

Redondo, A.; Becerra, J.; García, A.; Ruiz, L.; Crespo, P.; Carbonell-Rivera, J. Clasificación Avanzada de Nube de Puntos LiDAR con Inteligencia Artificial: el caso práctico de Extremadura

Clasificación Avanzada de Nube de Puntos LiDAR con Inteligencia Artificial: el caso práctico de Extremadura

Redondo, Alejandro ¹ Becerra, Javier ¹ García, Aurelio ¹ Ruiz, Luis Ángel ² Crespo, Pablo ² Carbonell-Rivera, Juan Pedro ²

¹ COTESA, España

² UPV

ORCID: Redondo 0000-0002-2392-3583 Becerra 0009-0004-5253-3746 Ruiz 0000-0003-0073-7259 Crespo 0000-0003-2241-4493 Carbonell-Rivera 0000-0002-6724-6780

Correspondencia: alejandrorredondo@grupotecopy.es javierbecerra@grupotecopy.es aureliogarcia@grupotecopy.es laruiz@cgf.upv.es pabcrepe@cgf.upv.es jp.carbonellrivera@ubc.ca

RESUMEN

La tercera cobertura del PNOA-LiDAR proporciona nubes de puntos de alta densidad que permiten mejorar la clasificación por usos y coberturas del suelo del territorio. Este trabajo presenta un enfoque híbrido para la clasificación de nubes de puntos LiDAR, basado en la combinación de técnicas de Deep Learning (DL) y postprocesado, aplicado a datos de Extremadura. El método emplea un modelo de DL entrenado sobre un conjunto de datos representativo y un proceso posterior de refinamiento mediante técnicas de Machine Learning y análisis espacial. La evaluación, realizada mediante un conjunto de datos independiente, alcanza una exactitud global del 88,2 % y muestra mejoras tras el postprocesado, especialmente en vegetación baja y en infraestructuras lineales como carreteras, ferrocarril y puentes. El enfoque propuesto es iterativo y escalable, lo que facilita su aplicación en ámbitos territoriales extensos.


Palabras clave: LiDAR, Deep Learning, Machine Learning, Clasificación LiDAR


Fecha de recepción: 17 febrero 2026 · Fecha de aceptación: 17 febrero 2026

Clasificación Avanzada de Nube de Puntos LiDAR con Inteligencia Artificial: el caso práctico de Extremadura

Redondo, Alejandro ⁽¹⁾, Becerra, Javier ⁽¹⁾, García, Aurelio ⁽¹⁾, Ruiz, Luis Ángel ⁽²⁾, Crespo, Pablo ⁽²⁾, Carbonell-Rivera, Juan Pedro ⁽²⁾


⁽¹⁾ COTESA, España.

 0000-0002-2392-3583, alejandoredondo@grupotecopy.es

 0009-0004-5253-3746, javierbecerra@grupotecopy.es ; aureliogarcia@grupotecopy.es

⁽²⁾ UPV

 0000-0003-0073-7259, laruiz@cgf.upv.es ;  0000-0003-2241-4493, pabcrepe@cgf.upv.es

 0000-0002-6724-6780, jp.carbonellrivera@ubc.ca

Resumen: La tercera cobertura del PNOA-LiDAR proporciona nubes de puntos de alta densidad que permiten mejorar la clasificación por usos y coberturas del suelo del territorio. Este trabajo presenta un enfoque híbrido para la clasificación de nubes de puntos LiDAR, basado en la combinación de técnicas de Deep Learning (DL) y postprocesado, aplicado a datos de Extremadura. El método emplea un modelo de DL entrenado sobre un conjunto de datos representativo y un proceso posterior de refinamiento mediante técnicas de Machine Learning y análisis espacial. La evaluación, realizada mediante un conjunto de datos independiente, alcanza una exactitud global del 88,2 % y muestra mejoras tras el postprocesado, especialmente en vegetación baja y en infraestructuras lineales como carreteras, ferrocarril y puentes. El enfoque propuesto es iterativo y escalable, lo que facilita su aplicación en ámbitos territoriales extensos.

