



ANÁLISIS DE LA DIVERSIDAD FUNCIONAL DEL ESTRATO HERBÁCEO EN UN ECOSISTEMA DE DEHESA A PARTIR DE DATOS HIPERESPECTRALES *IN SITU*

CARLOS GONZALO^{1*} , VICENTE BURCHARD-LEVINE¹ ,
VÍCTOR ROLO² , ROSARIO GONZÁLEZ-CASCON³ ,
GERARDO MORENO² , M. PILAR MARTÍN¹ 

¹ *Laboratorio de Espectro-radiometría y Teledetección Ambiental (SpecLab), Consejo Superior de Investigaciones Científicas (CSIC), Madrid, España.*

² *Grupo de Investigación Forestal, INDEHESA, Universidad de Extremadura, Plasencia, España.*

³ *Departamento de Medio Ambiente y Agronomía, INIA-CSIC, Madrid, España.*

RESUMEN. El presente trabajo aborda la estimación de la diversidad funcional (FD) del estrato herbáceo en un ecosistema de dehesa mediante datos hiperespectrales obtenidos con un espectro-radiómetro portátil ASD FieldSpec® 3 (Analytical Spectral Devices Inc., Boulder, CO, EE. UU.). Los datos ópticos se correlacionaron con variables biofísicas (área foliar específica (SLA), biomasa aérea (AGB), índice de área foliar (LAI) y contenido de nitrógeno (N%) e índices de diversidad tradicionales como Shannon y Evenness y otros relacionados con la diversidad funcional como el índice multidimensional de dispersión funcional (FDis) usando como variables predictoras: a) índices de vegetación (VIs) y métodos de regresión simple, y b) bandas espectrales y Partial Least Squares Regression (PLSR). Las correlaciones, especialmente de las variables biofísicas relacionadas con FDis, mejoraron sustancialmente al utilizar información hiperespectral ($R^2 > 0.6$, rRMSE < 0.1) lo que confirma el interés de la dimensión espectral para estimar la diversidad funcional de un ecosistema complejo como es el caso de los pastizales semi-áridos.

Analysis of the functional diversity of the herbaceous stratum in a ‘dehesa’ ecosystem using in situ hyperspectral proximal sensing

ABSTRACT. The aim of this paper is the estimation of functional diversity (FD) of the herbaceous stratum in a “dehesa” ecosystem using hyperspectral data obtained with an ASD FieldSpec® 3 (Analytical Spectral Devices Inc., Boulder, CO, EE. UU.) spectroradiometer. Optical data were correlated with biophysical variables (specific leaf area (SLA), above-ground biomass (AGB), leaf area index (LAI) and nitrogen content (N%)) and traditional diversity indices (Shannon and Evenness) and functional diversity indices (FDis) using as predictor variables: a) vegetation indices (VIs) and simple regression methods, and b) spectral bands and Partial Least Squares Regression (PLSR). Correlations, especially with biophysical variables, improved substantially when using hyperspectral information ($R^2 > 0.6$, rRMSE < 0.1), which confirms the interest of the spectral dimension to estimate the functional diversity of a complex ecosystem such as semi-arid grasslands.

Palabras clave: variables biofísicas, índices de vegetación, diversidad funcional, datos hiperespectrales, pastizales.

Key words: biophysical variables, vegetation indices, functional diversity, hyperspectral data, grasslands.

Recibido: 14 Enero 2022

Aceptado: 26 Marzo 2022

***Correspondencia:** Carlos Gonzalo Gil, Laboratorio de Espectro-radiometría y Teledetección Ambiental (SpecLab), Consejo Superior de Investigaciones Científicas (CSIC), Madrid, España. E-mail address: carlosgonzalogil@gmail.com

1. Introducción

Los sistemas vegetales tipo sabana constituidos por comunidades arbustivas y/o de pastizal combinadas con arbolado disperso conforman uno de los biomas más extensos de la Tierra (Hanan *et al.*, 2012; Hill *et al.*, 2011). En España este tipo de ecosistemas se encuentran representados por las dehesas; sistemas agroforestales con gran parte de su superficie cubierta por pasto que se complementa habitualmente con una cobertura arbórea dispersa de encinas y/o alcornoques (Escribano *et al.*, 2014; Pulido *et al.*, 2011). En este ecosistema, el arbolado posee una gran capacidad para incrementar la fertilidad edáfica, evitar los distintos procesos de erosión, mantener el ciclo hidrológico y permitir aprovechamientos de carácter comercial que contribuyen al desarrollo y mejora de las condiciones de vida de la población rural (Campos, 1993). El pastizal semiárido, constituye un componente vital en la dehesa y está conformado generalmente por especies de vegetación anual con una reducida capacidad productiva debido a factores limitantes climáticos y edáficos (Montserrat *et al.*, 1968; Olea *et al.*, 1990). Procesos globales como el cambio de uso del suelo, el aumento del CO₂ atmosférico y la alteración de los patrones de precipitación, están provocando una serie de cambios en los factores abióticos, bióticos y antrópicos que pronostican un futuro incierto para estos ecosistemas (Hanan *et al.*, 2012).

A nivel global, la conservación y mantenimiento de la diversidad constituye un factor de gran relevancia en pastizales como los que forman parte de estos ecosistemas de sabana que proporcionan servicios ecosistémicos de carácter fundamental relacionados, entre otros, con su papel en el secuestro de carbono (Sebastià *et al.*, 2012). No obstante, la variabilidad espacio-temporal de las especies que integran estos pastizales dificulta su monitorización y conservación (Wang *et al.*, 2019). La introducción de la teledetección en el estudio y seguimiento de la vegetación a distintas escalas geográficas puede ser de gran ayuda para mejorar el conocimiento, planificación y gestión de la diversidad vegetal en los ecosistemas de pasto y sus consecuencias sobre los servicios ecosistémicos que proporcionan (Wang *et al.*, 2019).

La posibilidad de obtener información a distintas escalas espaciales y temporales en regiones del espectro como el Eje rojo (*RE* – 680-730 nm) o el Infrarrojo medio de onda corta (*SWIR* – 1.200-2.500 nm) ha resultado de gran relevancia en el seguimiento y estimación de variables biofísicas y estructurales de la vegetación que tienen un papel fundamental en la monitorización y caracterización de la biodiversidad, así como en la evaluación y determinación del impacto producido por el cambio climático y la actividad antrópica sobre las comunidades vegetales (Melendo-Vega *et al.*, 2017). El estudio y discriminación de la diversidad taxonómica a partir de la teledetección está limitado principalmente por la resolución espacial de los sensores actuales para abordar dicho análisis que requiere una discriminación de las especies y su abundancia (Cavender-Bares *et al.*, 2020). La diversidad funcional (*FD*), entendida como la diversidad de tipos, rangos y abundancia de rasgos morfológicos, fisiológicos y anatómicos de los individuos de una comunidad, está estrechamente vinculada con la estructura y el funcionamiento de los ecosistemas (Córdova-Tapia *et al.*, 2015). Asimismo, está relacionada, entre otras, con variables biofísicas como el área foliar específica o *Specific Leaf Area (SLA)*, biomasa o *Above-ground Biomass (AGB)*, índice de área foliar o *Leaf Area Index (LAI)* y contenido en nitrógeno o *Nitrogen Content (N%)* cuya estimación a partir de teledetección resulta potencialmente más asequible (Cavender-Bares *et al.*, 2020). Sin embargo, a diferencia de los índices de diversidad funcional que consideran la variabilidad a nivel de especie dentro de una comunidad, las variables biofísicas estimadas a partir de teledetección ofrecen un valor integrado a nivel de comunidad.

El *SLA* es uno de los parámetros biofísicos relevantes para caracterizar la estructura y funcionamiento de los ecosistemas (Ali *et al.*, 2017). Se define como el área foliar por unidad de masa foliar seca y permite evaluar el uso de los recursos, así como la interacción que mantienen las especies vegetales en la obtención y asimilación de estos (Rossi *et al.*, 2020). Algunos autores investigaron la relación de esta variable con las capacidades adaptativas de cuatro tipos de pasto ante una serie de escenarios que simulaban distintas condiciones ambientales demostrando una relación dependiente entre *SLA* y *FD* a diferentes escalas: satelital e *in situ* (e.g. Rossi *et al.*, 2020). Otros analizaron la capacidad de la teledetección para discriminar la vegetación afectada por el pastoreo en las distintas etapas fenológicas del pasto (e.g. Möckel *et al.*, 2014). A través del estudio de la variable biofísica *SLA* se pudieron analizar los efectos del pastoreo en las especies vegetales según el período y el grado de constancia de la actividad.

AGB es otra variable biofísica relevante en el estudio del manejo de los ecosistemas de pasto (Shoko *et al.* 2016). Algunos autores estudiaron el *AGB* con el objetivo de cuantificar el efecto del pastoreo en los pastizales (e.g. Li *et al.*, 2013). Los resultados determinaron una disminución de la productividad causada por el pastoreo cuando se supera la capacidad de carga del ecosistema. La alteración de la productividad en pastizales con alta carga ganadera afecta directamente a su biodiversidad (Xiang *et al.*, 2021). Otros autores han monitorizado el *AGB* en los pastizales pirenaicos (e.g. Barrachina *et al.*, 2015) demostrando una gran variabilidad en los ciclos interanuales e intraestacionales de esta variable en el área de estudio debido principalmente a las condiciones meteorológicas y a las prácticas agrícolas.

LAI es otra variable biofísica de carácter dinámico, tanto espacial como temporalmente que resulta clave para caracterizar la estructura vegetal, especialmente en la determinación de los flujos de intercambio en la biosfera, la fotosíntesis y la producción de biomasa (Asam *et al.*, 2015; Doughty *et al.*, 2008; Martin *et al.*, 2020). Algunos autores han analizado la relación entre índices de vegetación (*VI*) como el *Normalized Difference Vegetation Index (NDVI)* (Rouse *et al.*, 1974) y la variable biofísica *LAI* en tres tipos de pastizales (e.g. Fan *et al.*, 2009) demostrando una correlación elevada entre *NDVI* y *LAI* para pastizales de diferente intensidad de pastoreo. En otros casos la variable *LAI* se ha utilizado con el propósito de identificar las diferentes prácticas de gestión en pastizales a partir de imágenes de alta resolución espacial utilizando un modelo de transferencia radiativa (e.g. Dusseux *et al.*, 2014). Los autores demostraron que la variable biofísica mostró cambios más significativos durante la temporada de crecimiento vegetal después del pastoreo y las prácticas de gestión mixta.

La concentración del nitrógeno (*N%*) es un parámetro funcional de gran importancia ya que constituye uno de los principales factores limitantes del crecimiento vegetal (Milcu *et al.*, 2014). Dicha variable está vinculada con la riqueza de especies y las propiedades estructurales de la vegetación, las cuales, a su vez, están relacionadas directamente con el uso de los recursos del ecosistema (Milcu *et al.*, 2014; Zuo *et al.*, 2016). Algunos autores estudiaron la relación entre *N%*, *FD* y los flujos de carbono (*C*) de los pastizales (e.g. Milcu *et al.*, 2014) demostrando que la diversidad de *N%* foliar en el dosel puede actuar como un predictor funcional clave de los flujos de *C* del ecosistema.

La mayor parte de los estudios sobre diversidad vegetal a diferentes escalas basados en teledetección han utilizado índices de vegetación (*VI*s) que combinan bandas o regiones espectrales de interés en la estimación de parámetros biofísicos y/o estructurales claves como los mencionados anteriormente (Wang *et al.*, 2019). Uno de los más utilizados es el *Normalized Difference Vegetation Index (NDVI)*, por ejemplo, para establecer la relación entre riqueza de especies y productividad en pasto con datos espectrales obtenidos a través de un espectro-radiómetro dando lugar a ajustes altos, $R^2 > 0.8$ en algunos casos (e.g. Wang *et al.*, 2016). Otros autores han planteado la relación entre diversos *VI*s y la riqueza de especies encontrando los mejores ajustes con otros índices como el *Simple Ratio (SR)* (Birth *et al.*, 1968; Madonsela *et al.*, 2017). El uso de índices hiperespectrales a partir de la información del *SWIR* como *Leaf Water Vegetation Index 2 (LWVI2)* (Galvão *et al.*, 2005) permite extraer información específica de variables biofísicas como *LAI* cuando no es posible a través de los *VI*s más

convencionales aprovechando la relación directa que existe entre vigor y contenido en humedad en especies herbáceas (Leitão *et al.*, 2015).

