



**2025** | **16-20**  
**GIJÓN** | **JUNIO**

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1359**

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

Organiza





## Discriminación de especies de pino mediante imágenes satelitales de Sentinel-2 y PRISMA en el distrito forestal Terra de Lemos

ESTEBAN CAVA, J. (1), GONZÁLEZ, I. (1) y TOMÉ, J.L. (1).

(1) Agresta Sociedad Cooperativa.

### Resumen

Los mapas de distribución de especies mejoran la precisión de las estimaciones forestales basadas en métodos de masa. En estos métodos, se crea un modelo que vincula las variables medidas en parcelas de campo con las métricas de la estructura de la vegetación derivadas de datos LiDAR a nivel de celda. En España, existe un mapa forestal nacional de gran calidad en continua mejora. Sin embargo, su escala de trabajo puede no ajustarse a la resolución con la que podemos llegar a trabajar en los inventarios LiDAR. En las teselas mixtas el mapa forestal indica las especies presentes y sus ocupaciones a nivel de tesela, pero no de celda.

Los sensores multiespectrales son herramientas valiosas para crear mapas de distribución de especies forestales. Además, las misiones hiperespectrales, como PRISMA de la Agencia Espacial Italiana (ASI), han abierto nuevas oportunidades de investigación. El presente trabajo compara las capacidades del nuevo sensor PRISMA, con las del conocido satélite Sentinel-2, para discriminar las principales especies de pinos presentes en el distrito forestal VIII: Terra de Lemos. Se aplican técnicas de clasificación supervisada y aprendizaje automático para distinguir las especies, así como análisis de firmas espectrales.

### Palabras clave

Clasificación de especies, Teledetección, LiDAR, inventario, hiperespectral.

### 1. Introducción

El uso de datos de sensores remotos se ha consagrado como una tecnología de gran utilidad en la generación de mapas temáticos de coberturas de uso del suelo (GÓMEZ et al., 2019). Sin embargo, cuando estas clasificaciones se ejecutan a nivel de especie forestal se incrementa la dificultad por su similitud en la respuesta espectral (ALONSO et al., 2022). Esta problemática hace necesario recurrir a metodologías más complejas o al uso de imágenes con resoluciones espaciales y espectrales diferentes (ALONSO et al., 2023; VANGI et al., 2021).

La adquisición de imágenes hiperespectrales proporciona datos de forma continuada en todo el espectro electromagnético, proporcionando una información más detallada que los sensores multiespectrales. Sin embargo, se trata de una tecnología con menor madurez dado los costes asociados con su adquisición y procesamiento. En 2019 se puso en órbita el satélite italiano hiperespectral PRISMA para el monitoreo de los recursos naturales. Como novedad sus imágenes pueden ser adquiridas gratuitamente en <http://prisma-i.it/index.php/en>. Su política gratuita



ha contribuido a que aparezcan estudios que empleen este tipo de imágenes en distintas aplicaciones: geología, diferenciación de especies forestales, modelos de combustibles, episodios de decaimiento (ALICANDRO et al., 2022; GUILLEN-CLIMENT et al., 2020; SHAIK et al.; 2022; VANGI et al., 2021). Sin embargo, hasta donde los autores son conscientes, apenas existen estudios de PRISMA centrados en los ecosistemas forestales españoles.

Galicia es una región con una industria forestal muy activa y un territorio altamente fragmentado. Estas características hacen imprescindible disponer de mapas detallados y actualizados de manera periódica, que permitan identificar las principales especies forestales (ALONSO et al., 2021, 2023). Conocer la distribución de las especies no solo es crucial para la gestión y conservación de recursos naturales, sino que también proporciona una base sólida para el desarrollo y la aplicación de modelos predictivos, como los métodos de masa (WHITE et al., 2016). En estos métodos, se establece un modelo que conecta las variables obtenidas en parcelas de campo con las métricas de la estructura de la vegetación derivadas de datos LiDAR a nivel de celda, lo que permite una estimación más detallada y precisa de las características forestales (WHITE et al., 2016). En este marco, Agresta desarrolló ForestMap como una herramienta esencial para la generación de inventarios continuos. Esta herramienta emplea fuentes cartográficas existentes para la selección de las especies forestales presentes (TOMÉ et al., 2022). Sin embargo, en ocasiones estas bases cartográficas no ofrecen el resultado esperado, debido a varias limitaciones. En primer lugar, su resolución espacial puede ser insuficiente para representar con precisión la alta heterogeneidad del territorio, especialmente en zonas de mosaico o teselas mixtas, donde conviven distintas especies en superficies reducidas. Además, la baja frecuencia de actualización puede impedir que se recojan cambios recientes en la cobertura forestal, afectando la actualidad y relevancia de la información. Por último, al tratarse frecuentemente de cartografías generadas a escalas nacionales o regionales, su aplicación a áreas de estudio específicas o a nivel local puede conllevar una pérdida de detalle y precisión que limita su utilidad para la caracterización fina del territorio. Con el objetivo de dar un salto cualitativo en el monitoreo y gestión de las masas, FORESTMAT-IA ha surgido como una nueva iniciativa y aspira a desarrollar cartografías temáticas de localización de especies forestales a partir de sensores remotos.

