7º CONGRESO FORESTAL ESPAÑOL

Gestión del monte: servicios ambientales y bioeconomía

26 - 30 junio 2017 | Plasencia
Cáceres, Extremadura

7CFE01-123

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

Sociedad Española de Ciencias Forestales
SECF

Generación de cartografía de matorrales a partir de Landsat 8 y variables auxiliares usando Random Forest

ESTEBAN, J.[1], FERNÁNDEZ-LANDA, A.[2] y TRASSIERRA, A.[2]
[1] Departamento de Ingeniería y Morfología del Terreno. ETSI Caminos, Canales y Puertos. Universidad Politécnica de Madrid.
[2] AGRESTA Sociedad Cooperativa.

Resumen
Un porcentaje significativo de nuestra superficie forestal está ocupado por matorral, sin embargo, no existe una adecuada caracterización de estas áreas. El estudio pretende obtener productos cartográficos de tres especies de matorral: *Cistus laurifolius*, *Erica arborea* y *Ulex europaeus* mediante el empleo de información del satélite Landsat 8. Este trabajo se enmarca en el proyecto Life + Enerbioscrub, cuyo objetivo es la evaluación de métodos innovadores para el aprovechamiento energético sostenible de matorrales. Se ha utilizado información ya disponible para generar una metodología que abarate los costes y sea implementada en otras zonas de estudio. El algoritmo elegido para la clasificación fue 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. Los resultados obtenidos fueron muy satisfactorios teniendo en cuenta la complejidad de distinguir espectralmente coberturas de matorral de otro tipo de coberturas forestales. En general la fiabilidad global superó el 80% en todos los casos, con errores de omisión para las especies de matorral objetivo entre 40 – 70% y errores de comisión entre 10 – 40%. Estos errores se deben a que se priorizo la detección de masas puras con potencial energético frente a otras masas de la misma especie, pero con coberturas abiertas de menor desarrollo. Este estudio plantea una metodología alternativa para caracterizar teselas de matorrales densas en las que la disponibilidad de datos LiDAR sea una restricción.

Palabras clave
Imágenes de satélite, clasificación, índices de vegetación, aprovechamiento energético, gestión forestal.

1. Introducción

Un porcentaje significativo de la superficie del territorio español está caracterizada por la presencia de masas de matorral. Estas especies vegetales desarrollan un papel fundamental en los ecosistemas españoles ya que son fuente de biodiversidad, tienen un importante valor protector de los suelos y ofrecen, sujetos a una apropiada explotación, una oportunidad para su aprovechamiento como fuente de biocombustibles sólidos. Esta aplicación contribuye 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.

A pesar del importante papel que los matorrales desempeñan existe una falta generalizada de información sobre su comportamiento que, en la mayoría de los casos, hace que estas áreas queden excluidas de los planes de gestión (ESTORNELL et al., 2012). La metodología de muestreo que se usa en el Inventario Forestal Nacional (IFN) requiere de una gran inversión económica que da lugar a intervalos de muestreo de diez años. Esta característica supone una desventaja para el estudio de especies con una tasa de crecimiento elevada (ÁLVAREZ-GONZÁLEZ et al., 2014).

Son pocas las investigaciones que se han centrado en la caracterización de estas áreas, la mayoría se centra en el estudio de especies arbóreas. Algunos estudios utilizaron información LiDAR (Laser Imaging Detection and Ranging) para determinar la carga de matorral o discriminar modelos de combustible de matorral (ESTORNELL et al., 2012; RIAÑO et al., 2002; GARCÍA et al., 2011). Sin embargo, en ocasiones la no disponibilidad de datos LiDAR, su antigüedad o/y sus propias características (densidad de puntos) imposibilitan su uso para estos fines. Además, la tecnología

LiDAR tiende a subestimar la altura de la vegetación en masas de matorral densas ya que el haz láser es incapaz de atravesar la cubierta y alcanzar el suelo (GREAVES et al., 2016). Estos inconvenientes dificultan la caracterización precisa de masas matorrales de elevada densidad y rápido crecimiento.