La teledetección hiperespectral es una herramienta de gran potencial en el estudio de la cubierta vegetal ya que proporciona decenas a cientos de bandas dentro de un mismo rango del espectro electromagnético (Cogliati *et al.*, 2015). En las últimas décadas, los datos hiperespectrales procedentes de espectro-radiómetros de campo, cámaras portátiles (Imran *et al.*, 2021) y sensores aeroportados (Gholizadeh *et al.*, 2020), han sido empleados en numerosas investigaciones enfocadas al estudio de la diversidad en pastizales. En algunos estudios se analiza el potencial de la información hiperespectral para cartografiar la biomasa de los pastizales demostrando la importancia de esta información en la conservación y seguimiento de la biodiversidad (e.g. Psomas *et al.*, 2010). Otros estudios tratan de relacionar de forma directa la *FD* con las imágenes satelitales ofrecidas por Sentinel-2 utilizando técnicas estadísticas como *Partial Least Squares Regression (PLSR)* junto con datos de carácter hiperespectral obtenidos a partir de cámaras instaladas en drones con el propósito de explicar la variabilidad espacial de la *FD* a nivel foliar (e.g. Ma *et al.*, 2019). A través de un modelo estadístico que empleó distintas bandas espectrales buscaron predecir la *FD* por medio de ciertas variables biofísicas, entre ellas *N%*, cuya correlación resultó ser elevada ($R^2 > 0.8$).

En el presente estudio se plantea el uso de datos hiperespectrales obtenidos mediante un espectro-radiómetro de campo ASD Fieldspec 3® (Analytical Spectral Devices Inc., Boulder, Colorado, EE. UU.) para la estimación de distintas variables biofísicas y estructurales en la cubierta de pasto en un ecosistema de dehesa con el objetivo de establecer una relación directa o indirecta entre la información espectral que sobre estas variables proporcionan los datos ópticos y la diversidad taxonómica y funcional observada en distintas parcelas de muestreo. A través de esta investigación se pretende demostrar si las variables biofísicas *LAI*, *SLA*, *AGB* y *N%* y los índices de diversidad *Shannon*, *Evenness* y *FD_{is}* pueden o no estimarse a partir de teledetección próxima en este tipo de ecosistemas y cuáles son las regiones del espectro electromagnético más relevantes en dicha estimación. Con este fin se utilizan los datos correspondientes a una campaña realizada por SpecLab (CSIC) e INDEHESA (Universidad de Extremadura) en mayo de 2019 en el contexto del proyecto SynerTGE (<http://www.lineas.cchs.csic.es/synertge/>).

2. Metodología

2.1. Área de estudio y diseño experimental

El área de estudio se encuentra en el término municipal de Majadas de Tiétar, en el noreste de la provincia de Cáceres, Extremadura (Figura 1). Se trata de un ecosistema de dehesa con un uso ganadero extensivo de carácter bovino. El clima de la zona de trabajo es Mediterráneo con una temperatura media anual de 16.7°C. La precipitación media anual se sitúa en torno a los 650 mm (Melendo-Vega *et al.*, 2017). El relieve que predomina es llano con ligeras ondulaciones o vaguadas que se vinculan con la presencia de láminas de agua que habitualmente tienen un carácter estacional. La altitud media es de 256 m. La vegetación se distribuye en dos estratos vegetales que presentan una clara diferenciación en sus características biofísicas y fenológicas. El estrato arbóreo cubre aproximadamente el 20% de la superficie y está compuesto por encinas (*Quercus ilex* L. subsp. *ballota* (Desf.) Samp.) y algunos alcornoques (*Quercus suber* L.) y quejigos aislados (*Quercus faginea* Lam.) (Martín *et al.*, 2020). El estrato herbáceo cubre prácticamente la totalidad de la zona de estudio y está conformado por una gran variedad de especies, en su mayoría anuales con un ciclo fenológico muy dinámico. Entre las especies más abundantes se encuentran *Tolpis barbata* (L.) Gaertn., *Chamaemelum mixtum* (L.) All., *Plantago lagopus* L., *Echium plantagineum* L. y *Cynodon dactylon* (L.) Pers. (Martín *et al.*, 2020).

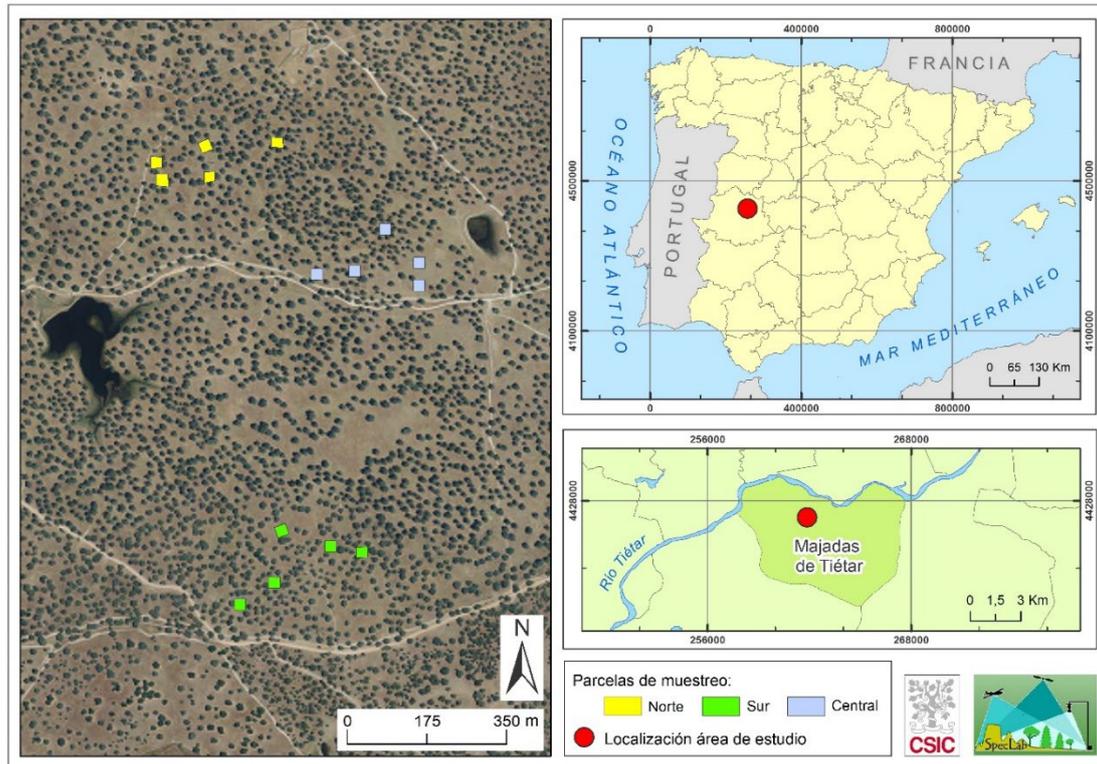


Figura 1. Localización de la zona de estudio y las parcelas de muestreo en la estación experimental de Majadas de Tiétar. En la imagen de la izquierda se muestra una fotografía aérea del Plan Nacional de Ortofotografía Aérea (PNOA) correspondiente al año 2019 con las parcelas de muestreo de pasto utilizadas en el estudio divididas en 3 zonas (central, norte y sur). En el mapa de la derecha se indica la ubicación del área de estudio a nivel nacional y regional.

Los datos utilizados en este estudio corresponden a una campaña de muestreo realizada los días 11 y 12 de mayo de 2019 coincidiendo con el pico de actividad vegetativa del pasto en la zona de estudio. Se muestrearon un total de 30 *plots* distribuidos en 15 parcelas de 25x25 m ubicadas en un área aproximada de 1 km² y distribuidas en tres zonas que denominaremos central, norte y sur (Figura 1) que coinciden con la ubicación de tres torres de medición de flujos de agua y carbono por el método de *Eddy Covariance* que operan en la zona de estudio desde 2009 (central) y 2014 (norte y sur) (Burchard-Levine *et al.*, 2020).

De los 30 *plots* muestreados durante la campaña se seleccionaron 20 (10 en la zona central y 5 en la norte y sur respectivamente) para llevar a cabo un muestreo simultáneo de variables biofísicas, espectrales, flujos de agua y carbono y biodiversidad. Ante la imposibilidad de realizar todas las mediciones sobre el mismo *plot*, ya que alguna implicaba la realización de muestreos destructivos o semi-destructivos, se seleccionaron “*plots* gemelos” próximos y con características similares a nivel visual, asumiendo que los resultados de los muestreos realizados en un *plot* podrían hacerse extensivos a su gemelo.

Se tomaron muestras de vegetación de pasto en cada una de las 15 parcelas sobre 2 cuadrantes de 25x25 cm (Figura 2) localizados a partir del muestreo no probabilístico de zonas representativas de la variabilidad de cada parcela. Tres de estos cuadrantes se ubicaron bajo el área de influencia de la copa de alguna de las encinas presentes en las parcelas de muestreo con la finalidad de considerar la variabilidad espacial del pasto debido al sombreado y a las propiedades del suelo causadas por el aporte de materia seca del arbolado (Moreno y Rolo, 2019). También se muestrearon ejemplares vegetales para llevar a cabo el análisis de diversidad taxonómica y rasgos funcionales de las especies identificadas (ver apartado 2.2.3).



Figura 2. Cuadrante de muestreo de 25x25 cm en el interior del plot antes de realizar el muestreo destructivo, a la izquierda de este se localiza un plot “gemelo” donde se situaría otro cuadrante para realizar el muestreo en un área próxima y visualmente similar (izquierda). Vista panorámica de una de las parcelas de muestreo (derecha).

2.2. Datos de campo

2.2.1. Datos espectrales

En la campaña se tomaron datos hiperespectrales en los *plots* de muestreo utilizando un espectro-radiómetro Fieldspec 3® (Analytical Spectral Devices Inc., Boulder, Colorado, EE. UU.) con un rango espectral entre 350 y 2500 nm y un campo de visión nominal de 25°. La información espectral se adquirió situando la fibra óptica del radiómetro a una altura aproximada de 1.20 m sobre la cubierta herbácea de cada *plot* de muestreo. Para la conversión de niveles digitales a valores de reflectividad se utilizó un panel calibrado Spectralon® (Labsphere Inc., North Sutton, NH, EE.UU.) con una reflectividad próxima al 99% en todo el rango espectral. Todas las mediciones se tomaron en condiciones de cielo despejado en un período de +/- 2 horas respecto al mediodía solar.

En cada *plot* de muestreo (gemelos 1 y 2) se tomaron una media de 10 espectros que fueron filtrados con el objetivo de omitir bandas ruidosas de los extremos del rango de medición (350-400 nm y 2400-2500 nm) así como las correspondientes a regiones espectrales de alta absorción atmosférica (1350-1450 nm y 1800-1950 nm) que presentan una muy baja relación señal ruido. No se consideró necesario ningún otro pre-tratamiento espectral ya que el protocolo de adquisición de datos en campo siguiendo un esquema de barrido, que consiste en mover ligeramente la fibra del espectro-radiómetro sobre el *plot*, contribuye a la integración de la señal evitando los habituales saltos entre detectores sobre superficies heterogéneas. Este protocolo ha sido contrastado en la zona de estudio respecto a otros esquemas de medición (medidas estáticas sobre uno o varios puntos dentro del *plot*) y se ha demostrado que el método de barrido minimiza los saltos entre detectores al tiempo que aumenta la reproducibilidad de las medidas. Mediante los datos resultantes de este filtrado se calcularon diversos *VI*s multi e hiperespectrales seleccionados entre los propuestos en la literatura de acuerdo con los objetivos del estudio (Tabla 1). Con esta selección se buscó incluir *VI*s que utilizaran las principales regiones del espectro electromagnético (Visible, *NIR* y *SWIR*) y que hubiesen demostrado su capacidad para estimar parámetros biofísicos de la vegetación de interés en nuestro estudio. Por un lado, los índices multiespectrales pueden utilizarse con la mayor parte de sensores próximos y remotos pues utilizan bandas anchas que corresponden a regiones espectrales habitualmente incluidas en dichas plataformas. Por otro, los índices hiperespectrales presentan la ventaja de poder centrarse en regiones o bandas espectrales más estrechas donde es posible observar respuestas específicas de la vegetación (rasgos de absorción). Es importante destacar que el número de sensores satelitales hiperespectrales es escaso y por esta razón, las relaciones encontradas a partir de este tipo de datos son difícilmente extrapolables a

estudios de escala regional o global. Sin embargo, actualmente existen misiones satelitales hiperespectrales ya operativas como “PRISMA” (<http://prisma-i.it/index.php/en/>), o en fase de desarrollo como “EnMAP” (<https://www.enmap.org/>), “Hyspiri” (<https://hyspiri.jpl.nasa.gov/>), o CHIME (https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Copernicus_Sentinel_Expansion_missions) que pronto permitirán un uso más operativo de estos datos.

