



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1312

Actas del Noveno Congreso Forestal Español
Edita: **Sociedad Española de Ciencias Forestales. 2025.**
ISBN: **978-84-941695-7-1**

Organiza





Clasificación supervisada de Jarales en Andalucía en el marco del Grupo Operativo “ESjara”

TOMÉ MORÁN, J.L. (1), ARELLANO PEREZ, S. (1), MONTERO JIMÉNEZ, M. (1), RODRIGUEZ GARCÍA, A. (2), ESTEBAN CAVA, J. (1),

(1) Agresta Sociedad Cooperativa.

(2) Fundación Cesefor.

Resumen

Uno de los principales objetivos del Grupo Operativo ESjara es analizar la disponibilidad del recurso. Sin embargo, no existe una cartografía actualizada precisa lo que hace crucial emplear técnicas de clasificación combinando datos de campo e imágenes de satélite como Sentinel-2. Para ello, se ha utilizado un conjunto de 591 parcelas, recopiladas en el marco del servicio de modelos de combustible del proyecto CILIFO en Andalucía, con el 70% de las parcelas para entrenamiento y el 30% para validación. De cara a seleccionar el momento fenológico idóneo para identificar los jarales se crearon compuestos de imágenes mensuales desde abril hasta octubre, a partir de las cuales se ha generado una batería de trece índices de vegetación. Se desarrollaron cartografías basadas en técnicas de clasificación automática mediante el algoritmo Random Forests para cada compuesto. Los mejores resultados se obtuvieron combinando los compuestos de mayo y agosto con errores de omisión y comisión del 23% y 26%, respectivamente. Los resultados muestran el potencial de los datos satelitales para generar clasificaciones, especialmente, en zonas dinámicas con gran presencia de desbroces. En estas zonas la teledetección proporciona información actualizada y precisa que complementa y en algunos casos supera a las fuentes cartográficas convencionales.

Palabras clave

Sentinel 2, jaral, Random Forest, teledetección.

1. Introducción

El Grupo Operativo ESjara está enfocado en el aprovechamiento de las jaras (*Cistus ladanifer* y *Cistus laurifolius*) para la obtención de aceites esenciales valorizando los residuos y subproductos, con objeto de poner en valor este recurso y sus cadenas de valor contribuyendo al desarrollo de la bioeconomía en el medio rural.

El grupo operativo aborda todos los aspectos necesarios para la explotación del recurso, desde la identificación del mismo y la cuantificación de la biomasa disponible (ARELLANO et al, 2024; MONTERO et al, 2024) a través de técnicas de teledetección, pasado por el desarrollo de técnicas rentables de mecanización, la caracterización química de los aceites y subproductos generados en su destilación acabando en análisis de la viabilidad económica de los mismos en el mercado.



España cuenta con 27,63 millones de hectáreas forestales, lo que supone un 54,8 % de su territorio, siendo el segundo país en cuanto a superficie forestal en Europa por detrás de Suecia (BRAVO et al, 2017). De esta superficie más del 35 % corresponde a formaciones de matorral que ocupan más de 10 millones de hectáreas a lo largo de toda España (MONTERO et al., 2017). Más concretamente, las especies de jara estudiadas en el grupo operativo tienen un enorme peso superficial. PÉREZ y ESTEBAN en 2008 cifraron superficies de 2.106.717 ha de *Cistus ladanifer* y 355.595 ha de *Cistus laurifolius* en formaciones arbustivas y bajo arbolado ralo, distribuidas fundamentalmente en zonas ácidas, en los pisos bioclimáticos mesomediterráneo y supramediterráneo respectivamente sobre inceptisoles en zonas de pendiente moderada.

Sin embargo, esta superficie no está perfectamente delimitada ni siquiera en el Mapa Forestal Nacional (MFE) que es la mejor cartografía disponible a nivel nacional. Esta falta de delimitación precisa subraya la necesidad de explorar técnicas avanzadas que permitan mejorar la distribución y extensión de los jarales. En este contexto, la teledetección se ha consagrado como una herramienta de gran utilidad para el mapeo de coberturas de suelo o discriminación de especies (GÓMEZ et al., 2019). Sin embargo, la mayoría de estudios realizados se han centrado en la clasificación de especies forestales arbóreas debido a la dificultad asociada con el mapeo de formaciones de matorral. Por lo general, este tipo de cubiertas presenta una gran heterogeneidad al mezclarse con otros elementos, como pastos, suelos desnudos, distintas especies de matorral, que hacen que sus características espectrales no sean tan puras (GAN et al.; 2022).

2. Objetivos

El objetivo de este estudio es testar el potencial de las imágenes de Sentinel-2 para clasificar masas puras de *Cistus Ladanifer* a partir de clasificaciones supervisadas usando técnicas de aprendizaje supervisado entrenadas a partir de datos de verdad terreno recogidos en el marco del proyecto CILIFO (Centro Ibérico para la Investigación y Lucha contra Incendios Forestales).

3. Metodología

3.1 Área de estudio

Como área de estudio se han elegido dos de las zonas piloto (Figura 1) del grupo operativo ESjara las comarcas de Jerez de los Caballeros en Badajoz y El Andévalo Occidental en Huelva.

