



7º CONGRESO FORESTAL ESPAÑOL

**Gestión del monte: servicios
ambientales y bioeconomía**

26 - 30 junio 2017 | Plasencia
Cáceres, Extremadura

7CFE01-083

Edita: Sociedad Española de Ciencias Forestales
Plasencia. Cáceres, Extremadura. 26-30 junio 2017
ISBN 978-84-941695-2-6

© Sociedad Española de Ciencias Forestales

Modelos de estimación de carga de biomasa aérea de matorral a partir de diferentes fuentes de información: LiDAR y Landsat

TRASSIERRA, A.¹, ESTEBAN, J.², FERNÁNDEZ-LANDA, A.¹, SABÍN, P.¹, SANCHEZ PELLICER, T.¹ y TOMÉ, J.L.¹

¹ AGRESTA Sociedad Cooperativa.

² Departamento de Ingeniería y Morfología del Terreno. ETSI Caminos, Canales y Puertos. Universidad Politécnica de Madrid.

Resumen

Los matorrales españoles, sujetos a una apropiada explotación, ofrecen una oportunidad para su aprovechamiento como fuente de biocombustibles sólidos. El conocimiento de la carga de matorral disponible para su aprovechamiento constituye una información primordial para el desarrollo de una adecuada gestión. Este estudio pretende evaluar la bondad del empleo de información LiDAR aerotransportado (densidad de 0.5 puntos/m²) y satelital Landsat 8 para la cuantificación de biomasa aérea de la especie *Cistus laurifolius* mediante el ajuste de modelos con dos conjuntos de variables dependientes. Los datos de campo se obtuvieron en 30 parcelas de 22,6 m de diámetro. Los errores de exactitud más bajos se obtuvieron cuando el modelo fue ajustado con estadísticos LiDAR, con una disminución del error de 41% (Landsat) a 27% (LiDAR). Los resultados muestran que el uso de estadísticos LiDAR permite obtener estimaciones más robustas, no obstante, la información espectral es una alternativa en áreas en las que la estructura del matorral y/o disponibilidad y calidad de los datos LiDAR supongan una restricción. Por ello, sería aconsejable realizar nuevas investigaciones para entender los problemas de saturación de la reflectividad y analizar nuevas combinaciones de variables predictoras con mayor relación con el parámetro biomasa área seca.

Palabras clave

Sensores de teledetección, inventario, modelos de regresión, aprovechamiento energético, *Cistus laurifolius*,

1. Introducción

Las masas de matorral desempeñan un papel fundamental en los ecosistemas españoles: constituyen fuente de biodiversidad y equilibrio biológico, contribuyen a la fijación de carbono atmosférico, tienen un importante valor protector de los suelos y ofrecen entre otros, una oportunidad para su aprovechamiento como fuente de biocombustibles sólidos, contribuyendo a la reducción de la dependencia de productos energéticos fósiles, a la disminución de la cantidad de combustible forestal y a la generación de actividad económica en masas forestales marginales. Sin embargo, existe una falta generalizada de información sobre el comportamiento de las especies leñosas no arbóreas que motiva que, en la mayoría de los casos, estas áreas queden excluidas de los planes de gestión (ESTORNELL et al., 2012).

En los últimos años la tecnología LiDAR se ha utilizado con gran éxito para caracterizar la vegetación y cuantificar existencias de biomasa y carbono. En el caso de las masas de matorral, algunos estudios han ajustado modelos de regresión a partir de datos de campo y medidas estadísticas derivadas de datos LiDAR (GREAVES et al. (2015), ZHANG et al. (2016), ESTORNELL et al. (2012), GLENN et al. (2015)). En muchos casos esta información LiDAR es una fuente de información válida para la caracterización y cuantificación del matorral. Sin embargo, en algunos ocasiones, debido a la propia estructura de las masas de matorral (elevada densidad y/o baja altura), la densidad de puntos del vuelo LiDAR disponible y/o al tiempo transcurrido desde la realización del vuelo, esta no permite caracterizar de forma adecuada la estructura del matorral actual. Además los

vuelos LiDAR de grandes superficies dan lugar a elevados volúmenes de datos con tiempos de procesamiento muy elevados.