Tabla 1. Índices de vegetación utilizados en el estudio. Se resaltan en **negrita** los IVs que se emplearon en el análisis comparativo de los *plots* gemelos.

Índices	Fórmula	Referencia
Índices multiespectrales		
NDVI	$\frac{R_{NIR} - R_R}{R_{NIR} + R_R}$	(Rouse <i>et al.</i> , 1974)
SR	$\frac{R_{NIR}}{R_R}$	(Birth <i>et al.</i> , 1968)
SIPI	$\frac{R_{800} - R_{445}}{R_{800} - R_{680}}$	(Penuelas <i>et al.</i> , 1995)
NDII	$\frac{R_{NIR} - R_{SWIR}}{R_{NIR} + R_{SWIR}}$	(Hardisky <i>et al.</i> , 1983)
RENDVI	$\frac{R_{750} - R_{705}}{R_{750} + R_{705}}$	(Sims <i>et al.</i> , 2002)
NDNI	$\frac{\log\left(\frac{1}{1510}\right) - \log\left(\frac{1}{1680}\right)}{\log\left(\frac{1}{1510}\right) + \log\left(\frac{1}{1680}\right)}$	(Serrano <i>et al.</i> , 2002)
Índices hiperespectrales		
PRI	$\frac{R_{531} - R_{570}}{R_{531} + R_{570}}$	(Gamon <i>et al.</i> , 1992)
MTVI2	$\frac{1.5 \cdot [2.5 \cdot (R_{800} - R_{550}) - 2.5 \cdot (R_{670} - R_{550})]}{\sqrt{(2 \cdot R_{800} + 1)^2 - (6 \cdot R_{800} - 5 \cdot \sqrt{R_{670}}) - 0.5}}$	(Haboudane <i>et al.</i> , 2004)
LWVI2	$\frac{R_{1094} - R_{1205}}{R_{1094} + R_{1205}}$	(Galvão <i>et al.</i> , 2005)
CIre	$\frac{R_{NIR}}{R_R} - 1$	(Wu <i>et al.</i> , 2009)

Además de utilizarse para la estimación de variables biofísicas y de biodiversidad, algunos de los índices se emplearon para comparar los *plots* gemelos y, por tanto, confirmar o descartar si su similitud visual se traducía efectivamente en una similitud espectral que permitiese asumir la hipótesis formulada de que los muestreos destructivos realizados en un *plot* podrían hacerse extensivos a su gemelo.

2.2.2. Variables biofísicas

La estimación de variables biofísicas se realizó mediante el análisis de la vegetación recogida en los *plots* de muestreo utilizando el protocolo desarrollado en el contexto del proyecto SynerTGE

(<http://www.lineas.cchs.csic.es/synertge>). En cada uno de los cuadrantes de 25x25 cm (gemelo 1) se recogió la vegetación enraizada (verde y seca) cortando a ras de suelo.

En el laboratorio se procesaron las muestras con el propósito de obtener los parámetros biofísicos de interés en el estudio: LAI, AGB, SLA y N%, seleccionados por su relación con la *FD* (Li *et al.*, 2018; Milcu *et al.*, 2014). En todos los casos se utilizó una submuestra que fue escaneada, una vez separadas las fracciones verde y seca (sin actividad fotosintética), para calcular la superficie foliar (que, en este caso, al tratarse de especies herbáceas incluía toda la planta: hojas, flores y tallos). Todas las muestras se secaron en una estufa a 60°C durante 48 horas y fueron pesadas con la misma balanza utilizada en campo para determinar su peso seco. Las variables *LAI*, *AGB* y *SLA* se calcularon a través de las siguientes ecuaciones:

$$LAI [m^2/m^2] = (W_d \cdot A_{leaf,s}) / (W_{d,s} \cdot A_{quadrant}) \quad (1)$$

$$AGB [g/m^2] = (10000 \cdot W_d) / (A_{quadrant}) \quad (2)$$

$$SLA [cm^2/g] = (A_{leaf,s}) / (W_{d,s}) \quad (3)$$

Donde W_d es el peso seco de la muestra total, $W_{d,s}$ es el peso seco de la submuestra, $A_{leaf,s}$ es la superficie foliar (incluyendo hojas, flores y tallos) de la submuestra y $A_{quadrant}$ es la superficie del cuadrante de muestreo. El N% se analizó por unidad de masa seca de hierba por medio del método de combustión seca con el analizador LECO CN-2000 (65°C).

Las mismas variables con el subíndice verde ($_v$) y no verde ($_{nv}$) se calcularon para las variables *LAI* y *SLA* a partir de las fracciones verde y no verde de las mismas submuestras. En el caso de *AGB* y N% este cálculo se realizó solo para la fracción verde ($_v$). La variable *AGB_v* fue estimada también con muestras obtenidas en el gemelo 2 y este dato se empleó posteriormente, al igual que se ha descrito anteriormente con los *IVs*, para confirmar o descartar si su similitud visual se traducía en datos comparables para esta variable biofísica de referencia.

2.2.3. Biodiversidad

El estudio de biodiversidad taxonómica y funcional fue realizado por el grupo INDEHESA sobre el gemelo 2 de 20 *plots* localizados en 15 parcelas de muestreo (Figura 1). En cada *plot*, se identificaron todas las especies presentes y se estimó visualmente su abundancia basada en la cobertura en una escala de seis categorías: (0) ausente; (1) < 1 %; (2) entre 1 y 12 %; (3) entre 12 y 25 %; (4) entre 25 y 50 %, (5) > 50 %. A continuación, se recolectó un individuo por especie de aquellas que colectivamente sumaban al menos el 80 % de cobertura en cada *plot* (Carmona *et al.*, 2014). En cada individuo se analizó el área foliar específica (*SLA*) y el contenido de materia seca foliar o *leaf dry matter content (LDMC)* siguiendo protocolos estandarizados (Pérez-Harguindeguy *et al.*, 2013) y se extrajeron de la literatura los valores medios por especie del contenido en nitrógeno N% y la altura vegetativa (*H*) (Rolo *et al.*, 2016).

Con la información recopilada en campo se calcularon dos índices de diversidad taxonómica. El índice de *Shannon* cuantifica la diversidad de especies en una comunidad (en nuestro caso un *plot*) considerando el número de especies y la proporción de individuos de cada especie. A partir de éste se calculó también el índice de *Evenness* que permite analizar la equidad en la distribución de las especies (Mulder *et al.*, 2004; Shannon *et al.*, 1949). Para calcular ambos índices se utilizaron las siguientes fórmulas:

$$Shannon\ Index\ (H) = - \sum_{i=1}^S p_i \cdot \ln \cdot p_i \quad (4)$$

$$Evenness\ Index = \frac{H}{H_{max}} = H / \ln \cdot S \quad (5)$$

Donde i corresponde a la proporción de la especie con respecto al número total de especies (p_i). H es el número derivado del Índice de Shannon y H_{max} corresponde al valor máximo de H mientras que S es el número total de especies (Mulder *et al.*, 2004; Shannon *et al.*, 1949).

Además de los índices de diversidad convencionales basados exclusivamente en la abundancia y distribución de especies se calculó un índice de diversidad que considera los rasgos funcionales de las especies identificadas y se puede relacionar con las variables biofísicas de la vegetación conformando un factor clave en los procesos y estabilidad del ecosistema. En este caso se utilizó el índice multidimensional de dispersión funcional ($FDis$) de Laliberté *et al.*, 2010. $FDis$ se calcula a partir de las variables $LDMC$, SLA , $N\%$ y la altura vegetativa (H), y se efectúa como el promedio de la distancia de los rasgos funcionales de cada especie individual al centroide ponderado de las especies totales de la comunidad donde los pesos pertenecen a la abundancia relativa de dichas especies (Laliberté *et al.*, 2010). Para el cálculo del índice se utilizó la siguiente fórmula:

$$FDis = \sum a_j z_j / \sum a_j ; c = \sum a_j x_{ij} / \sum a_j \quad (6)$$

Donde a_j es la abundancia de especies (j) y z_j es la distancia de la especie al centroide ponderado (c). x_{ij} se refiere al atributo de la especie j para el rasgo i (Laliberté *et al.*, 2010).

2.3. Análisis comparativo de los plots gemelos

Con el objetivo de confirmar la similitud de los *plots* gemelos utilizados para obtener datos biofísicos (gemelo 1) y de biodiversidad (gemelo 2) se comparó la información común disponible recogida en ambos gemelos durante la campaña: datos espectrales y AGB_v .

A partir de la información espectral medida con el espectro-radiómetro en ambos gemelos se efectuó un análisis estadístico comparativo utilizando como referencia tres índices, $NDVI$, $RENDVI$ y $NDII$, que incluyen bandas en las principales regiones del espectro (Visible, RE , NIR y $SWIR$) (Tabla 1). Se realizó un análisis de correlación, así como la prueba *U de Mann-Whitney* (Wilcoxon, 1945) y se calcularon el coeficiente de determinación (R^2) y el error medio cuadrático relativo ($rRMSE$) para evaluar el ajuste entre los datos correspondientes a los gemelos.

$$rRSME = RSME / \bar{y} \quad (7)$$

Donde \bar{y} hace referencia al promedio de valores resultantes de las variables biofísicas en los 20 *plots* analizados.

Una comparación estadística similar se abordó utilizando, en lugar de los VI s, los datos de AGB_v .

2.4. Estimación de variables biofísicas y biodiversidad basada en IV s

Los VI s calculados para cada *plot* (Tabla 1) se utilizaron como variables predictoras en un análisis de regresión simple para estimar las variables biofísicas AGB , LAI , SLA y $N\%$ y los índices de *Shannon*, *Evenness* y $FDis$. Se representaron los diagramas de dispersión y se calcularon el R^2 y el $rRMSE$ para evaluar el ajuste y el error de predicción respectivamente.

2.5. Estimación de variables biofísicas y biodiversidad basada en datos hiperespectrales

Los VI s resumen excesivamente la información espectral disponible ya que se centran en un número reducido de bandas. La teledetección hiperespectral tiene la ventaja de ofrecer una mayor dimensionalidad espectral, pero requiere el uso de técnicas estadísticas específicas. En este estudio hemos utilizado la técnica estadística conocida como *PLSR* con el propósito de estimar las variables biofísicas y de biodiversidad aprovechando la totalidad de la variabilidad espectral de los datos

disponibles y de esta forma comparar su eficacia frente al análisis más tradicional basado en *VIs*. *PLSR* descompone las variables independientes en distintos parámetros o factores no correlacionados a través de la información contenida en la variable dependiente, y seguidamente emplea un modelo de regresión entre los datos espectrales observados y la variable de respuesta con la finalidad de seleccionar un número de componentes principales limitado que reducen la elevada dimensionalidad de la información hiperespectral (Clevers *et al.*, 2007). Aunque lo habitual en este tipo de técnicas estadísticas es separar los datos del estudio en un conjunto de ‘calibración’ (para entrenar el modelo) y otro de ‘validación’ (para evaluar como de extrapolable es el modelo en cuestión), en este caso no fue posible por el reducido número de datos disponibles por lo que se optó por aplicar la técnica de *cross-validation* que consiste en dividir iterativamente el conjunto de datos en diferentes grupos eliminando uno de ellos y ajustando un modelo a los grupos restantes (Kiala *et al.*, 2016). El modelo se utiliza para predecir los valores del grupo excluido, repitiendo el proceso para cada una de las muestras, y en última instancia, se promedian las métricas para obtener las puntuaciones finales (Kiala *et al.*, 2016).

