

Lamelas Gracia, M.T.; Montealegre Gracia, A.; Romero Medina, S. Clasificación de tipos de combustibles forestales empleando la tercera cobertura del PNOA LIDAR en la Depresión del Ebro

Clasificación de tipos de combustibles forestales empleando la tercera cobertura del PNOA LIDAR en la Depresión del Ebro

Lamelas Gracia, María Teresa ¹ Montealegre Gracia, Antonio Luis ² Romero Medina, Santiago Patricio ¹

¹ Geoforest-IUCA, Departamento de Geografía y O.T., Universidad de Zaragoza, Zaragoza, España

² Centro Universitario de la Defensa, Academia General Militar, Zaragoza, España

ORCID: Lamelas Gracia 0000-0002-8954-7517 Montealegre Gracia 0000-0001-6288-2780

Correspondencia: tlamelas@unizar.es monteale@unizar.es 924211@unizar.es

RESUMEN

El conocimiento de los combustibles forestales es fundamental para tratar de mitigar el riesgo de incendio que se está intensificando en los últimos años. En este estudio se evalúa la capacidad que tiene la información extraída de las nubes de puntos de la tercera cobertura del PNOA LiDAR para estimar combustibles forestales según la clasificación Prometheus. La verdad terreno está compuesta por una muestra de 108 parcelas ubicadas en el centro de la Depresión del Ebro, en las cuales se ha identificado el tipo combustible forestal. Las nubes de puntos fueron procesadas para eliminar los puntos de ruido y solape, ser reclasificadas utilizando una metodología adaptada a ambientes forestales, y crear un modelo digital del terreno con un tamaño de píxel adecuado a la distancia entre puntos LiDAR. Posteriormente, se procedió a la normalización de las alturas y al recorte de las nubes de puntos según el tamaño y forma de las parcelas para la extracción de métricas relacionadas con las alturas de la vegetación, la densidad de puntos a diferentes alturas e índices de diversidad. Finalmente, se crearon conjuntos de datos para entrenar y validar distintos modelos de clasificación de aprendizaje automático: random forest, support vector machine lineal y radial. De cada modelo e iteración se calcula una serie de estadísticos que determinan la calidad de la clasificación. Los resultados muestran alrededor del 75% de precisión global, siendo el que mejor resultado brinda el que combina la elevación del momento L3, el porcentaje de todos los retornos sobre la media, y el índice de rugosidad vegetal, con una precisión global del 78%. Estos resultados confirman que un aumento de la densidad de puntos mejora la capacidad de estimación de los combustibles forestales.

Palabras clave: combustible forestal, modelo Prometheus, Random Forest, Support Vector Machine


Fecha de recepción: 6 febrero 2026 · Fecha de aceptación: 6 febrero 2026


Clasificación de tipos de combustibles forestales empleando la tercera cobertura del PNOA LIDAR en la Depresión del Ebro

Lamelas Gracia, María Teresa ⁽¹⁾, Montealegre Gracia, Antonio Luis ^(1,2), Romero Medina, Santiago Patricio ⁽¹⁾

⁽¹⁾ GEOFOREST-IUCA, Departamento de Geografía y Ordenación del Territorio, Universidad de Zaragoza, Pedro Cerbuna 12, 50009 Zaragoza, España.

⁽²⁾ Centro Universitario de la Defensa de Zaragoza, Academia General Militar, Ctra. de Huesca s/n, 50090 Zaragoza, España.