## 2. Objetivos

El objetivo de este estudio es desarrollar una metodología para la cartografía detallada de las principales especies de pinos del distrito forestal VIII. Terra de Lemos: *Pinus sylvestris*, *Pinus radiata* y *Pinus Pinaster*. Para ello se comparará las capacidades del sensor PRISMA, con las del conocido satélite Sentinel-2.

## 3. Metodología

La zona de estudio se encuentra en el distrito forestal VIII, Terra de Lemos, una división administrativa de la Xunta de Galicia en la región sur de la provincia de Lugo, abarca una superficie forestal arbolada superior a 50.000 hectáreas. Este

distrito abarca un total de cuatro demarcaciones, cada una compuesta por distintos municipios, que son: demarcación de Chantada, de Quiroga, de Monforte 1 y de Monforte 2 (Figura 1).

Dentro de este distrito se delimitó una zona piloto (Figura 1) basada en la disponibilidad de la mejor imagen del satélite PRISMA adquirida en los meses de verano. Tras una búsqueda de estos criterios el área piloto seleccionada abarca parcialmente las demarcaciones de Chantada y la de Monforte 1. Estas áreas forman parte de la región vitivinícola de la Ribeira Sacra, conocida por su paisaje escarpado y terrazas vitícolas. Ambas demarcaciones comparten un clima de transición entre el atlántico y el mediterráneo, con inviernos moderadamente fríos y veranos cálidos. De acuerdo con el Mapa Forestal Español, la zona piloto cuenta con una superficie arbolada que representa el 40% de su extensión. En la superficie arbolada predominan las masas de *Quercus robur*, *Pinus pinaster*, *Pinus radiata*, *Quercus pirenaica* y *Pinus sylvestris*, de más a menor importancia.

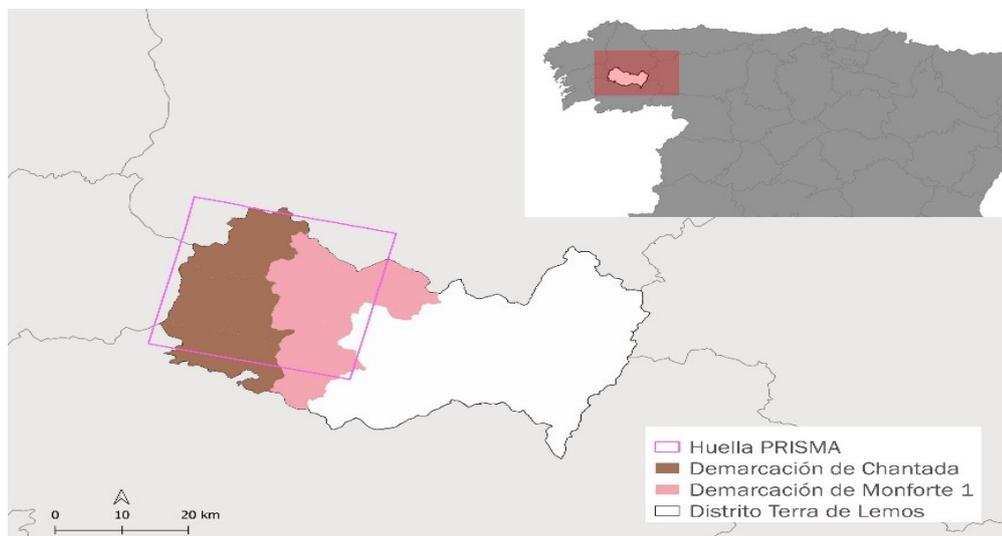


Figura 1. Zona piloto seleccionada dentro del distrito forestal VIII. Terra de Lemos

