

Estimación de biomasa en herbáceas a partir de datos hiperespectrales, regresión PLS y la transformación *continuum removal*

Marabel-García, M.*; Álvarez-Taboada, F.

GEOINCA-202. Universidad de León. Campus de Ponferrada C/ Avda. de Astorga s/n 24401 Ponferrada (León), España.

Resumen: El objetivo del estudio fue comparar los resultados de dos métodos para la estimación de la biomasa aérea a partir de datos de espectroradiometría de campo: (i) regresión por mínimos cuadrados parciales (*Partial Least Squares Regression*, PLSR) y (ii) regresión lineal utilizando los índices Profundidad del Mínimo (*Maximum Band Depth*, MBD) y Área Sobre el Mínimo (*Area Over the Minimum*, AOM) como descriptores. En ambos casos se llevó a cabo una previa transformación de los espectros mediante *Continuum Removal* (CR). Como los resultados empleando PLS ($R^2=0,920$, $RMSE=3,622$ g/m²) fueron muy similares a los obtenidos con los índices (para AOM: $R^2=0,915$, $RMSE=3,615$ g/m²), recomendamos los índices derivados del CR puesto que su interpretación es más sencilla que la del PLSR.

Palabras clave: biomasa, pastizal, *continuum-removal*, espectrorradiómetro, hiperespectral, *partial least squares regression*.

Herbaceous biomass estimation using hyperspectral data, PLS regression and continuum removal transformation

Abstract: The aim of this research work was to compare the results of two methods to estimate aboveground biomass by using field spectrometer data: (i) Partial least squares regression (PLSR), and (ii) linear regression applied to the Maximum Band Depth (MBD) and Area Over the Minimum (AOM) indices. In both cases different regions of the spectrum were transformed by Continuum Removal (CR). Since the results using PLSR ($R^2=0.920$, $RMSE=3.622$ g/m²) were similar to the results achieved by the indices ($R^2=0.915$, $RMSE=3.615$ g/m² for AOM), using the indices derived from CR is recommended, since their interpretation is easier than the PLS output.

Key words: biomass, grass, continuum-removal, spectroradiometer, hyperspectral, partial least squares regression.

1. Introducción

La biomasa es una de las principales variables biofísicas de interés en los estudios de vegetación. La posibilidad de estimar la cantidad de biomasa sobre el terreno en zonas dominadas por especies herbáceas resulta fundamental por su relación directa con el carbono (Barrio *et al.*, 2006), que permite el estudio integral de los sistemas agroforestales como sumidero de carbono así como su

contribución al ciclo global del carbono. La capacidad de secuestro de carbono y su modelización puede facilitar la toma de decisiones en la estimación de la cosecha y del manejo de los residuos tras la misma (Pordesimo *et al.*, 2004). La biomasa se puede definir en términos de peso de materia fresca o como peso de la materia seca.

El empleo de técnicas no destructivas como la teledetección ha sido de uso habitual para caracterizar

* Autor para la correspondencia: mmarag@unileon.es

la vegetación mediante la estimación, por ejemplo, de la cantidad de clorofila o el contenido de agua. Estos estudios están relacionados con los datos de reflectividad espectral en la región de 400-2500 nm, debido a la presencia de características de absorción de diagnóstico en las curvas de reflectancia (Kokaly y Clark, 1999). Para la estimación de biomasa se han utilizado diferentes índices de vegetación derivados de las bandas del rojo y el infrarrojo cercano (NIR), (por ejemplo el ratio simple o el índice de vegetación de diferencia normalizada) (Nitsch *et al.*, 1991; Cho *et al.*, 2007). Sin embargo, varios estudios han mostrado que el cálculo de estos índices puede ser inadecuado para estimar la biomasa, debido a las variaciones de determinados factores como es el color del suelo, la estructura de la cubierta y/o las condiciones atmosféricas (Nitsch *et al.*, 1991) o porque pueden llegar a un valor asintótico cuando se alcanza un determinado valor de la biomasa (Gao *et al.*, 2000), lo que dificulta su uso en modelos predictivos. En este contexto, la aplicación de transformaciones espectrales y técnicas estadísticas adecuadas que tengan en cuenta la continuidad del espectro se plantea como una oportunidad para mejorar los modelos que estiman la biomasa aérea (Atzberger *et al.*, 2010).

Las mediciones hiperespectrales de cubiertas vegetales obtenidas mediante espectrorradiómetros (De Jong, 1994; Smith y Curran, 1996; Kokaly y Clark, 1999; Atzberger *et al.*, 2010) o sensores aerotransportados hiperespectrales (Huang *et al.*, 2004; Cho *et al.*, 2007; Axelsson *et al.*, 2013) contienen información útil para caracterizar la vegetación, si bien este conjunto de datos contiene mucha información redundante (Grossman *et al.*, 1996 y Schlerf *et al.*, 2005) y presenta un menor ratio señal/ruido que los datos de sensores multiespectrales. Estas dos deficiencias han fomentado el desarrollo de técnicas que permitan superar dichos problemas.

Uno de los retos habituales al emplear datos de espectrorradiómetro como datos de entrada en un modelo de estimación de una variable biofísica es la fuerte multicolinealidad entre las bandas del espectro, lo que desaconseja su uso como variables predictoras en un modelo de regresión lineal por mínimos cuadrados (OLSR, *Ordinary Least Square Regression*) (Curran *et al.*, 2001). Otro de los problemas en el ajuste de estos modelos es que

el número de muestras es mucho menor que el de variables descriptoras. Para evitar estos problemas se puede emplear (entre otras) la regresión por mínimos cuadrados parciales (PLSR, *Partial Least Squares Regression*), que tiene en cuenta la elevada correlación entre las variables y genera nuevas variables descriptoras en número inferior a las variables originales (Williams *et al.*, 1987). Esto último que resuelve también el problema del menor número de muestras que de variables predictoras. PLSR se ha empleado previamente en estudios relacionados con la estimación de biomasa a partir de datos hiperespectrales de sensores aerotransportados (Atzberger *et al.*, 2010; Mutanga *et al.*, 2012; Axelsson *et al.*, 2013).