En este contexto es necesario explorar otras tecnologías que permitan cuantificar la carga de matorral, como es el caso de la teledetección. La mayoría de las investigaciones con teledetección se han centrado en determinar la biomasa forestal arbórea (POWELL et al. 2010, ASLAN et al. (2016), JIA et al. (2016)) ya que la caracterización de masas de matorral con información espectral presenta cierta dificultad: existe un elevado número de píxeles en los que el porcentaje de matorral que recubre el suelo es muy bajo de modo que la reflectividad de esta cubierta se mezcla con la del suelo desnudo. Este factor dificulta la discriminación de matorrales con respecto al suelo.

Dada la necesidad de estimar la biomasa de matorral es aconsejable comparar distintas metodologías para analizar la bondad de sus predicciones y evaluar posibles soluciones para solventar los problemas descritos hasta ahora.

Este estudio se enmarca en el proyecto Life + Enerbioscrub, cuyo objetivo es la evaluación de métodos innovadores para el aprovechamiento energético sostenible de matorrales aplicados en cuatro superficies de actuación entorno a cuatro localidades de España: Garray (Soria), Navas del Marqués (Ávila), Fabero (León) y As Pontes (A Coruña), cada una de ellas asociada a una de las cuatro especies más ampliamente representadas en la península ibérica: *Cistus laurifolius* (Garray, Soria), *Genista sp.* (Ávila), *Erica arborea* (Fabero, León) y *Ulex europaeus* (As Pontes, A Coruña).

2. Objetivos

El objetivo principal del presente estudio consiste en el ajuste de modelos de regresión para estimar la biomasa seca aérea de *Cistus laurifolius*. Para ello se ajustan modelos paramétricos a partir de información LiDAR y modelos no paramétricos Random Forest con información espectral. Como objetivos secundarios se pretende evaluar la bondad de las predicciones y comparar los resultados de ambas metodologías. El ámbito de estudio queda delimitado por un radio de 100 km en torno a la localidad de Garray (Soria).

3. Metodología

3.1 Información espectral

Se trabajó con datos proporcionados por el sensor Operational Land Imager (OLI, satélite Landsat 8), empleándose un total de tres escenas recopiladas en el mes de Junio de 2015, de 30 m resolución.

El pre procesamiento de las imágenes de satélite consistió en una serie de conversiones estándar que permitieron transformar los niveles digitales (ND) a valores de reflectividad de la superficie terrestre. Para eliminar los efectos de la dispersión atmosférica se aplicó el método de corrección del histograma por sus valores mínimos (CHAVEZ, 1996). Finalmente, los efectos de la cubierta nubosa fueron eliminados mediante el algoritmo Fmask (ZHU et al. 2015) implementado en R software.

Dado que la zona de estudio engloba más de una escena de satélite, fue necesario generar un mosaico de las mismas. Previamente se normalizaron sus valores de reflectividad para reducir las diferencias entre las distintas imágenes debidas a las distintas condiciones atmosféricas. Para ello, se utilizó el método *Iteratively Reweighted Multivariate Alteration Detection* (IR-MAD) propuesto por CANTY&NIELSEN (2008).

3.2 Información LiDAR

Se trabajó con datos LiDAR procedentes de la campaña de vuelos del Plan Nacional de Ortofotografía Aérea (PNOA) realizados en el año 2010, con una densidad de 0,5 puntos/m².

El pre-procesamiento de estos datos se realizó con el software FUSION (MCGAUGHEY, 2014). Dado que se detectaron problemas de clasificación de vegetación en el tramo entre 0,4 m y 1 m por encima de la altura del suelo, se procedió a una optimización de la clasificación de matorral mediante el ajuste de parámetros de la herramienta *lasground*.

Finalmente se computó un modelo digital de elevación (MDE), a partir de los puntos reclasificados como suelo.

Para el cálculo de los estadísticos de la nube de puntos LiDAR, se seleccionó un tamaño de celda de 20x20 metros (400x400 m²). Para cada celda se normalizó la nube de puntos, obteniéndose las alturas de la vegetación sobre el suelo. La batería de estadísticos se estimó a partir de los retornos correspondientes a vegetación por encima de 0,4 metros. Para cada celda se estimó un total de 26 estadísticos: porcentaje de primeros retornos sobre 0,4 m, mínima altura, máxima altura, media, moda, desviación estándar, varianza, coeficiente de variación, rango intercuartílico, skewness, curtosis y percentiles (1, 5, 10, 20, 25, 30, 40, 50, 60, 70, 75, 80, 90, 95 y 100).

