

Marcello Ruiz, F.; Eugenio González, F.; Mederos Barrera, A.; Gonzalo Martín, C.; García Pedrero, Á.; Boumahdi, M.
Cartografía forestal mediante datos multiespectrales de alta resolución y técnicas avanzadas de clasificación

Cartografía forestal mediante datos multiespectrales de alta resolución y técnicas avanzadas de clasificación

Marcello Ruiz, Francisco Javier ¹ Eugenio González, Francisco ¹ Mederos Barrera, Antonio ¹ Gonzalo Martín, Consuelo ² García Pedrero, Ángel Mario ² Boumahdi, Meryeme ²

¹ Universidad de Las Palmas de Gran Canaria, España

² Universidad Politécnica de Madrid, España

ORCID: Marcello Ruiz 0000-0002-9646-1017 Eugenio González 0000-0002-0010-4024 Mederos Barrera 0000-0003-1680-0726 Gonzalo Martín 0000-0002-0804-9293 García Pedrero 0000-0002-6848-481X Boumahdi 0000-0003-0600-8137

Correspondencia: javier.marcello@ulpgc.es francisco.eugenio@ulpgc.es antonio.mederos@ulpgc.es
consuelo.gonzalo@upm.es angelmario.garcia@upm.es m.boumahdi@alumnos.upm.es

RESUMEN

La isla de La Palma presenta una elevada diversidad forestal como resultado de su compleja orografía, variedad climática y gradiente altitudinal, lo que hace imprescindible disponer de herramientas eficaces para la monitorización y gestión de sus ecosistemas forestales. En este contexto, la teledetección se posiciona como una herramienta clave para la clasificación y análisis de las formaciones forestales. Este trabajo evalúa la clasificación de la vegetación forestal arbolada de La Palma como paso previo al análisis de la salud de los distintos hábitats. Para ello, se emplearon datos multiespectrales de muy alta resolución del satélite WorldView-2, complementados con información de referencia procedente de cartografías oficiales y datos multiespectrales y LiDAR adquiridos mediante dron. Se definieron cinco clases principales de cobertura forestal y se comparó el rendimiento de distintos algoritmos de clasificación supervisada, incluyendo métodos clásicos, técnicas de aprendizaje máquina (Random Forest, SVM, etc.) y un modelo avanzado de aprendizaje profundo basado en transformers (SegFormer). Los resultados muestran que los clasificadores Random Forest y SVM ofrecen las mejores precisiones globales (superiores al 70%), especialmente cuando se combinan las bandas espectrales con índices de vegetación y variables topográficas. El modelo de aprendizaje profundo presenta un buen comportamiento general, aunque no supera cuantitativamente a los métodos de aprendizaje máquina, lo que exige incrementar la base de datos de entrenamiento del modelo. El estudio confirma el potencial de los datos multiespectrales y las técnicas basadas en inteligencia artificial para la cartografía forestal de alta precisión.


Palabras clave: WorldView, clasificación forestal, Random Forest, Support Vector Machine, SegFormer


Fecha de recepción: 5 febrero 2026 · Fecha de aceptación: 16 febrero 2026


Cartografía forestal mediante datos multiespectrales de alta resolución y técnicas avanzadas de clasificación

Marcello Ruiz, Francisco Javier ⁽¹⁾, Eugenio González, Francisco ⁽¹⁾, Mederos Barrera, Antonio ⁽¹⁾, Gonzalo Martín, Consuelo ⁽²⁾, García Pedrero, Ángel Mario ⁽²⁾, Boumahdi, Meryeme ⁽²⁾


⁽¹⁾ Universidad de Las Palmas de Gran Canaria, España.


 0000-0002-9646-1017, javier.marcello@ulpgc.es.


 0000-0002-0010-4024, francisco.eugenio@ulpgc.es.

 0000-0003-1680-0726, antonio.mederos@ulpgc.es.

⁽²⁾ Universidad Politécnica de Madrid, España.

 0000-0002-0804-9293, consuelo.gonzalo@upm.es.

 0000-0002-6848-481X, angelmario.garcia@upm.es.

 0000-0003-0600-8137, m.boumahdi@alumnos.upm.es.