Con el fin de mejorar la relación entre la información derivada del espectro y las variables biofísicas, en este caso la biomasa aérea, se pueden aplicar diferentes transformaciones que mejoran la precisión de los modelos de predicción (Dunn *et al.*, 2002; Kooistra *et al.*, 2003; Cho *et al.*, 2007; Vasques *et al.*, 2008; Axelsson *et al.*, 2013). Algunas de las transformaciones más comunes consisten en hacer suavizados, promedios, normalizaciones o derivadas (Vasques *et al.*, 2008), si bien la transformación más utilizada para la estimación de biomasa es la transformación *continuum removal* (CR) (Mutanga, 2004; Mutanga y Skidmore, 2004; Cho *et al.*, 2007; Axelsson, 2013). El espectro transformado en su conjunto, o bien los índices derivados del mismo, han permitido obtener modelos más exactos para predecir la biomasa aérea y otras variables biofísicas a partir de datos hiperespectrales (Pu *et al.*, 2003; Mutanga y Skidmore, 2004), en comparación con los obtenidos por los datos sin transformar.

2. Objetivos

El objetivo del presente estudio fue comparar los resultados en la estimación de la biomasa aérea medida como el peso seco de la fracción verde (Peso verde, PV), el peso seco de la biomasa aérea total (Peso total, PT), y el porcentaje del peso seco de la fracción verde (Porcentaje de peso verde, %PV) de herbáceas empleando dos métodos: (i) PLSR, y (ii) OLSR empleando índices calculados a partir de CR.

3. Material y Métodos

3.1. Área de estudio

El área de estudio se localizó en dos parcelas adyacentes de cultivos herbáceos, compuestas fundamentalmente por *Lolium perenne*, *Poa pratense* y *Trifolium repens*, sometidas a irrigación y de la misma edad. Estas dos parcelas se ubicaron en el municipio de Villanueva de la Cañada (Madrid), con una localización del centro de las mismas definida por las coordenadas ETRS89 UTM30 416381 4478513 y ETRS89 UTM30 416463 4478505.

3.2. Material

3.2.1. Datos espectrales

Los datos espectrales se tomaron en 30 unidades de muestreo. Cada una de estas unidades fue una parcela de 1×1 m, dividida en 4 subparcelas de 0,5×0,5 m. En cada subparcela se midieron 15 espectros, por lo que se recogieron un total de 60 espectros por parcela. Cada parcela quedó caracterizada espectralmente por el espectro promedio de las 60 mediciones correspondientes.

Las muestras espectrales se tomaron con un espectrorradiómetro de campo ASD Fieldspec®4, con un FOV de 25° a 1,5 m. Este instrumento codifica la luz entrante en 16 bits y la separa en tres espectrómetros: Visible/Infrarrojo cercano (VNIR) [350-1000] nm, Infrarrojo de onda corta 1 (SWIR1) [1000-1800] nm e Infrarrojo de

Tabla 1. Estadísticos descriptivos de la muestra (n=30).

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

PT: Peso de la biomasa aérea total, PV: Peso de la fracción verde, %PV: Porcentaje de peso de la fracción verde.

onda corta 2 (SWIR2) [1800-2500] nm. Antes de cada medición se calibró el instrumento empleando un blanco estándar de referencia (Spectralon Labsphere®), lo que permitió obtener reflectancias absolutas en superficie.

3.2.2. Toma y procesamiento de datos de biomasa

Para obtener el peso de la biomasa aérea de cada unidad de muestreo se cortó la biomasa aérea de la subparcela noroeste de cada parcela de 1×1 m y se tomó como muestra representativa de la misma. Con el fin de evitar la pérdida de humedad, las muestras se introdujeron en bolsas herméticas y fueron transportadas al laboratorio en neveras frigoríficas. En el laboratorio se procedió a su pesado y a su separación en biomasa seca y biomasa verde. A posteriori se procedió al secado en una estufa durante 48 horas a 65°C, obteniendo por separado, el peso seco de la biomasa aérea verde (PV), el peso seco de la biomasa aérea total (PT) y el porcentaje de peso verde respecto al total (%PV). El peso seco de la biomasa aérea

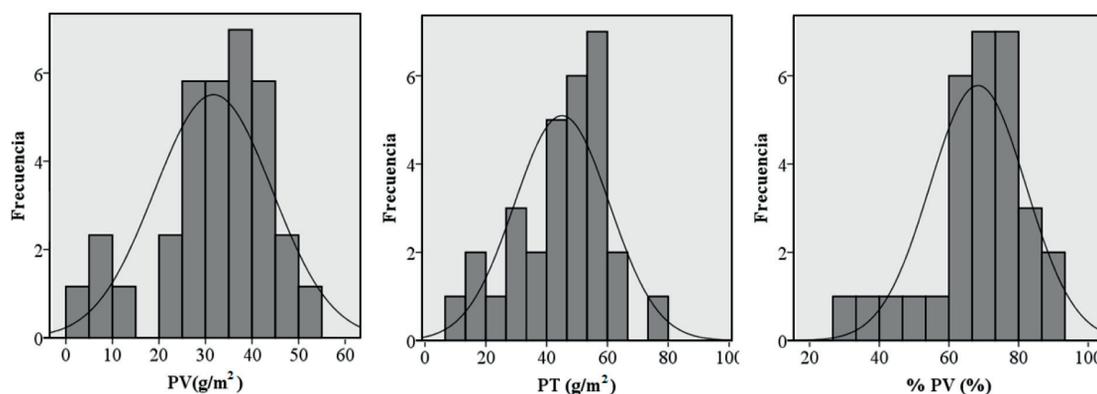


Figura 1. Histogramas y curva de normalidad de las variables PV, PT, %PV.

total (PT) se utilizó como equivalente a la biomasa aérea seca (*aboveground dry biomass*) de cada parcela. La biomasa se determinó dividiendo el peso de la hierba cosechada por el área de las parcelas (expresado como g/m²). La Tabla 1 resume los estadísticos descriptivos más relevantes de las variables PV, PT y %PV para las 30 parcelas de césped/trébol, mientras que la Figura 1 muestra la distribución de frecuencias de la muestra para las tres variables. El test de Shapiro-Wilk mostró que las tres variables son normales ($\alpha=0,01$).

