



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

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1629**

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

Organiza





## Evaluación de *endmembers* en las regiones de procedencia del *Pinus sylvestris* en España

MUNUERA, S (1), RODRÍGUEZ-PUERTA, F. (1), ÁGUEDA, B. (1) y GÓMEZ, C. (1)

(1) iuFOR-EiFAB, Universidad de Valladolid, Campus de Soria, España.

### Resumen

Este estudio explora la aplicación de técnicas de mezcla espectral para la detección de cambios en series de datos espectrales, poniendo un énfasis particular en la definición de los componentes espectrales, conocidos como *endmembers*. En particular, se analiza la definición de *endmembers* específicos de *Pinus sylvestris*, calculados en 18 regiones de procedencia en España durante el año 2019. Para ello, se utilizan imágenes Sentinel-2 procesadas a través de la plataforma *Google Earth Engine*, usando la colección *Harmonized Sentinel-2 MSI: MultiSpectral Instrument (Nivel-2A)*. El objetivo es evaluar la especificidad de estos componentes mediante la selección de 45 *endmembers* por región, distribuidos en 15 muestras representativas de cada etapa de desarrollo: monte bravo, latizal y fustal. Se emplea un muestreo aleatorio estratificado, realizado en R, para asegurar la representatividad de las muestras. El estudio busca determinar si la ubicación geográfica de la especie influye en la representatividad de los *endmembers*. Los *endmembers* obtenidos se utilizarán en algoritmos de detección de perturbaciones mediante el índice NDFI (*Normalized Difference Fraction Index*) calculado a partir de ellos. Este análisis proporcionará información sobre cómo las características geográficas influyen en la representatividad de *endmembers* y su potencial para evaluar la dinámica de cambios naturales y de gestión del pino silvestre en diferentes regiones españolas.

### Palabras clave

Técnicas de mezcla espectral, firma espectral, teledetección óptica, gestión forestal, *Google Earth Engine*, detección de cambios.

### 1. Introducción

El pino silvestre o pino albar (*Pinus sylvestris*), es una de las especies forestales más importantes de Europa. En España destaca especialmente y se distribuye por regiones como el Sistema Central, Sistema Ibérico, Pirineos y las Sierras Penibéticas. Estas áreas representan una notable diversidad climática y edáfica, lo que convierte a esta especie en un modelo ideal para estudios de adaptación y gestión forestal (ALÍA et al., 2009). Su papel en la regulación climática, la biodiversidad y la economía forestal subraya la importancia de desarrollar metodologías avanzadas para su seguimiento y conservación.

En el ámbito de la teledetección, las técnicas de mezcla espectral (*Spectral Unmixing*, SU) han surgido como herramientas fundamentales para descomponer las firmas espectrales registradas en cada píxel de imágenes hiperespectrales y multispectrales, identificando componentes puros denominados *endmembers* (DRUMETZ et al., 2019; BORSOI et al., 2021). Estas técnicas son especialmente útiles para el análisis de ecosistemas forestales, donde cada píxel a menudo contiene una mezcla de materiales debido a la resolución espacial de los sensores remotos (GRABSKA et al., 2020).

Sin embargo, la precisión de estas técnicas puede verse afectada por la variabilidad espectral, que se refiere a las diferencias en las firmas espectrales de un mismo material debido a condiciones atmosféricas, iluminación, variaciones

intrínsecas del material y cambios ambientales (THEILER et al., 2019). En el caso del *Pinus sylvestris*, su distribución en 20 regiones de procedencia (RP) en España con características geográficas y climáticas diversas, refuerza la necesidad de analizar cómo estas diferencias influyen en la selección de *endmembers* y en su aplicación en algoritmos de detección de cambios.

## 2. Objetivos

El objetivo general de este trabajo es evaluar la influencia de las características geográficas en la variabilidad espectral del *Pinus sylvestris* en las RP de España, mediante la definición y análisis de *endmembers* espectrales específicos. En cuanto a los objetivos específicos, estos son los siguientes:

1. Definir los *endmembers* del *Pinus sylvestris* en las RP en España empleando imágenes Sentinel-2.
2. Evaluar las diferencias significativas en las características espectrales de los *endmembers* entre los distintos estados de desarrollo del *Pinus sylvestris* (fustal, latizal y monte bravo) y entre las RP, utilizando análisis estadísticos y técnicas de agrupamiento espacial (*clustering*).
3. Definir regiones geográficas en las cuales se pueden aplicar *endmembers* únicos.