Resumen: La isla de La Palma presenta una elevada diversidad forestal como resultado de su compleja orografía, variedad climática y gradiente altitudinal, lo que hace imprescindible disponer de herramientas eficaces para la monitorización y gestión de sus ecosistemas forestales. En este contexto, la teledetección se posiciona como una herramienta clave para la clasificación y análisis de las formaciones forestales. Este trabajo evalúa la clasificación de la vegetación forestal arbolada de La Palma como paso previo al análisis de la salud de los distintos hábitats. Para ello, se emplearon datos multiespectrales de muy alta resolución del satélite WorldView-2, complementados con información de referencia procedente de cartografías oficiales y datos multiespectrales y LiDAR adquiridos mediante dron. Se definieron cinco clases principales de cobertura forestal y se comparó el rendimiento de distintos algoritmos de clasificación supervisada, incluyendo métodos clásicos (MD, MhD, P, SAM, ML, NB), técnicas de aprendizaje automático (KNN, RF, SVM) y un modelo avanzado de aprendizaje profundo basado en *transformers* (SegFormer). Los resultados muestran que los clasificadores Random Forest y SVM ofrecen las mejores precisiones globales (superiores al 70%), especialmente cuando se combinan las bandas espectrales con índices de vegetación y variables topográficas. El modelo de aprendizaje profundo presenta un buen comportamiento general, aunque no supera cuantitativamente a los métodos de aprendizaje automático, lo que exige incrementar la base de datos de entrenamiento del modelo. El estudio confirma el potencial de los datos multiespectrales y las técnicas basadas en inteligencia artificial para la cartografía forestal de alta precisión.

Palabras clave: WorldView, clasificación forestal, *Random Forest*, *Support Vector Machine*, SegFormer

Forest mapping using high-resolution multispectral data and advanced classification techniques

Abstract: La Palma exhibits a high level of forest diversity as a result of its complex topography, climatic variability, and altitudinal gradient, making the availability of effective tools for monitoring and managing its forest ecosystems essential. In this context, remote sensing emerges as a key tool for the classification and analysis of forest formations. This study evaluates the classification of forested vegetation in La Palma as a preliminary step toward assessing the health of different habitats. To this end, very high-resolution multispectral data from the WorldView-2 satellite were used, complemented by reference information from official cartography and multispectral and LiDAR data acquired by an unmanned aerial vehicle. Five forest cover classes were considered, and the performance of different supervised classification algorithms was compared, including classical methods (MD, MhD, P, SAM, ML, NB), machine learning techniques (KNN, RF, SVM), and an advanced deep learning model based on transformers (SegFormer). The results show that the Random Forest and SVM classifiers achieve the highest overall accuracies (above 70%), particularly when spectral bands are combined with vegetation indices and topographic variables. The deep learning model demonstrates good overall performance; however, it does not quantitatively outperform machine learning methods, highlighting the need to increase the size of

the training dataset. This study confirms the potential of multispectral data and artificial intelligence-based techniques for high-precision forest mapping.

Keywords: WorldView, forest classification, Random Forest, Support Vector Machine, SegFormer

1. INTRODUCCIÓN

La riqueza forestal de La Palma es uno de los elementos más emblemáticos de su patrimonio natural, resultado de la combinación de una geografía abrupta, un clima variado y una gran diversidad de pisos bioclimáticos sobre un pequeño territorio insular. Sin embargo, se ha visto seriamente afectada en los últimos años como consecuencia de incendios forestales, la erupción volcánica de Tajogaite (Carracedo *et al.*, 2022) y el efecto del cambio climático, que incrementa la frecuencia e intensidad de episodios de sequía, olas de calor y condiciones favorables para la proliferación de plagas, como la lagarta (*Calliteara fortuneata*), que afecta al pinar canario. Todo ello hace imprescindible una monitorización continua del estado de la masa forestal. En este contexto, la teledetección se presenta como una herramienta especialmente útil para la clasificación y el seguimiento de las especies forestales de La Palma.