En este contexto la teledetección satelital emerge como una herramienta alternativa en el estudio de matorrales. No obstante, son pocos los trabajos que han realizado estudios de presencia/ausencia de especies concretas de matorral (VANSELOW & SAMIMI, 2014), la mayoría de ellos lleva a cabo una clasificación general de las masas de matorral (RODRIGUEZ-GALIANO & CHICA-RIVAS, 2012; ZHAO et al., 2016; SENF et al., 2015). En la mayoría de los casos la distribución de especies especificas deriva del uso de imágenes hiperespectrales (CLARK & KILHAM, 2016; LANDMANN et al., 2015; LAWRENCE, WOOD, & SHELEY, 2006; NAIDOO et al., 2012). Los sensores hiperespectrales registran información continua en el espectro óptico obteniéndose una firma espectral detallada para cada píxel de la imagen, lo cual permite una caracterización muy precisa de la superficie. Sin embargo, el gran volumen de datos que se genera hace que el coste de adquisición y procesamiento sea elevado.

2. Objetivos

El estudio se enmarca en el proyecto Life + Enerbioscrub, cuyo objeto es la evaluación de métodos innovadores para el aprovechamiento energético sostenible de matorrales. Para ello se han delimitado una serie de superficies de actuación situadas en tres localidades de España: Garray (Soria), Fabero (León) y As Pontes (A Coruña). Para cada una de estas localidades se han establecido radios de acción de 100 kilómetros para las instalaciones de producción de pellets y electricidad situadas en As Pontes (La Coruña) y en Garray (Soria) y de 20 km para las instalaciones de calor de distrito situadas en Fabero (León). Cada superficie de actuación potencial está asociada con una de las cuatro especies más ampliamente representadas en la península ibérica: *Cistus laurifolious* (Garray, Soria), *Erica arborea* (Fabero, León) y *Ulex europaeus* (As Pontes, A Coruña).

El objetivo del presente estudio consiste en caracterizar cada una de las especies de matorral mencionadas, proporcionando información cartográfica de las mismas, tendiendo en todo momento a identificar zonas densas aptas para su aprovechamiento energético. La rápida dinámica de estos matorrales junto con los años transcurridos desde la realización del último vuelo LiDAR disponible recomiendan el uso alternativo de otro tipo de fuentes de información. El libre y gratuito acceso a las imágenes Landsat y su resolución temporal, espectral y espacial han sido determinantes para su selección en el presente estudio como una fuente de información complementaria al LiDAR en la caracterización de las masas de matorral. Se desarrollará una metodología que abarate los costes y pueda ser implementada en otras zonas de estudio en las que la disponibilidad de datos LiDAR actuales sea una restricción.

3. Metodología

Con el objetivo de obtener productos cartográficos y realizar una caracterización del matorral a la fecha más actual posible, se trabajo con los datos del sensor Operational Land Imager (OLI, satélite Landsat 8). Concretamente se usaron un total de seis escenas (Figura 1) recopiladas en el mes de junio de 2015 (30 m resolución).