3.3 Parcelas de campo

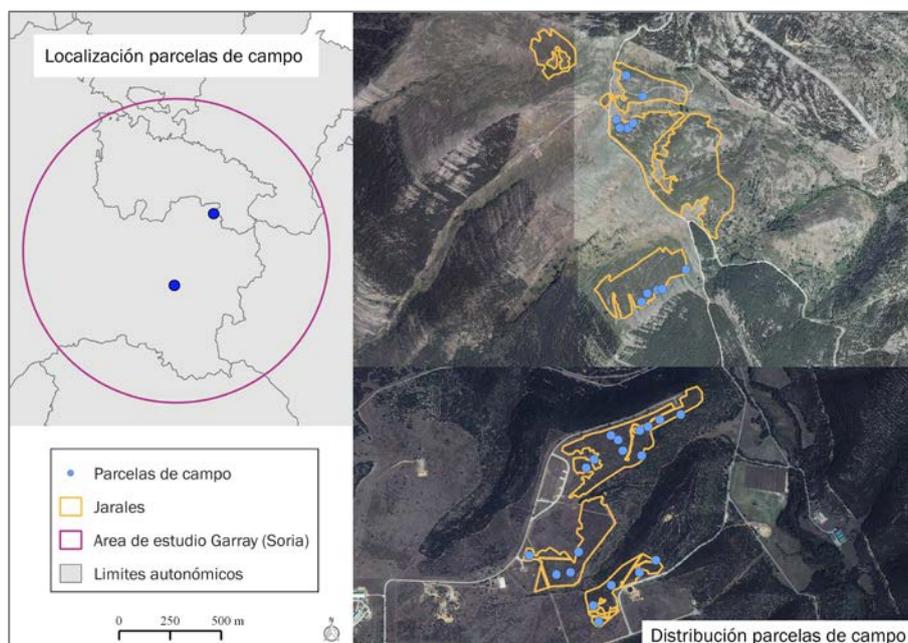
La toma de datos de campo se realizó en parcelas de muestreo circulares de 11,3 metros de radio en planta, de superficie equivalente a la de una celda de información LiDAR. En el interior de cada una de las parcelas se localizaron de forma sistemática 5 subparcelas circulares de 2 metros de radio (12,6 m²) en las que se concentraron los trabajos de desbroce y pesado de matorral.

Se levantó un total de 30 parcelas de muestreo distribuidas espacialmente en función de criterios de variabilidad estructural (Figura 1). Para ello se consideró la combinación de la fracción de cabida cubierta y la altura media del matorral.

En cada parcela y subparcela se midieron la altura dominante (cm) y la altura máxima (cm) del matorral. A continuación se desbrozaron a ras de suelo todos los individuos de especies leñosas presentes en cada una de las subparcelas y se determinó su biomasa in situ mediante una balanza eléctrica. En cada parcela se tomó una muestra representativa de matorral de entre 1,5 kg y 2,5 kg para la determinación de su correspondiente coeficiente de transformación de materia verde a materia seca en los laboratorios del centro CEDER.

Una vez levantadas las parcelas de campo y conocidas sus coordenadas con precisión submétrica se calcularon los 26 estadísticos LiDAR mencionados anteriormente.

Figura 1. Localización del área de estudio entorno a Garray (Soria) y distribución de las parcelas de campo para determinar la variable de biomasa seca aérea de *Cistus laurifolius*



3.4 Estimación de biomasa. Ajuste de modelos

Los estadísticos de estructura de vegetación se utilizaron para ajustar un modelo de regresión paramétrico para estimar la variable biomasa seca (t/ha). Se elaboraron varias baterías de modelos de entre los cuales se seleccionó el que presentó mejores resultados en la fase de diagnóstico y validación.

Para el ajuste de los modelos no paramétricos de biomasa se utilizó la guía del *American Museum of Natural History* (AMNH), propuesta por HORNING (2013). Esta metodología fue implementada en el software R mediante el paquete “RandomForest: Breiman and Cutler’s Random Forests for classification and regression” (LIAW y WIENER, 2002).

Se seleccionó un conjunto de ocho bandas como variables predictoras: seis bandas espectrales y dos índices de vegetación (Tabla 1). Se decidió descartar el uso del índice de vegetación NDVI al ser más susceptible a la respuesta del suelo en píxeles con poca cubierta forestal (GARCIA et al. 2011).