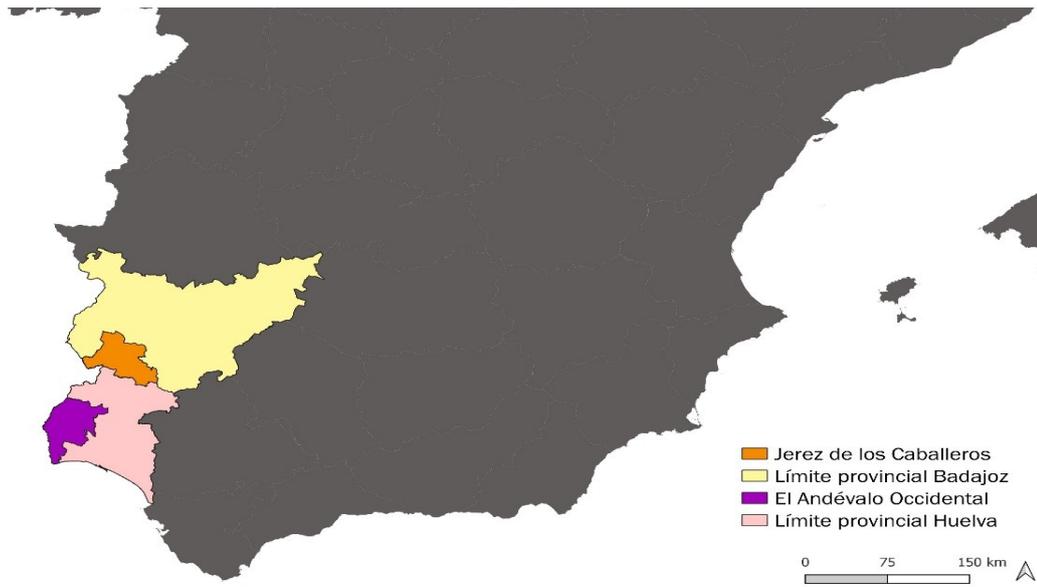


Figura 1. Localización zonas piloto

3.2 Cartografías base de jarales

En este trabajo hemos utilizado como base la Foto Fija 2018 del MFE (ROBLA et al., 2017) que agrupa las formaciones de jaral bajo los siguientes códigos de IDFORMAT catalogados en la base de datos:

- 220 Jarales y matorrales de Cistáceas
- 221 Jarales mixtos o mezclados (*Cistus spp.*)
- 222 Jaguarzales y jaral-carpazales menores (*Halimium spp. pl.*)

En Huelva la cartografía de la Foto Fija corresponde al MFE de 2005, por lo que esta cartografía se ha complementado con las siguientes formaciones del Sistema de Información sobre el Patrimonio Natural de Andalucía (SIPNA 2020) de la Red de Información Ambiental de Andalucía (REDIAM):

- 322 Matorral denso,
- 351 Jarales dispersos con pastizal,
- 367 Jarales dispersos con pasto y roca o suelo

3.3 Datos de campo

Como datos de verdad terreno se utilizaron 591 parcelas levantadas durante los trabajos de campo del servicio de modelización del combustible forestal en Andalucía. En dichas parcelas se registró tanto las especies de matorral como las de arbolado cuando este estaba presente. Las parcelas se reclasificaron en tres clases: “no matorral”, “jaral” y otros matorrales o “no jarales” distribuidas a lo largo de Andalucía tal como se puede apreciar en la figura 2.

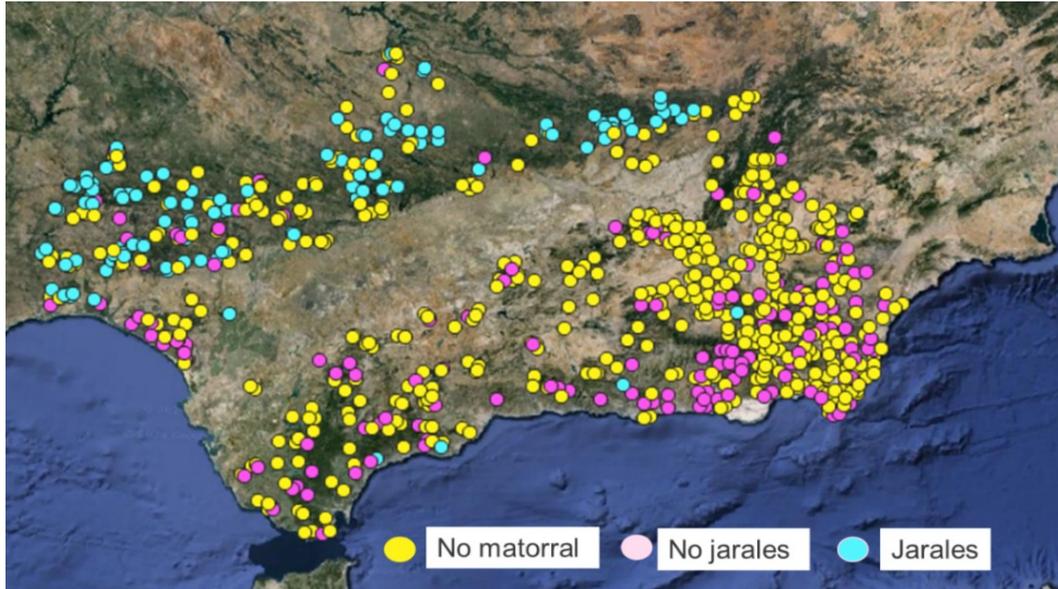


Figura 2. Localización de la base de datos de parcelas recopiladas en Andalucía utilizadas para el entrenamiento y la evaluación del rendimiento de los modelos de clasificación

3.4 Datos satelitales

Para el desarrollo de clasificaciones supervisadas se han utilizado datos de imágenes satelitales Sentinel 2 (S2) del programa Copernicus de la Unión Europea. S2 capta información en 13 bandas espectrales diferentes en el espectro visible, infrarrojo cercano e infrarrojos de onda corta, con una resolución espacial que varía entre los 10 y 60 m.