3.3. Metodología

La metodología consistió en dos pasos principales: el procesamiento de datos espectrales y análisis estadístico (Figura 2). En primer lugar se realizó un pre-procesamiento y se aplicó la transformación CR a los espectros, derivándose dos índices de los datos transformados. Posteriormente, la información espectral se empleó como datos de entrada para estimar PT, PV y % PV usando PLSR

y OLSR. A continuación se describen los procesos descritos en la Figura 2.

3.3.1. Procesamiento de los datos espectrales

Una vez en laboratorio se procedió a la depuración de los espectros mediante el software ViewSpecPro. Se calculó la mediana de cada espectro de reflectancia en superficie y se estimó el espectro promedio. Se visualizaron todos los espectros para localizar y excluir las zonas con irregularidades debidas al ruido atmosférico, obteniéndose así un espectro depurado sin CR (SCR), sin las regiones comprendidas entre [1360-1385 nm], [1800-1930 nm] y [2400-2500 nm]. Este espectro se empleó como base para los análisis estadísticos posteriores. A los espectros depurados se les aplicó la transformación CR para resaltar las zonas de absorción del espectro que pueden estar más relacionadas con la biomasa (Kokaly y Clark, 1999). La transformación CR se obtiene dividiendo los valores de reflectancia originales en la zona de absorción por los valores

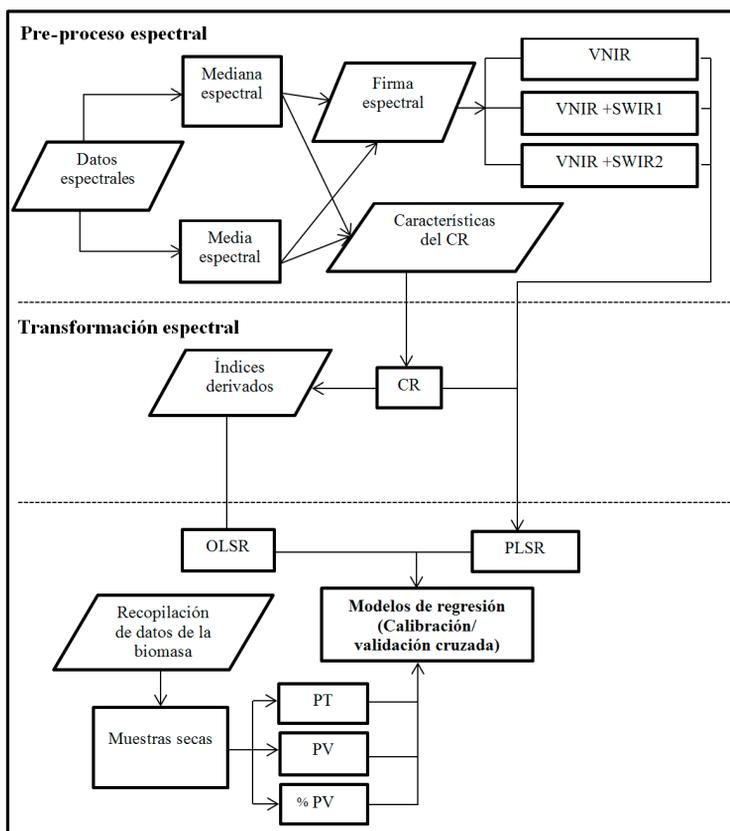


Figura 2. Diagrama de Flujo.

correspondientes del continuum (recta que representa la tendencia) (Kokaly y Clark, 1999). Para realizar la transformación es necesario identificar los límites de las regiones a las que se va a aplicar. Estas zonas deben ser sensibles a cambios en el contenido de la variable que queremos detectar (en este caso la biomasa). Mediante el software ENVI 4.7 se identificaron cinco zonas y se aplicó la transformación. El rango espectral de cada zona se muestra en la Tabla 2.

Tabla 2. Zonas de aplicación del *continuum removal*.

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

Las zonas Z1 y Z2 se han usado con éxito en estudios previos para la estimación de componentes bioquímicos de las hojas (Curran *et al.*, 2001) así como para la identificación de diferentes especies de gramíneas (Adjorlolo *et al.*, 2012). Asimismo, las zonas Z3, Z4 y Z5 se han empleado

satisfactoriamente en estudios relacionados con la variación del contenido de agua foliar (Clevers *et al.*, 2008; Mutanga e Ismail, 2010). Para este trabajo ha sido necesario redefinir los límites de cada región para ajustarlos a los datos de la muestra. Se descartó aplicar la transformación CR en regiones comprendidas entre [1800-2100] nm, debido a la elevada cantidad de ruido que representaban cuando se analizaron visualmente las signaturas espectrales. La Figura 3 muestra gráficamente las regiones definidas para la transformación CR. Para caracterizar cada una de las zonas del CR se derivaron dos índices: la profundidad (*Maximum Band Depth*, MBD) y el área sobre el mínimo (*Area Over the Minimum*, AOM). La MBD es la magnitud de la diferencia frente a la tendencia (Chuvieco y Huete, 2010) y está relacionada con la intensidad de la absorción en esa región (Clevers *et al.*, 2008). El AOM se describe como el producto de la profundidad y la anchura (ancho total a la mitad de la profundidad) (Pu *et al.*, 2003). Ambos índices se han empleado con éxito en estudios de estimación de biomasa (Clevers *et al.*, 2008) y de contenido en agua y bioquímicos foliares (Curran *et al.*, 2001; Pu *et al.*, 2003) Los cálculos de estos índices se realizaron con un aplicativo IDL desarrollado por Shuti Khannaa (CSTARS. UC-DAVIS).