Tabla 1. Variables predictoras usadas en el ajuste del modelo no paramétrico Random Forest para la estimación de biomasa seca de jara en el ámbito de Garray. IRC: Infrarrojo cercano, SWIR: Short Wave Infrared, NDII: Normalized Difference Infra Red Index, MSI: Moisture Stress Index.

Grupo	Id	Variable
Información espectral	1	Azul
	2	Verde
	3	Rojo
	4	IRC
	5	SWIR 1
	6	SWIR2
Índices de humedad	7	NDII
	8	MSI

Los modelos obtenidos se evaluaron calculando una serie de medidas estadísticas: R^2 , RMSE y RMSE relativo mediante dos tipos de validaciones. En el caso de los modelos de regresión paramétricos, se aplicó el método de validación cruzada “dejando uno fuera”. En cuanto a los modelos no paramétricos Random Forest, se utilizó la validación interna del propio modelo.

A la hora de comparar los resultados obtenidos por ambas metodologías se eligieron tres zonas, A, B y C, localizadas en el ámbito de estudio, de extensión individual de 4.000 ha, donde se detectaron teselas continuas de matorral denso (Figura 2). Previamente se obtuvo una clasificación de jarales densos con Random Forest, el cual fue entrenado mediante un conjunto de variables predictoras constituido por bandas espectrales, índices de vegetación, texturas y el modelo digital del terreno.

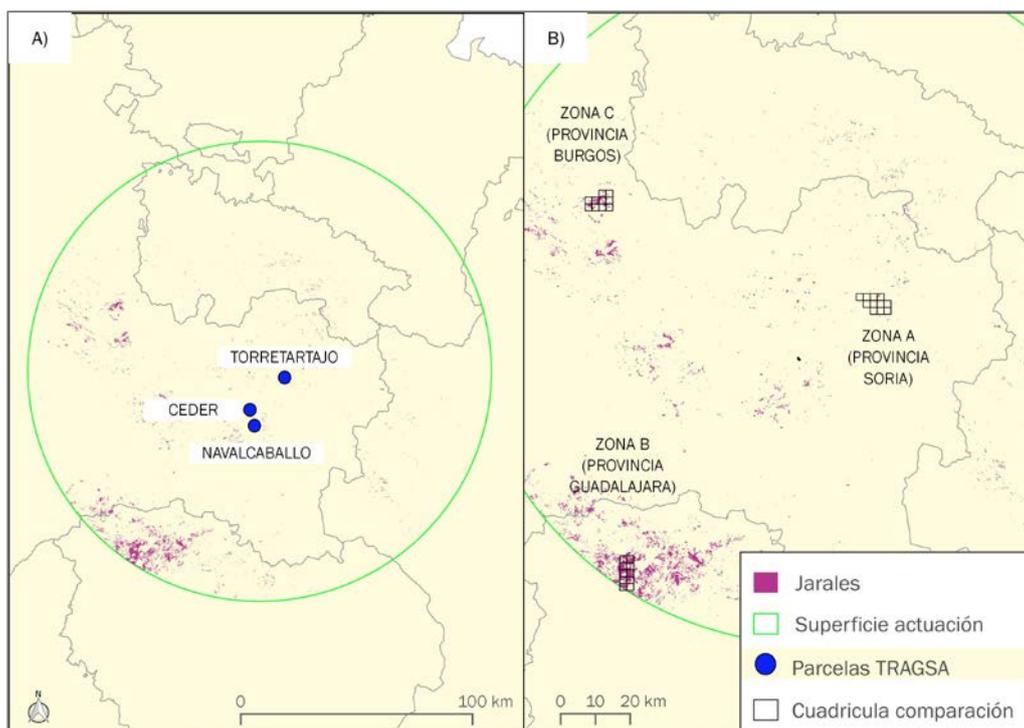
Dado que las parcelas LiDAR tienen una resolución de 20 metros, fue necesario remuestrearlas a la resolución de 30 metros correspondiente a Landsat mediante el método del vecino más próximo. Posteriormente se seleccionó para cada zona el 75% de los píxeles, extrayendo para cada uno de ellos el valor de biomasa estimado mediante los dos modelos ajustados.

Los resultados se compararon mediante una serie de medidas estadísticas:

- Promedio de las diferencias.
- Media cuadrática de las diferencias (raíz cuadrada del promedio de las diferencias al cuadrado).