## 3. Metodología

### 3.1. Área de estudio

El presente estudio se llevó a cabo en las 20 RP del *Pinus sylvestris* en España, que se distribuyen en áreas con condiciones climáticas y geográficas muy diversas, como el Sistema Central, los Pirineos y las Sierras Penibéticas (Figura 1). La altitud en estas regiones oscila entre 800 y 2000 m.s.n.m., la precipitación media anual oscila entre 500 y 1500 mm y la temperatura media anual entre 6 °C y 12 °C.

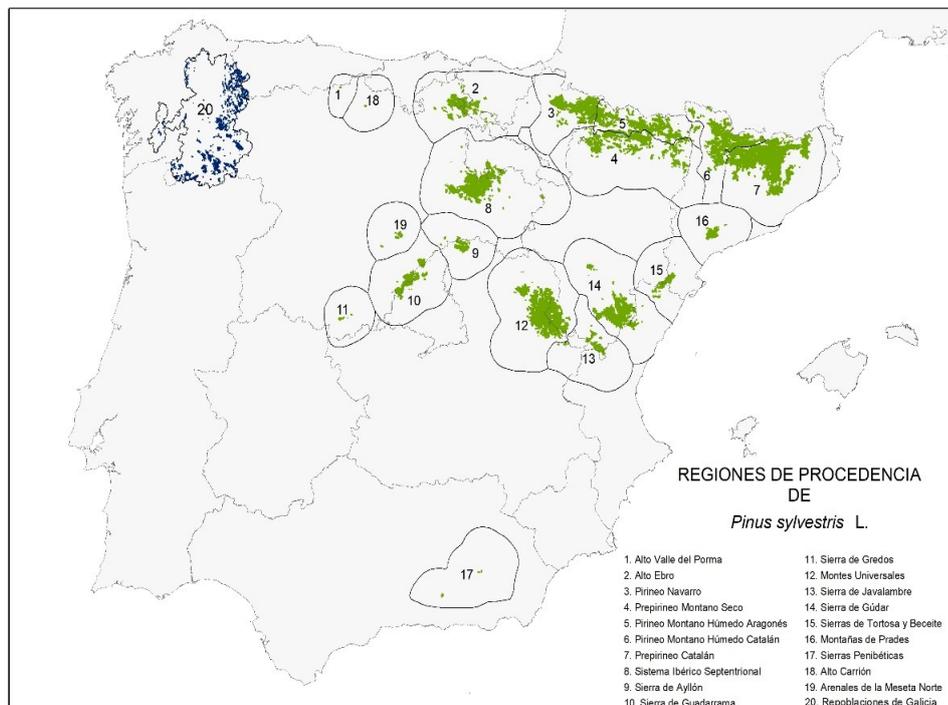


Figura 1. RP de *Pinus sylvestris* en España. Fuente: Resolución de 17 de enero de

2023, de la Dirección General de Biodiversidad, Bosques y Desertificación

### 3.2. Automatización del muestreo aleatorio en R

Para garantizar la representatividad de las muestras utilizadas en el estudio, se implementó un procedimiento automatizado de muestreo aleatorio simple utilizando R. El código desarrollado permitió seleccionar muestras de manera sistemática en las capas geográficas correspondientes a las 18 RP donde está presente el *Pinus sylvestris* en España (ya que según el Mapa Forestal Español (MFE) de máxima actualidad en la RP 19 y 11 no se encuentran existencias del mismo).

El proceso incluyó la clasificación del MFE en tres categorías principales de desarrollo del *Pinus sylvestris*: monte bravo (vegetación en etapa inicial), latizal (árboles en etapa juvenil intermedia), fustal (árboles adultos con troncos bien desarrollados). En cada región de procedencia, se seleccionaron 15 muestras de cada una de estas categorías, resultando 45 muestras por región, y un total de 810 para las 18 RP. Además, se incluyeron 20 muestras de suelo y 20 de vegetación no fotosintética (NPV) por región, alcanzando un total de 1530 muestras (Figura 2).