 0000-0002-8954-7517, tlamelas@unizar.es
924211@unizar.es

 0000-0001-6288-2780, monteale@unizar.es

Resumen: El conocimiento de los combustibles forestales es fundamental para tratar de mitigar el riesgo de incendio que se está intensificando en los últimos años. En este estudio se evalúa la capacidad que tiene la información extraída de las nubes de puntos de la tercera cobertura del PNOA LiDAR para estimar combustibles forestales según la clasificación Prometheus. La verdad terreno está compuesta por una muestra de 108 parcelas ubicadas en el centro de la Depresión del Ebro, en las cuales se ha identificado el tipo combustible forestal. Las nubes de puntos fueron procesadas para eliminar los puntos de ruido y solape, ser reclasificadas utilizando una metodología adaptada a ambientes forestales, y crear un modelo digital del terreno con un tamaño de píxel adecuado a la distancia entre puntos LiDAR. Posteriormente, se procedió a la normalización de las alturas y al recorte de las nubes de puntos según el tamaño y forma de las parcelas para la extracción de métricas relacionadas con las alturas de la vegetación, la densidad de puntos a diferentes alturas e índices de diversidad. Finalmente, se crearon conjuntos de datos para entrenar y validar distintos modelos de clasificación de aprendizaje automático: *random forest*, *support vector machine* lineal y radial. De cada modelo e iteración se calculó una serie de estadísticos que determinan la calidad de la clasificación. Los resultados muestran alrededor del 75% de exactitud global, siendo el que mejor resultado brinda el que combina la elevación del momento L3, el porcentaje de todos los retornos sobre la media, y el índice de rugosidad vegetal, con una exactitud global del 78%. Estos resultados confirman que un aumento de la densidad de puntos mejora la capacidad de estimación de los combustibles forestales.

Palabras clave: incendio forestal, modelo Prometheus, Random Forest, Support Vector Machine

Classification of forest fuel types using the third capture of the PNOA LIDAR in the Ebro Depression

Abstract: Knowledge of forest fuels is fundamental to mitigating the fire risk that has been intensifying in recent years. This study evaluates the capacity of information extracted from point clouds of the third layer of the PNOA LiDAR survey to estimate forest fuels using the Prometheus methodology. The ground reality consists of 108 plots, located in the center of the Ebro Depression, which were classified in the field according to forest fuel type in a previous study. The point clouds downloaded from the National Geographic Information Center were processed to remove noise and overlapping points, reclassified using a methodology adapted to forest environments, and used to create a digital terrain model with a pixel size appropriate to the distance between points in the file. Subsequently, the heights were normalized and the point clouds were cropped to the size and shape of the plots to extract statistical metrics related to vegetation heights, point density at different heights, and diversity indices. Finally, datasets were created to train and validate different machine learning classification models: *random forest*, *linear support vector machine*, and *radial*. A series of statistics that determine the classification quality were calculated for each model and iteration. The results show approximately 75% overall accuracy, with the best result coming from the model that combines L3 moment elevation, the percentage of all returns above the mean, and the vegetation roughness index, achieving an overall accuracy of 78%. These results confirm that increasing point density improves the ability to estimate forest fuels.

1. INTRODUCCIÓN

Los incendios forestales han arrasado aproximadamente 400.000 hectáreas en España en el año 2025, según las estimaciones del Sistema de Información de Incendios Forestales de la Comisión Europea (EFFIS), considerándose uno de los años más catastróficos del presente siglo por el número de hectáreas quemadas.

Los modelos de combustibles forestales clasifican la vegetación según determinados criterios, como son la biomasa consumible, su capacidad de ignición y propagación del fuego (Marino *et al.*, 2016). El modelo Prometheus, creado por la Comisión Europea, es una adaptación y simplificación del modelo de Estados Unidos desarrollado por el Laboratorio de Incendios Forestales del Norte (*Northern Forest Fire Laboratory*, NFFL), adaptado a ecosistemas mediterráneos, que clasifica la vegetación en siete tipos de combustibles forestales basado en ciertos umbrales de altura y cobertura de la vegetación (Montealegre, 2017).