En este trabajo se evalúa la clasificación de la vegetación forestal arbolada de La Palma como paso previo para un análisis de la salud de cada tipo de hábitat forestal. Con el objetivo de discriminar las distintas formaciones forestales, se han usado datos multiespectrales de muy alta resolución procedentes del satélite WorldView. Se han comparado diferentes algoritmos de clasificación (Matyukira, 2024), incluyendo tanto métodos clásicos como clasificadores avanzados, evaluando su exactitud y fiabilidad en función de diferentes datos de entrada. Para el entrenamiento y el análisis de la precisión se han utilizado las cartografías existentes, así como datos multiespectrales y LiDAR captados desde un dron y abarcando zonas representativas en toda la isla.

2. MATERIAL Y MÉTODOS

2.1. Zona de estudio

La Palma, a pesar de tener una superficie de aproximadamente 706 km², presenta una gran altitud (2.423 metros). Por este motivo, la isla posee una amplia variedad de pisos bioclimáticos, algunos sometidos a la presencia de los alisios, lo que los hace más húmedos y lluviosos, y otros más secos como los del Sur y el Oeste insular. Estos pisos de vegetación contribuyen a la singularidad del ecosistema de la isla. Habitualmente, entre los 600 y 1000 metros de altitud se desarrolla la laurisilva, un bosque húmedo y fresco. Por encima de este piso aparece el fayal-brezal. A mayores altitudes, este bosque da paso al pinar canario, una formación fundamental para la protección del suelo frente a la erosión en zonas abruptas y acompañada de especies adaptadas a suelos volcánicos como el codeso y la retama. Además, en las medianías y el norte de la isla destaca la presencia de castañeros.

2.2. Datos

Dado que el objetivo de este trabajo consiste en generar un mapa con los tipos de vegetación forestal más representativos de la isla de La Palma, como paso previo,

se han obtenido y revisado las cartografías existentes. Es de elevada importancia seleccionar la cartografía de referencia adecuada, ya que será pieza fundamental en el proceso de entrenamiento y evaluación de los modelos y resultados obtenidos. Específicamente, se han analizado las existentes, tanto a nivel insular, como regional, nacional y europeo, destacando las cartografías de vegetación del Gobierno de Canarias (2021), Cabildo de la Palma (PIOLP 2020), Mapa Forestal Español (2018), SIOSE de Alta Resolución (2017) y Corine Land Cover + BackBone (2021). Se seleccionó como cartografía de referencia el mapa de vegetación del Gobierno de Canarias, proporcionado por la empresa pública Cartográfica de Canarias GRAFCAN.

Respecto a los datos de teledetección, se han utilizado datos multiespectrales de alta resolución captados por el satélite WorldView-2 (WV-2). Este satélite dispone de 8 bandas multiespectrales con resolución espacial de 1,8 m y una resolución radiométrica de 11 bits. Para abarcar la isla completa se hizo el mosaico de escenas mayoritariamente captadas el 4 de mayo de 2024.

Además, para tener una referencia precisa para generar regiones de entrenamiento y evaluación, se obtuvieron datos dron en 43 parcelas de 9 ha. Se utilizó la plataforma DJI Matrice 300 RTK equipada con el sensor multiespectral MicaSense RedEdge-MX Dual de 10 bandas y con el sensor LiDAR Zenmuse L1 que permitió la obtención del modelo digital de elevación del terreno (MDT) y de la altura de la vegetación (CHM).

En la Figura 1 se muestran los datos utilizados para este trabajo y los datos dron para las 2 parcelas recuadradas.

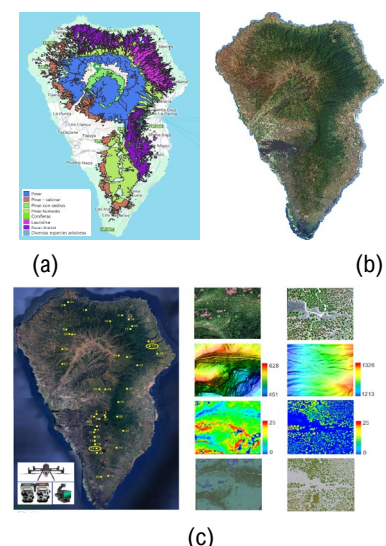


Figura 1. Datos utilizados: (a) Hábitats forestales más representativos (Gov. Canarias, 2021), (b) WorldView-2 del 4 de mayo 2024 (reflectancia en superficie), y (c) parcelas dron y ejemplos de datos multiespectrales, LiDAR (MDT y CHM en metros) y mapas clasificados.