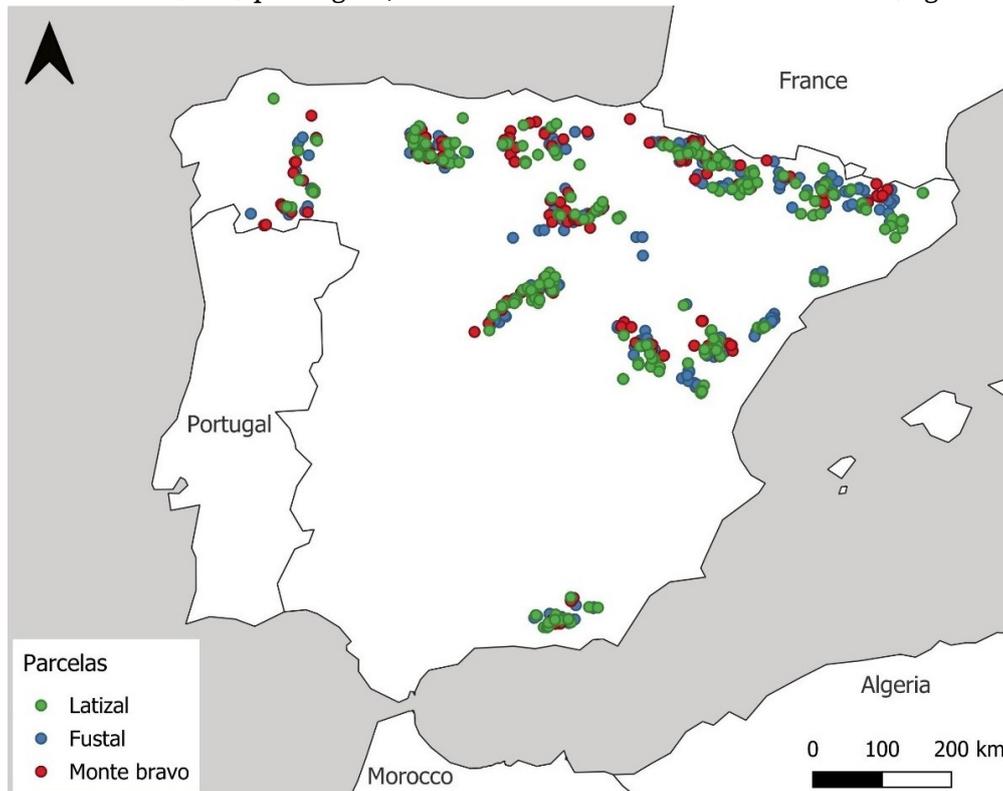


Figura 2. Localización de puntos de muestreo de vegetación en las RP de *Pinus sylvestris*.

### 3.3. Obtención de *endmembers* en GEE

Los *endmembers* para cada muestra seleccionada se calcularon utilizando GEE, aprovechando la colección S2\_SR\_HARMONIZED de Sentinel-2. Este proceso se adaptó a las características específicas de los componentes a analizar en las bandas B2, B3, B4, B8, B11, B12:

1. Vegetación verde (GV): los *endmembers* correspondientes a la vegetación activa se generaron calculando la mediana espectral de todas las imágenes disponibles entre mayo y agosto de 2019. Este periodo coincide con la temporada de crecimiento del *Pinus sylvestris*, lo que garantiza que las

- firmas espectrales capturen adecuadamente el estado fenológico de la vegetación.
- Suelo: para los *endmembers* de suelo, se utilizaron imágenes específicas de agosto de 2019, un mes caracterizado por una baja actividad fotosintética en las áreas forestales consideradas. Esto permitió identificar con precisión píxeles dominados por suelo desnudo.
  - Vegetación no fotosintética (NPV): los *endmembers* de NPV se obtuvieron utilizando imágenes de octubre de 2019, donde los valores espectrales reflejan predominantemente vegetación seca o en senescencia.

### 3.4. Evaluación de *endmembers* y clustering

Para evaluar las diferencias significativas entre los estados de desarrollo del *Pinus sylvestris* (fustal, latizal y monte bravo) y entre distintas RP, se realizaron análisis de varianza (ANOVA) utilizando los valores espectrales de los *endmembers* definidos. Este análisis permitió determinar si las coberturas y estados de desarrollo dentro de una misma región presentan diferencias estadísticamente significativas ( $p < 0.05$ ).

Además, para el latizal y el fustal, que son los estados de desarrollo más relevantes para las actividades de gestión forestal, se implementó un análisis de agrupamiento espacial mediante el algoritmo *k-means*. Este *clustering* permitió identificar patrones espectrales homogéneos entre distintas RP, facilitando la delimitación de áreas prioritarias para la gestión forestal y optimizando la aplicación de los *endmembers* en tareas de seguimiento y detección de cambios.