Palabras clave: LiDAR, Deep Learning, Machine Learning, Clasificación LiDAR

Advanced Classification of LiDAR Point Clouds with Artificial Intelligence: the case study of Extremadura

Abstract: *The third coverage of the PNOA-LiDAR provides high-density point clouds that enable improved classification of land use and land cover in the territory. This paper presents a hybrid approach to LiDAR point cloud classification, based on a combination of deep learning (DL) and post-processing techniques, applied to data from Extremadura. The method uses a DL model trained on a representative dataset and a subsequent refinement process using machine learning techniques and spatial analysis. The evaluation, carried out using an independent dataset, achieves an overall accuracy of 88.2% and shows improvements after post-processing, especially in low vegetation and linear infrastructure such as roads, railways and bridges. The proposed approach is iterative and scalable, facilitating its application in large territorial areas.*

Keywords: LiDAR, Deep Learning, Machine Learning, LiDAR Classification

1. INTRODUCCIÓN

La clasificación automática de nubes de puntos LiDAR es un proceso fundamental para la generación de productos cartográficos y modelos digitales de alta calidad, utilizados en numerosos ámbitos de la gestión territorial y ambiental. El creciente volumen y densidad de los datos LiDAR (*Light Detection and Ranging*) adquiridos mediante sensores aerotransportados hace inviable su tratamiento manual, lo que ha impulsado el desarrollo de metodologías automáticas capaces de garantizar resultados precisos, homogéneos y escalables a grandes extensiones.

En este contexto, la clasificación de nubes de puntos ha sido abordada tradicionalmente mediante enfoques

basados en reglas heurísticas y algoritmos geométricos, ampliamente implementados en software comercial como *TerraScan* (Montero-Calvo *et al.*, 2025), así como en herramientas de código abierto. Más recientemente, se han propuesto metodologías basadas en aprendizaje automático y redes neuronales profundas, incluyendo arquitecturas como PointNet (Kowalczyk & Szymański, 2019), PointNet++ (Fan *et al.*, 2023) o KPConv (Thomas *et al.*, 2019), que han demostrado un alto potencial para capturar patrones complejos en datos tridimensionales. No obstante, estas aproximaciones presentan todavía limitaciones cuando se aplican de forma operativa a grandes volúmenes de datos heterogéneos, especialmente en escenarios nacionales, donde la variabilidad del territorio, la diversidad de coberturas y la

necesidad de cumplir especificaciones técnicas estrictas suponen un reto adicional. En el ámbito institucional, existen experiencias previas de clasificación LiDAR con distintos grados de automatización y edición manual en algunas comunidades autónomas, como Aragón, Comunidad Valenciana o Navarra, si bien dichas soluciones no siempre son directamente transferibles ni escalables a un marco estatal homogéneo.

Este trabajo se enmarca en la tercera cobertura del PNOA-LiDAR (<https://pnoa.ign.es/pnoa-lidar/tercera-cobertura>), que proporciona nubes de puntos con coordenadas X, Y y Z obtenidas a partir de adquisiciones aéreas sobre el territorio nacional. Iniciada parcialmente en 2012 y extendida al conjunto del Estado a partir de 2023, esta cobertura supone un avance significativo respecto a campañas anteriores, al ofrecer una densidad homogénea de 5 puntos·m⁻², frente a los valores de 0,5 a 2 puntos·m⁻² de la segunda cobertura.

En este marco, el objetivo principal del trabajo es la particularización de las especificaciones técnicas del proceso de datos del PNOA-LiDAR de tercera cobertura para la clasificación automática de la nube de puntos mediante técnicas de Inteligencia Artificial. De forma específica, se persigue la generación de ficheros LAS/LAZ versión 1.4 (v8) completamente clasificados, exigiendo un F-Score general superior a 0,90, un F-Score superior a 0,98 en la clasificación básica —con umbrales específicos para suelo, vegetación, edificaciones y puentes— y un F-Score superior a 0,85 en la clasificación avanzada, asegurando así la precisión, consistencia y validez operativa de los resultados obtenidos.

2. MATERIAL Y MÉTODOS

2.1. Zona de Estudio

La zona de estudio seleccionada para el desarrollo del proyecto es la Comunidad Autónoma de Extremadura. Este ámbito territorial comprende un total de 20.889 hojas LiDAR de 1 × 1 km, distribuidas de manera heterogénea a lo largo de la región. La selección de dichas hojas ha sido determinada por la dirección técnica del Instituto Geográfico Nacional (IGN), atendiendo a información cartográfica complementaria, lo que explica la disposición espacial observada en el conjunto de datos analizados.

El enfoque propuesto para la clasificación automática de la nube de puntos LiDAR se estructura en dos fases principales, concebidas como un proceso secuencial y complementario. En una primera fase, se emplea un modelo basado en *Deep Learning* (DL) para realizar una clasificación inicial de la nube de puntos. Posteriormente, los resultados obtenidos son refinados mediante una fase de postprocesado, en la que se combinan reglas heurísticas y técnicas de *Machine Learning* (ML) con el objetivo de mejorar la coherencia espacial y la fiabilidad global de la clasificación.

