

# ESTIMACIÓN DE BIOMASA EN HERBÁCEAS A PARTIR DE DATOS HIPERESPECTRALES, REGRESIÓN PLS Y LA TRANSFORMACIÓN CONTINUUM REMOVAL

Miguel Marabel García, Flor Álvarez-Taboada

GEOINCA-202. Universidad de León. Campus de Ponferrada C/ Avda. de Astorga s/n 24401 Ponferrada (León),  
[mmarag00@estudiantes.unileon.es](mailto:mmarag00@estudiantes.unileon.es)

## RESUMEN

El objetivo del estudio fue comparar los resultados en la estimación de la biomasa aérea seca empleado dos métodos a partir de los datos del espectrómetro de campo: (i) regresión por mínimos cuadrados parciales (PLS) de diferentes partes del espectro transformado mediante Continuum Removal (CR) y (ii) regresión lineal aplicada a dos índices calculados a partir del CR: profundidad del mínimo (DM) y el área sobre el mínimo (AOM). Los resultados empleando PLS ( $R^2=0,920$ ,  $RMSE= 3,622 \text{ g/m}^2$ ) fueron similares a los obtenidos para los índices (para AOM:  $R^2= 0,915$ ,  $RMSE=3,615 \text{ g/m}^2$ ). Se recomienda emplear los índices derivados del CR puesto que su interpretación es más sencilla que el PLS.

**Palabras clave:** Biomasa; pastizal; Continuum-removal; espectrorradiómetro; hiperespectral; Partial least squares regresión.

## ABSTRACT

The aim of this research work was to compare the estimation of dry aboveground biomass, by using two methods from field spectrometer data: (i) Partial least squares regression (PLS) in different regions of the spectrum transformed by Continuum Removal (CR) and (ii) linear regression applied to two indices derived from the CR: Depth Minimum (DM) and Area Over the Minimum (AOM). The results using PLS ( $R^2=0,920$ ,  $RMSE= 3,622 \text{ g/m}^2$ ) were similar to the results achieved by the indices ( $R^2= 0,915$ ,  $RMSE=3,615 \text{ g/m}^2$  for AOM). Thus, using the indices derived from CR is recommended, since their interpretation is easier than the PLS output.

**Keywords:** 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 (cultivados y naturales). La biomasa se puede definir en términos de peso de materia fresca o como peso de la materia seca. 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) tanto por el estudio integral de los sistemas agroforestales como sumidero de carbono como por 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). El empleo de técnicas no destructivas como la teledetección ha sido de uso habitual durante los últimos años, en estudios de vegetación, minerales y propiedades del suelo. Estos estudios están relacionados con los datos de alta resolución espectral en la región de 400-2500 nm debido a la presencia de características de absorción de diagnóstico en las curvas de reflectancia (Kokaly y Clark, 1999). La aplicación de técnicas estadísticas y de transformaciones adecuadas para tratar con datos hiperespectrales se plantea como una oportunidad para mejorar los resultados (Atzberger *et al.*, 2010).

## 2. OBJETIVOS

El objetivo del presente estudio fue comparar los resultados en la estimación de la biomasa aérea seca (verde) (Peso verde, PV), biomasa aérea seca total (Peso total, PT), y el porcentaje de biomasa aérea seca (verde) (Porcentaje de peso verde, %PV) de herbáceas empleando dos métodos: (i) regresión por mínimos cuadrados parciales (PLSR) aplicada a diferentes partes del espectro transformado mediante Continuum Removal (CR), y (ii) regresión lineal aplicada a los índices calculados a partir del CR (LSR).

## 3. MATERIAL Y MÉTODOS

### 3.1. Área de estudio

El área de estudio se localizó en dos parcelas adyacentes de especies herbáceas de origen artificial, 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 4163814478513 y ETRS89 UTM30 4164634478505.

### 3.2 Material

#### 3.2.1. Datos espectrales

Los datos espectrales se tomaron en 30 unidades de muestreo, definidas como parcelas homogéneas de 1 x 1 m, divididas en subparcelas de 0.5 x 0.5 m. Para evitar la contaminación espectral de la señal, cada una de las parcelas se localizó dentro de un área homogénea de 2 x 2 m. Se registraron 15 espectros fijos para cada subparcela de 0.5 x 0.5 m. Los 60 espectros por parcela, se emplearon para caracterizar cada unidad de muestreo de 1 x 1 m a través de un espectro promedio. Las muestras espectrales se tomaron con un espectrorradiómetro de campo ASD Fieldspec®4, con un FOV de 25° a 1.5 m. La luz entrante es codificada en 16 bits y separada en tres espectrómetros: Visible/Infrarrojo cercano (VNIR) [350 – 1000] nm, Infrarrojo de onda corta 1 (SWIR1) [1000 – 1800] nm e Infrarrojo de onda corta 2 (SWIR2) [1800 – 2500] nm. Antes de cada toma de datos, se realizó una medición de referencia en un blanco estándar de referencia (Spectralon Labsphere®) para calibrar el instrumento y obtener reflectancias absolutas en superficie.