## 4. Resultados

### 4.1. Obtención de *endmembers* en GEE

En la Figura 3 se presentan los *endmembers* obtenidos en las coberturas del *Pinus sylvestris* de las 18 RP analizadas. Cada línea representa la reflectancia promedio en una RP específica, agrupada según su estado de desarrollo o categoría.

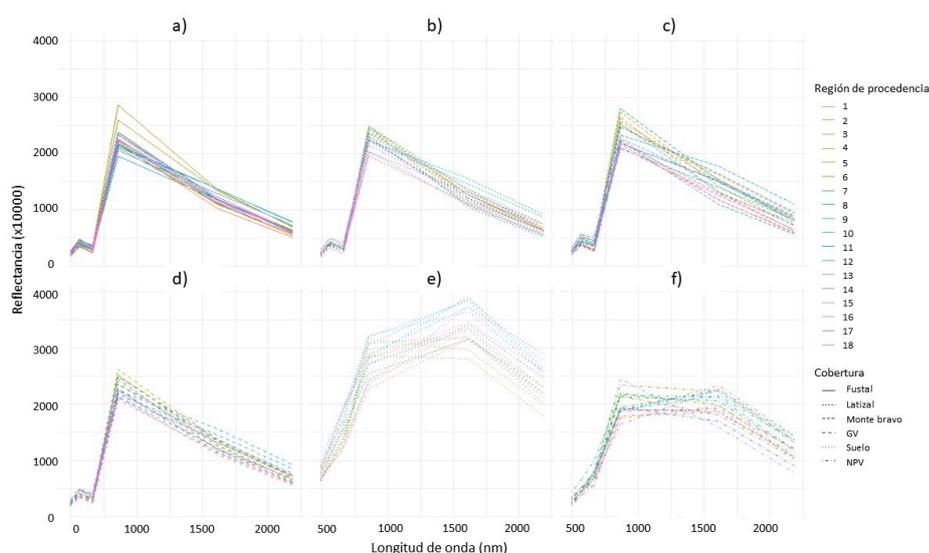


Figura 3. Firmas espectrales de los *endmembers* muestreados en las RP. Fustal (a), Latizal (b), Monte bravo (c), Vegetación verde (GV) (d), Suelo (e) y Vegetación no fotosintética (NPV) (f).

### 4.2. Evaluación de *endmembers* y clustering

El mapa de calor de resultados de Tukey (Figura 4) muestra las diferencias significativas entre los estados de desarrollo del *Pinus sylvestris* (monte bravo, latizal y fustal) en cada RP, evaluadas mediante ANOVA y pruebas post hoc. Los resultados indican que las mayores diferencias se dan entre monte bravo y los otros estados de desarrollo (latizal y fustal), especialmente en las bandas visibles (B2, B3, B4) y NIR (B8). Por el contrario, las comparaciones entre latizal y fustal fueron menos significativas. Con base en estos resultados, se decidió incluir únicamente latizal y fustal en el análisis de *clustering*, ya que representan los estados de desarrollo más relevantes para actividades de gestión forestal, excluyendo monte bravo por su mayor variabilidad y menor representatividad.

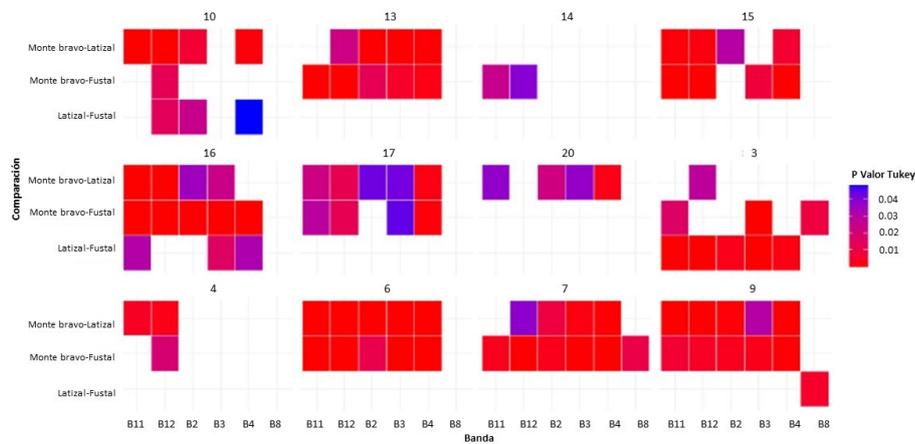


Figura 4. Mapa de Calor de Resultados de Tukey entre los distintos estados de desarrollo del *Pinus sylvestris* en cada RP.