De cara analizar la fenología de la especie a lo largo del año se ha utilizado un enfoque multitemporal creando composiciones mensuales desde abril hasta octubre del 2023 a partir de imágenes de nivel 2A (*Bottom-of-atmosphere reflectance*). Los compuestos mensuales se crearon combinando las imágenes disponibles en cada mes y calculando la mediana para cada píxel.

A partir de estas composiciones se calcularon 13 índices de vegetación, seleccionando aquellas bandas espectrales que aportan información relevante sobre el estado de la vegetación y el contenido de la humedad, especialmente las bandas del rojo, borde del rojo, infrarrojo cercano e infrarrojo medio.

Tabla 1. Índices de vegetación calculados a partir de las composiciones de imágenes de satélite analizadas

Índice de vegetación	Cálculo con las bandas de Sentinel-2 (*)	Descripción
EVI	$2.5 * (NIR - R) / (NIR + 6 * R - 7.5 * B + 1)$	“Enhanced Vegetation Index”
GVMi	$((NIR + 0.1) - (SWIR2 + 0.02)) / ((NIR + 0.1) +$	“Global Vegetation Moisture Index”

	$(SWIR2 + 0.02)$	
IRECI	$RE3 - R / (RE1 / RE2)$	"Inverted Red-Edge Index"
NBR	$(NIR - SWIR2) / (NIR + SWIR2)$	"Normalized Burn Ratio"
NDMI	$(NIR - SWIR1) / (NIR + SWIR1)$	"Normalized Difference Moisture Index"
NDVI	$(NIR - R) / (NIR + R)$	"Normalized Difference Vegetation Index"
NREDI1	$(RE2 - RE1) / (RE2 + RE1)$	"Normalized Red-Edge Index"
NREDI2	$(RE3 - RE1) / (RE3 + RE1)$	"Normalized Red-Edge Index"
NREDI3	$(RE3 - RE2) / (RE3 + RE2)$	"Normalized Red-Edge Index"
PSRI	$(R - G) / RE1$	"Plant Senescence Reflectance Index"
VARIGREEN	$(G - R) / (G + R - B)$	"Visible Atmospherically Resistant Index Green"
VARIRE	$(RE1 - R) / (RE1 + R)$	"Visible Atmospherically Resistant Indices RedEdge"
VIGREEN	$(G - RE1) / (G + RE1)$	"Vegetation Index Green"

(*) Band 2 – Blue (B); Band 3 – Green (G); Band 4 – Red (R) ; Band 5 – Vegetation Red Edge 1 (RE1); Band 6 – Vegetation Red Edge 2 (RE2); Band 7– Vegetation Red Edge 3 (RE3); Band 8 – Near Infrared (NIR); Band 8A – Near Infrared (NIR8A); Band 11 – Short Wave Infrared 1 (SWIR1)); Band 12 – Short Wave Infrared 2 (SWIR2)

3.5 Datos LiDAR

Tras seleccionar las zonas piloto objetivo se hizo un análisis de la disponibilidad de datos LiDAR del PNOA para complementar los datos satelitales con datos de estructura de vegetación. Para ello se ha trabajado utilizando la información del propio PNOA que se actualiza con una periodicidad mensual en su WEB: <https://pnoa.ign.es/estado-del-proyecto-lidar>

De esta manera se han seleccionado los archivos LiDAR disponibles más recientes para cada una de las zonas piloto, los cuales se descargaron y almacenaron para su posterior procesado.

Se generaron Modelos Digitales de Elevación (MDE) a partir de archivos ".LAZ" clasificados con una malla de 2 m. Posteriormente, se normalizaron los retornos láser clasificados como vegetación (baja, media y alta) en celdas de 20x20 m, equivalente a la resolución del satélite Sentinel-2. Se calculó una batería de estadísticos LIDAR de estructura y altura para vegetación arbustiva y matorral, con objeto de refinar los resultados de la clasificación excluyendo áreas arboladas mediante una máscara. Finalmente, se generaron capas georreferenciadas en formato ráster para el análisis espacial y la elaboración de cartografías de clasificación de la especie objetivo y disponibilidad de biomasa de jaral.

3.6 Modelización

Para la generación de las cartografías basadas en técnicas de clasificación automática se utilizó el algoritmo de aprendizaje automático Random Forests (RF) (BREIMAN, 2001). RF genera y combina un conjunto de árboles de decisión donde cada uno se genera usando un subconjunto de la muestra de entrenamiento diferente en cada iteración y los nodos se dividen utilizando la mejor de las



variables de una muestra aleatoria de estas. Combina predicciones individuales mediante un proceso de votación (para clasificación) reduciendo el sobreajuste y mejorando la precisión mediante la aleatorización en la selección de datos y variables. Es, por tanto, un método estadístico basado en árboles que consigue segmentar el espacio de los predictores en regiones simples, dentro de las cuales es más sencillo manejar las interacciones, consiguiendo mejores resultados que métodos de regresión paramétrica, aunque más difíciles de interpretar.

El algoritmo tomó como variables de entrada las bandas espectrales de las composiciones satelitales y los índices de vegetación calculados. Para el análisis estadístico se utilizó el software estadístico R (R Development Core Team, 2014), utilizando los paquetes randomForest (LIAW y WIENER, 2002) y VSURF (GENUER et al., 2016).