La caracterización y cartografía de los combustibles forestales es un proceso complejo; si bien el trabajo de campo proporciona la referencia más fiable, su alto coste operativo restringe su uso extensivo, lo que ha impulsado el empleo de técnicas de teledetección. Abdollahi & Yebra (2023) presentaron una revisión de investigaciones realizadas para su estimación utilizando diferentes métodos de teledetección, concluyendo que, empleando Landsat, ASTER y Sentinel 2 (datos multispectrales de baja resolución espacial), se consiguió una exactitud entre el 70 y el 91,74 %, con Quickbird y WorldView 2 y 3 (multispectrales de alta resolución espacial) exactitudes entre 74,27 y 85,43 %, con AVIRIS y PRISMA (hiperespectrales de alta y media resolución espacial) exactitudes entre 80 y 87 % y con SAR (radar de apertura sintética) exactitudes entre 70 y 85 %. En el citado artículo, se indica que las investigaciones realizadas con LiDAR aerotransportado muestran exactitudes entre el 81,26 y 89,5 %, sin embargo, este valor aumenta a un intervalo entre el 84 y el 92,8 % al combinar la información LiDAR con sensores multispectrales o hiperespectrales.

El grupo GEOFOREST-IUCA de la Universidad de Zaragoza ha desarrollado en la última década una línea de investigación sobre estimación de combustibles forestales según la clasificación Prometheus en ambientes mediterráneos de elevada diversidad y heterogeneidad ambiental, analizando la idoneidad de diferentes sensores activos, particularmente sensores LiDAR y SAR.

Con estos antecedentes, y considerando la disponibilidad reciente de información LiDAR de mayor densidad de puntos, el objetivo del presente trabajo es estimar combustibles forestales según el modelo Prometheus, utilizando técnicas de clasificación digital de aprendizaje automático, a partir de información tomada en campo e información derivada de las nubes de puntos de la tercera cobertura LiDAR del Plan

Nacional de Ortofotografía Aerea (PNOA LiDAR). Entre los objetivos secundarios a abordar se encuentran:

- Analizar las métricas extraídas del PNOA LiDAR e identificar la capacidad que poseen para diferenciar entre varios tipos de combustible forestal Prometheus.
- Comparar la exactitud en la estimación de combustibles forestales de tres modelos de clasificación de aprendizaje automático.
- Comparar los resultados obtenidos con trabajos previos realizados con tecnología LiDAR.

2. MATERIAL Y MÉTODOS

2.1. Área de estudio y verdad terreno

Los espacios forestales de Aragón presentan una elevada vulnerabilidad frente a los incendios forestales debido a la combinación del tipo de vegetación, la complejidad del relieve y unas condiciones meteorológicas adversas, caracterizadas por baja humedad relativa, vientos intensos, altas temperaturas estivales y una elevada frecuencia de tormentas eléctricas. El área de estudio se sitúa en el sector central de la Depresión del Ebro, en el entorno del Centro Nacional de Adiestramiento (CENAD) San Gregorio, donde las actividades militares con empleo de armas, explosivos y munición incrementan significativamente el riesgo de ignición y la probabilidad de incendios forestales (Montealegre, 2017).

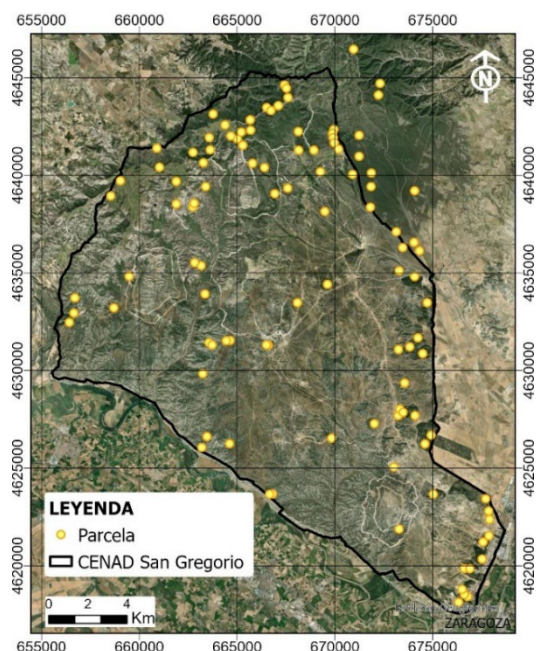


Figura 1. Localización del CENAD San Gregorio y de las parcelas de muestreo.