2.3. Metodología de clasificación

En primer lugar, se aplicó una etapa de preprocesado, ya que las imágenes WorldView-2 captadas por plataformas espaciales sufren una serie de distorsiones, que deben ser corregidas para obtener valores precisos de reflectancia de la superficie terrestre. Se aplicó la corrección y calibración radiométrica, que ajusta los valores digitales del sensor y corrige el funcionamiento de los detectores; la corrección atmosférica, que compensa los efectos de absorción y dispersión en la atmósfera; y la corrección geométrica, que adapta la imagen a un sistema de coordenadas y proyección cartográfica. En este estudio, la corrección atmosférica se realizó mediante el modelo FLAASH, debidamente parametrizado para la fecha de captación y las condiciones locales de la escena. Además, para obtener la imagen ortorectificada se aplicaron los RPCs (*Rational Polynomial Coefficients*) junto con un modelo digital de elevación del terreno de alta resolución (Marcello *et al.*, 2021).

A continuación, se llevó a cabo una clasificación supervisada. Se consideraron seis clases de interés: coníferas, laurisilva, fayal-brezal, castaño, otras especies vegetales, y suelo desprovisto de vegetación, áreas urbanas y otras cubiertas. Las regiones de entrenamiento y evaluación se definieron a partir del mapa de vegetación y de los datos adquiridos con dron. Para cada clase, se seleccionaron 100.000 píxeles de entrenamiento y 10.000 píxeles de evaluación, procurando que las muestras fueran representativas y recogieran la variabilidad existente dentro de cada categoría. Asimismo, la separabilidad espectral entre pares de clases se evaluó mediante la distancia de Jeffries-Matusita (Xu *et al.*, 2023).

Para la etapa de asignación se han abordado dos aproximaciones: (i) la primera basada en clasificadores supervisados clásicos y los basados en técnicas de inteligencia artificial de aprendizaje automático (*machine learning*) (Farnaz *et al.*, 2025). Específicamente, se evaluaron 9 clasificadores siguientes: *Minimum Distance* (MD), *Mahalanobis Distance* (MhD), *Parallelepiped* (P), *Spectral Angle Mapper* (SAM), *Maximum Likelihood* (ML), *Naïve Bayes* (NB), *K-Nearest Neighbors* (KNN), *Random Forest* (RF) y *Support Vector Machine* (SVM). (ii) la segunda aproximación basada en un clasificador avanzado de inteligencia artificial usando técnicas de aprendizaje profundo (*deep learning*). Se seleccionó el modelo SegFormer (Xie *et al.*, 2021) (Figura 2), que consiste en una arquitectura *encoder-decoder* con *transformers* que combina un codificador jerárquico eficiente con un decodificador ligero, permitiendo capturar tanto detalles locales como contexto global en las imágenes. Destaca por su capacidad para manejar resoluciones altas y variabilidad espacial, logrando representaciones robustas sin necesidad de convoluciones pesadas.

Para mejorar los resultados obtenidos, además de utilizar las bandas espectrales se hizo una evaluación de la exactitud obtenida al añadir también las características derivadas de los datos satelitales (tales como el índice de vegetación WDRVI y la textura, específicamente la varianza) e información relativa a la topografía (modelo

de elevación del terreno MDT, pendiente y orientación) y climatología (temperatura y precipitación).

3. RESULTADOS

3.1. Clasificadores basados en técnicas clásicas y de aprendizaje automático

En primer lugar, se identificó el clasificador supervisado que proporcionaba una mejor precisión al ser evaluado en 2 conjuntos de entradas: (1) MS: las 8 bandas multispectrales del WV-2, y (2) Todas: 8 bandas + características derivadas (índice de vegetación y textura) y datos topográficos (MDT, pendiente y orientación). En la Tabla 1 se presentan los resultados obtenidos para los 9 clasificadores analizados.

Tabla 1. Exactitud de la clasificación para los 9 clasificadores y 2 combinaciones de datos de entrada.