Se construyó un modelo diferente para cada composición mensual. En cada modelo se utilizó, el 70% de las parcelas para entrenamiento (413 parcelas) y el 30% para validación (178 parcelas), seleccionando este porcentaje en función de la categoría de la parcela. Con el conjunto de datos de validación se calculó el rendimiento del modelo de clasificación para cada mes calculándose la exactitud global, la exactitud del productor y la exactitud del usuario para la clase de jarales.

4. Resultados

Tal y como se puede apreciar en la tabla 2, la clase clasificada de jarales presentó exactitudes diferentes en función de la composición mensual utilizada. Los valores de exactitud del usuario y productor inferiores al 70% se obtuvieron para los meses de abril, junio, julio, septiembre y octubre. Los mejores resultados se obtuvieron para el mes de mayo con una exactitud del productor del 70% y del 84% para la exactitud del usuario. Esto implica errores de omisión del 30% de la clase de jarales y un error de sobreestimación del 16%. En este sentido, agosto también presentó resultados satisfactorios con errores de omisión del 21% y errores del 32% de comisión. Al combinar los datos de mayo y agosto para realizar una clasificación satelital conjunta, se logró obtener una clasificación con unos resultados más equilibrados. En esta clasificación los errores de omisión y comisión son del 23% y 26%, respectivamente.

Tabla 2. Resultados de la validación de la clasificación de jarales. Exactitudes en %

Exactitud	Abril	Mayo	Junio	Julio	Ago	Sept	Oct.	Mayo + Agosto
Productor	56	70	54	62	79	50	59	77
Usuario	53	84	52	68	68	67	53	74
Global	89	93	87	91	92	88	89	92

Nota: las exactitudes del productor y usuario se muestran únicamente para la clase de jarales, mientras que la exactitud global refleja los resultados globales de la clasificación binaria jarales no jarales.

En base a los resultados obtenidos, se decidió que el modelo final de

clasificación se entrenase con los datos del mosaico de mayo y de agosto. Las variables finales predictoras de ajuste del modelo de clasificación fueron:

- Mayo: Bandas del rojo, infrarrojo cercano e infrarrojo medio.
- Agosto: Bandas del rojo, infrarrojo cercano, borde del rojo 1 y los índices de vegetación NDVI, PSRI, NREDI1, NREDI3 y VARIGREEN.

Además, se evaluó la separabilidad espectral de las parcelas de jara y no jara analizando las firmas espectrales de las clases en los distintos meses analizados (Figura 3). Se observa que las parcelas de jara y no jara tienen mayor separabilidad en mayo, julio y agosto. Además, se observa un pico en las bandas espectrales del borde del rojo y del infrarrojo cercano dando lugar a una mayor separabilidad entre las parcelas de jarales y no jarales. Los resultados obtenidos en la validación coinciden con los perfiles fenológicos.

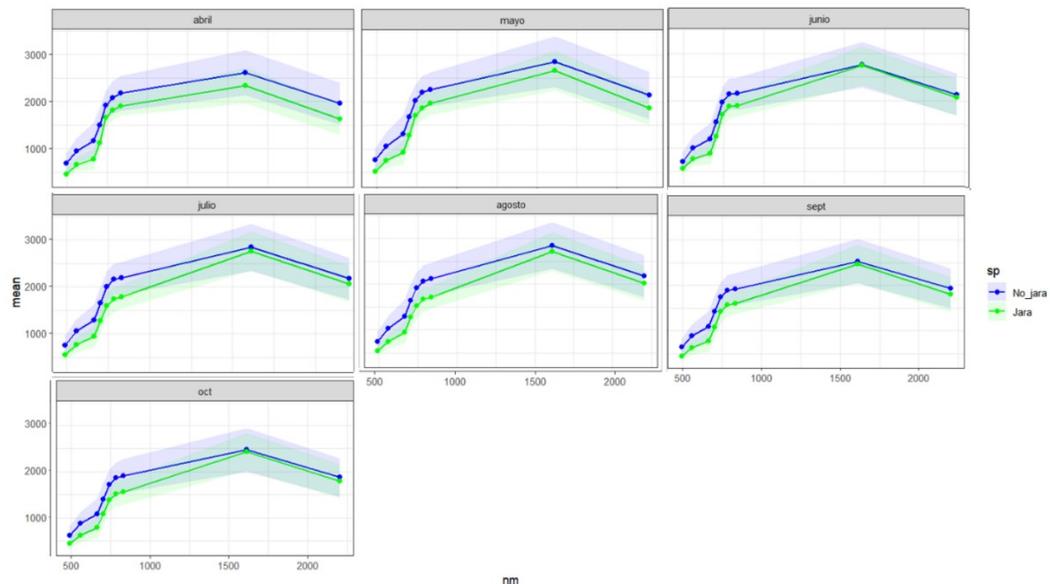


Figura 3. Firma espectral mensual del conjunto de parcelas de jarales y no jarales para las bandas espectrales analizadas

Mediante la aplicación de los modelos descritos se han obtenido cartografías continuas de la distribución de jara pringosa en las comarcas piloto del sur de España del GO ESjara: Andévalo occidental en Huelva y Jerez de los Caballeros en Badajoz. De esta manera ha sido posible concretar un poco más las cartografías base utilizadas delimitando las zonas con presencia pura de *Cistus ladanifer* en las zonas de estudio tal como se puede ver en las figuras 4 y 5.