Finalmente se compararon los resultados de cuantificación de la variable biomasa seca obtenidos con datos estimados por Tragsa (Figura 2) durante los trabajos de desbroce demostrativos realizados en tres áreas localizadas en el ámbito de Garray: Navalcaballo (19,3 ha), Ceder (37,4ha) y Torretartajo (27,2 ha). Se obtuvieron los datos medios de biomasa seca en dichas áreas por cada uno de los métodos.

Figura 2. Localización de las zonas de desbroce de TRAGSA (MAPA A) y las zonas A, B, C (MAPA B) donde se han comparado las estimaciones de biomasa mediante el ajuste de modelos paramétricos y no paramétricos.



4. Resultados

Los resultados de las validaciones de los modelos de regresión ajustados para estimar la biomasa seca se muestran en la Tabla 2. Se obtuvieron mejores resultados para el modelo en que se utilizó información LiDAR, pasando de un error de exactitud del 41% (Landsat) a un 27% (LiDAR). El uso de los estadísticos LiDAR permitió explicar el 60% de la varianza de la variable estimada.

Tabla 2. Resultados de la bondad de ajuste de las predicciones de los modelos paramétricos y no paramétricos. : RMSE: root mean square error, rRMSE: relative root mean square error. B toneladas de biomasa seca por hectárea; variables independientes derivadas de la nube de puntos LiDAR: porcentaje de primeros retornos sobre 0,4 m (LFCC), percentiles 5, 40, 60, 90,95 (Elev.P5-95), altura media (Elev.mean).

Zona	Clase	Modelo	RMSE (t/ha)	rRMSE (%)	R ²
Garray (Soria)	Jara	$B=0.0077*(LFCC*((Elev.P90-Elev.P40)/(Elev.P90-Elev.mean)))^{1.8727*(LFCC*(Elev.P95-Elev.P60))^{-0.5267}*Elev.P05^{-2.2668}}$	4,25	26,75	0,60
Garray (Soria)	Jara	No paramétrico Random Forest	6,34	41,00	

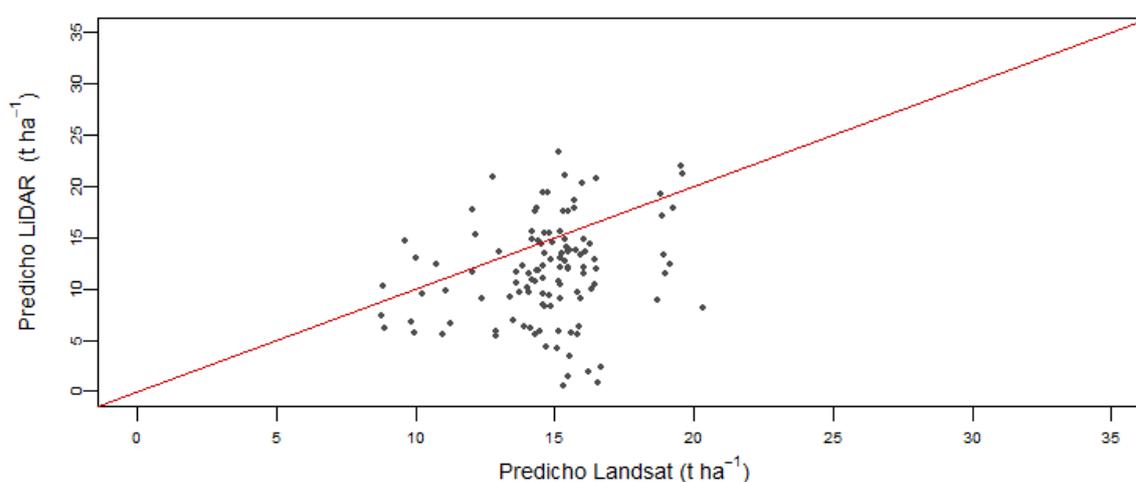
Los estadísticos de comparación obtenidos en las zonas A y C indican que las estimaciones del modelo no paramétrico son muy parecidas a las obtenidas por LiDAR, siendo sustancialmente peores en la zona B (Tabla 3). En cuanto a la media cuadrática de las diferencias, todas las zonas presentan valores superiores a 5t seca/ha, destacando la zona B que llega a 7 t seca/ha.