Método	Datos	Precisión (%)						
		L	F-B	P	C	OV	S	Global
MD	MS	55,2	25,9	32,0	44,3	26,9	57,5	40,1
	Todas	56,2	25,5	32,2	82,4	12,0	55,0	43,1
MhD	MS	60,7	31,4	47,0	72,2	54,0	79,0	57,2
	Todas	57,2	33,9	48,7	76,1	20,2	72,1	50,5
P	MS	20,3	5,1	29,6	0,0	39,2	49,5	24,2
	Todas	16,8	24,8	19,6	14,1	32,9	8,9	18,9
SAM	MS	55,9	34,7	11,3	74,6	17,1	78,9	44,6
	Todas	58,8	33,1	33,7	92,2	3,1	75,3	48,1
ML	MS	71,9	42,0	67,9	92,0	62,9	87,2	70,4
	Todas	66,5	52,6	70,4	92,5	80,4	85,2	74,5
NB	MS	53,2	46,8	24,9	77,5	54,1	86,9	56,8
	Todas	47,4	70,2	47,1	84,1	73,6	79,5	66,6
KNN	MS	63,5	47,4	65,4	86,8	58,5	99,4	69,5
	Todas	60,8	48,1	74,4	86,1	80,6	97,6	74,4
RF	MS	72,8	49,5	75,8	91,5	70,3	99,0	76,1
	Todas	75,7	44,2	79,8	89,6	78,4	98,3	77,5
SVM	MS	73,7	49,5	71,1	89,3	65,0	98,3	74,1
	Todas	70,0	47,1	70,9	91,2	68,4	97,6	73,8

Clases: L: Laurisilva, F-B: Fayal-Brezal, P: Pinar, C: Castaño, OV: Otra Vegetación, S: Suelo-otro

SVM y RF son los dos algoritmos que proporcionan la mejor precisión. Tras el análisis previo se ha seleccionado el modelo Random Forest por su elevada precisión y mayor rapidez de cálculo. En segundo lugar, para este clasificador, se ha realizado un análisis más detallado en función de los datos de entrada. Se ha incorporado, adicionalmente, el mapa anual de precipitación acumulada (1975-2020) y el de temperatura media (1991-2020), disponibles en el Atlas Climático de Canarias para ver si con esta información climática se lograban mejorar los resultados de la clasificación. Los resultados son en general bastante similares para las diferentes combinaciones de entrada. Se aprecia que la textura apenas supone una mejora en la precisión, al igual que la inclusión de información de temperatura o precipitación, mientras que las bandas multispectrales, junto con el índice de vegetación, la

pendiente y la orientación, obtienen una mejor precisión en las clases de interés (Figura 2).

3.2. Clasificador basado en técnicas de aprendizaje profundo

El mapa de los hábitats forestales más representativos obtenido mediante el modelo SegFormer, tras el ajuste fino con datos WorldView-2, se presenta en la Figura 2(b). Como se aprecia, los resultados son bastante similares al mapa de referencia, aunque los resultados cuantitativos obtenidos sobre las regiones de interés de test no mejoran a los modelos de aprendizaje automático (Tabla 2). El modelo de segmentación mostró un buen rendimiento general, con una fiabilidad aceptable en las coberturas dominantes (pinos, laurisilva y fayal-brezal), aunque persisten dificultades en las clases minoritarias o espectralmente menos distintivas, como Otra Vegetación. Es, por tanto, necesario aumentar la base de datos de entrenamiento para mejorar las prestaciones de este clasificador.

Tabla 2. Evaluación de la exactitud global de la clasificación.

Clase	Precisión	Exhaustividad (Recall)	F1-Score
Laurisilva	0.57	0.94	0.71
Fayal-Brezal	0.65	0.83	0.73
Pinares	0.86	0.99	0.92
Castaño	0.99	0.50	0.67
Otra vegetación	0.00	0.00	0.00
Suelo y otros	0.51	0.8	0.65
Promedio	0.60	0.69	0.61

4. CONCLUSIONES

Este trabajo confirma la idoneidad de los datos multispectrales de muy alta resolución, combinados con variables topográficas, para la cartografía detallada de las formaciones forestales de La Palma, un territorio caracterizado por una elevada heterogeneidad ambiental. La integración de distintas fuentes de información permite mejorar la discriminación entre hábitats y proporciona una representación más fiable de la distribución espacial de la vegetación forestal.