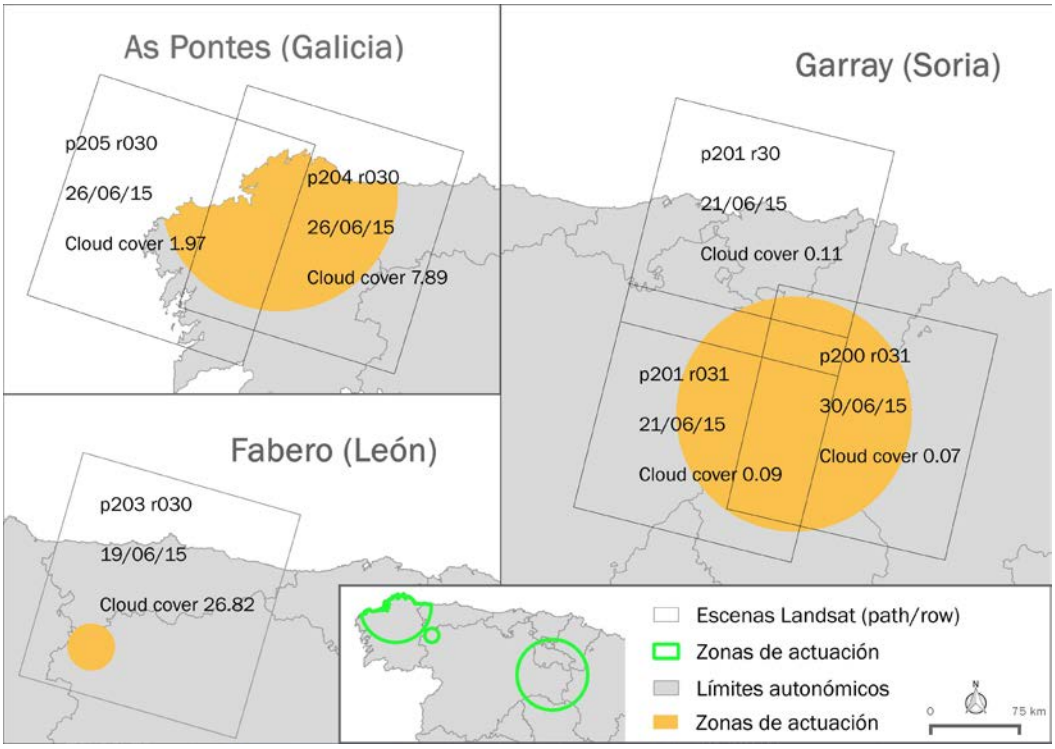


Figura 1. Detalles de las escenas del satélite Landsat 8 que se utilizaron para caracterizar las especies de matorral objetivo en cada una de las zonas de actuación enmarcadas en el proyecto Life + Enerbioscrub.

El pre procesamiento de las imágenes de satélite consistió una serie de conversiones estándar que permiten transformar los niveles digitales (ND) a valores de reflectividad de la superficie terrestre. Para eliminar los efectos de la dispersión atmosférica se ha aplicado el método de corrección del histograma por sus valores mínimos (CHAVEZ, 1996). Finalmente, los efectos de la cubierta nubosa han sido eliminado mediante el algoritmo Fmask (ZHU et al. 2015) implementado en MATLAB. Dado que las zonas de estudio de As Pontes y Garray englobaban más de una escena de satélite, fue necesario generar un mosaico de las mismas en cada una de las áreas. Previamente se normalizaron sus valores de reflectividad para reducir las diferencias entre las distintas imágenes debidas a las distintas condiciones atmosféricas. Para ello, se utilizo el método *Iteratively Reweighted Multivariante Alteration Detection* (IR-MAD) propuesto por CANTY & NIELSEN (2008).

En la clasificación de las imágenes se establecieron cuatro clases espectrales; el matorral objetivo, otros matorrales, zonas forestales y arboladas y zonas no forestales ni arboladas. Para su discriminación se definieron una serie de áreas de interés a partir de diferentes materiales de referencia. Las áreas de especies forestales y arboladas se determinaron a partir del inventario forestal nacional (IFN4). En cuanto a las áreas de entrenamiento de los matorrales objetivo, primeramente se creó una cartografía inicial con los siguientes mapas auxiliares:

- Mapa Forestal de España escala 1:200.000 (MFE200) para las zonas de Guadalajara y Zaragoza.
- Cartografía de la vegetación en las áreas desarboladas del Mapa Forestal de España a escala 1:50.000 (MFE50).
- Mapa Forestal de España a escala 1:25.000 (MFE25).

Esta cartografía inicial se combinó con fotografías aéreas PNOA más actuales y con mayor resolución espacial para localizar aquellas zonas de matorral objetivo más densas. En la medida de lo posible, se intentó digitalizar las facies de matorral más puras, evitando píxeles de borde o contaminados por otras cubiertas.