Tabla 3. Estadísticos de comparación de las estimaciones de la variable biomasa seca realizadas con LiDAR y Landsat en las zonas de validación A, B y C en el ámbito de influencia de Garray (Soria).

Estadístico	Zona A	Zona B	Zona C
Promedio diferencias (tseca/ha)	-1,04	-3,43	-0,96
Media cuadrática de las diferencias (tseca/ha)	5,50	6,90	5,52

Los valores predichos por el modelo obtenido con información Landsat oscilan en un rango mucho menor que los valores predichos con el modelo LiDAR, entre 3 y 25 frente a 10 y 20 toneladas secas por hectárea, respectivamente (Figura 3). Esto se debe a que, en zonas con valores de biomasa fuera de dicho intervalo, las variables independientes utilizadas para ajustar el modelo de regresión a partir de imágenes Landsat no son capaces de recoger toda la variabilidad del parámetro que se pretende estimar.

Figura 3. Gráfico de dispersión de los valores de biomasa ajustados con información espectral Landsat e información LiDAR a escala tesela en las zonas A, B y C de la zona de Garray (Soria) para *Cistus laurifolius*.



En cuanto a la comparación de los valores de biomasa estimados con Landsat con los datos obtenidos en los trabajos de desbroce realizados por el grupo Tragsa en las localizaciones de Navalcaballo, Ceder y Torretartajo, todas ellas ubicadas en la zona de Garray, se observa que en el área del Ceder las estimaciones de biomasa seca son prácticamente idénticas con un promedio de diferencias de -0.46 t/ha (Tabla 4). Sin embargo, en Navalcaballo se aprecia una gran diferencia entre ambas predicciones (4,86 t/ha). Probablemente la predicción en la zona Ceder es más parecida porque parte de las parcelas que se utilizaron para ajustar el modelo de regresión se situaban en esa zona. En cuanto a Torretartajo, se obtuvo una diferencia de aproximadamente 2 t/ha.

Tabla 4. Valores de biomasa seca estimados por el modelo no paramétrico Random Forest y obtenidos por Tragsa para las zonas de Ceder, Navalcaballo y Torretartajo (Garray, Soria).

Zona	Tragsa (tseca/ha)	Landsat (tseca/ha)	Promedio diferencias (tseca/ha)	Promedio diferencias (%)
Ceder	13,63	13,17	-0,46	3,37

Navalcaballo	10,97	15,83	4,86	44,30
Torretartajo	11,05	12,99	1,94	17,56

Las predicciones estimadas a partir de la información LiDAR muestran un promedio de diferencias negativo en todas las zonas, lo que indicaría que dicho modelo está subestimando las estimaciones de biomasa con respecto a los valores proporcionados por Tragsa (Tabla 5). Sin embargo, hay que tener en cuenta el desfase temporal que hay entre la fecha del vuelo LiDAR (2010) y los desbroces de Tragsa (2016) lo que podría explicar los resultados obtenidos. La zona de Navalcaballo, al igual que en la comparación anterior, presenta los peores resultados.

Tabla 5. Valores de biomasa seca estimados por el modelo paramétrico y obtenidos por Tragsa para las zonas de Ceder, Navalcaballo y Torretartajo (Garray, Soria).

Zona	Tragsa (tseca/ha)	LiDAR (tseca/ha)	Promedio diferencias (tseca/ha)	Promedio diferencias (%)
Ceder	13,63	11,20	-2,43	-17,85
Navalcaballo	10,97	7,01	-3,96	-36,07
Torretartajo	11,05	8,91	-2,14	-19,39

5. Discusión

Uno de los objetivos de este estudio es evaluar la bondad de las predicciones de los modelos de regresión ajustados. En cuanto al modelo no paramétrico Random Forest los resultados son muy satisfactorios, teniendo en cuenta la dificultad de caracterizar masas de matorral, con un error de exactitud del 41% (Tabla 2). Estas cifras resultan coherentes con los resultados obtenidos en otros estudios: GLENN et al. (2015) determinaron la biomasa seca aérea de un conjunto de matorrales, ajustando modelos no paramétricos a partir de información espectral (Landsat 8), obteniendo errores de exactitud (64%). ZHAO et al. (2016) llevaron a cabo un estudio similar en el noreste de China en el que las estimaciones de biomasa de matorral presentaron un error del 40.4 %. ESTORNELL et al. (2012) estimaron la carga de matorral en una área 100 ha en Valencia con un error del 37%. Además estos resultados son similares a los obtenidos en otros trabajos de estimación de parámetros forestales en masas arboladas que emplearon información radiométrica (HYYPÄ et al. (2000), MÄKELA Y PEKKARINEN (2004), MUUKKONEN Y HEISKANEN (2005), POWELL et al. (2010), FRAZIER et al. (2014), ASLAN et al (2016)).