Las bandas más significativas para realizar el análisis de *clustering* fueron identificadas a partir de los resultados del ANOVA y las pruebas post hoc de Tukey. Las bandas B2 (azul), B3 (verde), B4 (rojo) mostraron la mayor discriminación entre latizal y fustal en la mayoría de las regiones de procedencia, siendo estas las más sensibles a las diferencias en densidad y vigor de la vegetación. Las bandas B8 y B12 también mostraron discriminación entre estados de desarrollo y coberturas, pero en menor medida (Figura 5). Estas bandas fueron seleccionadas como variables clave para el análisis de agrupamiento, ya que capturan las características espectrales más relevantes para separar las regiones según sus estados de desarrollo y condiciones ambientales.

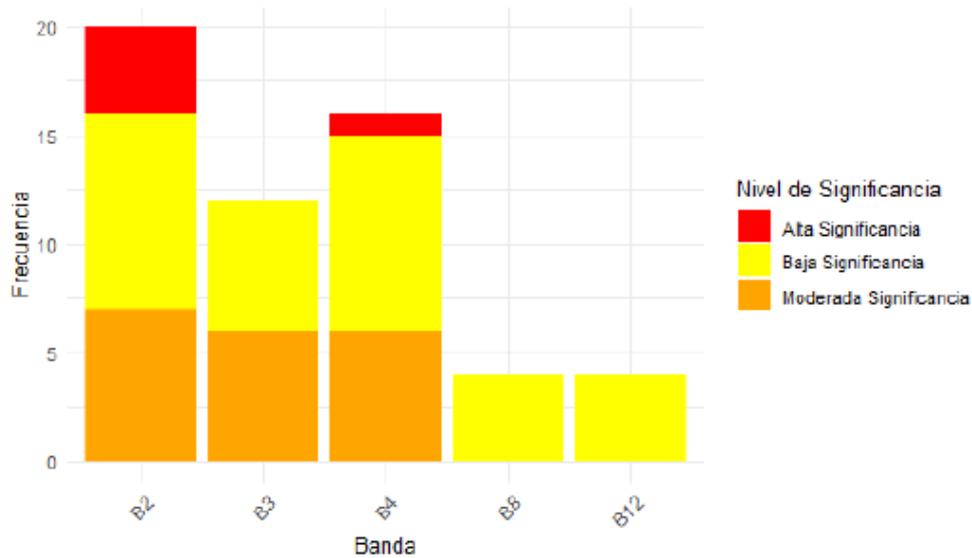


Figura 5. Bandas seleccionadas para el agrupamiento de clústeres.

En la Figura 6 se presenta la distribución geográfica de los agrupamientos obtenidos mediante el algoritmo de *k-means*, el cual agrupa las RP del *Pinus sylvestris* en tres categorías principales basadas en sus características espectrales. Las áreas de cada agrupamiento o clúster se representan con un color:

1. Clúster 1 (verde): Regiones con valores espectrales homogéneos, asociados a condiciones climáticas más húmedas y vegetación más vigorosa. Este clúster incluye zonas del noroeste.
2. Clúster 2 (amarillo): Regiones intermedias en términos de variabilidad espectral, con mayor dispersión en bandas. Este clúster incluye zonas como los Pirineos y las cordilleras Penibéticas.
3. Clúster 3 (naranja): Agrupa regiones caracterizadas por condiciones más secas y una menor reflectancia en bandas clave, como el Red Edge y el NIR. Este clúster abarca zonas del este y sur.