### 3.1 Imágenes satelitales

Inicialmente se realizó una búsqueda de las escenas PRISMA disponibles en la zona de estudio junto con sus metadatos. Tras el análisis se descargó una imagen PRISMA L2D (corregida atmosféricamente y ortorectificada), libre de nubes, adquirida el 31 de julio de 2021. Esta imagen tiene una resolución espacial de 30 metros y un total de 239 bandas espectrales que varían entre 402 y 2497 nm. 66 bandas están en la región del visible e infrarrojo cercano y 173 en la región del infrarrojo cercano medio. El procesado de la imagen PRISMA se realizó utilizando el paquete de R *prismaread* (BUSETTO & RANGHETTI, 2020), que facilita la conversión del formato original de las imágenes a formato ráster GeoTiff. A la hora de trabajar con imágenes hiperespectrales es fundamental eliminar las bandas susceptibles de ser ruidosas (SHAIK et al., 2022). Para la determinación de las

bandas a eliminar se siguió la metodología descrita en (ALICANDRO et al., 2022). Los autores determinan si una banda es mala o buena en función de la distribución del histograma de los valores espectrales (Figura 2). Si existe un número elevado de píxeles cercanos a cero o anomalías en la distribución de los valores, la banda es eliminada del análisis. En este caso se prescindió de las bandas: 99-105, 143-146, 147-160, 223-230.

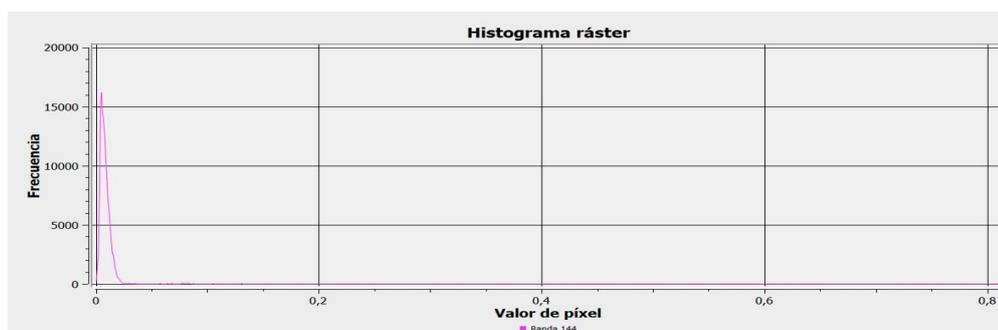


Figura 2. Distribución de la frecuencia de los valores de la banda 144 de PRISMA eliminada del análisis por ser candidata como banda con ruido.

Para el análisis comparativo se descargaron las imágenes Sentinel-2 que solapaban con la zona piloto y que también fueron adquiridas el 31 de julio de 2022. Se descargaron dos escenas con identificador 29TNH y 29TPH y nivel de procesamiento 2A. Las nubes y sombras se enmascararon mediante el uso de la banda SCL (Scene Classification Layer) y el conjunto de datos de probabilidad de nubes. Para el análisis se utilizaron las bandas del espectro visible, borde del rojo e infrarrojo medio.

Además, con el objetivo de explorar si existen diferencias fenológicas que puedan mejorar la clasificación de los pinos, se utilizaron compuestos mensuales de Sentinel-2 a lo largo de tres años: 2020, 2021 y 2022. Estas composiciones se crearon con las imágenes disponibles de cada mes, con una cobertura nubosa inferior al 10%, en función del valor de la mediana de sus píxeles. Esta evaluación fenológica permitiría determinar si un enfoque multitemporal contribuye a una clasificación más precisa.

### 3.2 Datos de referencia

La base de datos utilizada para el desarrollo de los modelos de clasificación consistió en 127 polígonos de distintas fuentes: i) una serie de puntos tomados en campo en los que se comprobó la especie principal (42 en total) y ii) puntos digitalizados manualmente utilizando imágenes de alta resolución y el mapa forestal español (Tabla 1).

Las clases objetivo a clasificar fueron cinco: i) áreas cubiertas por *Pinus sylvestris* (PS, en adelante), ii) áreas cubiertas por *Pinus radiata* (PR, en adelante), iii) áreas

cubiertas por *Pinus pinaster* (PP, en adelante), iv) otras formaciones forestales y v) zonas de no arbolado (como cultivos, tejido urbano, suelo desnudo, matorral, pastizal).