Un paso clave en la aplicación del *PLSR* es la selección del número de componentes principales. En nuestro estudio la selección se efectuó cuando el número de componentes principales llega al valor mínimo de *RMSE* del análisis de *cross-validation* (Burnett *et al.*, 2021), limitando el número máximo de componentes principales a 8. De esta forma tratamos de evitar posibles problemas de *overfitting* (modelo con una elevada especificidad que sería incapaz de poder predecir ningún resultado eficaz sobre nuevos datos) así como encontrar un balance óptimo entre el rendimiento del modelo analizado y su nivel de extrapolación (Capolupo *et al.*, 2015). Seguidamente, se calculó la relación entre los valores observados y esperados del modelo *PLSR* de cada una de las variables biofísicas e índices de diversidad a través del R^2 .

Como análisis adicional se investigó, a través de los coeficientes de regresión normalizados, qué bandas o rangos espectrales tuvieron más peso en el modelo y, por lo tanto, pueden considerarse más relevantes en la estimación de las variables analizadas. La justificación en el empleo de este método reside en su sencilla comprensión e implementación en comparación con otras técnicas (Dechant *et al.*, 2017; Burnett *et al.*, 2021).

2.6. Relación entre variables biofísicas y diversidad

Finalmente, con objeto de comprobar si las variables biofísicas utilizadas en el estudio permitían explicar total o parcialmente la diversidad taxonómica y funcional del ecosistema en los *plots* de muestreo, se efectuó una regresión lineal múltiple entre las variables correspondientes al gemelo 1, *SLA*, *AGB*, *LAI* y *N%* en sus variantes total, verde y no verde, y la diversidad estimada según los índices *Shannon*, *Evenness* y *FDis* utilizando las primeras como variables predictoras y los índices como variables respuesta. Cabe destacar que la fracción *N%_v* no se empleó en este análisis debido a la ausencia de información en algunos *plots*. A partir de los coeficientes de regresión resultantes analizamos la sensibilidad de la variable biofísica frente al modelo derivado para estimar los índices de biodiversidad. Con el propósito de que los coeficientes de regresión fuesen comparables se estandarizaron las variables independientes. Por otro lado, para conocer la fuerza de la relación de los dos conjuntos de datos, se calculó el R^2 en referencia a cada uno de los tres índices de biodiversidad: índice de *Shannon*, *Evenness* y *FDis*, y a través del R^2 múltiple se obtuvo el porcentaje de variación de la diversidad que pudo ser explicada por las variables biofísicas.

3. Resultados

3.1. Análisis comparativo de los *plots* gemelos

La Figura 3 presenta los resultados de la comparación de los valores de *AGB_v* obtenidos de los muestreos realizados en el gemelo 1 y el gemelo 2. Como se puede observar, los datos son muy similares,

aunque los valores de AGB_v del gemelo 1 son ligeramente inferiores a los registrados en el gemelo 2 (148.96 y 163.67 g/m^2 respectivamente) y presentan también una menor dispersión (36.8 y 30.1 g/m^2 respectivamente). De la correlación entre los dos conjuntos de datos obtuvimos un R^2 de 0.35 y un $RMSE$ de 2.08 g/m^2 . Por lo que respecta a la prueba *U Mann-Whitney*, el p -value resultante fue de 0.341 por lo que se acepta la hipótesis nula de que AGB_v presenta valores similares en los *plots* gemelos y conforman la misma población y distribución.

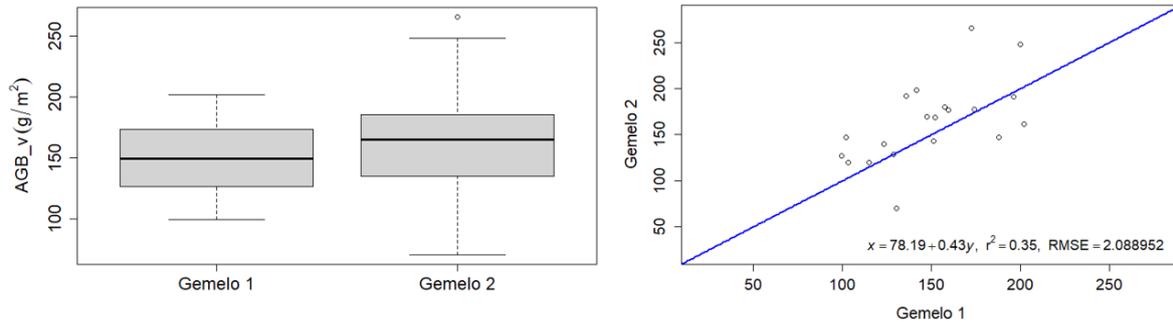


Figura 3. Diagrama de cajas (izquierda) y gráfico de dispersión (derecha) comparando los valores de AGB_v obtenidos en los gemelos 1 y 2 de los 20 *plots* muestreados. En el diagrama de cajas la línea horizontal negra indica la mediana de cada caja. En el gráfico de dispersión se muestra la ecuación de la recta, R^2 y $rRMSE$ así como la recta 1:1 (en azul).

Los resultados del análisis de similitud espectral basado en la comparación de valores de VIs calculados a partir de mediciones realizadas en ambos gemelos se muestran en la Tabla 2. El mayor R^2 se obtuvo con el $NDVI$ y el menor con el $NDII$. Cabe destacar que 5 de los 15 *plots* analizados presentan diferencias superiores al 40%, 3 de ellos corresponden a parcelas de la zona central 1 de la norte y 1 de la sur. De los 3 *plots* identificados en la zona central, dos corresponden a una misma parcela, la Z1P5. En relación con los resultados de la prueba *U Mann-Whitney* (Tabla 2), la mayoría de los *plots* presentaron diferencias espectrales que pueden ser consideradas aceptables para asumir la hipótesis inicial de su similitud.

Tabla 2. Resultados de la correlación (R^2) y su error relativo ($rRMSE$) así como de la prueba *U Mann-Whitney* en los tres VIs analizados.

VI	R^2	$rRMSE$	p -value
$NDVI$	0.39	0.101	0.3273
$RENDVI$	0.23	0.095	0.3013
$NDII$	0.16	0.277	0.4777

En la Figura 4 se muestra uno de los *plots* que ofrecieron mayor diferencia espectral entre gemelos (parcela Z1P5 muestra 2). Como se puede observar en este caso, las diferencias espectrales más importantes se encuentran las regiones del NIR y el $SWIR$, especialmente en la primera. En la Figura 5 se muestra el ejemplo contrario, un *plot* con gemelos que presentan un comportamiento espectral muy similar (parcela Z5P2 muestra 1) en todas las regiones del espectro.

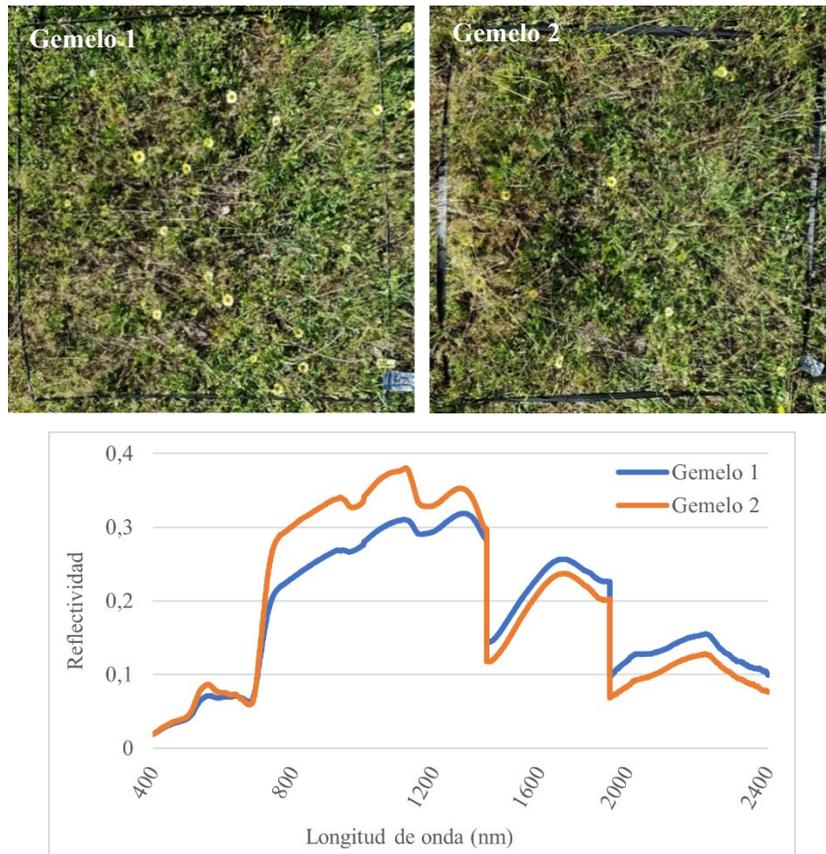


Figura 4. Fotografías de campo y espectros promedio obtenidos con el espectro-radiómetro ASD en los plots gemelos de la parcela ZIP5 (zona central) muestra 2.

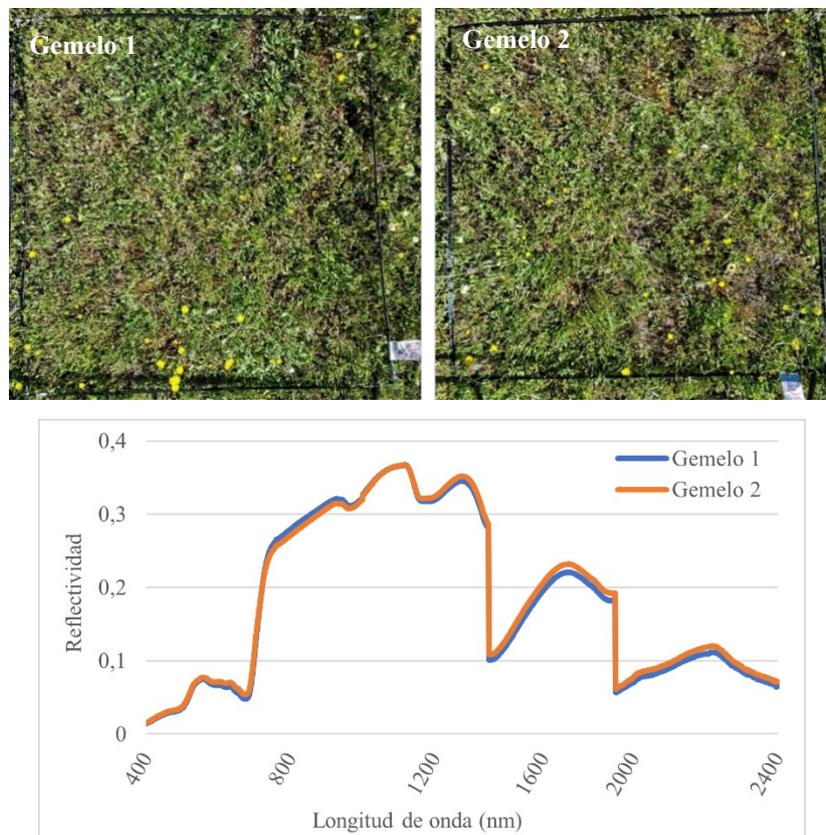


Figura 5. Fotografías de campo y espectros promedio obtenidos con el espectro-radiómetro ASD en los plots gemelos de la parcela Z5P2 (zona central) muestra 1.

3.2. Estimación de variables biofísicas y diversidad basada en VIs

Las Tablas 3 y 4 muestran el R^2 y el $rRMSE$ obtenidos en el análisis de regresión entre VIs e índices de diversidad y entre VIs y variables biofísicas, respectivamente. Los ajustes obtenidos con los índices de diversidad fueron muy bajos en general, aunque ligeramente superiores en el caso de *FDis*. *NDNI* presentó el mayor R^2 (0.26) y $rRMSE$ de 0.15 seguido de *LWVI2* ($R^2 = 0.19$) con un $rRMSE$ de 0.15. *PRI* mostró el R^2 más alto (0.19) con el índice de *Shannon* cuyo $rRMSE$ fue de 0.22 mientras que las correlaciones con el índice *Evenness* fueron muy bajas ($R^2 < 0.1$) para todos los VIs.