Los resultados evidencian que los métodos de aprendizaje automático, especialmente Random Forest y SVM, ofrecen un rendimiento sólido y estable frente a enfoques más complejos de aprendizaje profundo, que requieren una mayor base de datos para alcanzar su máximo potencial.

Estos resultados, pueden permitir hacer análisis multitemporales con datos Sentinel-2 del estado de la salud forestal, en función del hábitat seleccionado, y evidenciar el impacto tras los incendios, la erupción volcánica y las plagas forestales.

5. AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio para la Transición Ecológica y el Reto Demográfico del Gobierno de España, el Gobierno de Canarias y el Cabildo Insular de La Palma en el marco del proyecto “Estudio de los efectos de la erupción volcánica de La Palma sobre

especies amenazadas y sus hábitats naturales” (ref. 316/2023/ACU) y por el Organismo Autónomo Parques Nacionales (Proyecto SPIP2022-02897). Agradecer la disponibilidad del MDT de alta resolución del Plan Nacional de Ortofotografía Aérea (PNOA_LiDAR).

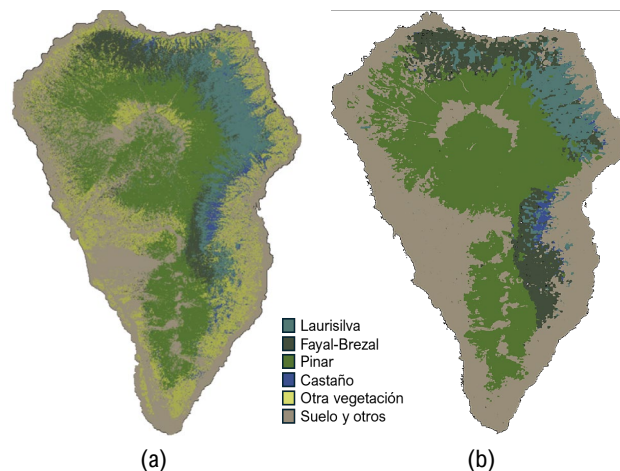


Figura 2. Cartografía de vegetación forestal: (a) Random Forest, y (b) SegFormer.

6. REFERENCIAS

- Carracedo JC., et al. (2022). The 2021 eruption of the Cumbre Vieja volcanic ridge on La Palma. *Geology Today* (38). <http://doi.org/10.1111/gto.12388>
- Farnaz, Nuthammachot, N., & Ali, M.Z. (2025). Comparative study of multiple algorithms classification for land use and land cover change detection and its impact on local climate of Mardan District, Pakistan. *Environmental Challenges*, (18). <https://doi.org/10.1016/j.envc.2024.101069>
- Mapa de Vegetación del Gobierno de Canarias (2021). [https://idecan2.grafcan.es/ServicioWMS/Vegetacion ?](https://idecan2.grafcan.es/ServicioWMS/Vegetacion?)
- Marcello, J., Eugenio, F., Gonzalo-Martín, C., Rodríguez-Esparragón, D., & Marqués, F. (2021). Advanced Processing of Multiplatform Remote Sensing Imagery for the Monitoring of Coastal and Mountain Ecosystems. *IEEE Access*, (9). <https://doi.org/10.1109/ACCESS.2020.3046657>
- Matyukira, C., Mhangara, P. (2024). Advances in vegetation mapping through remote sensing and machine learning techniques: a scientometric review. *European Journal of Remote Sensing*, 57(1). <https://doi.org/10.1080/22797254.2024.2422330>
- Xie, E., Wang, W., Yu, Z., Anandkumar, A., Alvarez, J. M., & Luo, P. (2021). SegFormer: Simple and efficient design for semantic segmentation with transformers. *Advances in Neural Information Processing Systems*, (34). <https://doi.org/10.48550/arXiv.2105.15203>
- Xu, F., Xu, Z., Xu, C., & Yu, T. (2023). Automatic Extraction of the Spatial Distribution of *Picea schrenkiana* in the Tianshan Mountains Based on Google Earth Engine and the Jeffries–Matusita Distance. *Forests*, 14(7), 1373. <https://doi.org/10.3390/f14071373>