Tabla 1. Distribución de los polígonos de referencia utilizados en el modelo de clasificación

Clase	Fuente	Número de polígonos
<i>Pinus sylvestris</i> (33 puntos)	Campo	28
Manual		5
<i>Pinus radiata</i> (21 puntos)	Campo	8
Manual		13
<i>Pinus pinaster</i> (18 puntos)	Campo	6
Manual		12
Otras formaciones (14 puntos)	Campo	
Manual		14
No arbolado (41 puntos)	Campo	
Manual		41

### 3. 3 Análisis espectral

A la hora de discriminar las diferentes especies de pinos se realizó un análisis de la firma espectral de los valores de reflectancia. Estas firmas se calcularon como la mediana de los valores de reflectividad de aquellos píxeles que coincidían espacialmente con los puntos tomados en campo. Además, la base de datos de campo se enriqueció con las parcelas del Inventario Forestal Nacional (IFN4). Las parcelas del IFN4 se filtraron seleccionando aquellas en las que las clases forestales analizadas fuesen la especie dominante, representen más del 80% del volumen total. Como resultado de este filtrado, se incluyó una parcela de *PS*, 2 para *PR* y 8 para *PP*. Estas parcelas fueron previamente fotointerpretadas para asegurar la ausencia de cambios desde la fecha de medición de las parcelas a la actualidad.

Los valores espectrales se extrajeron de todas las bandas de PRISMA y de las seleccionadas para Sentinel-2.

### 3.4 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). Para el análisis estadístico se utilizó el software estadístico R (R



Development Core Team, 2014), utilizando los paquetes randomForest (LIAW & WIENER, 2002).

El ajuste del modelo de clasificación se planteó en función de los resultados observados en el análisis espectral. En caso de encontrar diferencias significativas entre las especies de pino, se prioriza el uso de PRISMA aprovechando su mayor resolución espectral. Sin embargo, si no se observan conclusiones concluyentes, se optará por Sentinel-2, dado que es un satélite con un procesamiento más consolidado; facilitando el manejo de los datos.

Dado que no contamos con datos de campo adicionales para realizar una validación independiente de los modelos de clasificación, se adaptó un enfoque basado en la construcción y evaluación de múltiples modelos de clasificación. Se ajustaron 1000 modelos diferentes empleando en cada iteración un 70% de la base de datos de referencia para entrenamiento y un 30% para validación. Esta selección se realizó de manera aleatoria en cada iteración para garantizar que cada modelo se entrenaba y validaba con conjuntos diferentes. En cada iteración se generó una matriz de confusión comparando los datos de validación y la clase asignada en las dos clasificaciones. Esta comparación sirvió de base para calcular la exactitud global de la clasificación y la exactitud del usuario y del productor.

#### 4. Resultados 4.1 Análisis espectral

En general el análisis espectral obtenido con la imagen del 31 de julio de PRISMA revela una firma espectral más definida para la especie PP, destaca una menor reflectividad en el infrarrojo cercano que le permite ser distinguida de las otras dos especies. La reflectividad en el infrarrojo medio es mayor en comparación con las otras dos especies, lo que a priori denotaría un mayor contenido en agua en la fecha de captura de la imagen. Esta firma espectral diferenciada es resultado de diversos factores que pueden afectar a la radiación como: la absorción por los cloroplastos, el contenido de agua y la estructura celular de las especies.

PS y PR muestran firmas espectrales muy similares, a excepción del rango del visible donde se observa una mayor diferenciación. Sin embargo, es en esta zona en la que PS y PP tienen mayor confusión (Figura 3). La similitud de las especies de PS y PR subraya la necesidad de utilizar información espectral de diferentes fechas que pueda ayudar a una discriminación mayor.