Tabla 3. R^2 y $rRMSE$ obtenidos en el análisis de regresión entre VIs e índices de biodiversidad.

	Índice de Shannon		Índice de Evenness		FDis	
	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$
<i>NDVI</i>	0.06	0.24	0.02	0.15	0.00	0.17
<i>SR</i>	0.05	0.24	0.01	0.15	0.00	0.17
<i>SIPI</i>	0.05	0.24	0.02	0.15	0.00	0.17
<i>NDII</i>	0.00	0.24	0.00	0.16	0.18	0.15
<i>RENDVI</i>	0.06	0.24	0.01	0.15	0.00	0.17
<i>PRI</i>	0.19	0.22	0.06	0.16	0.03	0.16
<i>MTVI2</i>	0.00	0.24	0.01	0.08	0.00	0.17
<i>LWVI2</i>	0.00	0.24	0.00	0.16	0.19	0.15
<i>NDNI</i>	0.03	0.24	0.04	0.15	0.26	0.15
<i>Clre</i>	0.07	0.24	0.01	0.15	0.00	0.17

Tabla 4. R^2 y $rRMSE$ obtenidos en el análisis de regresión entre VIs y las variables biofísicas. Se han destacado en negrita aquellas con $R^2 > 0.5$.

	AGB		AGB v		LAI		LAI v		LAI nv	
	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$
<i>NDVI</i>	0.30	0.17	0.29	0.18	0.01	0.23	0.01	0.21	0.00	0.48
<i>SR</i>	0.19	0.19	0.15	0.20	0.05	0.19	0.08	0.20	0.01	0.46
<i>SIPI</i>	0.20	0.19	0.15	0.20	0.05	0.19	0.09	0.20	0.04	0.46
<i>NDII</i>	0.11	0.20	0.20	0.19	0.24	0.17	0.40	0.16	0.04	0.46
<i>RENDVI</i>	0.23	0.18	0.21	0.19	0.02	0.20	0.03	0.21	0.01	0.47
<i>PRI</i>	0.17	0.19	0.25	0.18	0.01	0.20	0.03	0.21	0.02	0.46
<i>MTVI2</i>	0.07	0.20	0.05	0.21	0.06	0.19	0.07	0.21	0.00	0.47
<i>LWVI2</i>	0.11	0.20	0.23	0.19	0.30	0.17	0.43	0.16	0.05	0.45
<i>NDNI</i>	0.11	0.20	0.17	0.19	0.32	0.16	0.42	0.16	0.02	0.46
<i>Clre</i>	0.20	0.19	0.19	0.19	0.01	0.20	0.02	0.21	0.00	0.47
	SLA		SLA v		SLA nv		N%		N% v	
	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$	R^2	$rRMSE$
<i>NDVI</i>	0.52	0.12	0.47	0.13	0.24	0.26	0.22	0.15	0.62	0.09
<i>SR</i>	0.62	0.10	0.55	0.12	0.35	0.24	0.20	0.16	0.41	0.11
<i>SIPI</i>	0.65	0.10	0.59	0.11	0.31	0.24	0.12	0.17	0.29	0.12
<i>NDII</i>	0.08	0.16	0.06	0.17	0.12	0.28	0.09	0.17	0.07	0.14
<i>RENDVI</i>	0.52	0.12	0.47	0.13	0.25	0.26	0.33	0.15	0.57	0.09
<i>PRI</i>	0.08	0.16	0.09	0.17	0.02	0.29	0.34	0.14	0.52	0.10
<i>MTVI2</i>	0.31	0.14	0.27	0.15	0.33	0.24	0.10	0.17	0.43	0.11
<i>LWVI2</i>	0.08	0.16	0.04	0.18	0.18	0.27	0.11	0.17	0.10	0.13
<i>NDNI</i>	0.07	0.16	0.08	0.17	0.07	0.28	0.08	0.17	0.03	0.14
<i>Clre</i>	0.41	0.13	0.38	0.14	0.17	0.27	0.38	0.14	0.55	0.09

Las correlaciones entre VIs y variables biofísicas presentan, en general, mejores ajustes que con las variables de diversidad (Tabla 4). La variable biofísica que presenta la mayor correlación es *SLA* con

el índice *SIPI* ($R^2 = 0.65$) y *rRMSE* de 0.1. Cabe destacar la variable *N%* ya que presenta las correlaciones más altas ($R^2 > 0.5$) hasta en cuatro *VI*s: *NDVI* (0.62), *RENDVI* (0.57), *PRI* (0.52) y *CIre* (0.55). En cuanto a las variables biofísicas *LAI* y *AGB* los resultados han sido inferiores ($R^2 < 0.4$). La variable *LAI_v* presenta la mayor correlación ($R^2 = 0.4$) con *LWVI2* y *rRMSE* de 0.16, que junto con *NDNI* presentan el mínimo *rRMSE*.

3.3. Estimación de variables biofísicas y biodiversidad basada en bandas espectrales

Los datos hiperespectrales a través del *PLSR* mejoraron los resultados del análisis de regresión expresada a través del R^2 y el *rRMSE* (Tabla 5) respecto a los conseguidos con los *VI*s (Tabla 3 y 4). En este caso, como ocurría con los *VI*s, las variables *SLA* y *N%* presentan los R^2 más altos (0.75 y 0.69 respectivamente). Además, la estimación basada en bandas con la técnica del *PLSR* permite alcanzar ajustes elevados también con otras variables como *AGB_v* ($R^2 = 0.72$). En todos los casos las fracciones verdes de las variables *AGB*, *LAI* y *SLA* presentan un R^2 igual o superior respecto al ajuste con el valor de dichas variables que incluye ambas fracciones. Los ajustes del modelo disminuyen en todos los casos al aplicar la validación cruzada lo que puede deberse a las limitaciones derivadas del tamaño de la muestra.

Tabla 5. R^2 y *rRMSE* obtenidos con *PLSR* y datos hiperespectrales para variables biofísicas e índices de diversidad para los modelos de calibración y validación (cross-validation). Se muestran en negrita valores de $R^2 > 0.5$.

Variable Biofísica / Diversidad	Calibración		Cross-Validation	
	R^2	<i>rRMSE</i>	R^2	<i>rRMSE</i>
AGB	0.5	0.11	0.14	0.17
AGB_v	0.72	0.08	0.33	0.15
<i>LAI</i>	0.15	0.16	0.03	0.19
<i>LAI_v</i>	0.26	0.15	0.09	0.18
<i>LAI_nv</i>	0.15	0.37	0.00	0.55
SLA	0.69	0.07	0.23	0.13
SLA_v	0.69	0.07	0.16	0.15
<i>SLA_nv</i>	0.12	0.24	0.00	0.31
N%	0.75	0.07	0.36	0.12
N%_v	0.52	0.07	0.26	0.10
<i>Índice de Shannon</i>	0.01	0.23	0.01	0.29
<i>Índice de Evenness</i>	0.01	0.15	0.00	0.18
<i>FDis</i>	0.01	0.16	0.00	0.19

El aumento de la dimensionalidad espectral no contribuye, sin embargo, a una mejora sustancial de la estimación de los índices de diversidad y confirma que los datos espectrales (multiespectrales e hiperespectrales) y la diversidad no presentan una correlación suficiente como para permitir la estimación de las últimas a partir de datos ópticos en este tipo de ecosistema y sin considerar la componente temporal (fenología).

Como se ha descrito en la metodología, en el estudio realizado a partir de los datos hiperespectrales además de la estimación de las variables objetivo se investigó, a través de los coeficientes de regresión, qué bandas o rangos espectrales tuvieron más peso en el modelo *PLSR* y, por lo tanto, pueden considerarse más relevantes en la estimación de las variables biofísicas y biodiversidad analizadas. Los resultados de este análisis se observan en la Figuras 6 y 7 que incluye los gráficos de dispersión entre las variables estimadas y predichas y los pesos relativos de los coeficientes para cada banda del modelo y cada variable analizada. Para simplificar la representación se han descartado las versiones *_nv* de las distintas variables ya que estas presentaron siempre menores ajustes (Tabla 5). Como se puede observar, *AGB* y *AGBv* los valores de los coeficientes de regresión indican que las regiones del Visible y el *SWIR* son las que presentan un mayor peso en el modelo y, por lo tanto, las más relevantes para la estimación de estas variables. En el caso de *LAI* y *LAI_v* destaca el peso de las

bandas *SWIR*. Para las variables *SLA* y *SLA_v* destaca la importancia de la región del Visible y el *Red-edge*. En la variable *N%* es evidente la importancia del *Red-edge* (680-750 nm) para *N%* total y de Visible + *RE* para la fracción verde y el *SWIR*, especialmente en la zona de 1500-1600 nm. En lo que respecta a los índices de diversidad, el rango espectral perteneciente al *NIR* seguido de *SWIR* muestran la mayor influencia en la estimación de los índices de *Shannon* y *Evenness*. Por lo que respecta a *FDis*, tanto el *Red-edge* como el *NIR* ostentan el mayor peso en el modelo.

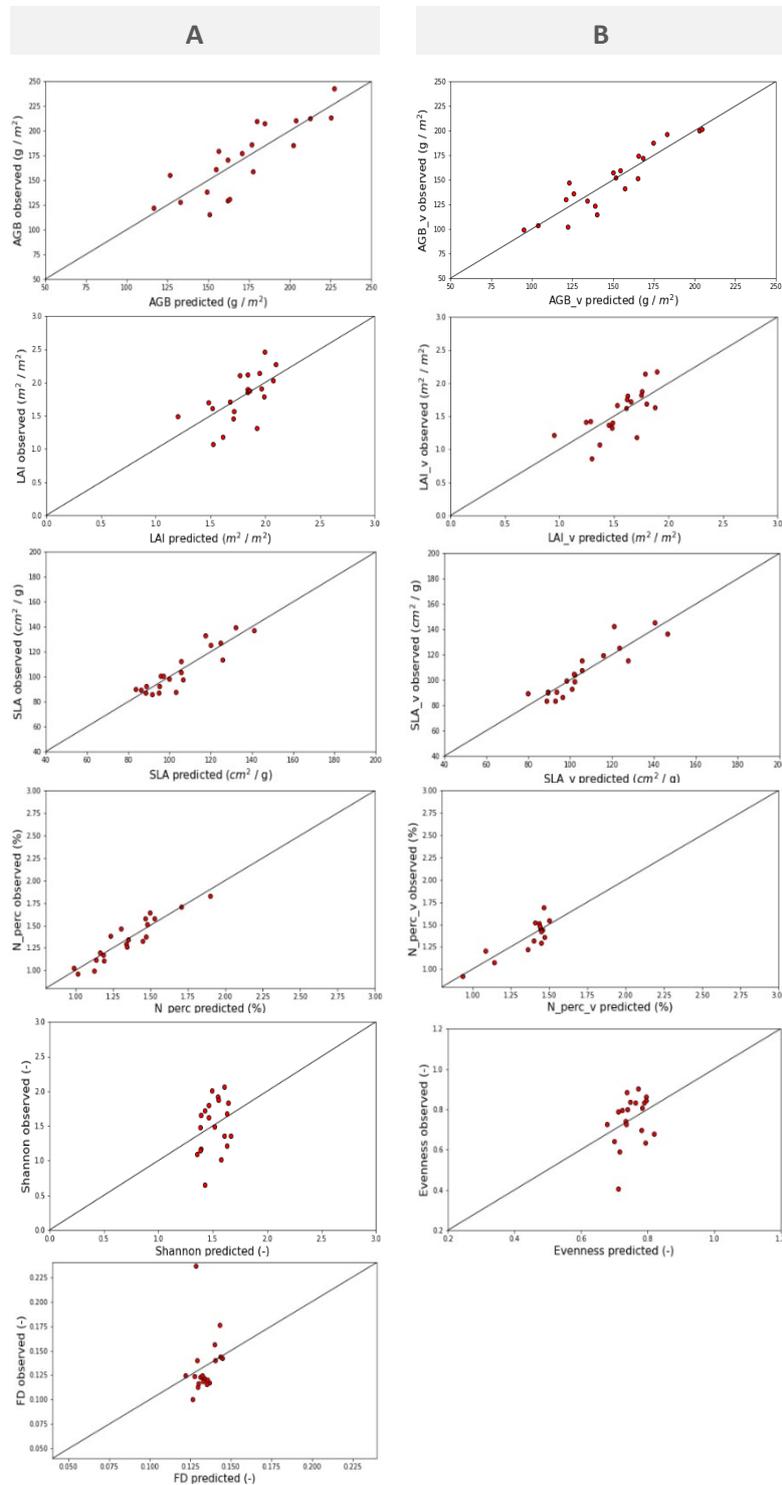


Figura 6. Gráficos de dispersión entre las variables biofísicas y de diversidad observadas y estimadas a través de los datos hiperespectrales por medio del método estadístico PLSR (Para las variables biofísicas la columna A muestra el valor total de la variable y la columna B el de la fracción verde).