Montealegre, Lamelas, de la Riva, *et al.* (2015) entre los meses de julio y septiembre de 2014 realizaron la identificación en campo de los tipos de combustibles forestales por el modelo Prometheus en 108 parcelas

circulares, de 15 m de radio, distribuidas de manera aleatoria pero estratificada por la zona de estudio (Fig. 1). Esas mismas parcelas fueron revisadas entre agosto y septiembre de 2020 para la realización de otra investigación (García-Martín *et al.*, 2025), en la que se hizo una verificación *in situ* de la clasificación de combustibles forestales y observándose que en 6 años la dinámica de la vegetación no había modificado la clasificación asignada previamente. En 2023 se revisaron las parcelas en el contexto del trabajo de Hoffrén *et al.* (2023) y se modificó el tipo de combustible forestal de algunas parcelas como producto de un pequeño conato de incendio ocurrido en agosto de 2022. Esta información actualizada sirvió como verdad terreno en el presente trabajo.

2.2. Recopilación y procesamiento de datos PNOA LiDAR

Un total de 79 ficheros LAZ de la tercera cobertura PNOA LiDAR fueron descargados del Centro Nacional de Información Geográfica (CNIG) y clasificados utilizando el algoritmo de filtrado MCC, que es el que brinda mejores resultados para ecosistemas forestales mediterráneos (Montealegre, Lamelas, & de la Riva, 2015). A continuación, se normalizaron las alturas de los puntos en RStudio mediante varios pasos:

- Selección de los puntos categorizados como “2”, es decir, suelo.
- Creación de un modelo digital del terreno (MDT) de 0,50 m de resolución espacial mediante interpolación con el método de redes irregulares de triángulos (TIN) a ráster, utilizando la función “*rasterize_terrain*” del paquete *lidR*.
- Normalización de alturas a través de la función *normalize_height* del mismo paquete *lidR*, estableciendo como superficie de suelo el MDT creado en el paso anterior.

Finalmente, se recortaron las nubes de puntos con las geometrías de las parcelas circulares de la verdad terreno.

2.3. Extracción de métricas

En primer lugar, se empleó el software FUSION para el cálculo automático de parámetros estadísticos de las alturas de los retornos láser. La herramienta “*CloudMetrics*” permite calcular diversas estadísticas, tanto de todos los retornos como de determinados retornos agrupados por estratos de altura, utilizando para ello el parámetro “*strata*”. De acuerdo con Domingo *et al.* (2020), se establecieron los siguientes intervalos de altura para estratificar los retornos y, en consecuencia, tratar de diferenciar mejor los tipos de combustibles del modelo Prometheus: 0,10 – 0,60 m; 0,60 – 2 m; 2 – 4 m y mayor a 4 m. Además, para el cálculo de los índices de diversidad LiDAR Height Diversity Index (LHDI) y LiDAR Height Evenness Index (LHEI), se establecieron intervalos de 50 cm (Listopad *et al.*, 2015).

Asimismo, se calculó el Rurple Index o Índice de rugosidad de Parker *et al.* (2004), que mide la heterogeneidad estructural del dosel en tres dimensiones mediante la división entre el área de la

superficie del dosel forestal y el área del suelo, obteniéndose valores entre uno e infinito.

2.4. Clasificación mediante modelos de aprendizaje automático

El primer paso es la identificación de las métricas LiDAR con mayor capacidad predictiva en la estimación de los tipos de combustibles, para su inclusión posterior en los modelos de clasificación. Se aplicó el test de Dunn a las 152 métricas LiDAR obtenidas considerando seis de los siete tipos de combustibles forestales de Prometheus. El tipo 1 (pastizal) fue excluido de la clasificación debido a la limitada sensibilidad del sensor LiDAR para discriminar entre vegetación de pastizal y matorral.