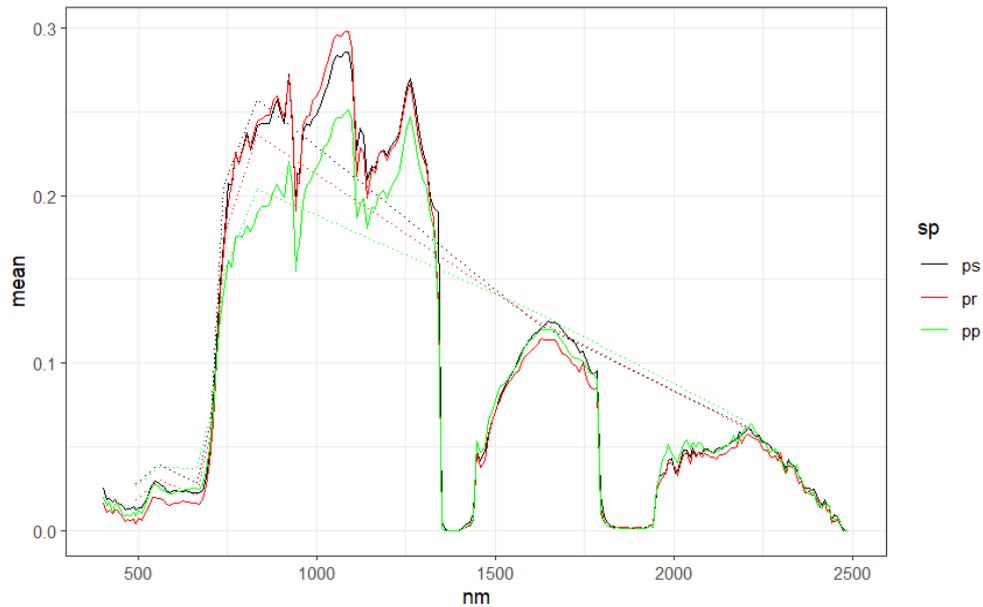


Figura 3. Firmas espectrales de las especies de pinos analizadas en base a los valores espectrales de la imagen PRISMA (línea continua) y Sentinel-2 (línea discontinua).  
Nota: ps: *Pinus sylvestris*, pr: *Pinus Radiata* y pp: *Pinus pinaster*.

Al analizar las firmas espectrales de Sentinel-2 a lo largo de diferentes meses y años (Figura 4), se observan algunos patrones significativos. Los resultados de julio muestran una mayor similitud entre PS y PR, en concordancia con lo observado con los datos de PRISMA. PR muestra una diferenciación más clara en mayo y octubre, época del año en el que se observa un pico mayor en la reflectividad del infrarrojo cercano. Por otro lado, PS no presenta una firma espectral diferenciada en ninguna época del año. En general, la reflectividad en el infrarrojo cercano de PP es consistentemente más baja. Es importante destacar que en junio y agosto los resultados son más variables; mientras que en estos meses de 2021 PR se distingue con mayor claridad, este patrón no se observa en los meses de los otros dos años.

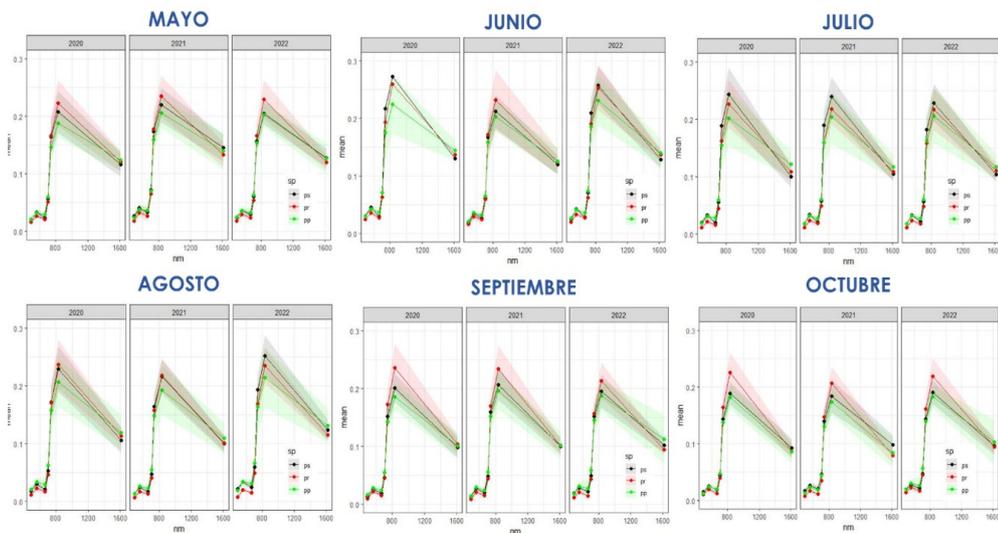


Figura 4. Firmas espectrales de las especies de pinos analizadas en base a los valores espectrales de la imagen Sentinel-2 en tres años diferentes: 2020, 2021 y 2022. Nota:

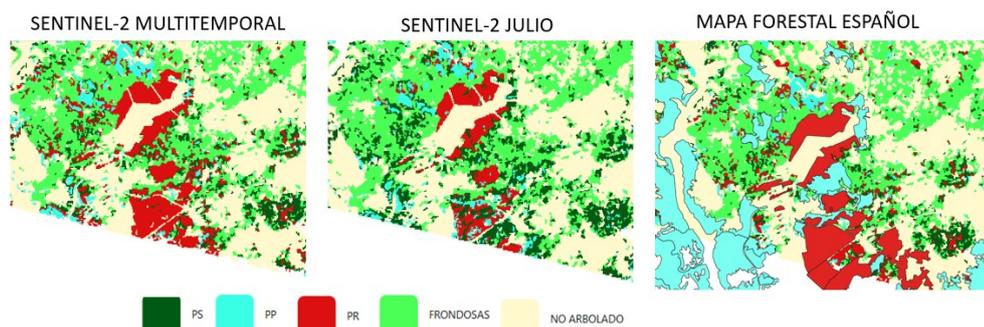
*ps: Pinus sylvestris, pr: Pinus Radiata y pp: Pinus pinaster.*