Se llevo a cabo una clasificación supervisada de las imágenes mediante el algoritmo Random Forest (BREIMAN, 2001). Esta metodología fue implementada en R usando el paquete de R "RandomForest: Breiman and Cutler's Random Forests for classification and regression" (LIAW & WIENER, 2002). Dado que numerosos estudios respaldan la robustez de este algoritmo como herramienta de clasificación combinando información espectral y auxiliar (GRINAND et al., 2013; RODRIGUEZ-GALIANO & CHICA-RIVAS, 2012; TATSUMI et al., 2015; GHOSH et al., 2014; NAIDOO et al., 2012) se genero una imagen multibanda constituida por 21 variables predictoras (Tabla 1). Una vez que las imágenes fueron pre procesadas se calculo un índice de vegetación (NDVI) por su capacidad de discriminar entre cubiertas de vegetación (GILABERT et al., 2002; JIN & SADER, 2005; SCHULTZ et al., 2016). También se determinó una serie de índices de textura del NDVI basados en las texturas de HARALICK (HARALICK et al., 1973). Finalmente se obtuvo una serie de medidas derivadas del modelo digital de elevación previamente remuestreado, por el método del vecino más próximo, a 30 metros de resolución.

Tabla 1. Conjunto de variables predictoras usadas en el proceso de clasificación de las zonas de actuación del proyecto LiFE + Enerbioscrub en el año 2015. Bandas 1-15 se han obtenido a partir de información espectral (Landsat 8) y las bandas 16-21 a partir del modelo digital de elevación (MDE) del CNIG (25 m). NDVI: Normalized Difference Vegetation Index; IRC: Infra rojo cercano; SWIR: Short Wave Infra Red.

Grupo	Id	Variable
Texturas NDVI	1	Energía
	2	Entropía
	3	Correlación
	4	Inverse Different Moment (IDM)
	5	Inercia
	6	Clustershade
	7	Cluster Prominence
	8	Correlación de Haralick
Índices de vegetación	9	NDVI
Información espectral	10	Azul
	11	Verde
	12	Rojo
	13	IRC
	14	SWIR 1
	15	SWIR 2
Derivadas MDE	16	Elevación
	17	Curvatura plana
	18	Sombras del relieve
	19	Convergencia
	20	Perfil de curvatura
	21	Pendiente

Finalmente, los productos cartográficos obtenidos fueron reclasificados en dos clases, obteniéndose una máscara de matorral para cada zona de actuación.

La validación de los mapas cartográficos se realizó a partir de una muestra de puntos independientes (no utilizados en el ajuste previo de la cartografía de matorral) cuyo tamaño se determinó siguiendo la metodología de OLOFFSON et al. (2014). Estos puntos fueron distribuidos aleatoriamente en cada estrato asignándoles la verdad terreno mediante el uso de fotografías aéreas del PNOA de alta resolución como material de referencia. Finalmente, dichos puntos se plasmaron en una matriz de confusión obteniéndose una serie de indicadores de exactitud a partir de las ecuaciones descritas en OLOFFSON et al. (2014). La tabla 2 recoge el número de puntos que se han utilizado para validar los resultados de las clasificaciones digitales de matorral.

Tabla 2. Número de puntos de control utilizados en el proceso de validación de la cartografía de matorral.

Zona	Clase	Puntos de control
Garray (Soria)	Jara	50
	No Jara	425
Fabero (León)	Brezo	51
	No brezo	424
As Pontes (Galicia)	Tojo	90
	No tojo	385

4. Resultados

Tras realizar la validación independiente de los resultados se ha obtenido una exactitud global con valores superiores al 85% alcanzado prácticamente el 100% en la zona de Garray (Tabla 3). Dado que el objetivo del estudio era caracterizar ciertas especies de matorral, conviene prestar atención a los porcentajes de exactitud de estas clases. En todos los casos la exactitud del productor es mucho menor, en comparación con los valores de exactitud del usuario, con rangos que oscilan aproximadamente entre 30-60%. Estas cifras indican que el procedimiento no ha clasificado superficies en las que el matorral objeto de estudio está presente. Sin embargo, estos resultados tienen lógica dentro del proceso de clasificación realizado ya que se ha entrenado el clasificador con áreas de matorral denso óptimas para el aprovechamiento de biomasa; consecuentemente, el proceso de clasificación ha dejado fuera superficies menos densas o en mezcla con otras coberturas obteniéndose un área inferior a la real. Se prefirió generar cartografías con exactitudes de usuario más elevadas, ya que esto asegura que las zonas clasificadas como matorral objetivo lo sean en la realidad, de hecho, los errores de comisión no superan el 10% con la excepción de As Pontes que llegan a alcanzar el 40%. El origen de los errores de clasificación en As Pontes se debe a que esta especie crece en asociación con otras especies de matorral, habiendo un número elevado de pixeles mixtos para este tipo de matorral.