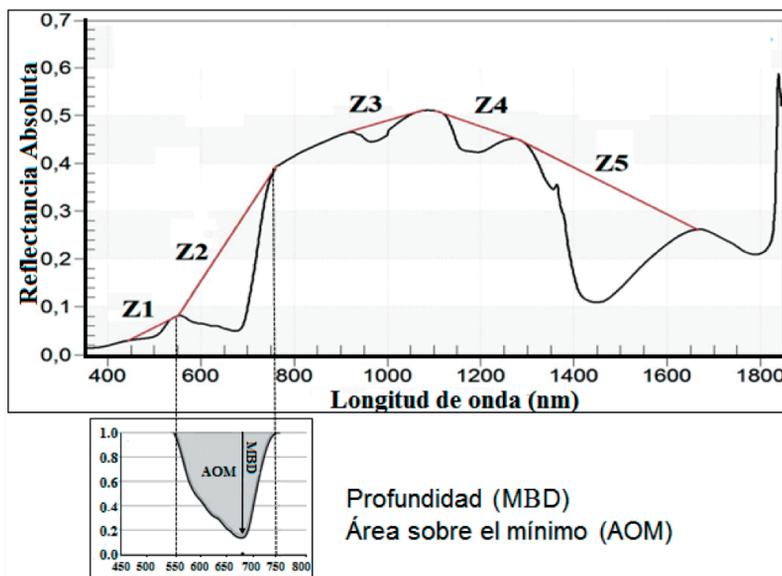


Figura 3. Signatura espectral característica de la vegetación de la zona de estudio, sobre la que se superponen las zonas de aplicación del *continuum removal* en este trabajo (Z1 – Z5). El detalle representa a los índices MBD y AOM en la zona Z2.

3.3.2. Ajuste estadístico

El ajuste estadístico entre la biomasa aérea (PV, PT, %PV) y la información espectral se realizó empleando dos técnicas: regresión por mínimos cuadrados parciales y regresión lineal por mínimos cuadrados.

3.3.2.1. Regresión por mínimos cuadrados parciales (PLSR)

En los análisis de datos hiperespectrales mediante regresiones lineales múltiples con ajuste por mínimos cuadrados suelen producirse fenómenos de multicolinealidad, que provocan altas correlaciones entre los predictores y por ello la invalidez de los resultados. El método PLSR fue elegido para este trabajo porque es adecuado para trabajar con datos hiperespectrales procedentes de muestras pequeñas y con problemas de colinealidad, así como con muestras con ruido en los datos biofísicos (Atzberger *et al.*, 2010). Se ha empleado anteriormente en trabajos similares para la el estudio de la vegetación y del suelo (Atzberger *et al.*, 2010; Mutanga *et al.*, 2012). Este método es una generalización de la regresión lineal múltiple que puede trabajar con partes continuas del espectro, empleando todas las longitudes de onda disponibles. Una explicación detallada del algoritmo PLSR se puede consultar en Geladi y Kowalski (1986). Como predictores se emplearon los valores

de la transformación CR para cada una de las zonas mostradas en la Tabla 2 (valor para cada longitud de onda). Se realizó un ajuste independiente PLSR para cada una de las regiones. Además, con fines comparativos, se realizó un ajuste empleando como datos de entrada el espectro depurado sin transformar (SCR), con valores de reflectancia. La selección del mejor modelo para cada variable se realizó teniendo en cuenta la construcción de un modelo sólido: con un número bajo de factores, un error bajo en la predicción de la validación cruzada, y un coeficiente de determinación (R^2) lo más cercano a uno posible. El número de factores fue optimizado por el software, considerando que no hubiera mucha divergencia entre la varianza explicada por el modelo en la fase de calibración y en la fase de validación. Se realizó una validación cruzada del tipo *Leave-One-Out* (LOOCV) (Atzberger *et al.*, 2010). Para la comparación de métodos se emplearon como criterios el número de factores, el RMSE y el coeficiente de determinación R^2 de la validación. Los análisis se realizaron con el software Unscrambler® X 10.2 (CAMO Software Inc., Woodbridge).

3.3.2.2. Regresión lineal simple (OLSR)

La regresión lineal simple por mínimos cuadrados se empleó utilizando como variables de respuesta las medidas de biomasa (PV, PT, %PV)

Tabla 3. Comparación de resultados de la regresión lineal por mínimos cuadrados parciales (PLSR) y la regresión lineal simple (OLSR), para la estimación de biomasa (PV, PT y %PV).

	PLSR				LSR			
	Z	F	R ²	RMSE	MBD		AOM	
					R ²	RMSE	R ²	RMSE
PV	z1	2	0,752	6,396	0,728	6,483	0,722	6,549
	z2	4	0,877	4,506	0,669	7,146	0,719	6,587
	z3	1	0,888	4,295	0,725	6,517	0,750	6,208
	z4	1	0,921	3,622	0,910	3,720	0,915	3,615
	z5	2	0,859	4,859	0,742	6,307	0,797	5,593
	SCR	3	0,890	4,254	-	-	-	-
PT	Z1	1	0,604	10,03	0,582	9,950	0,578	9,997
	Z2	5	0,678	9,040	0,534	10,510	0,577	10,008
	Z3	1	0,682	8,988	0,600	9,743	0,625	9,426
	Z4	1	0,735	8,198	0,707	8,328	0,716	8,176
	Z5	2	0,692	8,841	0,594	9,810	0,639	9,253
	SCR	3	0,750	7,970	-	-	-	-
%V	Z1	7	0,762	6,852	0,567	8,931	0,554	9,064
	Z2	1	0,621	8,641	0,603	8,551	0,591	8,674
	Z3	1	0,575	9,153	0,557	9,034	0,541	9,193
	Z4	1	0,557	9,343	0,524	9,359	0,522	9,384
	Z5	1	0,625	8,602	0,608	8,502	0,594	8,648
	SCR	4	0,682	7,913	-	-	-	-

Z: número de zona del CR, F: número de factores en PLSR, MBD: profundidad, AOM: área sobre el mínimo, R²: coeficiente de determinación del ajuste, RMSE: error medio cuadrático (g/m²).

y como predictores los índices (i) MBD y (ii) AOM derivados de la transformación CR para las regiones Z1-Z5 (Tabla 3). Este método se eligió por su sencillez y rapidez de cálculo. Estas dos variables se emplearon como datos de entrada para la regresión dando buenos resultados en otros estudios (Pu *et al.*, 2003; Clevers *et al.*, 2008). La validación de los modelos fue similar a la realizada para PLSR, empleando una validación cruzada completa (Geladi y Kowalski, 1987; Huang *et al.*, 2004; Clever *et al.*, 2008; Atzberger *et al.*, 2010) y como criterios para la comparación el RMSE (Valor absoluto y porcentaje de la variable) y el coeficiente de determinación R^2 de la validación. El ajuste estadístico y la validación se realizaron con el software Unscrambler® X 10.2 (CAMO Software Inc., Woodbridge).