## 4.2 Clasificaciones

Los resultados del análisis espectral han dado lugar a seleccionar un enfoque multi temporal en el que se han ido generando clasificaciones individuales utilizando distintas composiciones mensuales de 2022 de Sentinel-2. Por otra parte, se ha generado una clasificación individual con la imagen de julio de 2022.

La clasificación multi temporal siguió un enfoque secuencial comenzando con una clasificación binaria arbolado no arbolado utilizando la imagen de julio de 2022. Para esta primera etapa la base de datos de referencia se agrupó en estas dos clases principales. Después, se procedió a una segunda clasificación, en la que las zonas arboladas se clasificaron en zonas de coníferas y frondosas. En la última etapa, la diferenciación de *PS* se realizó utilizando las composiciones de julio y agosto; puesto que fueron los meses donde había una mayor diferenciación. Por otra parte, y en base a este mismo criterio, las otras dos especies de pino se llevó a cabo combinando las bandas de las composiciones de mayo y octubre.

Los resultados de las clasificaciones muestran una distribución general similar, sin embargo, un análisis más detallado revela diferencias notables en algunos polígonos (Figura 5). La clasificación de julio tiende a clasificar más zonas como *PS*, mientras que en la multitemporal se observa una mayor superficie clasificada como *PP*. Además, en la clasificación multitemporal se observan rodales más homogéneos, lo que genera un efecto visual de menor ruido. Ante la ausencia de datos de referencia, se ha contrastado los resultados obtenidos con los del Mapa Forestal Español.



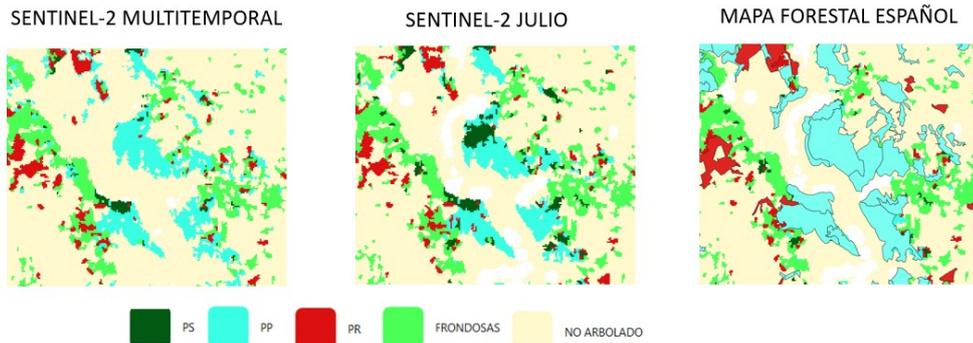


Figura 5. Ejemplos seleccionados de dos áreas para ejemplificar las discrepancias entre las diferentes clasificaciones y el Mapa Forestal Español. Nota: PS: *Pinus sylvestris*, PR: *Pinus Radiata* y PP: *Pinus pinaster*.

En general, la clasificación multi temporal alcanzó resultados más satisfactorios que refuerzan la bondad del enfoque secuencial elegido (Tabla 2). En particular, la clasificación multi temporal mejoró significativamente en el caso de PR y PP. Para PR, la exactitud del usuario y productor fue del 94,7% y del 93,9%, frente a los valores inferiores obtenidos en julio de 86,5 y 80,5% en julio. Para PP, el uso de las composiciones de mayo y octubre contribuye a incrementar las exactitudes; pasando del 69 al 75% para la exactitud del usuario y del 66,9 al 76,5% para del productor. En el caso de PS, es la única excepción en la que las exactitudes de la clasificación de julio son ligeramente superiores (88,9% de exactitud del usuario y 96,4% del productor).