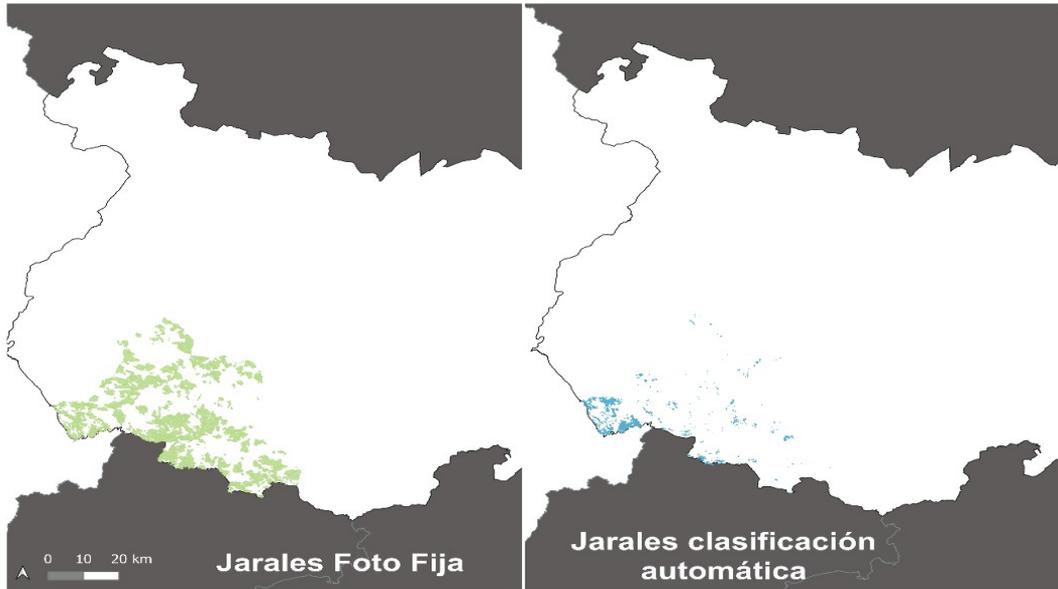


Figura 4. Distribución de la masa de jarales en la comarca de Jerez de los Caballeros de Badajoz de acuerdo a la información de la foto fija (izquierda) y a la clasificación automática de imágenes de satélite para el año 2023 (derecha).

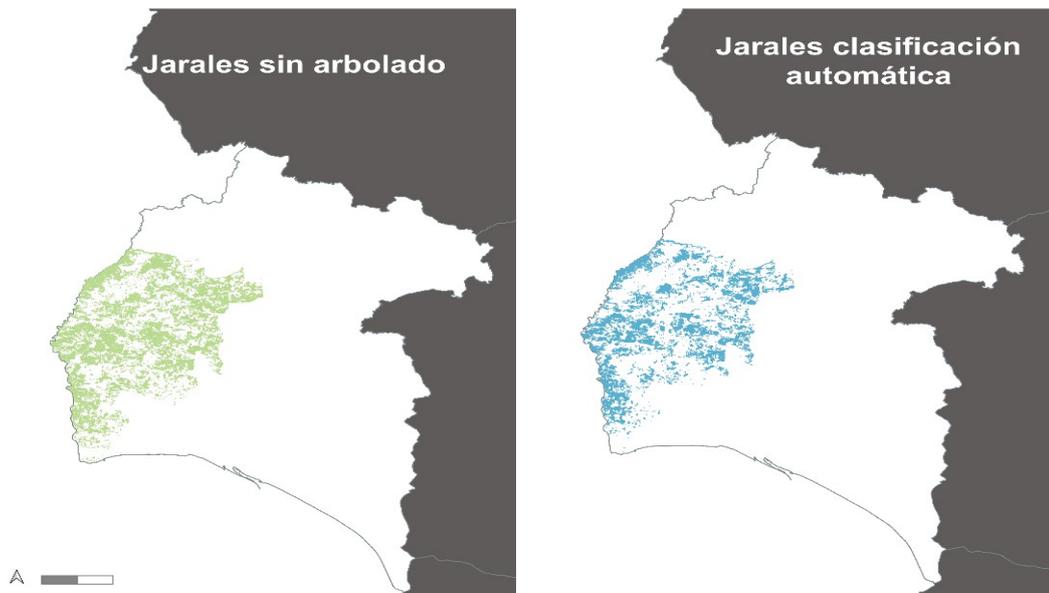


Figura 5. Distribución de la masa de jarales en la comarca de Andévalo Occidental de Huelva de acuerdo a la información del SIPNA (izquierda) sin ESTRATO ARBOLADO y a la clasificación automática de imágenes de satélite para el año 2023 (derecha).

Los resultados de la Tabla 3 reflejan que hay diferencias significativas respecto a la cantidad de superficie de jarales en cada una de las dos comarcas estudiadas.

Tabla 3. Superficie de Jaral y Comarcal

Comarca	Mejor cartografía disponible		Mejor cartografía disponible sin estrato arbóreo (*)		Cartografía por imágenes satelitales	
	Sup Jaral (ha)	% Comarcal	Sup Jaral (ha)	% Comarcal	Sup Jaral (ha)	% Comarcal
Badajoz: Jerez	63.279,58	29,5	23.573,70	10,99	1.682,82	0,78

de los Caballeros						
Huelva: Andévalo occidental	53.450,06	23,3	48.346,95	21,11	14.686,16	6,41

(*) El estrato arbóreo se ha definido a partir de los datos LiDAR considerando como arbolado el criterio de fracción de cabida cubierta superior al 30%.