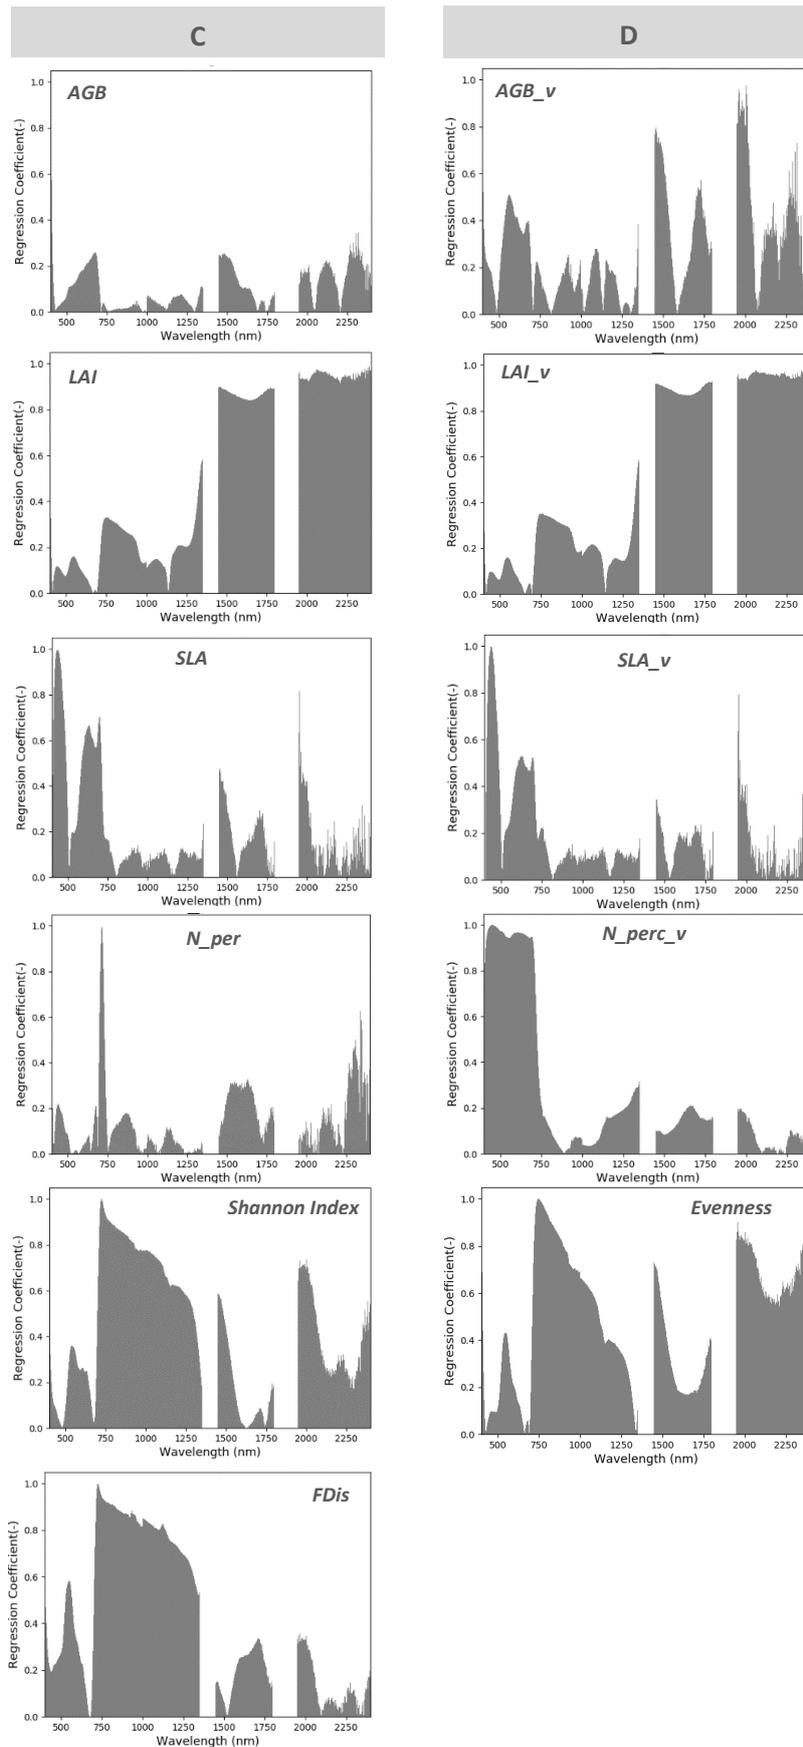


Figura 7. Gráficos con los valores normalizados de los coeficientes de regresión de cada banda que muestra su importancia relativa en la estimación de las variables (para las variables biofísicas la columna A muestra el valor total de la variable y la columna B el de la fracción verde).

3.4. Relación entre variables biofísicas y diversidad

El análisis de regresión múltiple nos permitió analizar, de forma preliminar, la relación entre las variables biofísicas estudiadas y la diversidad observada en campo a nivel de *plot* de muestreo. La correlación más elevada la mostró el modelo predictivo de *FDis* ($R^2 = 0.63$, $rRMSE = 0.13$), seguido de *Evenness* ($R^2 = 0.51$, $rRMSE = 0.11$) y *Shannon* ($R^2 = 0.46$, $rRMSE = 0.18$).

En la Tabla 6 se muestran los coeficientes de regresión obtenidos para cada variable biofísica (cuyos valores fueron normalizados previamente) en cada uno de los modelos predictivos de índices de diversidad. La variable *LAI_v* presenta el coeficiente de regresión más alto para los tres índices de diversidad (-2.70, -1.03, -0.22, para *Shannon*, *Evenness* y *FDis* respectivamente), por lo que podría considerarse como la variable que más influye para explicar la variabilidad de estos índices en el conjunto de datos de muestreo. *AGB_v* sería la segunda variable con más peso en el índice de *Shannon* y *FDis* (coeficientes de 2.38 y 0.17, respectivamente) mientras que la variable *LAI* ocuparía el segundo lugar en orden de importancia para el modelo predictivo del índice de *Evenness* (1.00). Las variables *N%* y *SLA* presentan los coeficientes más bajos.

Tabla 6. Coeficientes de regresión estandarizados obtenidos en los tres modelos regresión múltiple entre las variables biofísicas (predictoras) y los índices de diversidad. Se indica el R^2 y $rRMSE$ de cada modelo.

Variables biofísicas	Diversidad		
	Índice de Shannon	Índice de Evenness	<i>FDis</i>
<i>AGB</i>	-2.18	-0.81	-0.13
<i>AGB_v</i>	2.38	0.84	0.17
<i>LAI</i>	2.33	1.00	0.16
<i>LAI_v</i>	-2.70	-1.03	-0.22
<i>SLA</i>	-0.33	-0.06	-0.08
<i>SLA_v</i>	0.74	0.15	0.13
<i>SLA_nv</i>	-0.27	-0.10	0.01
<i>N%</i>	-0.16	-0.01	0.01
R^2	0.46	0.51	0.63
$rRMSE$	0.18	0.11	0.13

4. Discusión

En este trabajo se ha demostrado la importancia de la dimensión espectral en la estimación de variables biofísicas de la vegetación y su relación funcional con la diversidad en un pastizal semi-árido comprobándose la mejora sustancial que los datos hiperespectrales aportan respecto a los *VI*s en dicha estimación.

Respecto a la recopilación de datos en campo, se ha podido demostrar la viabilidad del planteamiento de un esquema de muestreo innovador, aplicable cuando el tipo de variables a muestrear impide trabajar sobre una única muestra y basado en la selección de *plots* que se consideraban “gemelos” a partir de un sencillo criterio visual. Este planteamiento ha permitido la recopilación de un conjunto de variables que hubiera sido imposible obtener en una única unidad de muestreo. Sin embargo, el diseño del muestreo ha puesto de manifiesto algunas limitaciones relacionadas con las diferencias observadas entre algunos *plots* gemelos en las variables biofísicas (*AGB_v*) y espectrales (*VI*s) comparadas en base a datos obtenidos en ambos *plots*. De los tres *VI*s utilizados en la comparación, *NDVI* presentó el mayor R^2 (0.39) y *NDII* el menor (0.16), lo cual podría indicar la existencia de mayores diferencias espectrales entre gemelos en la región del *SWIR*, utilizada en el cálculo de *NDII* frente a las bandas del Visible usadas en el *NDVI* (Tabla 1). Existen una serie de factores ambientales que podrían explicar las disimilitudes espectrales observadas entre algunos *plots* visualmente similares. Las flores y las condiciones edáficas afectan especialmente al espectro visible y como se ha observado en las fotos de

campo de las Figuras 4 y 5, los *plots* gemelos poseen algunas especies en estado de floración. La estructura vertical de la vegetación y más concretamente el ángulo de orientación de las hojas (*LAD*) afecta a la reflectividad de la vegetación de los *plots* analizados, específicamente en el rango del *NIR*. Por tanto, ligeras diferencias en la proporción de especies de cada *plot* gemelo, no evidentes a simple vista, podrían provocar diferencias espectrales a veces significativas. En lo que respecta al rango del *SWIR*, las diferencias en el contenido de humedad de algunas especies, así como la mezcla de especies que han iniciado su senescencia y que presentan rangos de absorción característicos en esta región podrían explicar las disimilitudes espectrales encontradas entre algunos *plots* gemelos.

En el análisis relativo a la estimación de variables biofísicas y diversidad basada en *VI*s se han obtenido correlaciones bajas para los índices de diversidad que mejoran para las variables biofísicas. Algunos autores han encontrado también ajustes discretos en la relación entre el *NDVI* y la riqueza de especies ($R^2 > 0.3$), debido a las condiciones ambientales y la fenología de la floración (e. g. Wang *et al.*, 2016). En el presente trabajo no se disponía de variabilidad temporal ya que todos los datos se tomaron en campo en una única campaña lo que podría explicar los ajustes resultantes entre *NDVI* y los índices de diversidad. Los resultados de nuestro estudio en lo que respecta a la estimación de variables biofísicas, aunque más altos, también fueron algo inferiores a los encontrados en otros estudios (e. g. Hurcom y Harrison, 1998) que obtuvieron ajustes altos entre *SLA* y *NDVI* ($R^2 > 0.7$). En nuestro trabajo la estimación de la variable *SLA* a partir de *VI*s obtuvo un $R^2 > 0.5$ en cuatro (*NDVI*, *SR*, *SIPI*, *RENDVI*) de diez *VI*s (Tabla 1) mientras que su fracción verde *SLA_v* en dos (*SR* y *SIPI*) *VI*s.