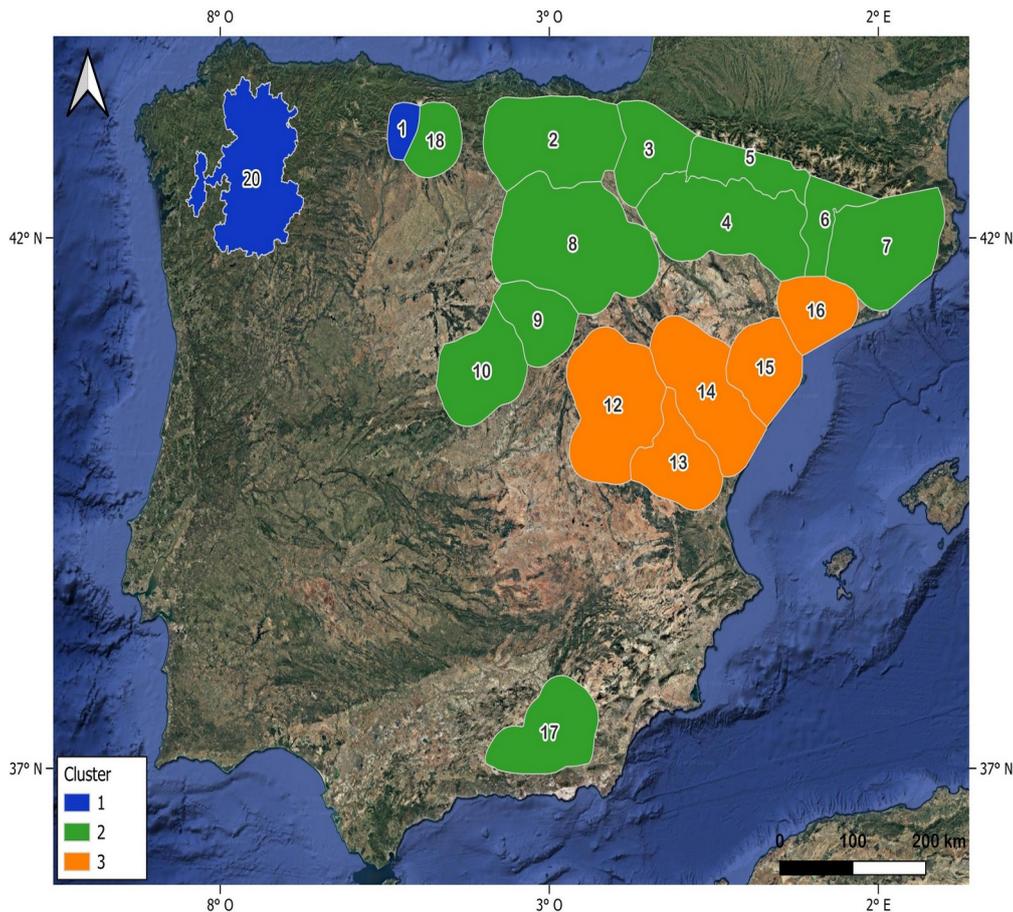


Figura 6. Agrupamiento en clústeres de las RP del *Pinus sylvestris* en España.

El mapa evidencia una segmentación geográfica clara, destacando la influencia de las características ambientales locales como altitud, precipitación y tipo de suelo en la reflectancia espectral.

### 5. Discusión

Los resultados de este estudio confirman que el *Pinus sylvestris* de las distintas RP y en sus distintos estados de desarrollo se diferencia claramente en las bandas del visible (B2, B3, B4) y en menor medida en el NIR y B12. Esta capacidad discriminadora es particularmente notable en el rango azul y rojo, donde las diferencias en densidad de vegetación y vigor se reflejan de manera más significativa. Este hallazgo refuerza la elección de estas bandas como las más relevantes para el análisis de estados de desarrollo y regiones de procedencia, alineándose con observaciones previas que destacan la sensibilidad del visible para capturar cambios estructurales en vegetación (GRABSKA et al., 2020; BORSOI et al., 2021).

La exclusión del monte bravo del análisis de *clustering* se justificó por su menor representatividad y mayor variabilidad espectral en estas bandas clave, lo que habría introducido ruido en el agrupamiento. En contraste, las coberturas de latizal y fustal presentaron patrones más consistentes en las bandas visibles, facilitando su segmentación y fortaleciendo la precisión del análisis.

La implementación del análisis de *clustering* utilizando estas bandas permitió identificar tres clústeres geográficos principales. Este enfoque refuerza la idea de que la variabilidad espectral del *Pinus sylvestris* está influenciada por factores ambientales, como la altitud y la precipitación, que afectan directamente las



propiedades espectrales en el visible y el NIR. Aunque estudios como los de CHEN et al. (2021) y TANG et al. (2023) se han centrado más en la dinámica temporal, este trabajo subraya la importancia de integrar el contexto geográfico para seleccionar *endmembers* representativos y mejorar la precisión en la detección de cambios forestales.