La metodología Random Forest permite estimar la importancia relativa de cada una de las variables predictoras, para ello se ha utilizado la medida Mean Decrease Accuracy (MDA). La variable más relevante fue la elevación ya que la distribución de la vegetación está condicionada por dicho factor. Otras bandas significantes fueron el infrarrojo cercano, la pendiente, el índice de vegetación NDVI y el SWIR. El resto de variables topográficas no contribuyeron significativamente ya que probablemente la información que proporcionan ya está incluida en otras bandas. En cuanto a las variables de textura, ninguna de ellas presentó valores significativos.

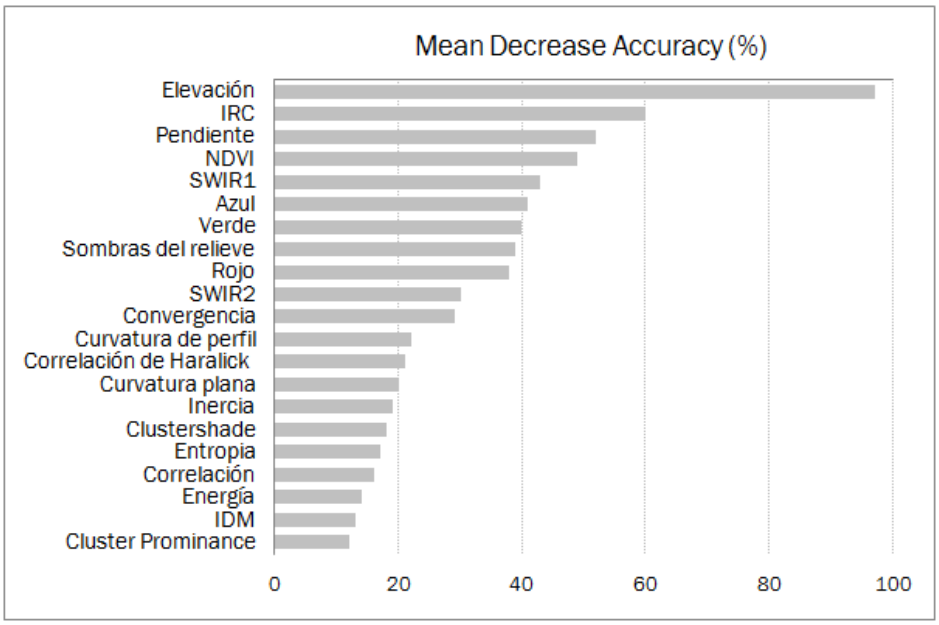


Figura 2. Importancia relativa de las variables predictoras (eje y) en el proceso de clasificación de matorral en cada una de las zonas del proyecto Life + Enerbioscrub. Mean Decrease Accuracy (MDA, eje x) es una medida de importancia relativa, a mayor porcentaje mayor importancia. Nota: IRC: Infra Rojo Cercano; NDVI: Normalized Difference Vegetation Index; SWIR: Short Wave Infrared; IDM: Inverse Different Moment.

Tabla 3. Validación de los productos cartográficos obtenidos en cada una de las zonas del proyecto Life + Enerbioscrub siguiendo la metodología propuesta por OLOFFSON et al. (2014). Los intervalos de confianza al 95 % de cada medida de exactitud se expresan entre paréntesis.