#### 3.2.2. Toma y procesamiento de datos de biomasa

Para cada unidad de muestreo se determinó el peso de la biomasa, obtenido a partir de la corta de la biomasa aérea de la subparcela de 0.5 x 0.5 m, localizada en el extremo NE de cada parcela, como muestra representativa. 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 total (PT) se utilizó como equivalente a la biomasa aérea seca (*aboveground dry biomass*) de cada parcela.

### 3.3 Metodología

#### 3.3.1 Procesamiento de los datos espectrales

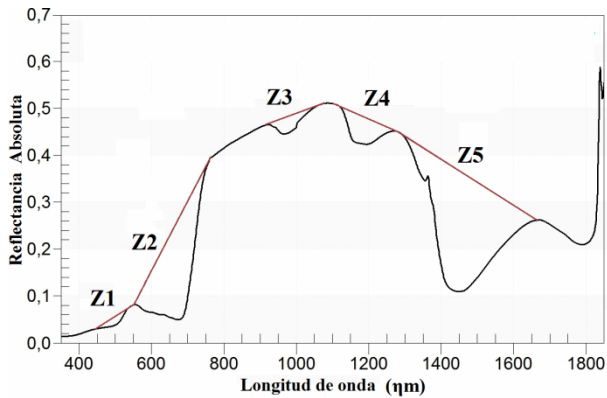
Una vez en laboratorio se procedió a la depuración de los espectros mediante el software ViewSpecPro. Se calculó la mediana de cada espectro de reflectancia en superficie y se estimó el espectro promedio. Se visualizaron todos los espectros para localizar las zonas con irregularidades debido al ruido atmosférico y se excluyeron, obteniéndose así un espectro depurado (sin las regiones comprendidas entre [1360-1385 nm], [1800-1930 nm], [2400-2500 nm]), el cual se empleó como base para los análisis estadísticos posteriores. A los espectros depurados se les aplicó la transformación

*Continuum removal* (CR), que se emplea para reducir los efectos del ruido y mejorar las características de absorción en el espectro (Kokaly y Clark, 1999). La transformación CR se obtiene dividiendo los valores de reflectancia originales en la zona de absorción por los valores correspondientes del continuum (recta que representa la tendencia) (Kokaly y Clark, 1999). Para realizar la transformación es necesario identificar los límites de las regiones a las que se va a aplicar. 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 1.

**Tabla 1.** 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 clasificación 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 (Mutanga e Ismail, 2010, Clevers *et al.* 2008). Para este trabajo ha sido necesario redefinir los límites de cada región para ajustarlos a los datos de la muestra. Se descartó aplicar el CR en regiones comprendidas entre [1800 – 2100] nm, al tratarse de zonas con una baja relación señal/ruido. La figura 2 muestra gráficamente las regiones definidas para la aplicación del CR. Para caracterizar cada una de las zonas del CR se derivaron dos índices: la profundidad (DM) y el área sobre el mínimo (AOM). La profundidad (DM) es la magnitud de la diferencia frente a la tendencia. (Chuvienco y Huete 2010) y está relacionada con la intensidad de la absorción en esa región (Clevers *et al.* 2008). El área sobre el mínimo (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 (Pu *et al.* 2003, Curran *et al.* 2001) Los cálculos de estos índices se realizaron con un aplicativo IDL desarrollado por Shuti Khanna (CSTARS. UC-DAVIS).



**Figura 2.** Zonas de aplicación del continuum removal en este trabajo

### 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 (PLSR) y regresión lineal por mínimos cuadrados (LSR).

#### 3.3.2.1. Regresión por mínimos cuadrados parciales (PLSR)

En los análisis de datos hiperespectrales suelen producirse fenómenos de multicolinealidad, debido a que el número de muestras de la variable dependiente es menor que el número de bandas utilizadas en el análisis (Curran, 1989). Esto provoca altas correlaciones entre las variables predictoras y la invalidez de los resultados. El método PLSR fue elegido para este trabajo ya que 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 variables independientes se emplearon los valores del CR para cada una de las zonas mostradas en la Tabla 1 (valor para cada longitud de onda). Se realizó un ajuste independiente PLS para cada una de las regiones. Además, con fines comparativos, se realizó un ajuste empleando como datos de entrada el espectro completo depurado (sin transformar, con valores de reflectancia, y tras la exclusión de las zonas de ruido). 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, un pequeño error ajustado en la validación cruzada y un coeficiente de determinación

( $R^2$ ) lo más cercano a uno posible (Botero *et al.* 2009). El número de factores fue optimizado por el software, considerando que no hubiera mucha divergencia entre la varianza explicada por el modelo en la fase de calibración y en la fase de validación. 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 y 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 (LSR).