Tabla 2. Resultados de las validaciones de los mapas

Pinus sylvestris	88,9	96,4	87,0	87,3
Pinus radiata	86,5	80,5	94,7	93,9
Pinus pinaster	69,0	66,9	75,0	76,5
91,8	98,7	97,1	92,3	
97,7	87,9	95,6	92,5	
87,04		89,01		

## 5. Discusión

De acuerdo con los resultados obtenidos el satélite Sentinel-2 ha permitido la distinción de las principales especies de pinos del distrito forestal Terra de Lemos, con resultados satisfactorios. El enfoque secuencial de creación de clasificaciones desde una más generalista a nivel de especie ha resultado apropiado, lo que coincide con lo observado en otros estudios (ALONSO et al., 2021). En este estudio los autores realizaron una clasificación de las principales especies forestales de una región de Galicia utilizando una imagen de alta resolución de Worldview-3 de julio de 2019. Los resultados de exactitud del productor, obtenidos por los autores,



fueron superiores a los nuestros, alcanzando un 94% para PS, 92% para PR y 71% para PP. No obstante, la resolución más grosera de Sentinel-2 explicaría nuestros resultados, especialmente en un territorio tan fragmentado como el de Galicia.

Es importante señalar que ALONSO y colaboradores en 2021 obtuvieron las exactitudes más bajas para PP. Dado que se trata de la especie de coníferas mayoritaria de Galicia, sería recomendable dedicar más esfuerzos a su clasificación. En este contexto, destacan los resultados del análisis espectral observados con las imágenes PRISMA para PP, con una firma más diferenciada y definida. No obstante, se requiere de investigaciones adicionales que permitan comprender a fondo la capacidad discriminadora de estas imágenes para diferenciar especies con alta precisión. Metodologías más robustas y maduras facilitarían el procesamiento de este tipo de datos y la extracción de información (VANGI et al., 2021). El uso de técnicas robustas que reduzcan la dimensión de estas imágenes y, por tanto, la presencia de bandas espectrales altamente correlacionadas es necesario (ALICANDRO et al., 2022). Además, sería conveniente realizar un análisis más exhaustivo sobre las características de las masas de PP que se han usado para determinar la firma espectral. Factores como la orientación, topografía y características forestales condicionan las firmas espectrales (VANGI et al., 2021).

Sería conveniente contar con una base de datos de referencia que permitiese corroborar la veracidad de las dos clasificaciones, especialmente en zonas de desacuerdo en la especie clasificada. La fotointerpretación para distinguir entre coníferas y frondosas es relativamente fácil por la caída de las hojas en otoño de estas últimas. Sin embargo, la discriminación de especies de pinos con el mero apoyo de imágenes de alta resolución es una tarea más compleja.

El análisis de firmas espectrales ha sido fundamental para identificar los momentos del año en los que hay una mayor diferenciación entre las especies. La inclusión de imágenes multi temporales ha permitido alcanzar exactitudes mayores al igual que en un estudio de clasificación de especies forestales en Noruega (PERSSON et al., 2018). En nuestro caso mayo y octubre han demostrado ser los meses en los que PR exhibe una mayor reflectividad en el infrarrojo cercano, dando lugar a una firma espectral más diferenciada. Hay pocos estudios que hayan realizado un análisis multi temporal de estas especies en España. En el estudio de PERSSON y colaboradores de 2018, también señalan mayo como el mejor mes para discriminar distintas especies forestales. No obstante, es importante señalar que su estudio se desarrolla en Noruega y que discriminan especies de frondosas. Por tanto, no podemos determinar de forma general que mayo sea el mejor mes para discriminar PR. Cada zona de estudio tendrá características inherentes que determinarán diferentes momentos de respuesta espectral diferenciada. En este sentido, se recomienda realizar futuras investigaciones que analicen imágenes individuales para identificar momentos específicos en los que la actividad vegetativa, brotación o decaimiento presenten patrones diferentes, especialmente interesante si el objetivo son especies caducifolias (HILL et al., 2010).



Considerando la importancia de los datos LiDAR en la estimación de variables estructurales (WHITE et al., 2016), resulta relevante explorar su integración con imágenes multiespectrales e hiperespectrales. Esta combinación podría aportar una visión más completa al aprovechar la complementariedad entre estructura y composición. Mientras los datos LiDAR proporcionan información detallada sobre la altura, densidad y estratificación del dosel, las imágenes espectrales permiten identificar la composición específica de especies (Esteban, 2020). En escenarios de teselas mixtas, donde la heterogeneidad espacial es alta, la fusión de estas fuentes de datos puede mejorar la precisión en la asignación de especies a nivel de celda y contribuir significativamente a una cartografía forestal más detallada.

## 6. Conclusiones

El presente estudio ha demostrado el potencial de Sentinel-2 para la clasificación de especies de pinos en el distrito forestal Terra de Lemos. El análisis de firmas espectrales y el enfoque multi espectral adaptado ha sido fundamental para mejorar las exactitudes en la clasificación. Se requiere de investigaciones futuras para seguir profundizando en el uso de imágenes hiperespectrales como PRISMA.