4. Resultados y discusión

4.1. Resultados de los ajustes estadísticos

La Tabla 3 muestra de forma conjunta los valores de los estadísticos empleados para comparar los resultados de la regresión PLS y la regresión lineal (OLSR) a la hora de estimar las tres medidas de biomasa (PV, PT y %PV).

Los mejores resultados del ajuste mediante PLSR, se han obtenido para el PV en todos los casos (Tabla 3). Dividiendo las zonas del espectro al aplicar la transformación CR, los resultados del trabajo mostraron una mejor capacidad de predicción de Z4 obteniéndose un error en la

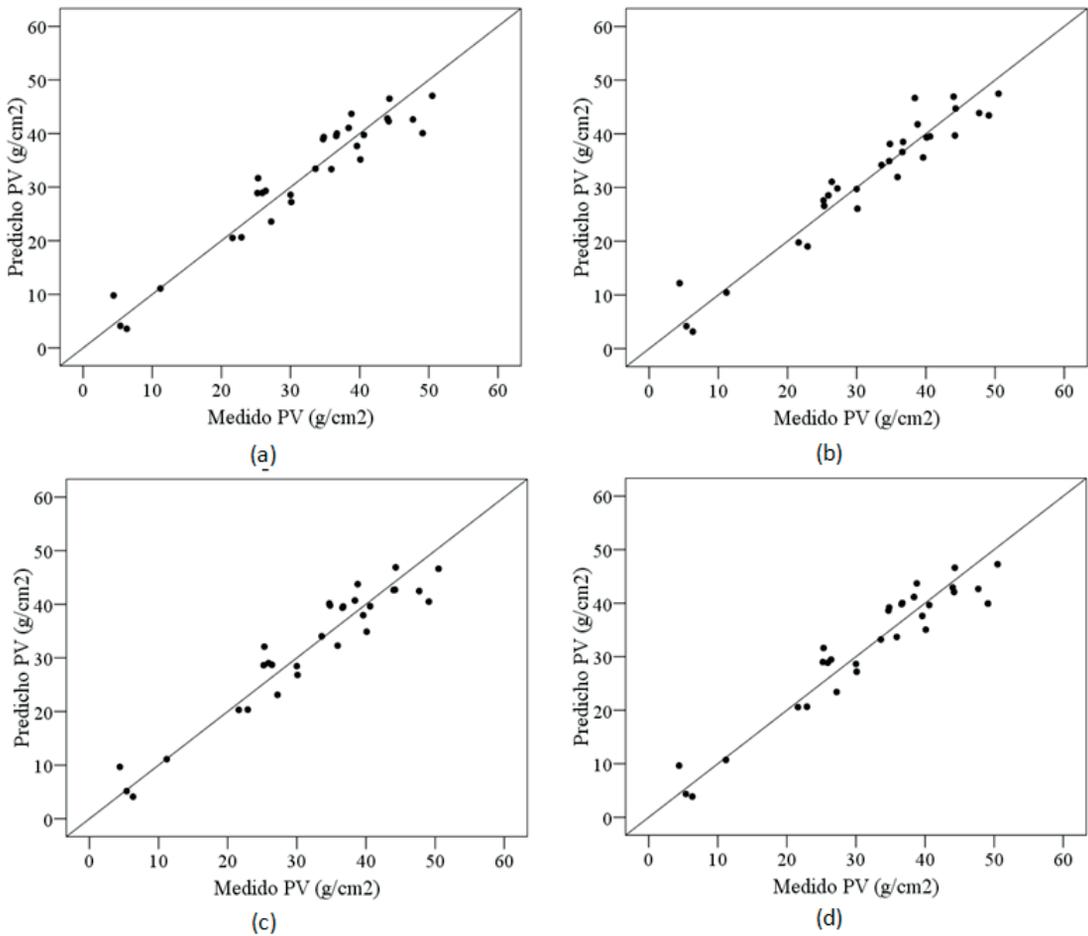


Figura 4. Resultados de la validación cruzada para predecir PV empleando (a) PLSR y Z4, (b) PLSR y el espectro SRC, (c) MBD de la Z4, (d) AOM de la Z4. En todos los gráficos se muestra la línea 1:1.