La regresión lineal simple por mínimos cuadrados se empleó utilizando como variables dependientes las medidas de biomasa (PV, PT, %PV), y como variables independientes los índices DM y AOM derivados de la transformación CR. Este método se eligió por su sencillez de cálculo y por su idoneidad para trabajar con pocas variables independientes. Estas dos variables se emplearon como datos de entrada para la regresión dando buenos resultados en otros estudios (Clevers *et al.* 2008, Pu *et al.* 2003). La validación de los modelos fue similar a la realizada para PLSR, empleando una validación cruzada completa y como criterios para la comparación el RMSE 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.

## 4. RESULTADOS Y DISCUSIÓN

### 4.1. Análisis preliminar de los datos de campo

La tabla 2 muestra los estadísticos descriptivos más relevantes de los datos de peso verde, peso total y porcentaje de peso verde para las 30 muestras.

**Tabla 2.** Estadísticos descriptivos de la muestra

	PV (g/m <sup>2</sup> )	PT(g/m <sup>2</sup> )	%V (%)
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

Los resultados del test de normalidad de Shapiro-Wilks indicaron que las tres variables son normales (a un nivel de probabilidad del 99%).

### 4.2. 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 (LSR) a la hora de estimar las tres medidas de biomasa (PV, PT y %V).

**Tabla 3.** Comparación de resultados de la regresión lineal por mínimos cuadrados parciales (PLSR) y la regresión lineal simple (LSR), para la estimación de biomasa (PV, PT y %V). Nota: Z: número de zona del CR, F: número de factores en PLSR, DM: profundidad, AOM: área sobre el mínimo, R<sup>2</sup>: coeficiente de determinación del ajuste, RMSE: error medio cuadrático.

	PLSR				LSR			
	Z	F	R <sup>2</sup>	RMSE	DM		AOM	
					R <sup>2</sup>	RMSE	R <sup>2</sup>	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	-	-	-	-

Los mejores resultados del ajuste mediante PLSR, se han obtenidos para el peso verde (PV) en todos los casos (Tabla 3). Dividiendo las zonas del espectro al aplicar (CR), los resultados del trabajo mostraron una mejor capacidad de predicción en la zona 4 obteniéndose un error en la predicción de 3.622 g/m<sup>2</sup> (<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), en comparación con el espectro sin ruidos (SCR) para el que se necesitaron 3 factores para llegar a estimaciones no tan exactas. Para la biomasa total (PT), en la zona 4 se obtuvo un error en la predicción del modelo de 8.20 g/m<sup>2</sup> y un R<sup>2</sup> de 0,735 con un solo factor; sin embargo en el espectro sin ruidos (SCR) mejoró los resultados al usar 3 factores con una exactitud en el ajuste del 75% y un error de 7,97 g/m<sup>2</sup>. El porcentaje de biomasa aérea verde (%PV) presenta como mejor resultado el de la zona uno con un error en la predicción de 6.85 g/m<sup>2</sup> y un

ajuste del 76%. En cuanto a los resultados de los índices derivados del CR, los mejores resultados para la estimación del peso verde (PV) se obtuvieron a partir del índice AOM de la zona 4 que muestra un error en la predicción del 3,615 g/m<sup>2</sup> (<12% del valor medio) con un ajuste del 0.915% y del índice DM para la misma zona con un error en la predicción del 3.720 g/m<sup>2</sup> y un ajuste del 91,0%. Al analizar los resultados para la estimación del PT, de nuevo los índices de la zona 4 proporcionaron la solución más exacta. El modelo construido con el índice DM logra predecir con un error 8,33 g/m<sup>2</sup> y un ajuste del 71%, y el índice AOM predice con un error del 8,18 g/m<sup>2</sup> y un ajuste del 72%. El porcentaje de biomasa aérea verde (%PV) presenta el mejor resultado para ambos índices en la zona 5.

