 12, 6351-6367. <https://doi.org/10.5194/bg-12-6351-2015>
- Pinty, B., Verstraete, M.M. 1992. GEMI: a non-linear index to monitor global vegetation from satellites. *Vegetatio*, 101(1), 15-20. <https://doi.org/10.1007/BF00031911>
- Privette, J.L., Myneni, R.B., Knyazikhin, Y., Mukelabai, M., Roberts, G., Tian, Y., Wang, Y., Leblanc, S.G. 2002. Early spatial and temporal validation of MODIS LAI product in the Southern Africa Kalahari. *Remote Sensing of Environment*, 83(1-2), 232-243. [https://doi.org/10.1016/S0034-4257\(02\)00075-5](https://doi.org/10.1016/S0034-4257(02)00075-5)
- Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H., Sorooshian, S. 1994. A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Reichstein, M., Tenhunen, J., Rouspard, O., Ourcival, J., Rambal, S., Miglietta, F., Peressotti, A., Pecchiari, M., Tirone, G., Valentini, R. 2003. Inverse modeling of seasonal drought effects on canopy CO₂/H₂O exchange in three Mediterranean ecosystems. *Journal of Geophysical Research*, 108(D23), 1-16-. <https://doi.org/10.1029/2003JD003430>
- Riaño, D., Vaughan, P., Chuvieco, E., Zarco-Tejada, P., Ustin, S.L. 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 Transaction on Geoscience and Remote Sensing*, 43, 819-826. <https://doi.org/10.1109/TGRS.2005.843316>
- Richter, K., Atzberger, C., Hank, T.B., Mauser, W. 2012. Derivation of biophysical variables from Earth observation data: validation and statistical measures. *Journal of Applied Remote Sensing*, 6(1), 1-23. <https://doi.org/10.1117/1.JRS.6.063557>
- Roujean, J.L., Breon, F.M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375-384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, J.W., Hass, R.H., Schell, J.A., Deering, D.W. 1974. Monitoring Vegetation Systems in the Great Plains with ERTS. *Proceeding, 3rd Earth Resource Technology Satellite (ERTS) Symposium, NASA, Washington DC, 1*, 48-62
- Schmidtlein, S., Sassin, J. 2004. Mapping of continuous floristic gradients in grasslands using hyperspectral imagery. *Remote Sensing of Environment*, 92(1), 126-138. <https://doi.org/10.1016/j.rse.2004.05.004>

- Scholes, R.J., Archer, S.R. 1997. Tree-grass interactions in savannas. *Annual Review of Ecology and Systematics*, 28, 517-544. <https://doi.org/10.1146/annurev.ecolsys.28.1.517>
- Schucknecht, A., Meroni, M., Kayitakire, F., Rembold, F., Boureima, A. 2015. Biomass estimation to support pasture management in Niger. *36th International Symposium on Remote Sensing of Environment*. Berlin, Germany, 109-114. <https://doi.org/10.5194/isprsarchives-xxl-7-w3-109-2015>
- Serrano, L., Peñuelas, J., Ustin, S.L. 2002. Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals. *Remote Sensing of Environment*, 81(2-3), 355-364. [https://doi.org/10.1016/S0034-4257\(02\)00011-1](https://doi.org/10.1016/S0034-4257(02)00011-1)
- Shapiro, S.S., Wilk, M.B. 1965. An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52(3-4), 591-611. <https://doi.org/10.1093/biomet/52.3-4.591>
- 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, 2653-2662. <https://doi.org/10.1080/014311699211994>
- Stagakis, S., González-Dugo, V., Cid, P., Guillén-Climent, M., Zarco-Tejada, P. 2012. Monitoring water stress and fruit quality in an orange orchard under regulated deficit irrigation using narrow-band structural and physiological remote sensing indices. *ISPRS Journal of Photogrammetry and Remote Sensing*, 71, 47-61. <https://doi.org/10.1016/j.isprsjprs.2012.05.003>
- Ustin, S.L., Roberts, D.A., Gamon, J.A., Asner, G.P., Green, R.O. 2004. Using Imaging Spectroscopy to Study Ecosystem Processes and Properties. *BioScience*, 54, 523-534. [https://doi.org/10.1641/0006-3568\(2004\)054\[0523:U1STSE\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2004)054[0523:U1STSE]2.0.CO;2)
- Ustin, S.L., Roberts, D.A., Pinzón, J., Jacquemoud, S., Gardner, M., Scheer, G., Castañeda, C.M., Palacios-Orueta, A. 1998. Estimating Canopy Water Content of Chaparral Shrubs Using Optical Methods. *Remote Sensing of Environment*, 65(3), 280-291. [https://doi.org/10.1016/S0034-4257\(98\)00038-8](https://doi.org/10.1016/S0034-4257(98)00038-8)
- Wieneke, S., Ahrends, H., Damm, A., Pinto, F., Stadler, A., Rossini, M., Rascher, U. 2016. Airborne based spectroscopy of red and far-red sun-induced chlorophyll fluorescence: Implications for improved estimates of gross primary productivity. *Remote Sensing of Environment*, 184, 654-667. <https://doi.org/10.1016/j.rse.2016.07.025>
- Wilcoxon, F. 1945. Individual Comparisons by Ranking Methods. *Biometrics Bulletin*, 1, 80-83. <https://doi.org/10.2307/3001968>
- Yebara, M., Chuvieco, E., Riaño, D. 2008. Estimation of live fuel moisture content from MODIS images for fire risk assessment. *Agricultural and forest meteorology*, 148, 523-536. <https://doi.org/10.1016/j.agrformet.2007.12.005>
- Yi, Q., Wang, F., Bao, A., Jiapaer, G. 2014. Leaf and canopy water content estimation in cotton using hyperspectral indices and radiative transfer models. *International Journal of Applied Earth Observation and Geoinformation*, 33, 67-75. <https://doi.org/10.1016/j.jag.2014.04.019>
- Zarco-Tejada, P., Miller, J.R., Mohammed, G.H., Noland, T.L., & Sampson, P.H. 1999. Índices ópticos obtenidos mediante datos hiperespectrales del sensor CASI como indicadores de estrés en zonas forestales. *VIII Congreso Nacional de Teledetección*. Albacete, 1-5
- Zarco-Tejada, P.J., Rueda, C.A., Ustin, S.L. 2003. Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*, 85(1), 109-124. [https://doi.org/10.1016/S0034-4257\(02\)00197-9](https://doi.org/10.1016/S0034-4257(02)00197-9)
- Zarco-Tejada, P.J., Ustin, S.L. 2001. Modeling canopy water content for carbon estimates from MODIS data at land EOS validation sites. *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium, Sydney*, 1, 342-344. <https://doi.org/10.1109/igarss.2001.976152>