En Badajoz, a priori destaca el descenso drástico de la superficie de jarales que podría ser indicativo de una fiabilidad baja de la cartografía automática. No obstante, al revisar la foto fija se observan numerosas zonas con arbolado disperso que no están siendo mapeados como jarales (Figura 6). En la imagen inferior derecha, la imagen de alta resolución muestra zonas prácticamente desnudas a excepción de una mancha en la parte superior que de ser jarales no habría sido mapeada por la clasificación automática. Por el contrario, en las primeras imágenes superior e inferior, las tonalidades azules indican coincidencia entre las dos cartografías en zonas de jarales densos.

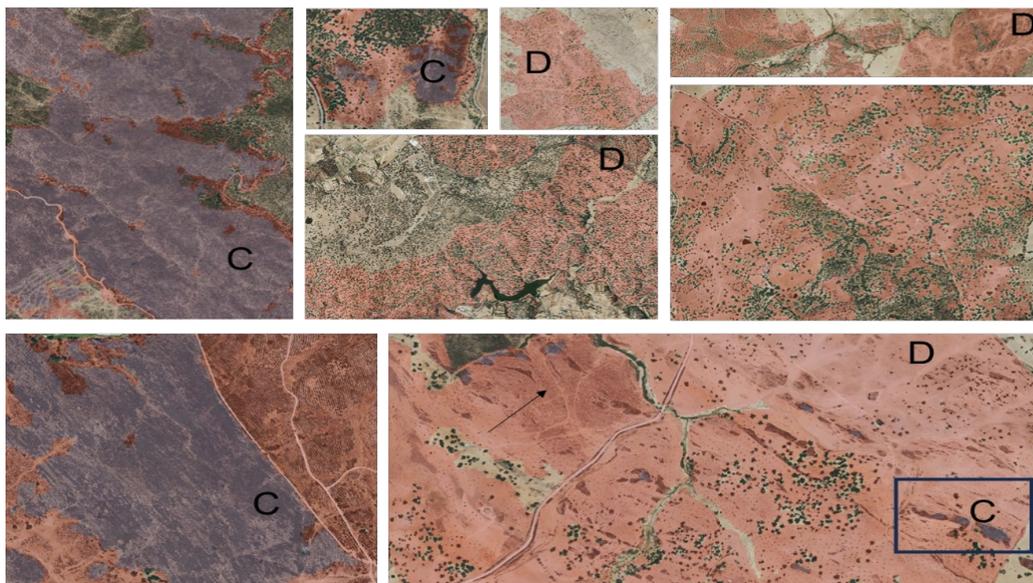


Figura 6. Ejemplos de coincidencias (C) y discrepancias (D) entre las cartografías de jarales en la comarca de Jerez de los Caballeros de Badajoz. Tonalidades azules indican coincidencias, mientras que los tonos rojos son indicativos de presencia de jarales de acuerdo con la mejor cartografía disponible.

En el caso de Huelva, el descenso de superficie respecto a la mejor cartografía disponible se debe en parte al periodo de actualización de la capa cartográfica del SIPNA. La cartografía disponible (Figura 7) identifica como jarales (tonos rojos) zonas que han sido desbrozadas. Estos desbroces pueden ser recientes, lo que explicaría por qué solo la cartografía automática refleja estas variaciones. Por otro lado, también se observa algunas zonas que podrían ser jarales de menor densidad y más dispersos que no han sido correctamente mapeados por la clasificación automática. En general, en las zonas densas se observa una gran coincidencia entre ambos recursos cartográficos.

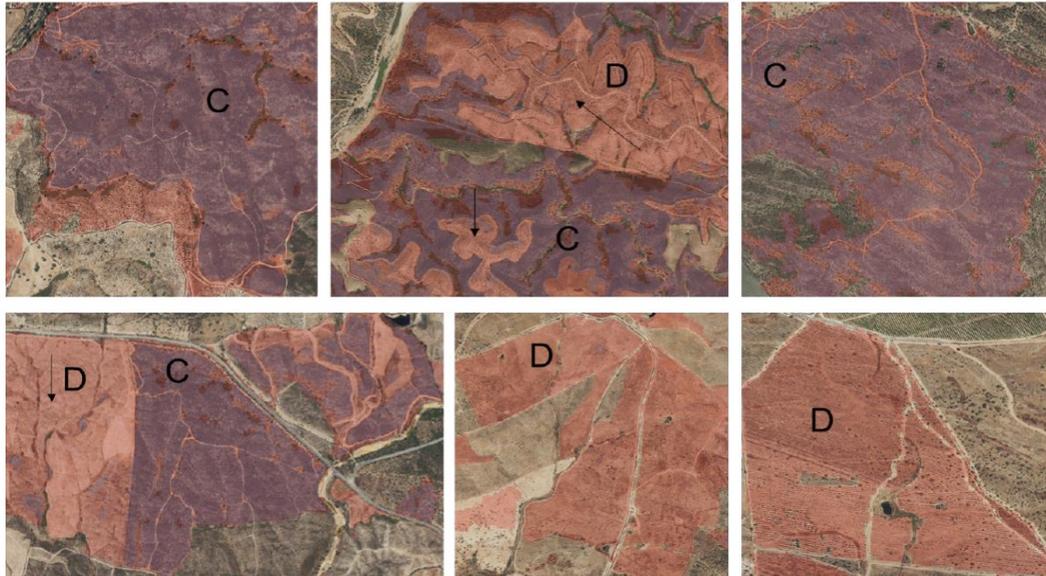


Figura 7. Ejemplos de coincidencias (C) y discrepancias (D) entre las cartografías de jarales en la comarca de Andévalo Occidental de Huelva. Tonalidades azules indican coincidencias, mientras que los tonos rojos son indicativos de presencia de jarales de acuerdo con la mejor cartografía disponible.