El aprendizaje automático (*machine learning*) es una técnica de Inteligencia Artificial basada en el uso de métodos computacionales para la extracción de patrones a partir de conjuntos de datos. En este estudio se adopta un enfoque de clasificación supervisada, en el que algoritmos entrenados con datos etiquetados asignan las observaciones de entrada a categorías predefinidas. En concreto, se emplearon los algoritmos *Random Forest* (RF) y *Support Vector Machine* (SVM), este último implementado con *kernel* lineal y radial. Aplicando el principio de parsimonia, el número de variables independientes incorporadas en los modelos se restringió a un rango de entre tres y cinco, ya que la inclusión de un mayor número de variables puede introducir ruido y reducir la capacidad de generalización de los modelos. Se realizó una validación cruzada de 10 iteraciones (*k-fold cross-validation*), que permite incrementar la robustez de las estimaciones (Hoffrén *et al.*, 2024). El rendimiento de los modelos de clasificación se evaluó mediante matrices de confusión, a partir de las cuales se derivaron métricas como la exactitud, la exhaustividad y los errores de omisión y comisión.

3. RESULTADOS

Los resultados del test de Dunn permiten evaluar la capacidad discriminante de cada métrica, cuantificando el número de pares de categorías que es capaz de diferenciar, lo que facilita la selección de aquellas métricas con mayor poder de separación entre tipos de combustible. A partir de las métricas seleccionadas se realizaron un total de 48 iteraciones, orientadas a maximizar la exactitud global de los modelos, obteniéndose las tres mejores combinaciones de variables independientes para cada uno de los tres modelos de clasificación. En la Tabla 1 se muestran los conjuntos de métricas que alcanzan la mayor exactitud global para cada modelo.

4. DISCUSIÓN Y CONCLUSIONES

El uso de métricas derivadas de las nubes de puntos de la tercera cobertura del PNOA LiDAR, que tiene una densidad de 5 puntos/m², aumenta la exactitud global hasta un 78 % de acierto en la estimación de tipos de combustible en comparación con los resultados obtenidos por Domingo *et al.* (2020) con una metodología similar basada en datos de la segunda cobertura del PNOA LiDAR, cuya densidad en la zona de estudio es de 1 punto/m², y con la que se alcanzó una

exactitud global del 59 % utilizando el modelo SVM lineal. No obstante, en este trabajo de Domingo *et al.* (2020) la extensión y heterogeneidad de la muestra verdadera era mayor. En todo caso, los valores de exactitud alcanzados no llegan al 81 % obtenido en la estimación de combustibles forestales a partir de métricas derivadas de sensores LiDAR a bordo de vehículos aéreos no tripulados (VANT), utilizando el algoritmo de clasificación RF (Hoffrén *et al.*, 2024).

Tabla 1. Combinación de variables que proporcionan la mayor exactitud global para cada modelo.

Modelo	Variables	Exactitud
SVMr	Elevación del momento L3, Porcentaje de todos los retornos sobre la altura media, Rumble Index	0,78
SVMl	Elevación media, Elevación del momento L3, Porcentaje de todos los retornos sobre la altura media, Rumble Index	0,78
RF	Elevación del momento L3; Porcentaje de todos los retornos sobre la altura media; Rumble Index; Rumble Index de los retornos menores a 0,60 m; Rumble Index de los retornos entre 3,5 y 4 m	0,75

En los tres modelos de clasificación, el tipo de combustible 6 es el que muestra la peor exhaustividad, debido a su confusión con los tipos 5 y 7. Esto obedece a que, según los resultados del test de Dunn, ninguna de las métricas seleccionadas es estadísticamente significativa para diferenciar entre estas tres categorías, mientras que sí resultan adecuadas para discriminar el resto de tipos de combustible.

Las múltiples iteraciones realizadas muestran que un exceso de métricas utilizadas como variables independientes en los modelos de clasificación pueden generar ruido y conllevar un deterioro de la exactitud general. Aun así, se logró obtener una exactitud global del 78 % con el modelo *Support Vector Machine* con *kernel* radial (SVMr), lo que confirma la mejora en la clasificación de combustibles mediante LiDAR de mayor densidad y puede contribuir a la mejora de la cartografía operativa de riesgo de incendio en combinación con información multispectral.