## 7. Agradecimientos

La redacción de este artículo ha sido financiada por el proyecto FORESTMAP-IA en el marco del Plan Integral de Impulso a la Economía Social para la Generación de un Tejido Económico, Inclusivo y Sostenible, en el marco del Plan de Recuperación, Transformación y Resiliencia del Ministerio de Trabajo y Economía Social.



Sus resultados están siendo determinantes para alcanzar los objetivos propuestos en el citado proyecto que ambiciona alcanzar una cobertura LiDAR de inventario forestal en tiempo real a nivel nacional.

## 8. Bibliografía

ALICANDRO, M.; CANDIGLIOTA, E.; DOMINICI, D.; IMMORDINO, F.; MASIN, F.; PASCUCI, N.; QUARESIMA, R.; ZOLLINI, S. 2022. Hyperspectral PRISMA and Sentinel-2 preliminary assessment comparison in Alba Fucens and Sinuessa archaeological sites (Italy). *Land*, 11, 2070.

ALONSO, L.; PICOS, J.; ARMESTO, J. 2021. Forest cover mapping and *Pinus* species classification using very high- resolution satellite images and random forest. the international archives of photogrammetry, remote sensing and spatial information science. XXIV ISPRS CONGRESSES, 6-11 JUNE, Nice, France.



ALONSO, L.; PICOS, J.; ARMESTO, J. 2022. Mapping eucalyptus species using worldview 3 and random forest. the international archives of photogrammetry, remote sensing and spatial informacion science. XXIV ISPRS CONGREES, 6-11 JUNE, Nice, France.

ALONSO, L.; 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):1-35.

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>.

BUSETTO, L.; RANGHETTI, L. 2020 PRISMAREAD: A TOOL FOR FACILITATING ACCESS AND ANALYSIS OF PRISMA L1/L2 HYPERSPECTRAL IMAGERY V1.0.0, URL: <HTTPS://IREA-CNR-MI.GITHUB.IO/PRISMAREAD/>.

ESTEBAN, 2020. MULTI-SENSOR APPROACH FOR EVALUATING FOREST RESOURCES IN LARGE AREAS. Tesis Doctoral. Universidad Politécnica de Madrid.

GUILLEN-CLIMENT, M.L.; MAS, H.; FERNÁNDEZ-LANDA, A.; ALGEET-ABARQUERO, N.; TOMÉ J.L. 2020. Uso de imágenes hiperespectrales para la predicción del marchitamiento de *Pinus Halepensis* (mill.) en el bosque mediterráneo. *Revista de Teledetección*, 55, 59-69.

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.

HILL., R.A.; WILSON, A.K.; GEORGE, M.; HINSLEY, S.A. 2010. Mapping tree species in temperate deciduous woodland using time-series multi-spectral data. *Applied Vegetation Science*, 13, 86-99.

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

NÆSSET, E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sens. Environ.* 80, 88–99. [https://doi.org/10.1016/S0034-4257\(01\)00290-5](https://doi.org/10.1016/S0034-4257(01)00290-5)

PERSSON, M.; LINDBERG, E.; REESE, HEATHER. 2018. Tree Species Classification with Multi-Temporal Sentinel-2 Data. *Remote Sens.*, 10(11), 1794.



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

SHAIK, R. U.; LANEVE, G.; FUSILLI, L. 2022. An automatic procedure for forest fire fuel mapping using hyperspectral (PRISMA) imagery: a semi-supervised classification approach. *Remote Sens.*, 14(5), 1264.

TOMÉ MORÁN, J.L.; GARCÍA CASTILLO, D.; OLIVAR RUÍZ, J.; RANZ VEGA, P.; MARTÍN ALCON, S. 2022. FMAP tecnología española monitorizando los bosques europeos. 8CFE-1057. Lleida.

VANGI, E.; D'AMICO, G.; FRANCINI, S.; GIANNETTI, F.; LASSERRE, B.; MARCHETTI, M.; CHIRICI, G. 2021. The new hyperspectral satellite PRISMA: imagery for forest types discrimination. *Sensors*, 21, 1182.

WHITE, J.C.; COOPS, N.C.; WULDER, M.A.; VASTARANTA, M.; HILKER, T.; TOMPALSKI, P. 2016. Remote sensing technologies for enhancing forest inventories: a review. *Can. J. Remote Sens.* 42, 619–641.