Zona	Clase	Exactitud Usuario (%)	Exactitud Productor (%)	Exactitud Global (%)	Área estimada (ha)
Garray (Soria)	Jara	82 (72–92)	37 (16–58)	99 (98–100)	27.315 (26.368–95.402)
	No Jara	99 (98–100)	100 (100-100)		3.114.273 (3.046.956–3.114.450)
Fabero (León)	Brezo	98 (94–102)	57 (49–65)	92 (90–94)	13.444 (19.936–26.178)
	No brezo	91 (88–94)	100 (99–100)		112.219 (99.518–105.693)
As Pontes (Galicia)	Tojo	60 (49–71)	28 (21–35)	87 (84–90)	116.657 (197.437–303.686)
	No tojo	89 (86–92)	97 (96–98)		1.637.703 (1.451.212–1.556.385)

La distribución de las zonas de matorral objetivo se muestra en la Figura 3. Tras el ajuste de los modelos de clasificación se han obtenido aproximadamente 27.000 ha de jara, 13.000 ha de brezo y 116.000 ha de tojo aptas para su aprovechamiento energético.

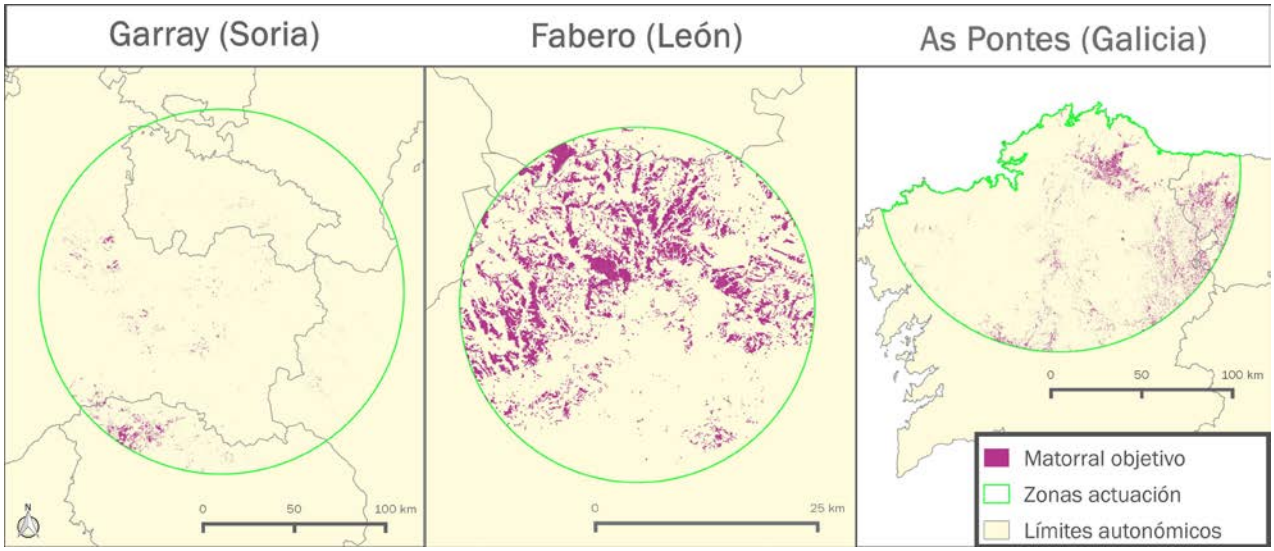


Figura 3. Cartografía de matorral objetivo en cada una de las zonas de actuación del proyecto Life Enerbioscrub en el año 2015 con resolución de 30 metros. Los matorrales objetivos de izquierda a derecha son: jara, brezo y tojo.

5. Discusión

El objetivo del presente estudio era desarrollar una metodología que permitiese caracterizar especies de matorral aptas para el aprovechamiento energético. Tras analizar los resultados se han obtenido exactitudes de usuario que varían entre 60-100% y exactitudes del productor entre 28-60%. Los resultados son satisfactorios teniendo en cuenta la dificultad de discriminar especies específicas de matorral. Variables auxiliares como la elevación, pendiente y el NDVI fueron importantes en el proceso de clasificación. En cuanto a las variables de textura, ninguna de ellas presento una importancia significativa. Podría ser que la elección del tamaño de ventana no fuese el más óptimo o que estas variables tuviesen una importancia limitada en la caracterización de masas matorrales. Dado que esto no era uno de los objetivos del estudio se deberían realizar trabajos más profundos para sacar alguna conclusión. El tojo (Tabla 3) fue la clase o categoría más difícil de discriminar debido al elevado número de pixeles mixtos. En algunos casos los matorrales comparten el mismo rango de distribución con especies caducifolias por lo que la incorporación de imágenes estacionales permitirá mejorar la discriminación entre masas forestales y matorrales (RIAÑO et al., 2002; SENF et al., 2015; CLARK & KILHAM, 2016; ZHAO et al., 2016). Además, la mayor resolución espacial y espectral de las imágenes del satélite Sentinel permitiría mejorar los resultados.