Este planteamiento híbrido permite aprovechar la capacidad de generalización de los modelos de aprendizaje profundo junto con mecanismos adicionales de ajuste que contribuyen a reducir errores residuales y

a adaptar los resultados a las características específicas de los datos y del ámbito de aplicación.

2.2. Conjunto de datos

El conjunto de datos empleado para el entrenamiento y evaluación del modelo de *Deep Learning* está compuesto por nubes de puntos LiDAR de la tercera cobertura del PNOA-LiDAR, etiquetadas conforme a una adaptación del estándar ASPRS. Las clases consideradas están representadas en la Tabla 1.

Tabla 1. Clases consideradas.

Código ASPRS	Nombre de la clase	Código ASPRS	Nombre de la clase
1	Fondo / Otros	11	Carreteras
2	Suelo	17	Puentes
3	Vegetación baja	68	Vehículos
4	Vegetación media	15	Torres eléctricas
5	Vegetación alta	14	Cables eléctricos
6	Edificios	64	Aerogeneradores
9	Agua	67	Placas solares
10	Ferrocarril	203	Ruido

Con el fin de garantizar una adecuada representatividad espacial y temática, el *dataset* se ha construido a partir de aproximadamente 10.000 teselas de 50 × 50 metros, distribuidas por el conjunto del territorio de Extremadura. La selección de dichas teselas se ha realizado mediante un proceso de estratificación, teniendo en cuenta diferentes indicadores de heterogeneidad derivados de capas cartográficas y temáticas proporcionadas por el Instituto Geográfico Nacional (IGN), por ejemplo: BTN, RT y LiDAR segunda cobertura. Este enfoque permite capturar la variabilidad espacial y estructural de los distintos elementos asociados a cada clase, así como sus particularidades geométricas y contextuales. De esta manera, se maximizan los puntos de las clases minoritarias en área y ocurrencia (por ejemplo: los aerogeneradores en Extremadura) permitiendo una distribución de puntos más equilibrada.

El proceso de etiquetado de los datos se ha llevado a cabo mediante una estrategia semiautomática, combinando técnicas automáticas de clasificación de nube de puntos inicial mediante GeoSAM (Sultan *et al.*, 2025) con una fase posterior de revisión y refinado manual. Este procedimiento permite alcanzar un equilibrio entre eficiencia en la generación de etiquetas y calidad en la anotación final, especialmente relevante en escenarios complejos o con alta densidad de elementos.

Adicionalmente, con el objetivo de mejorar la capacidad de generalización del modelo y aumentar la robustez frente a variaciones espaciales y geométricas, se ha aplicado una estrategia de aumento de datos (*data augmentation*) durante el entrenamiento. Dicho aumento se realiza de forma dinámica y en tiempo de ejecución, sin generar nuevos ficheros persistentes, e incluye transformaciones espaciales y estructurales tales como

rotaciones, traslaciones, reflejos, deformaciones geométricas y modificaciones controladas en la densidad de puntos. Este enfoque contribuye a enriquecer el espacio de aprendizaje del modelo sin incrementar el volumen almacenado del *dataset*.

2.3. Preprocesado de datos

Como parte del preprocesado de los datos, se llevó a cabo un estudio exhaustivo de los predictores empleados en los modelos de clasificación. En particular, se analizó la distribución estadística de las variables espectrales y geométricas disponibles —incluyendo los canales R, G y B, el canal NIR, la coordenada altimétrica (Z) y la intensidad del retorno— mediante el estudio de sus histogramas y estadísticas descriptivas, con el fin de evaluar la capacidad de separabilidad de cada predictor entre las distintas clases temáticas. Previamente a su uso en el modelo, todas las variables fueron normalizadas a un rango común [0,1], lo que permitió homogeneizar las escalas, mejorar la estabilidad numérica del entrenamiento y facilitar la comparación relativa entre predictores. Este análisis se integró en un proceso iterativo de ajuste del modelo y de definición de tareas de postprocesado orientadas a mejorar la coherencia y precisión de la clasificación final.

2.4. Modelo DL - KPConv

Para la clasificación de la nube de puntos se adoptó un modelo basado en convoluciones sobre puntos, concretamente una arquitectura inspirada en KPConv (*Kernel Point Convolution*). Este tipo de modelos está especialmente diseñado para trabajar directamente con geometría no estructurada, evitando la necesidad de rasterización o voxelización previa de los datos.