5. Discusión

La elaboración de la Foto Fija se realiza mediante fotointerpretación sobre ortofotos de alta resolución (ROBLA et al, 2017) y nos delimita a formaciones donde hay dominancia de especies de *Cistus*, incluyendo zonas de arbolado ralo e información detallada a nivel de tesela de la vegetación, siendo a día de hoy la cartografía de mayor calidad de la que disponemos a nivel nacional, sin embargo, no llega al nivel de detalle de identificar masas puras de jaral.

Por su parte, este sistema de clasificación automática basado en Sentinel-2 que presenta una resolución espacial media (entre 10 y 20 m según las bandas utilizadas) complementado con información estructural de la vegetación a partir de datos LiDAR PNOA, es mucho más precisa en la búsqueda de superficies puras de la especie objetivo. No obstante, esta precisión baja en las zonas de matorral disperso o abierto debido a la contaminación de la señal espectral del píxel por la presencia de suelo desnudo (KYCHO et al., 2022).

Estas diferencias de comportamiento plantean desafíos importantes a la hora de comparar los mapas. ALONSO y sus colaboradores (2023) observaron que la integración de la cartografía oficial de la foto fija y las generadas a partir de Sentinel-2 supone un reto al tener formatos tan diferentes, pudiendo incluso llevar a tomar conclusiones diferentes sobre la estimación y distribución de los recursos forestales. En este trabajo se generaron clasificaciones automáticas sobre la distribución de las masas de eucalipto, coníferas y frondosas. Los resultados revelaron diferencias significativas en la estimación de la superficie, con variaciones de hasta 90.000 hectáreas a nivel provincial.



Las precisiones globales obtenidas en el presente estudio son coherentes con las obtenidas por otros autores como ZHONG et al. (2024) que reportan una exactitud global del 90,66 % en la identificación de formaciones arbustivas en desiertos empleando datos multiespectrales de media resolución con random forest.

Combinando esta información de localización del recurso con información estructural proveniente de datos LiDAR es posible cuantificar la biomasa de recurso disponible (ARELLANO et al., 2024) lo que puede tener aplicaciones notables tanto para la prevención frente a incendios. Además algunas especies concretas como la jara pringosa pueden tener un interés económico para la obtención de productos derivados, como sus aceites esenciales y el ládano.

Tal y como establecen ZHONG et al. (2024) nuestro estudio contrasta que la combinación de sensores activos y pasivos contribuye a mejorar la precisión en la clasificación de especies gracias a la complementariedad de las características espectrales y estructurales, lo que nos permite discretizar las zonas de jaral puro de posibles confusiones con jaral bajo arbolado.

Pese a que JIMÉNEZ MICHAVILLA (2012) establece que el trabajo con datos hiperespectrales es superior al trabajo con sensores multiespectrales para clasificación de especies, especialmente en entornos especialmente heterogéneos como las que ocupa el matorral mediterráneo, conviene significar que nuestros resultados apuntan a que Sentinel 2 puede ser suficiente para discretizar especies concretas como la jara pringosa. Además, su recurrencia y gratuidad permiten trabajar con series temporales lo que redundaría en poder estudiar los cambios fenológicos de las especies a costes abordables demostrando un potencial muy interesante para este tipo de estudios de clasificación de especies.

6. Conclusiones

Los resultados obtenidos demuestran el potencial de los datos satelitales para generar clasificaciones automáticas sobre la distribución de jarales, complementando la información de las fuentes cartográficas oficiales. No obstante, la integración de ambas fuentes cartográficas ha supuesto un reto, debido a las diferencias metodológicas empleadas, lo que dificulta la comparación y evaluación de los resultados.

Los resultados han sido muy satisfactorios en zonas muy dinámicas con frecuentes cambios (como Huelva) demostrando el potencial de la teledetección para obtener cartografías con mayor periodicidad. Además, se ha observado que en general las cartografías oficiales podrían estar sobreestimando la presencia de jarales en zonas con arbolado muy disperso (Badajoz). Por el contrario, en las cartografías automáticas existe una omisión en la detección de jarales más dispersos o de menor densidad.

Los resultados obtenidos apuntan a que técnicamente se podría abordar una



mejora de las cartografías del mapa forestal a partir de datos satelitales. Para ello sería necesario abordar trabajos de recopilación de puntos de verdad terreno en zonas de matorral que puedan servir como base para entrenar y validar los modelos desarrollados. De la misma manera sería recomendable profundizar en los métodos de inteligencia artificial utilizados para las clasificaciones automáticas testando si merece el aumento del coste computacional que supone trabajar con técnicas de deep learning frente al machine learning utilizado en este caso concreto.

7. Agradecimientos

Los autores agradecen la colaboración de todas las personas que hicieron los trabajos de campo en el marco del proyecto CILIFO que han servido como base al presente estudio.

El grupo operativo GO ESjara ha recibido para su proyecto de innovación una subvención de 598.428,13 €. El importe del proyecto es financiado al 100% con fondos procedentes del Instrumento de Recuperación Europeo (EU Next Generation), tal como se establece en el Real Decreto 169/2018, de 23 de marzo.