No obstante, las predicciones de este modelo mostraron problemas de subestimación y sobrestimación para las observaciones mayores y menores, respectivamente (Figura 3). Se observa que en aquellos puntos donde la biomasa presenta valores muy bajos, la densidad de vegetación es bastante escasa, y que por tanto, el suelo influye en el comportamiento espectral de esas zonas lo que explica los problemas de sobrestimación. Por otra parte, en algún momento las variables espectrales son invariables a los aumentos de biomasa. Este problema de saturación de reflectividad explicaría las subestimaciones. Otra de las causas de este problema podría ser que las observaciones de biomasa se tomaron en parcelas equivalentes a celdas de 20x20 m, de tamaño menor a la resolución espacial de las imágenes Landsat (30 m).

El modelo paramétrico ajustado a partir de información LiDAR presentó un error de exactitud mucho menor (26,75%), lo que indica que las variables que participaron en su ajuste están más relacionadas con el parámetro de biomasa. Se pueden encontrar resultados parecidos a los de este

estudio en la literatura científica. ESTONELL et al. (2012) determinó la biomasa en un bosque mediterráneo ajustando modelos paramétricos a partir de datos LiDAR con un error del 28%. GLENN et al. (2015) también ajusto modelos con datos LiDAR, sin embargo, no obtuvo mejores resultados (65%). GREAVES et al. (2016) estimó la biomasa de matorral en la tundra del Ártico con un R^2 del 0.62.

6. Conclusiones

Este estudio demuestra el potencial de los datos LiDAR y la información espectral para estimar la biomasa seca de las masas de matorral. La metodología propuesta en este estudio permite estimar la biomasa de *Cistus laurifolius* a partir de datos LiDAR, pero también es posible aplicarla en otras áreas en las que la disponibilidad, estructura del matorral y calidad de los datos LiDAR suponga una restricción.

Sería aconsejable realizar nuevas investigaciones para entender los problemas de saturación de la reflectividad y analizar nuevas combinaciones de variables predictoras con mayor relación con el parámetro biomasa área seca. Algunos estudios han afirmado que el uso de variables de textura, como las propuestas por HARALICK (1973), da lugar a estimaciones de biomasa más exactas en comparación con el uso de índices de vegetación (DUBE y MUTANGA (2015), LU et al. (2005), KELSEY y NEFF (2014)). También sería interesante evaluar los ajustes de otro tipo de algoritmos no paramétricos, DUBE y MUTANGA (2015) afirman que el algoritmo SGB (Stochastic gradient boosting) es una herramienta más robusta para estimar la biomasa aérea seca forestal.

7. Agradecimientos

Este trabajo se ha realizado con el apoyo del proyecto Life+ Enerbioscrub financiado parcialmente por la Unión Europea.

8. Bibliografía

Aslan, A.; Rahman, A.F.; Warren, M. W.; Robeson, S. M.; 2016. Mapping spatial distribution and biomass of coastal wetland vegetation in Indonesian Papua by combining active and passive remotely sensed data. *RemoteSens. Environ.* 183 65–81.

Álvarez-González, J. G.; Cañellas, I.; Alberdi, I.; Gadow, K. V.; Ruiz-González, A. D; 2014. National Forest Inventory and forest observational studies in Spain: Applications to forest modeling. *Forest EcolManag* 316 54–64.

Breiman, L.; 2001. Random Forests. *Mach. Learn.*45 (1) 5–32.

Canty, M.J.; Nielsen, A.A; 2008. Automatic radiometric normalization of multitemporal satellite imagery with the iteratively re-weighted MAD transformation. *Remote Sens. Environ.*112 1025–1036.

Chavez, P.S.; 1996. Image-based atmospheric corrections. Revisited and improved. *Photogramm. Eng. Remote. Sens.* 62 1025–1036.

Dube, T.; Mutanga, O.; 2015. Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas. *ISPRS J. Photogramm. Remote Sens.* 108 12–32.