Las propias características de la metodología dificultan la comparación con otros estudios ya que, por un lado, únicamente se han clasificado especies específicas y por otro, se ha intentado detectar teselas densas de matorral aptas para su aprovechamiento energético. No obstante, los resultados obtenidos por otros autores están en línea con los obtenidos en este trabajo. SENF et al. (2015) ajustó un modelo de clasificación de usos del suelo en un área de 2000 km^2 de Portugal. Tras clasificar masas de matorral obtuvo porcentajes de exactitud del usuario entre 30-50% y valores de exactitud del productor con rangos entre 40-80%. Los errores de omisión son menores en comparación con los citados anteriormente, sin embargo, en la metodología implementada en este estudio se prefirió generar cartografías clasificadas correctamente a costa de omitir zonas que, a pesar de contener la especie matorral objetivo, no fuesen aptas para el aprovechamiento energético. ZHAO et al. (2016) realizo un mapa de usos de suelo de Chile, a partir de imágenes multitemporales de Landsat 8, clasificando superficies de matorral. Esta categoría presento una exactitud del usuario muy elevada (80%) y una exactitud del productor del 54% Sin embargo, tras llevar a cabo un análisis de subclases de masas de matorral la exactitud del usuario varía entre 38% y 49% y la exactitud del

productor entre 14% y 79%. Por el contrario, hay que destacar que los resultados no son tan satisfactorios como los obtenidos a partir de imágenes hiperespectrales; CLARK et al. (2016) clasifico teselas de matorral denso con exactitudes de aproximadamente el 80%.

Sería interesante que esta metodología se aplicase en otras zonas de estudio con diferentes especies de matorral para comprobar que los resultados no dependen de la especie objeto de estudio. Además, convendría realizarse una validación independiente para matorral denso y matorral abierto, de este modo se podría realizar una valoración más exhaustiva sobre los errores de omisión que se han obtenido.

6. Conclusiones

Ante de los resultados obtenidos se puede afirmar que la combinación de información espectral y auxiliar, en el ajuste de los modelos de clasificación, hace posible obtener productos cartográficos adecuados para la toma de decisiones de gestión de masas de matorral. De este modo este estudio plantea una metodología alternativa para caracterizar teselas de matorrales densas en las que la disponibilidad de datos LiDAR sea una restricción. En todo momento se ha utilizado información ya disponible lo que permitiría aplicar esta metodología en otras zonas de estudio; de esta manera, se obtendría información actualizada que permitiría caracterizar las masas de matorral más densas. Estos productos podrían ser incorporados en los planes de gestión forestal y de aprovechamiento energético.

7. Agradecimientos

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

8. Bibliografía

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 Ecol Manag*, 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.

Clark, M. L.; Kilham, N. E.; 2016. Mapping of land cover in northern California with simulated hyperspectral satellite imagery. *ISPRS J. Photogramm. Remote Sens.*119 228–245.

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.

Garcia, 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. of Environ. 115(6) 1369–1379.

Ghosh, A.; Sharma, R.; Joshi, P.K.; 2014. Random forest classification or urban landscape using Landsat archive and ancillary data: Combining seasonal maps with decision level fusion. *Appl. Geogr.* 48 31- 41.

Gilabert, M.A.; González-Piqueras, J.; García-Haro, F.J.; Meliá, J.; 2002. A generalized soil adjusted vegetation index. *Remote Sens. Environ.* 82 (2–3) 303–310.

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. of Environ.* 184 361–373.

Grinand, C.; Rakotomalala, F.; Gond, V.; Vaudry, R.; Bernoux, M.; Vieilledent, G.; 2013. Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier. *Remote Sens. Environ.* 139 68–80.