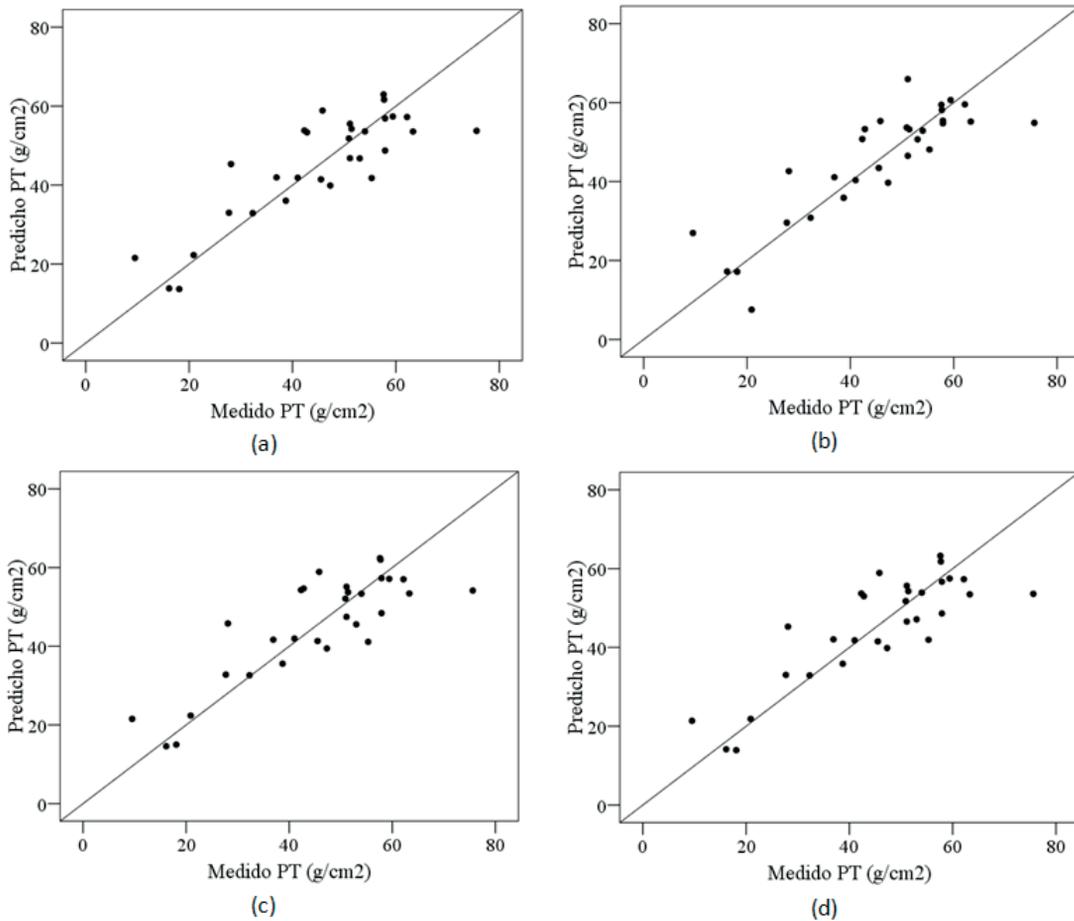


Figura 5. Resultados de la validación cruzada para predecir PT empleando (a) PLSR y Z4, (b) PLSR y el espectro SRC, (c) MBD de la Z4, (d) AOM de la Z4. En todos los gráficos se muestra la línea 1:1.

predicción de 3,622 g/m² (<12% del valor medio) y un modelo que explica más del 92% de la varianza del PV. Estos resultados se obtuvieron con el uso de un solo factor (F), mientras que empleando el SCR como predictor las estimaciones no fueron tan exactas y se necesitaron 3 factores. Para la biomasa aérea PT, empleando Z4 se obtuvo un error en la predicción del modelo de 8,20 g/m² y un R² de 0,735 con un solo factor. En este caso en el espectro SRC mejoró los resultados, con una exactitud en el ajuste del 75% y un error de 7,97 g/m² (con 3 factores).

El %PV presenta como mejor resultado el de Z1, con un error en la predicción de 6,85 g/m² y un ajuste del 76%. En cuanto a los resultados de los índices derivados de la transformación CR, los mejores resultados para la estimación del PV se

obtuvieron a partir del índice AOM de la zona 4 (RMSE: 3,615 g/m² (<12% del valor medio de PV); R²: 0,915) y del índice MBD para la misma zona 4 (RMSE: 3,720 g/m²; R²:0,910). Al analizar los resultados para la estimación de PT, de nuevo los índices de la zona 4 proporcionaron la solución más exacta. El modelo construido con el índice MBD logra predecir con un error 8,33 g/m² y un ajuste del 71%, y el índice (AOM) predice con un error del 8,18 g/m² y un ajuste del 72%. El (%PV) presenta el mejor resultado para ambos índices en la zona. 5. Las figuras 4, 5 y 6 muestran la idoneidad de los tres modelos más exactos para PV, PT y %PV empleando PLSR e índices, así como el modelo que no emplea CR (con fines comparativos). Para PV y PT todos modelos analizados se consideraron adecuados, puesto que los valores medidos y predichos se