El modelo se basa en una arquitectura de convolución específicamente diseñada para operar directamente sobre nubes de puntos, donde las convoluciones se definen en el espacio tridimensional a partir de conjuntos locales de puntos (*kernel points*). Este enfoque permite capturar de forma eficaz la geometría local y su contexto espacial, adaptándose a la irregularidad inherente de los datos LiDAR. En este trabajo, la configuración del modelo se ha centrado en un reducido conjunto de hiperparámetros considerados clave para su comportamiento, como el tamaño y el radio de los kernels de convolución, que determinan el nivel de detalle geométrico capturado, así como las estrategias de muestreo y reducción de resolución empleadas a lo largo de la red. Adicionalmente, el proceso de entrenamiento se ha ajustado mediante parámetros globales como la tasa de aprendizaje y el número máximo de épocas, combinados con criterios de parada temprana, con el objetivo de garantizar una convergencia estable y un buen equilibrio entre precisión y eficiencia computacional.

2.5. Postprocesado

El postprocesado tiene como objetivo refinar y completar la clasificación inicial obtenida por el modelo de DL, incorporando información adicional derivada del análisis geométrico y espacial de la nube de puntos extraída mediante el software CloudCompare v2.13.2. Esta etapa se apoya en un conjunto de variables descriptoras

calculadas a partir del vecindario local de cada punto, ampliamente utilizadas en el análisis de nubes de puntos tridimensionales.

Entre las variables consideradas se incluyen vectores normales, descriptores basados en análisis de componentes principales (PCA) —como valores propios y métricas derivadas—, así como indicadores de dispersión, anisotropía, planaridad, linealidad, esfericidad y verticalidad. Asimismo, se emplean descriptores relacionados con la rugosidad y curvatura de la superficie, medidas de densidad local y variables geométricas asociadas a la distribución espacial de los puntos. Estas características permiten caracterizar de forma más precisa la estructura local de los distintos elementos del territorio desde un punto de vista complementario al modelo de DL.

A partir de dichas variables, se aplicó una estrategia de decisión basada en modelos y reglas, diseñada para actuar de manera selectiva sobre determinadas clases. Este proceso combina árboles de decisión y operaciones de suavizado espacial, manteniendo sin modificación aquellas clases que presentan un alto grado de confianza en la clasificación inicial y centrando el refinamiento en clases con mayor complejidad geométrica o menor coherencia espacial.

2.6. Metodología de Evaluación

La evaluación del enfoque propuesto se realizó sobre un conjunto de datos independiente del entrenamiento, compuesto por 2.000 muestras distribuidas homogéneamente por el territorio de Extremadura y seleccionadas para garantizar la representación de todas las clases temáticas consideradas. La validación combinó un análisis cuantitativo, basado en métricas estándar de clasificación ampliamente utilizadas en el ámbito LiDAR —incluyendo la matriz de confusión, la precisión, el *recall*, la exactitud global (*accuracy*) y el F1-score—, con un análisis cualitativo orientado a la inspección visual y a la coherencia espacial de los resultados. Este análisis cualitativo fue llevado a cabo por personal experto mediante áreas no vistas durante el entrenamiento, permitiendo evaluar la capacidad de generalización del modelo y detectar posibles inconsistencias espaciales. Adicionalmente, los resultados fueron sometidos a un proceso de validación independiente por parte del Instituto Geográfico Nacional, realizado sobre áreas distintas a las empleadas en la evaluación interna y no conocidas por los autores, reforzando así la robustez y generalización del enfoque propuesto.

3. RESULTADOS

Los resultados cuantitativos se presentan de forma resumida en una tabla comparativa (Tabla 2), en la que se contrastan las métricas obtenidas directamente tras la fase de DL con aquellas resultantes tras la aplicación de la fase de postprocesado. El análisis de dicha tabla pone de manifiesto una mejora consistente de las métricas al incorporar los algoritmos de refinamiento, lo que confirma la aportación positiva del enfoque híbrido propuesto, obteniendo una Precisión global del 88,2 %.

Tabla 2. Rendimiento global de la clasificación. La Precisión, Recall y F-Score son los rendimientos obtenidos después de aplicar el postprocesado, y Dif. DL es la diferencia entre antes y después del postprocesado.