### 4.3. Discusión y comparación de métodos

En este estudio, se ha demostrado la adecuación para estimación de biomasa aérea de dos métodos estadísticos que emplean los datos espectrales transformados mediante el continuum removal. Esta transformación demostró que su aplicación en determinadas zonas del espectro como la zona 3 ([916 - 1120] nm) o la zona 4 ([1079 - 1297] nm), favorece la simplificación del modelo frente al uso del espectro completo sin aplicar CR, tal y como demuestra que el número de factores latentes se reduzca de 3 a 1. Este resultado concuerda con los obtenidos por Axelsson (2013) para la estimación de Nitrógeno, y los resultados de Cho *et al.* (2007) para la estimación de biomasa. Las zonas del espectro que resultaron más adecuadas para la estimación de la biomasa aérea (PV y PT) se corresponden con las bandas de absorción de 1079 nm a 1297 nm, identificadas en estudios similares por Curran (2001), Cho (2007), Clevers (2008) y Mutanga (2010) Además se han identificado otras zonas (Z5) correspondiente a una zona de alta absorción [1265 1676] nm que no se habían identificado en trabajos previos como importantes para la estimación de biomasa aérea. En un trabajo de estimación de biomasa arbórea en la sabana Cho *et al.* (2007) obtuvo un RMSE equivalente al 19% del valor medio de la biomasa (aplicando PLSR y CR a ciertas bandas, con 6 factores), mientras que en nuestro trabajo el RMSE supone menos del 12% del valor medio de la biomasa verde y se obtiene con un menor número de factores (1). En ambos trabajos se alcanzaron resultados más exactos al trabajar con los datos transformados (CR) que sin transformar. Respecto al empleo de los índices DM y AOM, los resultados de este trabajo mostraron que los valores derivados del infrarrojo de onda corta (SWIR1) [1079-1297] nm permiten obtener los modelos más exactos para la estimación del PV y el PT de biomasa aérea, de forma análoga a lo que ocurría al emplear la regresión PLS con toda la información espectral de esa zona (Z4). Estos resultados confirman que la selección óptima de las zonas a las que aplicar el CR es clave para

minimizar el error de estimación. Clevers *et al.* (2008) emplearon estos índices para estimar el contenido de agua de una cubierta de *Lolium perenne* y *Trifolium repens*, si bien los coeficientes de determinación del ajuste fueron menores a los de este estudio ( $R^2= 0,73$  y  $R^2= 0,54$  para DM y AOM respectivamente), considerando una región del espectro entre [1115 - 1270] nm, muy similar a la zona 4 de este trabajo, corroborando la idoneidad de esta región del espectro para la estimación de biomasa (PV y PT). No existen diferencias significativas en los  $R^2$  obtenidos empleando regresión PLS con CR o los índices DM y AOM al estimar biomasa aérea, y los RMSE son muy similares, independientemente del método empleado, si se trabaja en la región de [1079 - 1297] nm. Considerando lo anterior, se recomienda el empleo de los índices DM y AOM y la regresión lineal simple para estimar la cantidad de biomasa aérea seca (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. Este trabajo ha mostrado la importancia de seleccionar la zona adecuada del espectro para hacer la transformación CR, así como la adecuación del método PLSR y LSR para el objetivo del mismo. Asimismo pone de manifiesto la pertinencia de separar la fracción verde y no verde de la biomasa aérea antes de su secado. El siguiente paso será evaluar el empleo de técnicas como SVM (*Support Vector Machine*), redes neuronales artificiales (NN) y otros métodos de transformación del espectro (suavizados).

## 5. REFERENCIAS

- ADJORLOLO, C., CHO, M.A., MUTANGA, O., ISMAIL, R., 2012. *Optimizing spectral resolutions for the classification of C 3 and C 4 grass species, using wavelengths of known absorption features*. Journal of Applied Remote Sensing, 6, 1-15.
- ATZBERGER, C., GUÉRIFB, M., BARETB, F., WERNERC, W. 2010. *Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat*. Computers and Electronics in Agriculture, 73, 165-173.
- 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, 1724-1743.
- 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)*. For. Ecol. Manage. 223, 24-34.
- CHO, M.A., SKIDMORE, A.K., CORSI, F., VAN WIEREN, S.E. AND SOBHAN, I. 2007. *Estimation of green grass - herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression*. International Journal of Applied Earth Observation and Geoinformation. 9, 414-424.
- 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, 388-397.
- CURRAN, P.J., DUNGAN, J.L., PETERSON, D.L. 2001. *Estimating the foliar biochemical concentration of leaves with reflectance spectrometry testing the Kokaly and Clark methodologies*. Remote Sensing of Environment, 76, 349-359.
- GELADI, P., KOWALSKI, B.R. 1986. *Partial least-squares regression: a tutorial*. Analytica Chimica Acta, 185, 1-17
- KOKALY, R.F., CLARK, R.N. 1999. *Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression*. Remote Sensing of Environment, 67, 267-287.
- MUTANGA, O. & R. ISMAIL. 2010. *Variation in foliar water content and hyperspectral reflectance of Pinus patula trees infested by Sirex noctilio*. Southern Forests, 72, 1-7.
- PORDESIMO, L. O., W. C. EDENS, AND S. SOKHANSANJ. 2004. *Distribution of aboveground biomass in corn stover*. Biomass and Bioenergy, 26, 337-343.
- PU, R., GE, S., KELLY, N. M., & GONG, P. 2003. *Spectral absorption features as indicators of water status in coast live oak (Quercus agrifolia) leaves*. International Journal of Remote Sensing, 24, 1799-1810.