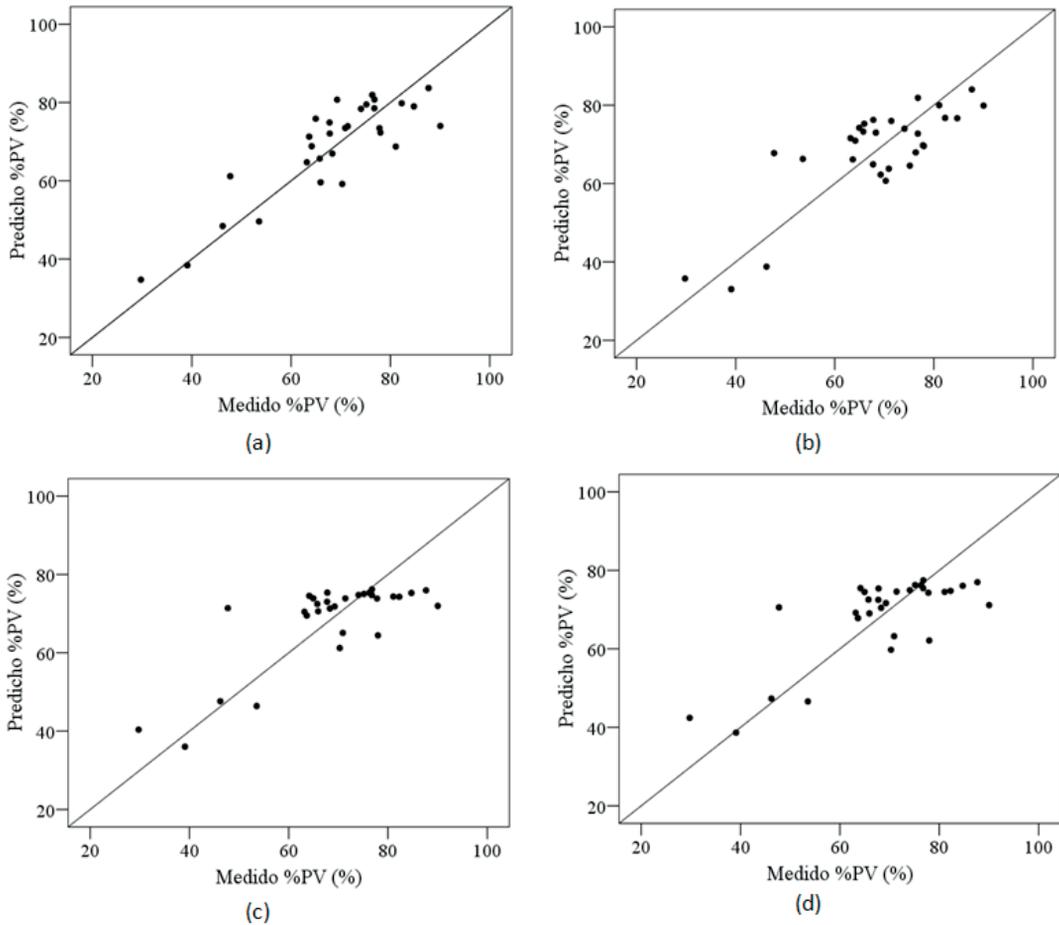


Figura 6. Resultados de la validación cruzada para predecir PT empleando (a) PLSR y Z5, (b) PLSR y el espectro SRC, (c) MBD de la Z5, (d) AOM de la Z5. En todos los gráficos se muestra la línea 1:1.

distribuyen a lo largo de la recta 1:1 y próximos a ella. En el caso de %PV los modelos de ajuste no son idóneos, puesto que los valores medidos y los predichos no se distribuyeron de una forma homogénea a lo largo de la recta 1:1.

4.2. Discusión y comparación de métodos

En este estudio se ha demostrado que PLSR y OLSR son adecuados para estimar biomasa aérea empleando datos espectrales transformados mediante CR. El empleo de CR y PLSR en zonas del espectro como Z3 ([916-1120] nm) o Z4 ([1079-1297] nm) simplifica los modelos de estimación de biomasa aérea, tal y como demuestra que el número de factores latentes se reduzca cuando se utilizan estas zonas en lugar del espectro

completo sin CR. Este resultado concuerda con los obtenidos por Axelsson (2013) para la estimación de Nitrógeno, y los de Cho *et al.* (2007) para la estimación de biomasa. Empleando los mismos datos de partida y máquinas de soporte vectorial (*Support Vector Machine*, SVM), el espectro transformado también proporcionó estimaciones más exactas de PV, PT y %PV que el espectro sin transformar (Marabel y Álvarez, 2013).

Los resultados para PV aquí presentados mejoran los de Cho *et al.* (2007), que obtuvo un RMSE equivalente al 19% del valor medio de la biomasa mientras que en nuestro trabajo el RMSE supone menos del 12% del valor medio de PV y se obtiene con un modelo PLSR más sencillo (con un menor número de factores).

La zona del espectro más adecuada para la estimación de PV y PT se corresponde con las bandas de absorción de 1079 nm a 1297 nm (Z4), corroborando los resultados de Curran (2001), Cho (2007), Clevers (2008) y Mutanga (2010). Además se ha identificado una nueva zona (de 1265 a 1676 nm) como relevante para la estimación de biomasa aérea, lo que supone una novedad en este tipo de trabajos.

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

Respecto a la comparación entre los métodos de regresión, si se emplean como predictores los datos de Z4 (con CR) no existen diferencias significativas entre los R² obtenidos empleando PLSR y los obtenidos con MBD y AOM. Además las diferencias entre los RMSE son menores del 2%, por lo que no se puede considerar que un procedimiento sea más exacto que otro (Kooistra *et al.*, 2006; Cho *et al.*, 2007; Clevers *et al.*, 2008). Se recomienda el empleo de los índices MBD y AOM y la regresión lineal simple para estimar la cantidad de biomasa aérea (PV o PT) debido a la simplicidad del modelo y a la facilidad para su interpretación, en comparación con la complejidad de los factores latentes de PLSR.

El siguiente paso será evaluar el empleo de técnicas de estimación no paramétricas como redes neuronales artificiales (NN) y otros métodos de transformación del espectro (suavizados).

Referencias

- Adjorlolo, C., Cho, M.A., Mutanga, O., Ismail, R. 2012. Optimizing spectral resolutions for the classification of C3 and C4 grass species, using wavelengths of known absorption features. *Journal of Applied Remote Sensing*, 6(1), 1-15. <http://dx.doi.org/10.1117/1.JRS.6.063560>
- Atzberger, C., Guérif, M., Baret, F., Werner, W. 2010. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. *Computers and Electronics in Agriculture*, 73(2), 165-173. <http://dx.doi.org/10.1016/j.compag.2010.05.006>
- Axelsson, C., Skidmore, A.K., Schlerf, M., Fauzi, A., Verhoef, W. 2013. Hyperspectral analysis of mangrove foliar chemistry using PLSR and support vector regression. *International Journal of Remote Sensing*, 34(5), 1724-1743. <http://dx.doi.org/10.1080/01431161.2012.725958>
- Barrio, A.M., Balboa, M.M.A., Castedo, D.F., Diéguez, A.U., Álvarez, G.J.A. 2006. An ecoregional model for estimating volume, biomass and carbon pools in maritime pine stands in Galicia (northwestern Spain). *Forest Ecology and Management*, 223(1-3), 24-34. <http://dx.doi.org/10.1016/j.foreco.2005.10.073>
- Cho, M.A., Skidmore, A.K., Corsi, F., Van Wieren, S.E., Sobhan, I. 2007. Estimation of green grass - herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression. *International Journal of Applied Earth Observation and Geoinformation*, 9(4), 414-424. <http://dx.doi.org/10.1016/j.jag.2007.02.001>
- Chuvieco, E., Huete, A. 2010. *Fundamentals of satellite remote sensing*. Boca Raton (FL), CRC Press. Boca Raton (USA), 302-310.
- Clevers, J.G.P.W., Kooistra, L., Schaepman, M.E. 2008. Using spectral information from the NIR water absorption features for the retrieval of canopy water content. *International Journal of Applied Earth Observation and Geoinformation*, 10(3), 388-397. <http://dx.doi.org/10.1016/j.jag.2008.03.003>
- Curran, P.J., Dungan, J.L., Peterson, D.L. 2001. Estimating the foliar biochemical concentration of leaves with reflectance spectrometry testing the Kokaly and Clark methodologies. *Remote Sensing of Environment*, 76(3), 349-359. [http://dx.doi.org/10.1016/S0034-4257\(01\)00182-1](http://dx.doi.org/10.1016/S0034-4257(01)00182-1)
- De Jong, S.M. 1994. *Applications of Reflective Remote Sensing for Land Degradation Studies in a Mediterranean Environment*. (Netherlands Geographical Studies (NGS)). Ph.D. Dissertation, Utrecht University, Utrecht, The Netherlands.