- García, M., Riaño, D., Chuvieco, E., Salas, J., & Danson, F. M. (2011). Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sens. Environ.* 115(6) 1369–1379.
- Estornell, J.; Ruiz, L.A; Velázquez-Martí, B.; Hermosilla, T.; 2012. Estimation of biomass and volume of shrub vegetation using LiDAR and spectral data in Mediterranean environment. *Biomass & Bioenergy* 46 710–721.
- Glenn, N. F.; Neuenschwander, A.; Vierling, L. A.; Spaete, L.; Li, A.; Shinneman, D.J.; Mcllroy, S. K; 2015. Landsat 8 and ICESat-2: Performance and potential synergies for quantifying dryland ecosystem vegetation cover and biomass. *Remote Sens. Environ.* 185 233–242.
- Greaves, H. E.; Vierling, L. A.; Eitel, J. U. H.; Boelman, N. T.; Magney, T. S.; Prager, C. M.; Griffin, K. L.; (2016). High-resolution mapping of aboveground shrub biomass in Arctic tundra using airborne LiDAR and imagery. *Remote Sens. Environ.* 184 361–373.
- Frazier, R.J.; Coops, N.C.; Wulder, M.A.; Kennedy, R.; 2014. Characterization of aboveground biomass in an unmanaged boreal forest using Landsat temporal segmentation metrics. *ISPRS J. Photogramm. Remote Sens.* 92(6) 137–146.
- Haralick, R.M.; Shanmugam, K.; Dinstein, I.H.; 1973. Textural features for image classification. *Syst., Man Cybernet., IEEE Trans SMC-3* 610–621.
- Horning, N; 2011. Training Guide for Creating Percent Cover Images. American Museum of Natural History - v10, Center for Biodiversity and Conservation. Available from <http://biodiversityinformatics.amnh.org/>
- Hyypä, J.; Hyypä, H.; Inkinen, M.; Engdahi, M.; Linko, S.; 2000. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. *Forest Ecol. and Manag.* 128 109-120.
- Jia, W.; Liu, M.; Yang, Y.; He, H.; Zhu, X.; Yang, F.; ... Xiang, W.; 2016. Estimation and uncertainty analyses of grassland biomass in Northern China: Comparison of multiple remote sensing data sources and modeling approaches. *Ecological Indicators* 60 1031–1040.
- Kelsey, K.C.; Neff, J.C.; 2014. Estimates of aboveground biomass from texture analysis of Landsat imagery. *Remote Sens.* 6, 6407-6422.
- Liaw, A.; Wiener, M.; 2002. Classification and regression by Random Forest. *R News* 218–22.
- Lu, D.; Batistella, M.; Moran, E.; (2005). Satellite estimation of aboveground biomass and impacts of forest stand structure. *Photogramm. Eng. Remote Sens.* 71 967–974.
- Macgaughey, R.J.; 2014. FUSION/LDV: Software for LiDAR Data Analysis and Visualization. VER 3.42. U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, University of Washington. 159 pp. Seattle.
- Mäkelä, H; Pekkarinen, A.; 2001. Estimation of timber volume at the sample plot level by means of image segmentation and Landsat TM imagery. *Remote Sens. Environ.* 77 66 -75.
- Muukkonen, P.; Heiskanen, J.; 2005. Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. *Remote Sens. Environ.* 99 434-447.

Powell, S. L.; Cohen, W. B.; Healey, S. P.; Kennedy, R. E.; Moisen, G. G.; Pierce, K. B.; Ohmann, J. L.; 2010. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: A comparison of empirical modeling approaches. *Remote Sens. Environ* 114(5) 1053–1068.

Zhang, L.; Cui, G.; Shen, W.; Liu, X.; 2016. Cover as a simple predictor of biomass for two shrubs in Tibet. *Ecological Indicators* 64 266–271.

Zhao, P.; Lu, D.; Wang, G.; Wu, C.; Huang, Y.; Yu, S.; 2016. Examining Spectral Reflectance Saturation in Landsat Imagery and Corresponding Solutions to Improve Forest Aboveground Biomass Estimation. *Remote Sens.* 8(6), 469.

Zhu, Z.; Wang, S.; Woodcock, C.E.; 2015. Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and sentinel 2 images. *RemoteSens.Environ.* 159, 269–277.