## 6. Conclusiones

Este estudio destaca la relevancia de los *endmembers* en la discriminación de las coberturas de *Pinus sylvestris*, evidenciando su capacidad para representar las características espectrales asociadas a diferentes tipos de vegetación y condiciones ambientales. El análisis de agrupamiento mediante *k-means* permitió identificar patrones en la variabilidad espectral, optimizando la representación de los *endmembers* al asociarlos con latizales y fustales de manera precisa y consistente.

La selección y uso de *endmembers* derivados de las RP aseguran una caracterización y segmentación eficiente de las coberturas forestales, proporcionando una representación simplificada pero efectiva de la heterogeneidad espectral. Este enfoque no solo mejora la precisión en la identificación de coberturas homogéneas, sino que también reduce la complejidad en los modelos espectrales, facilitando su integración en herramientas de monitoreo y gestión forestal.

De cara a futuros trabajos, se plantea la posibilidad de utilizar *endmembers* generalizados que representen áreas geográficas con características espectrales similares. Esta estrategia abre nuevas oportunidades para desarrollar modelos más flexibles y aplicables en distintos contextos ecológicos, fortaleciendo el uso de la teledetección en la gestión sostenible de *Pinus sylvestris* y otras especies forestales.

## 7. Agradecimientos

Al Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria (INIA-CSIC) por definir las Regiones de Procedencia del *Pinus sylvestris* en España, al Ministerio para la Transición Ecológica y el Reto Demográfico (MITECO) por proporcionar el Mapa Forestal Español (MFE) y sus versiones actualizadas, y a la Agencia Espacial Europea (ESA) por proporcionar las imágenes de Sentinel-2.

## 8. Bibliografía

ALÍA, R.; GARCÍA, J.M.; IGLESIAS, S.; MANCHA, J.A.; DE MIGUEL, J.; NICOLÁS, J.L.; PÉREZ, F.; SÁNCHEZ, D.; 2009. Regiones de procedencia de especies forestales en España. *Pinus sylvestris*. Organismo Autónomo Parques Nacionales. 195-199. Madrid.

BORSOI, R. A.; IMBIRIBA, T.; BERMUDEZ, J. C. M.; RICHARD, C.; CHANUSSOT, J.; DRUMETZ, L.; TOURNERET, J.-Y.; ZARE, A.; JUTTEN, C.; 2021. Spectral Variability in Hyperspectral Data Unmixing: A comprehensive review. *IEEE Geosci Remote Sens Mag*, 9(4), 223-270. <https://doi.org/10.1109/mgrs.2021.3071158>

CHEN, S.; WOODCOCK, C. E.; BULLOCK, E. L.; ARÉVALO, P.; TORCHINAVA, P.; PENG, S.; OLOFSSON, P.; 2021. Monitoring temperate forest degradation on Google Earth Engine using Landsat time series analysis. *Remote Sens Environ*, 265, 112648. <https://doi.org/10.1016/j.rse.2021.112648>

DRUMETZ, L.; CHANUSSOT, J.; JUTTEN, C.; 2019. Data Handling in Science and Technology. Chapter 2.7 - Variability of the endmembers in spectral unmixing. Elsevier. 167-203. <https://doi.org/10.1016/b978-0-444-63977-6.00009-2>



GRABSKA, E.; HAWRYŁO, P.; SOCHA, J.; 2020. Continuous Detection of Small-Scale Changes in Scots Pine Dominated Stands Using Dense Sentinel-2 Time Series. *Remote Sens Environ*, 12(8), 1298. <https://doi.org/10.3390/rs12081298>

TANG, X.; BRATLEY, K. H.; CHO, K.; BULLOCK, E. L.; OLOFSSON, P.; WOODCOCK, C. E.; 2023. Near real-time monitoring of tropical forest disturbance by fusion of Landsat, Sentinel-2, and Sentinel-1 data. *Remote Sens Environ*, 294, 113626. <https://doi.org/10.1016/j.rse.2023.113626>

THEILER, J.; ZIEMANN, A.; MATTEOLI, S.; DIANI, M.; 2019. Spectral Variability of Remotely Sensed Target Materials: Causes, Models, and Strategies for Mitigation and Robust Exploitation. *IEEE Geosci Remote Sens Mag*, 7(2), 8-30. <https://doi.org/10.1109/mgrs.2019.2890997>