5. AGRADECIMIENTOS

Investigación financiada por los proyectos CUD2024_18 y CUD-2026_14 del Centro Universitario de la Defensa de Zaragoza, la ayuda RED2024-154139-E Alianza Observa financiada por MICIU/AEI/10.13039/501100011033/, el Proyecto FLARE, PID2023-148568OB-I00, aprobado en la convocatoria de proyectos de Generación de Conocimiento de 2023 y el Instituto Universitario de Ciencias Ambientales de Aragón (IUCA).

6. REFERENCIAS

Abdollahi, A., & Yebra, M. (2023). Forest fuel type classification: Review of remote sensing techniques,

constraints and future trends. *Journal of Environmental Management*, 342, 118315. <https://doi.org/10.1016/j.jenman.2023.118315>

Domingo, D., de la Riva, J., Lamelas, M., García-Martín, A., Ibarra, P., Echeverría, M., & Hoffrén, R. (2020). Fuel Type Classification Using Airborne Laser Scanning and Sentinel 2 Data in Mediterranean Forest Affected by Wildfires. *Remote Sensing*, 12(21), 3660. <https://doi.org/10.3390/rs12213660>

García-Martín, A., Domingo, D., Lamelas, M. T., de la Riva, J., Escribano, F., Montealegre, A.L, Montorio, R., Pérez-Cabello, F. (2025) Fuel type mapping with X-band SAR in military training areas for wildfire risk assessment. *Journal of Applied Remote Sensing*, 19(4), 044514. <https://doi.org/10.1117/1.JRS.19.044514>

Hoffrén, R., Lamelas, M. T., & de la Riva, J. (2023). UAV-derived photogrammetric point clouds and multispectral indices for fuel estimation in Mediterranean forests. *Remote Sensing Applications: Society and Environment*, 31, 2. <https://doi.org/10.1016/j.rsase.2023.100997>

Hoffrén, R., Lamelas, M. T., & de la Riva, J. (2024). Classification and Mapping of Fuels in Mediterranean Forest Landscapes Using a UAV-LiDAR System and Integration Possibilities with Handheld Mobile Laser Scanner Systems. *Remote Sensing*, 16(18), 3536. <https://doi.org/10.3390/rs16183536>

Listopad, C. M., C. S., Masters, R. E., Drake, J., Weishampel, J., & Branquinho, C. (2015). Structural diversity indices based on airborne LiDAR as ecological indicators for managing highly dynamic landscapes. *Ecological Indicators*, 57, 268-279. <https://doi.org/10.1016/j.ecolind.2015.04.017>

Marino, E., Ranz Vega, P., Tomé, J. L., & Noriega, M. Á. (2016). Cartografía de alta resolución de modelos de combustible forestal: metodología de bajo coste basado en datos LIDAR. *Foresta*, 65, 34-43.

Montealegre, A. L. (2017). Aplicaciones forestales de los datos LiDAR-PNOA en ambiente mediterráneo: su filtrado e interpolación y el modelado de parámetros estructurales con apoyo en trabajo de campo. Tesis Doctoral, Universidad de Zaragoza, 25-27.

Montealegre, A. L., Lamelas, M. T., De la Riva, J., García-Martín, A., & Escribano, F. (2015). Cartografía de modelos de combustible mediante combinación de imágenes LiDAR, SAR y ópticas en el Centro de Adiestramiento «San Gregorio». En R. Asorey Cacheda, R. Devesa Rey, M. M. Solla Carracelas, & J. M. Pousada Carballo (Eds.), *Actas: III Congreso Nacional de i+d en Defensa y Seguridad, DESEi+d* (Primera, pp. 1185-1192). Centro Universitario de la Defensa de Marín.

Parker, G. G., Harmon, M. E., Lefsky, M. A., Chen, J., Pelt, R. Van, Weis, S. B., Thomas, S. C., Winner, W. E., Shaw, D. C., & Frankling, J. F. (2004). Three-dimensional Structure of an Old-growth Pseudotsuga-Tsuga Canopy and Its Implications for Radiation Balance, Microclimate, and Gas Exchange. *Ecosystems*, 7(5). <https://doi.org/10.1007/s10021-004-0136-5>.