Haralick, R.M.; Shanmugam, K.; Dinstein, I.H.; 1973. Textural features for image classification. *Syst., Man Cybernet., IEEE Trans* SMC-3 610–621.

Jin, S.; Sader, S.A.; 2005. Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances. *Remote Sens. Environ*. 94 (3) 364–372.

Landmann, T.; Piiroinen, R.; Makori, D. M.; Abdel-Rahman, E. M.; Makau, S.; Pellikka, P.; Raina, S. K.; 2015. Application of hyperspectral remote sensing for flower mapping in African savannas. *Remote Sens. Environ*. 166 50–60.

Lawrence, R. L.; Wood, S. D.; Sheley, R. L.; (2006). Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (randomForest). *Remote Sens. Environ*. 100(3) 356–362.

Liaw, A.; Wiener, M.; 2002. Classification and regression by Random Forest. *R News* 2 18–22.

López, C. et al. (2000 – 2008). Cartografía de la vegetación en las áreas desarboladas del Mapa Forestal del España. Universidad Politécnica de Madrid. Banco de Datos para la Biodiversidad.

Ministerio de Agricultura, Alimentación y Medio Ambiente MAGRAMA. (2007-2017). Mapa Forestal de España a escala 1:25.000. Ministerio de Agricultura, Alimentación y Medio Ambiente. Serie publicación digital. Madrid.

Ministerio de Medio Ambiente. (1986-1997). Mapa Forestal de España a escala 1:200.000. Ministerio de Medio Ambiente. Serie publicación digital. Madrid.

Naidoo, L.; Cho, M. A.; Mathieu, R.; Asner, G.; (2012). Classification of savanna tree species, in the Greater Kruger National Park region, by integrating hyperspectral and LiDAR data in a Random Forest data mining environment. *Photogramm. Eng. Remote. Sens*. 69 167–179.

Olofsson, P.; Foody, G.M.; Herold, M.; Stehman, S. V.; Woodcock, C.E.; Wulder, M. A.; (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sens. Environ.* 148 42–57.

Riaño, D.; Chuvieco, E.; Salas, J.; Palacios-Orueta, A.; Bastarrika, A.; 2002. Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Can. J. For. Res.* 32 1301–1315.

Rodriguez-Galiano, V.; Chica-Olmo, M.; 2012. Land cover change analysis of a Mediterranean area in Spain using different sources of data: multi-seasonal Landsat images, land surface temperature, digital terrain models and texture. *Appl. Geogr.* 35 (1–2) 208–218.

Schultz, M.; Clevers, J.G.P.W.; Carter, S.; Verbesselt, J.; Avitabile, V.; Quang, H.V.; Herold,M.; 2016. Performance of vegetation indices from Landsat time series in deforestation monitoring. *Int. J. Appl. Earth Obs. Geoinf.* 52, 318–327.

Senf, C.; Leitão, P.; Pflugmacher, D.; Van der Linden, S.; Hostert, P.; 2015. Mapping land cover in complex Mediterranean landscapes using Landsat: Improved classification accuracies from integrating multi-seasonal and synthetic imagery. *Remote Sens. Environ.* 156 527-536.

Tatsumi, K.; Yamashiki, Y.; Canales Torres, M.A.; Taipe, C.L.R.; 2015. Crop classification of upland fields using Random forest of time-series Landsat 7 ETM+ data. *Comput. Electron. Agric.* 115 171–179.

Vanselow, K.; Samimi, C.; 2014. Predictive mapping of dwarf shrub vegetation in an arid high mountain ecosystem using remote sensing and random forests. *Remote Sens* 6 (7) 6709—6726.

Zhao, Y.; Feng, D.; Yu, L.; Wang, X.; Chen, Y.; Bai, Y.; Hernández, H.J.; Galleguillos, M.; Estades, C.; Biging, G.S.; Radke, J.D.; Gong, P.; 2016. Detailed dynamic land cover mapping of Chile: Accuracy improvement by integrating multi-temporal data. *Remote Sens. Environ.* 183 170–185.

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. *Remote Sens. Environ.* 159, 269–277.