Clase	Precisión final (%)	Recall (%)	F1-score (%)	Dif. DL / Postproc (%)
Suelo	87,1	95,6	91,2	+0,4
Vegetación baja	67,0	33,4	44,5	+10,7
Vegetación media	82,9	91,5	87,0	-0,1
Vegetación alta	99,2	95,0	97,0	-0,4
Edificios	96,7	96,6	96,7	-0,2
Agua	98,1	91,2	94,5	-2,1
Ferrocarril	79,3	87,0	83,0	+3,5
Carreteras	81,5	82,6	82,0	+2,3
Puentes	97,1	87,1	91,8	+4,2
Vehículos	96,8	78,8	86,9	0,0
Torres eléctricas	86,5	79,1	82,7	0,0
Cables eléctricos	94,1	92,1	93,1	0,0
Aerogeneradores	100,0	88,9	94,1	0,0
Placas solares	92,6	83,5	87,8	+0,7

Finalmente, el análisis visual de los resultados se complementa con ejemplos gráficos representativos (Figura 1). En particular, se observa una mejora notable en la uniformidad de la clase de vegetación baja, cuya discriminación respecto al suelo presenta una mayor subjetividad, sobre todo en zonas donde la vegetación baja está muy apelmazada al suelo. Asimismo, en las clases asociadas a infraestructuras lineales, como carreteras y ferrocarril, el postprocesado contribuye a una mayor continuidad espacial y reducción de fragmentaciones, lo que redundará en resultados más coherentes desde el punto de vista cartográfico y operativo.




Figura 1. Ejemplos de resultados. Imagen en RGB (izq.), resultados de DL (centro) y resultados finales tras postprocesado (dcha.). Leyenda: suelo (azul), edificios (verde claro), vegetación (verde oscuro).

4. CONCLUSIONES Y TRABAJOS FUTUROS

Este proyecto permite extraer conclusiones relevantes tanto sobre el uso de DL como sobre la aportación del postprocesado en la clasificación de nubes de puntos LiDAR. Los resultados ponen de manifiesto la importancia de disponer de un conjunto de datos bien distribuido espacial y temáticamente, ya que una adecuada representatividad del territorio permite

entrenar modelos de DL con un alto nivel de desempeño utilizando un volumen de muestras contenido. Este enfoque facilita un proceso de entrenamiento iterativo e incremental, reduciendo los tiempos de etiquetado y permitiendo la incorporación progresiva de nuevas muestras en aquellas clases o zonas donde se detectan limitaciones. Asimismo, este flujo de trabajo presenta un alto potencial de escalabilidad, se pueden ampliar las clases en la clasificación, y es operacional, se puede aplicar al resto de España en un tiempo de máquina razonable (2 minutos por hoja de 1×1 km).

En cuanto al postprocesado, este actúa como una etapa complementaria orientada a refinar la clasificación inicial del modelo de DL. Si bien el margen de mejora global es limitado debido al buen desempeño general del modelo, se observan mejoras significativas en clases complejas como la vegetación baja, así como en elementos lineales como carreteras, ferrocarril y puentes, donde se incrementa la continuidad espacial y la coherencia de los resultados. No obstante, el postprocesado presenta una dependencia directa de las predicciones del modelo de DL y conlleva un aumento del tiempo de ejecución, por lo que resulta clave encontrar un equilibrio entre mejora en precisión y coste computacional.

5. AGRADECIMIENTOS

Este trabajo ha sido desarrollado en el marco de un contrato de licitación con el Instituto Geográfico Nacional (IGN), en el contexto del Plan de Recuperación, Transformación y Resiliencia, y ha sido financiado por la Unión Europea – NextGenerationEU. Por otro lado, la investigación realizada por la UPV ha sido financiada con Ayuda a Primeros Proyectos de Investigación (PAID-06-23), Vicerrectorado de Investigación de la Universitat Politècnica de València (UPV).

6. REFERENCIAS

- Jing, Z., Guan, H., Zhao, P., Li, D., Yu, Y., Zang, Y., ... & Li, J. (2021). Multispectral LiDAR point cloud classification using SE-PointNet++. *Remote Sensing*, 13(13), 2516.
- Kowalczyk, Z., & Szymański, K. (2019). Classification of objects in the LIDAR point clouds using Deep Neural Networks based on the PointNet model. *IFAC-PapersOnLine*, 52(8), 416-421.
- Montero-Calvo, A. J., Martín-Tardío, M. A., & Felicísimo, Á. M. (2025). Automated Morphological Characterization of Mediterranean Dehesa Using a Low-Density Airborne LiDAR Technique: A DBSCAN-Concaveman Approach for Segmentation and Delineation of Tree Vegetation Units. *Forests*, 17(1), 16.
- Sultan, R. I., Li, C., Zhu, H., Khanduri, P., Brocanelli, M., & Zhu, D. (2024). GeoSAM: Fine-tuning SAM with multi-modal prompts for mobility infrastructure segmentation. *arXiv preprint arXiv:2311.11319*.
- Thomas, H., Qi, C. R., Deschaud, J. E., Marcotegui, B., Goulette, F., & Guibas, L. J. (2019). Kpconv: Flexible and deformable convolution for point clouds. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 6411-6420).