El organismo responsable del contenido es el GO-ESjara. La Dirección General de Desarrollo Rural, Innovación y Formación Agroalimentaria (DGDRIFA) es la autoridad de gestión encargada de la aplicación de la ayuda del FEADER. «Fondo Europeo Agrícola de Desarrollo Rural: Europa invierte en las zonas rurales»



El trabajo del 1º autor: Stéfano Arellano Pérez en este artículo ha sido financiado por la ayuda PTQ2021-012150 otorgada por el MCIN/AEI / 10.13039/501100011033.

8. Bibliografía

- ALONSO, L., PORTO-RODRÍGUEZ, J. C., PICOS, J., & ARMESTO, J. 2023. Comparison of a Sentinel-2 land cover map obtained through multi-temporal analysis with the official forest cartography. the case of Galicia (Spain). *Geocarto international*, 38(1). [HTTPS://DOI.ORG/10.1080/10106049.2023.2181986](https://doi.org/10.1080/10106049.2023.2181986).
- ARELLANO-PÉREZ, S., MARINO-DEL AMO, E., TOMÉ-MORÁN, J.L., MARTÍN-ALCÓN, S. 2024. Modelización de la carga de combustible de matorrales de jara a partir de LIDAR en el sur de España. En *Teledetección y Cambio Global: Retos y Oportunidades para un Crecimiento Azul*. Actas del XX Congreso de la Asociación Española de Teledetección, pp. 311-314. 2024, Cádiz.
- BRAVO F., GUIJARRO M., CÁMARA A., DÍAZ BALTEIRO L., FERNÁNDEZ P., PAJARES J.A., PEMÁN J., RUIZPEINADO R. 2017. *La situación de los bosques y el sector forestal en España – ISFE 2017*.
- BREIMAN, L.; 2001. *Random Forests*. *Machine Learning*,



DOI-10.1023/A:1010933404324, 45(1): 5-32. Disponible en:

<http://dx.doi.org/10.1023/A%3A1010933404324>.

GAN, L., CAO, X., CHEN, X., HE, Q.; CUI, X., ZHAO, C. 2022. Mapping Shrub Coverage in Xilin Gol Grassland with Multi-Temporal Sentinel-2 Imagery. *Remote Sens.* 14. 3266.

GENUER, R., POGGI, J.-M., TULEAU-MALOT, C. ; 2016. Variable selection using Random Forests. *Pattern Recognition Letters*, 31(14): 2225-2236.

GOMEZ, C., ALEJANDRO, P., HERMOSILLA, T., MONTES, F., PASCUAL, C., RUIZ, L.Á., ALVAREZ-TABOADA, F., TANASE, M.A., VALBUENA, R. 2019. Remote sensing for the Spanish forests in the 21 st century: a review of advances , needs , and opportunities. *For. Syst.* 28. (1). 33.

JIMÉNEZ MICHAVILA, M.; 2012. Cartografía de especies de matorral de la Reserva Biológica de Doñana mediante el sistema hiperespectral aeroportado INTA-AHS. *Ecosistemas*, 21(1-2), 211-217.

KYCKO, M., ZAGAJEWSKI, B., KLUCZEK, M., TARDÀ, A., PINEDA, L., PALÀ, V.; CORBERA, J. 2022. Sentinel-2 and AISA Airborne Hyperspectral Images for Mediterranean Shrubland Mapping in Catalonia. *Remote Sens.* 14, 5531.

LIAW, A.; WIENER, M. 2002. Classification and Regression by randomForest. *R News*, 2(3): 18–22.

MONTERO, G., ONRUBIA, R., LÓPEZ-LEIVA, C., RUIZ-PEINADO, R., LOPEZ-SENEPLEDA, E., PASALODOS, M. 2017. Producción de biomasa aérea por los matorrales españoles. *Revista Montes*, 129, 54-56.

MONTERO, G., LÓPEZ-LEIVA, C., RUIZ-PEINADO, R., LÓPEZ-SENEPLEDA, E., ONRUBIA, R., PASALODOS, M. 2020. Producción de biomasa y fijación de carbono por los matorrales españoles y por el horizonte orgánico superficial de los suelos forestales. 447.

PÉREZ P., ESTEBAN L.S. 2008. Evaluación de diferentes alternativas de recolección del matorral de *Cistus laurifolius* para la producción de biomasa con fines energéticos. CIEMAT (ed), Madrid (Spain).

R DEVELOPMENT CORE TEAM; 2014. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria.

ROBLA GONZÁLEZ, E., VALLEJO BOMBÍN, R., LERNER CUZZI, M. 2017. La Foto Fija del Mapa Forestal de España, fuente de información para el cálculo de tendencias e indicadores de los ecosistemas forestales españoles. Principales resultados. 7º Congreso Nacional Forestal. Plasencia.

ROUSSEL, J.-R., AUTY, D., COOPS, N., TOMPALSKI, P., GOODBODY, T.R.H., MEADOR A.S., BOURDON J-F., BOISSIEU, F., ACHIM, A. 2020. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sens. of Environ.*, Volume 251, 112061, ISSN 0034-4257.

ZHONG, L., DAI, Z., FANG, P., CAO, Y., & WANG, L. 2024. A Review: Tree Species Classification Based on Remote Sensing Data and Classic Deep Learning-Based Methods. *Forests*, 15(852). <https://doi.org/10.3390/f15050852​>.