- Dunn, B.W., Beecher, H.G., Batten, G.D., Ciavarella, S. 2002. The potential of near-infrared reflectance spectroscopy for soil analysis, a case study from the Riverine Plain of south-eastern Australia. *Australian Journal of Experimental Agriculture*, 42(5), 607-614. <http://dx.doi.org/10.1071/EA01172>
- Gao, X., Huete, A.R., Ni, W., Miura, T. 2000. Optical biophysical relationships of vegetation spectra without background contamination. *Remote Sensing of Environment*, 74(3), 609-620. [http://dx.doi.org/10.1016/S0034-4257\(00\)00150-4](http://dx.doi.org/10.1016/S0034-4257(00)00150-4)
- Geladi, P., Kowalski, B.R. 1986. Partial least-squares regression: a tutorial. *Analytica Chimica Acta*, 185, 1-17. [http://dx.doi.org/10.1016/0003-2670\(86\)80028-9](http://dx.doi.org/10.1016/0003-2670(86)80028-9)
- Grossman, Y.L. Ustin, S.L., Jacquemoud, S., Sanderson, E.W., Schmuck, G., Verdebout, J., 1996. Critique of stepwise multiple linear regression for the extraction of leaf biochemistry information from leaf reflectance data. *Remote Sensing of Environment*, 56(3), 182-193. [http://dx.doi.org/10.1016/0034-4257\(95\)00235-9](http://dx.doi.org/10.1016/0034-4257(95)00235-9)
- Huang, Z., Turner, B.J., Dury, S.J., Wallis, I.R., Foley, W.J. 2004. Estimating foliage nitrogen concentration from HYMAP data using continuum removal analysis. *Remote Sensing of Environment*, 93(1-2), 18-29. <http://dx.doi.org/10.1016/j.rse.2004.06.008>
- Kokaly, R.F., Clark, R.N. 1999. Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression. *Remote Sensing of Environment*, 67(3), 267-287. [http://dx.doi.org/10.1016/S0034-4257\(98\)00084-4](http://dx.doi.org/10.1016/S0034-4257(98)00084-4)
- Kooistra, L., Wanders, J., Epema, G.F., Leuven, R.S.E.W., Wehrens, R., Buydens, L.M.C. 2003. The potential of field spectroscopy for the assessment of sediment properties in river floodplains. *Analytica Chimica Acta*, 484(2), 189-200. [http://dx.doi.org/10.1016/S0003-2670\(03\)00331-3](http://dx.doi.org/10.1016/S0003-2670(03)00331-3)
- Kooistra, L., Suárez Barranco, M.D., van Dobben, H., Schaepman, M.E. 2006. Regional Scale Monitoring of Vegetation Biomass in river Floodplains using Imaging Spectroscopy and Ecological Modeling. En: *Proceedings of the IEEE Geoscience and Remote Sensing Symposium*, Denver, CO, USA, 31 July-4 August 2006, 124-127.
- Marabel, M., Álvarez, F. 2013. Spectroscopic Determination of Aboveground Biomass in Grasslands Using Spectral Transformations, Support Vector Machine and Partial Least Squares Regression. *Sensors*, 13(8), 10027-10051. <http://dx.doi.org/10.3390/s130810027>
- Mutanga, O., Skidmore, A.K. 2004. Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International Journal of Remote Sensing*, 25(19), 3999-4014. <http://dx.doi.org/10.1080/01431160310001654923>
- Mutanga, O., Ismail R. 2010. Variation in foliar water content and hyperspectral reflectance of *Pinus patula* trees infested by *Sirex noctilio*. *Southern Forests*, 72 (1), 1-7. <http://dx.doi.org/10.2989/20702620.2010.481073>
- Nitsch, B.B., Meyer, G.E., Mortensen, D.A. 1991. Visible near-infrared plant, soil and crop residue reflectivity for weed sensor design. *ASAE*, Paper No. 91-3006. ASAE, St. Joseph, MI, USA.
- Pordesimo, L.O., Edens, W.C., Sokhansanj, S. 2004. Distribution of aboveground biomass in corn stover. *Biomass and Bioenergy*, 26(4), 337-343. [http://dx.doi.org/10.1016/S0961-9534\(03\)00124-7](http://dx.doi.org/10.1016/S0961-9534(03)00124-7)
- Pu, R., Ge, S., Kelly, N.M., Gong, P. 2003. Spectral absorption features as indicators of water status in coast live oak (*Quercus agrifolia*) leaves. *International Journal of Remote Sensing*, 24(9), 1799-1810. <http://dx.doi.org/10.1080/01431160210155965>
- Schlerf, M., Atzberger, C., Hill, J. 2005. Remote sensing of forest biophysical variables using HyMap imaging spectrometer data. *Remote Sensing of Environment*, 95(2), 177-194. <http://dx.doi.org/10.1016/j.rse.2004.12.016>
- Smith, G.M., Curran, P.J. 1996. The signal-to-noise ratio (SNR) required for the estimation of foliar biochemical concentrations. *International Journal of Remote Sensing*, 17(5), 1031-1058. <http://dx.doi.org/10.1080/01431169608949062>
- Vasques, G.M., Grunwald, S., Sickman, J.O. 2008. Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra. *Geoderma*, 146(1-2), 14-25. <http://dx.doi.org/10.1016/j.geoderma.2008.04.007>
- Williams, P.C., Norris, K.H. 1987. *Near-Infrared Technology in the Agricultural and Food Industries*. St. Paul, MN, USA: American Association of Cereal Chemists, 143-167.