Los datos hiperespectrales empleados a través de la técnica *PLSR* mejoraron notablemente la estimación de variables como *AGB* ($R^2 > 0.7$), *SLA* ($R^2 > 0.6$) y *N%* ($R^2 > 0.7$) mientras que *LAI* obtuvo tan sólo un R^2 ligeramente superior al del análisis basado en *VI*s. Los resultados obtenidos en este estudio para la variable *N%* ($R^2 = 0.75$, $rRMSE = 0.07$) coincide con los de otros autores (e. g. Pellissier *et al.*, 2015) que estimaron *N%* en pastizales a partir de modelos *PLSR* empleando información adquirida por espectro-radiómetros de campo ($R^2 = 0.76$, $rRMSE = 0.29$). Cabe destacar que la reducción del R^2 y el aumento de $rRMSE$ del *cross-validation* comparado con los estadísticos obtenidos durante la calibración de los modelos *PLSR* señalizan una extrapolabilidad limitada de estos modelos empíricos, que muy probablemente se ven afectados por el pequeño tamaño de la muestra utilizada en este estudio. A partir del modelo *PLSR* se determinaron, además, aquellas bandas y rangos del espectro que presentaban una mayor importancia en el modelo y con ello, una mayor relevancia en la estimación de las variables biofísicas e índices de diversidad. Las regiones *VIS* y *RE* son claramente destacadas en la estimación de las variables *SLA* y *N%*. La región del *SWIR* ha demostrado ser relevante en la estimación de las variables relacionadas con el crecimiento vegetal, *AGB* y *LAI*, debido probablemente a los efectos producidos por la disponibilidad de los recursos hídricos en un ecosistema semi-árido, además de los causados por los contenidos de carbohidratos y polifenoles estructurales de la vegetación como lignina, almidón y celulosa (Elvidge, 1990). Finalmente, el *NIR* aparece como la región más importante en la estimación de los índices *Shannon*, *Evenness* y *FDis*, influido posiblemente por la estructura y disposición de las especies (Hunt, 1991). De la misma forma que con los coeficientes de regresión, existen otros métodos como *Variable Influence on Projection (VIP)* que también son de utilidad en la selección y distinción de aquellas bandas espectrales más influyentes en la estimación de variables biofísicas (e.g. Sakowska *et al.*, 2016; Burnett *et al.*, 2021). Otros autores también describen métodos para seleccionar las bandas espectrales más informativos como paso previo para mejorar la calibración y aplicabilidad de los modelos *PLSR* (e.g. Jia y Wang, 2019). En relación con la estimación de las variables biofísicas analizadas, aunque no se ha abordado en este estudio, se podrían haber aplicado pre-tratamientos de los datos hiperespectrales tales como normalizaciones o derivadas para maximizar los rasgos de absorción que quizá podrían mejorar el ajuste de la técnica *PLSR* (e.g. Gong *et al.*, 2015; Feilhauer *et al.*, 2010). Por ejemplo, Feilhauer *et al.* (2010) recomendaron el uso de *brightness normalization* (o normalización de brillo) sobre los espectros hiperespectrales para limitar los efectos de las condiciones de observación como el ángulo, condiciones atmosféricas, etc., y de la estructura del dosel obteniendo una mejora de

los ajustes de los modelos *PLSR* para estimar variables bioquímicas a nivel de hoja y una estabilización de estos para las estimaciones a nivel de dosel.

El análisis de regresión múltiple demostró la relación entre el conjunto de variables biofísicas seleccionadas y la diversidad funcional representada por *FDis*. Esto permitiría pensar en la posibilidad de realizar una estimación indirecta de la diversidad funcional a partir de datos espectrales mediante la estimación de variables biofísicas que permitan su caracterización. Algunos autores han analizado la *FD* a partir de la variable *SLA* mediante datos espectrales de Sentinel-2 con el objetivo de distinguir los distintos tipos de gestión en un ecosistema de pasto (e.g. Rossi *et al.*, 2018). Los resultados mostraron que a través de *SLA* se puede estimar la *FD* a distintas escalas en este ecosistema ofreciendo, por tanto, una herramienta clave para la toma de decisiones de conservación y restauración ambiental. En el presente trabajo, *SLA* obtuvo, en la estimación de *FDis*, un coeficiente de regresión inferior al de otras las variables como *AGB_v*, *LAI* y *LAI_v*. La variable biofísica *LAI*, seguida de las fracciones *AGB_v* y *LAI_v* fueron las que mostraron una mayor influencia en la estimación de los índices de *Shannon*, *Evenness* y *FDis*. Sin embargo, es preciso indicar que el análisis de regresión múltiple efectuado puede presentar problema de multicolinealidad que podrían afectar a la interpretación del modelo. Al tratarse de un análisis de carácter exploratorio se ha asumido dicho problema y por esta razón se ha utilizado todo el conjunto de las variables biofísicas seleccionadas.

Las limitaciones de este trabajo se relacionan principalmente con la cantidad de datos disponibles desde el punto de vista espacial, pero sobre todo desde el punto de vista temporal. La dificultad de obtener dicha información a la escala y con la calidad requerida es un limitante importante al abordar este tipo de estudios. Un ejemplo son los problemas que presenta para comprobar el rendimiento de los modelos *PLSR* mediante el conjunto de datos independientes para la calibración y validación obligando a recurrir a métodos alternativos como *cross-validation*. Por otro lado, la componente temporal conforma un factor de gran relevancia en los ecosistemas semi-áridos donde la presencia de especies está condicionada por la fenología. La falta de variabilidad temporal ha impedido en este estudio utilizar la diversidad fenológica existente en el ecosistema para mejorar la capacidad predictiva de los modelos. Futuros estudios en el contexto del proyecto que se describe en este trabajo prevén incorporar nuevos muestreos que consideran la componente fenológica como variable auxiliar para mejorar la capacidad predictiva de los modelos. Alternativamente, ante la dificultad de abordar muestreos intensivos en el espacio y el tiempo, algunos autores han recurrido al uso de datos hiperespectrales obtenidos en continuo por sensores autónomos o semi-autónomos utilizados en diseños experimentales controlados (e.g. Wang *et al.*, 2018; Hollberg and Schellberg, 2017).

5. Conclusión

En este trabajo se ha demostrado el potencial de la teledetección hiperespectral frente al uso más convencional de información multispectral en forma de *VI*s para estimar variables biofísicas claves en relación con la diversidad funcional del estrato herbáceo en un ecosistema de dehesa. Los resultados han concluido que la utilización de datos hiperespectrales mejora notablemente la estimación de variables biofísicas, *SLA* y *N%*. Los rangos espectrales más relevantes en la estimación de las variables biofísicas ha sido el *SWIR* para *AGB* y *LAI*, y el Visible para *SLA* y *N%*. El análisis de regresión múltiple ha demostrado que las variables *LAI*, *LAI_v* y *AGB_v* fueron las más influyentes en la estimación de los índices de diversidad, especialmente *FDis*.

Referencias

Ali, A.M., Darvishzadeh, R., Skidmore, A.K., Duren, I. 2017. Specific leaf area estimation from leaf and canopy reflectance through optimization and validation of vegetation indices. *Agricultural and Forest Meteorology*, 236, 162-174. <https://doi.org/10.1016/j.agrformet.2017.01.015>

- Barrachina, M., Cristóbal, J., Tulla, A.F. 2015. Estimating above-ground biomass on mountain meadows and pastures through remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 38, 184-192. <https://doi.org/10.1016/j.jag.2014.12.002>
- Birth, G., McVey, G. 1968. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer. *Agronomy Journal*, 60, 640-643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>
- 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. <https://doi.org/10.1016/j.agee.2006.05.024>
- Bréda, N.J.J. 2003. Ground-based measurements of leaf area index: a review of methods, instruments, and current controversies. *Journal of Experimental Botany*, 54, 2403-2417. <https://doi.org/10.1093/jxb/erg263>
- Burchard-Levine, V., Nieto, H., Riaño, D., Migliavacca, M., El-Madany, T. S., Perez-Priego, O., et al. 2020. Seasonal Adaptation of the Thermal-Based Two-Source Energy Balance Model for Estimating Evapotranspiration in a Semiarid Tree-Grass Ecosystem. *Remote Sensing*, 12 (6), 904. <https://doi.org/10.3390/rs12060904>
- Burnett, A., Anderson, J., Davidson, K., Ely, K., Lamour, J., Li, Q., et al. 2021. A best-practice guide to predicting plant traits from leaf-level hyperspectral data using partial least squares regression. *Journal of Experimental Botany*, 72, 6175-6189. <https://doi.org/10.1093/jxb/erab295>
- Campos, P. 1993. Valores comerciales y ambientales de las dehesas españolas. *Agricultura y sociedad*, 66, 9-41.
- Carmona, C. P., Rota, C., Azcárate, F.M., Peco, B., 2015. More for less: sampling strategies of plant functional traits across local environmental gradients. *Functional Ecology*, 29, 579-588. <https://doi.org/10.1111/1365-2435.12366>
- Cavender-Bares, J., Gamon, J.A., Townsend, P.A. 2020. Remote Sensing of Plant Biodiversity. Springer. <https://doi.org/10.1007/978-3-030-33157-3>
- Clevers, J., Van der Heijden, G., Verzakov, S., Schaepman, M.E. 2007. Estimating Grassland Biomass Using SVM Band Shaving of Hyperspectral Data. *Photogrammetric Engineering & Remote Sensing*, 73 (10), 1141-1148. <https://doi.org/10.14358/PERS.73.10.1141>
- Cogliati, S., Rossini, M., Julitta, T., Meroni, M., Schickling, A., Burkart, A., et al. 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>
- Córdova-Tapia, F., Zambrano, L. 2015. La diversidad funcional en la ecología de comunidades. *Ecosistemas*, 24 (3), 78-87. <https://doi.org/10.7818/ECOS.2015.24-3.10>
- Dechant, B., Cuntz, M., Vohland, M., Schulz, E., Doktor, D. 2017. Estimation of photosynthesis traits from leaf reflectance spectra: Correlation to nitrogen content as the dominant mechanism. *Remote Sensing of Environment*, 196, 279-292. <https://doi.org/10.1016/j.rse.2017.05.019>
- Doughty, C.E. Goulden, M.L. 2008. Seasonal patterns of tropical forest leaf area index and CO₂ exchange. *J. Geophys. Res.*, 113. <https://doi.org/10.1029/2007JG000590>
- Dusseux, P., Gong, X., Hubert-Moy, L., Corpetti, T. 2014. Identification of grassland management practices from leaf area index time series. *Journal of Applied Remote Sensing*, 8 (1). <https://doi.org/10.1117/1.JRS.8.083559>
- Elvidge, C.D. 1990. Visible and near infrared reflectance characteristics of dry plant materials. *International Journal of Remote Sensing*, 11, 1775-1795. <https://doi.org/10.1080/01431169008955129>
- Escribano, J.A., Hernández, C.G., Tarquis, A.M. 2014. Selección de índices de vegetación para la estimación de la producción herbácea. *Pastos*, 44, 2, 6-18.
- Feilhauer, H., Asner, G.P., Martin, R.E., Schmidtlein, S. 2010. Brightness-normalized Partial Least Squares Regression for hyperspectral data. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 111 (12), 1947-1957. <https://doi.org/10.1016/j.jqsrt.2010.03.007>

- Galvão, L.S., Formaggio, A.R., Tisot, D.A. 2005. Discrimination of sugarcane varieties in Southeastern Brazil with EO-1 Hyperion data. *Remote Sensing of Environment*, 94 (4), 523-534. <https://doi.org/10.1016/j.rse.2004.11.012>
- Gamon, J., Serrano, L., Surfus, J. 1997. The Photochemical Reflectance Index: An Optical Indicator of Photosynthetic Radiation Use Efficiency Across Species, Functional Types and Nutrient Levels. *Oecologia*, 112. 492-501. <https://doi.org/10.1007/s004420050337>
- Gholizadeh, H., Gamon, J.A., Helzer, C.J., Cavender-Bares, J. 2020. Multi-temporal assessment of grassland α - and β -diversity using hyperspectral imaging. *Ecological Applications*, 30 (7). <https://doi.org/10.1002/eap.2145>
- Gong, Z., Kawamura, K., Ishikawa, N., Inaba, M., Alateng, D. 2015. Estimation of herbage biomass and nutritive status using band depth features with partial least squares regression in Inner Mongolia grassland, China. *Grassland Science*, 62 (1), 45-54. <https://doi.org/10.1111/grs.12112>
- 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, 337-352. <https://doi.org/10.1016/j.rse.2003.12.013>
- Hanan, N., Hill, M. 2012. Savannas in a Changing Earth System. The NASA Terrestrial Ecology Tree-Grass Project, Geographic Information Science Center of Excellence (GIScCE), South Dakota State University.
- Hardisky, M., Klemas, V., Smart, R. 1983. The Influences of Soil Salinity, Growth Form, and Leaf Moisture on the Spectral Reflectance of *Spartina Alterniflora* Canopies. *Photogrammetric Engineering and Remote Sensing* 49, 77-83.
- Hill, M.J., Hanan, N.P., Hoffmann, W., Scholes, R., Prince, S., Ferwerda, J., et al. 2011. Remote sensing and modelling of savannas: The state of the dis-union. 34th International Symposium on Remote Sensing of Environment, Sydney.
- Hollberg, J.L., Schellberg, J. 2017. Distinguishing Intensity Levels of Grassland Fertilization Using Vegetation Indices. *Remote Sensing*, 9 (1), 81. <https://doi.org/10.3390/rs9010081>
- Hurcom, S.J., Harrison, A.R. 1998. The NDVI and spectral decomposition for semi-arid vegetation abundance estimation. *International Journal of Remote Sensing*, 19 (16), 3109-3125. <https://doi.org/10.1080/014311698214217>
- Hunt, E.R. 1991. Airborne remote sensing of canopy water thickness scaled from leaf spectrometer data. *International Journal of Remote Sensing* 12, 643-649. <https://doi.org/10.1080/01431169108929679>
- Imran, H.A., Gianelle, D., Scotton, M., Rocchini, D., Dalponte, M., Macolino, S. 2021. Potential and Limitations of Grasslands α -Diversity Prediction Using Fine-Scale Hyperspectral Imagery. *Remote Sens.*, 13, 2649. <https://doi.org/10.3390/rs13142649>
- Jin, J., Wang, Q. 2019. Evaluation of Informative Bands Used in Different PLS Regressions for Estimating Leaf Biochemical Contents from Hyperspectral Reflectance. *Remote Sensing*, 11 (2), 197. <https://doi.org/10.3390/rs11020197>
- Kiala, Z., Odindi, J., Mutanga, O., Peerbhay, K. 2016. Comparison of partial least squares and support vector regressions for predicting leaf area index on a tropical grassland using hyperspectral data. *Journal of Applied Remote Sensing*, 10 (3). <https://doi.org/10.1117/1.JRS.10.036015>
- Laliberté, E., Legendre, P. 2010. A distance-based framework for measuring functional diversity from multiple traits. *Ecology*, 91(1), 299-305. <https://doi.org/10.1890/08-2244.1>
- Leitão, P., Schwieder, M., Suess, S., Okujeni, A., Galvão, L., Linden, S., et al. 2015. Monitoring Natural Ecosystem and Ecological Gradients: Perspectives with EnMAP. *Remote Sensing*, 7(10), 13098-13119. <https://doi.org/10.3390/rs71013098>
- Li, F., Jiang, L., Wang, X., Zhang, X., Zheng, J., Zhao, Q. 2013. Estimating grassland aboveground biomass using multitemporal MODIS data in the West Songnen Plain, China. *Journal of Applied Remote Sensing*, 7(1). <https://doi.org/10.1117/1.JRS.7.073546>

- Liu, L., Guan, L., Peng, D., Hu, Y., Jiao, Q., Liu, L. 2012. Monitoring the distribution of C3 and C4 grasses in a temperate grassland in northern China using moderate resolution imaging spectroradiometer normalized difference vegetation index trajectories. *Journal of Applied Remote Sensing*, 6 (1). <https://doi.org/10.1117/1.JRS.6.063535>
- Ma, X., Mahecha, M.D., Migliavacca, M., Van der Plas, F., Benavides, R., Ratcliffe, S., et al. 2019. Inferring plant functional diversity from space: the potential of Sentinel-2. *Remote Sensing of Environment*, 233. <https://doi.org/10.1016/j.rse.2019.111368>
- Madonsela, S., Cho, M.A., Ramoelo, A., Mutanga, O. 2017. Remote sensing of species diversity using Landsat 8 spectral variables. *ISPRS Journal of Photogrammetry and Remote Sensing*, 133, 116-127. <https://doi.org/10.1016/j.isprsjprs.2017.10.008>
- Martín, M.P., Pacheco-Labrador, J., González-Cascón, R., Moreno, G., Migliavacca, García, M., et al. 2020. Estimación de variables esenciales de la vegetación en un ecosistema de dehesa utilizando factores de reflectividad simulados estacionalmente. *Revista de Teledetección*, 55, 31-48.
- Melendo-Vega, J.R., Martín, M.P., Vilar del Hoyo, L., Pacheco-Labrador, J., Echavarría, P., Martínez-Vega, J. 2017. Estimación de variables biofísicas del pastizal en un ecosistema de dehesa a partir de espectroradiometría de campo e imágenes hiperespectrales aeroportadas. *Revista de Teledetección*, 48, 13-28. <https://doi.org/10.4995/raet.2017.7481>
- Milcu, A., Roscher, C., Gessler, A., Bachmann, D., Gockele, A., Guderle, M., et al. 2014. Functional diversity of leaf nitrogen concentrations drives grassland carbon fluxes. *Ecology Letters*, 17, 435-444. <https://doi.org/10.1111/ele.12243>
- Montserrat, P. 1968. La dehesa extremeña, VII Reunión científica de la Sociedad Española para el Estudio de los Pastos: Badajoz, Portugal, 1-7.
- Moreno, G., Rolo, V. 2019. Agroforestry practices: silvopastorism. *Agroforestry for sustainable agriculture*, Burleigh Dodds Science, 119-164.
- Mulder, C., Bazeley-White, E., Dimitrakopoulos, P., Scherer-Lorenzen, M., Schmid, B. 2004. Species evenness and productivity in experimental plant communities. *Oikos*, 107, 50-63. <https://doi.org/10.1111/j.0030-1299.2004.13110.x>
- Olea, L., Verdasco, M.P., Paredes, J. 1990. Características y producción de los pastos de las dehesas del S. O. de la Península Ibérica. *Pastos*, 131-156.
- Penuelas, J., Baret, F., Filella, I. 1995. Semi-Empirical Indices to Assess Carotenoids/Chlorophyll-a Ratio from Leaf Spectral Reflectance. *Photosynthetica*, 31, 221-230.
- Pérez-Harguindeguy, N., Díaz, S., Garnier, E., Lavorel, S., Poorter, H., Jaureguiberry, P. et al. 2013. New handbook for standardised measurement of plant functional traits worldwide. *Australian Journal of Botany*, 61(3), 167.
- Pellissier, P.A., Ollinger, S.V., Lepine, L.C., Palace, M.W., McDowell, W.H. 2015. Remote sensing of foliar nitrogen in cultivated grasslands of human dominated landscapes. *Remote Sensing of Environment*, 167, 88-97. <https://doi.org/10.1016/j.rse.2015.06.009>
- Psomas, A., Kneubühler, M., Huber, S., Itten, K., Zimmermann, N.E. 2010. Hyperspectral remote sensing for estimating aboveground biomass and for exploring species richness patterns of grassland habitats. *International Journal of Remote Sensing*, 32 (24), 9007-9031. <https://doi.org/10.1080/01431161.2010.532172>
- Pulido, F., Picardo, A., Campos, P., Carranza, J., Coletto, J., Díaz, M. et al. 2010. Libro Verde de la Dehesa., Consejería de Medio Ambiente, Junta Castilla La Mancha.
- Rinnan, Å., Berg, F., Engelsen, S.B. 2009. Review of the most common pre-processing techniques for near-infrared spectra. *TrAC Trends Anal. Chem.*, 28, 1201-1222. <https://doi.org/10.1016/j.trac.2009.07.007>
- Rolo, V., Rivest, D., Lorente, M., Kattge, J., Moreno, G. 2016. Taxonomic and functional diversity in Mediterranean pastures: insights on the biodiversity-productivity trade-off. *Journal of Applied Ecology* 53 (5), 1575-1584.

- Rossi, C., Kneubühler, M., Schütz, M., Schaepman, M.E, Haller, R.M. Risch, A.C. 2020. From local to regional: Functional diversity in differently managed alpine grasslands. *Remote Sensing of Environment*, 236. <https://doi.org/10.1016/j.rse.2019.111415>
- Rouse, J.W., Haas, R.H., Schell, J.A, Deering, D.W. 1973. Monitoring Vegetation Systems in the Great Plains with ERTS. Third ERTS Symposium, NASA, 309-317.
- Sakowska, K., Juszczak, R., Gianelle, D. 2016. Remote Sensing of Grassland Biophysical Parameters in the Context of the Sentinel-2 Satellite Mission. *Journal of Sensors*, 1-16. <https://doi.org/10.1155/2016/4612809>
- Sebastià, M.T., Llurba, R., Gouriveau, F., De Lamo, X., Ribas, A. Altimir, N. 2012 Biodiversidad y servicios ecosistémicos en pastos: distribución y respuesta al cambio global. *Sociedad Española para el Estudio de los Pastos (SEEP)*, 51, 134-145.
- Serrano, L., Peñuelas, J., Ustin, S.L. 2002. Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data. *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)
- Shannon, C., Weaver W. 1949. The mathematical theory of communication”, University of Illinois Press. Urbana, IL, EEUU, 144.
- Shoko, C., Mutanga, O., Dube, T. 2016. Progress in the remote sensing of C3 and C4 grass species aboveground biomass over time and space. *ISPRS Journal of Photogrammetry and Remote Sensing*, 120, 13-24. <https://doi.org/10.1016/j.isprsjprs.2016.08.001>
- Sims, D., Gamon, J. 2002. Relationships Between Leaf Pigment Content and Spectral Reflectance Across a Wide Range of Species, Leaf Structures and Developmental Stages. *Remote Sensing of Environment*, 81, 337-354. [https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/10.1016/S0034-4257(02)00010-X)
- Van Cleemput, E., Helsen, K., Feilhauer, H., Honnay, O., Somers, B. 2021. Spectrally defined plant functional types adequately capture multidimensional trait variation in herbaceous communities. *Ecological Indicators*, 120, 106970. <https://doi.org/10.1016/j.ecolind.2020.106970>
- Vohland, M., Jarmer, T. 2008. Estimating structural and biochemical parameters for grassland from spectroradiometer data by radiative transfer modelling (PROSPECT+SAIL). *International Journal of Remote Sensing*, 29 (1), 191-209. <https://doi.org/10.1080/01431160701268947>
- Wang, R., Gamon, J. 2019. Remote sensing of terrestrial plant biodiversity. *Remote Sensing of Environment*, 231, 111-218. <https://doi.org/10.1016/j.rse.2019.111218>
- Wang, R., Gamon, J., Montgomery, R., Townsend, P., Zyguelbaum, A., Bitan, K., et al. 2016. Seasonal Variation in the NDVI–Species Richness Relationship in a Prairie Grassland Experiment (Cedar Creek). *Remote Sensing*, 8 (2), 128. <https://doi.org/10.3390/rs8020128>
- Wang, R., Gamon, J., Schweiger, A.K., Cavender-Bares, J., Townsend, P.A., Zyguelbaum, A.I., Kothari, S. 2018. Influence of species richness, evenness, and composition on optical diversity: A simulation study. *Remote Sensing of Environment*, 211, 218-228. <https://doi.org/10.1016/j.rse.2018.04.010>
- Wilcoxon, F. 1945. Some Uses of Statistics in Plant Pathology. *Biometrics Bulletin*, 1, 41-45.
- Wu, C., Niu, Z., Tang, Q., Huang, W., Rivard, B., Feng, J. 2009. Remote estimation of gross primary production in wheat using chlorophyll-related vegetation indices. *Agricultural and Forest Meteorology*, 149(6-7), 1015-1021. <https://doi.org/10.1016/j.agrformet.2008.12.007>
- Xiang, M., Wu, J., Wu, J., Guo, Y., Lha, D., Pan, Y., Zhang, X. 2021. Heavy Grazing Altered the Biodiversity–Productivity Relationship of Alpine Grasslands in Lhasa River Valley, Tibet. *Frontiers Ecology and Evolution*, 9. <https://doi.org/10.3389/fevo.2021.698707>
- Zuo, X., Zhou, X., Lv, P., Zhao, X., Zhang, J., Wang, S., et al. 2016. Testing Associations of Plant Functional Diversity with Carbon and Nitrogen Storage along a Restoration Gradient of Sandy Grassland. *Frontiers in Plant Science*, 7. <https://doi.org/10.3389/fpls.2016.00189>