

Morales-Martín, A.; Mesas-Carrascosa, F.; Pérez-Porras, F.; Vargas, V.; Moreno-Cano, F.; Gutiérrez, P. Evaluación del potencial de los modelos de Deep Learning para la clasificación de árboles a nivel de género utilizando datos LiDAR

Evaluación del potencial de los modelos de Deep Learning para la clasificación de árboles a nivel de género utilizando datos LiDAR

Morales-Martín, Alejandro¹ **Mesas-Carrascosa, Francisco Javier**² **Pérez-Porras, Fernando**² **Vargas, Víctor Manuel**¹ **Moreno-Cano, Francisco**¹ **Gutiérrez, Pedro Antonio**¹

¹ Universidad de Córdoba. Departamento de Ciencia de la Computación e Inteligencia Artificial. Edif. Albert Einstein (C2)–3ª Planta. Campus de Rabanales Ctra. N-IV km. 396 C.P. 14071, Córdoba, España.

² Universidad de Córdoba. Departamento de Ingeniería Gráfica y Geomática. Edif. Gregor Mendel (C5)–2ª Planta. Campus de Rabanales Ctra. N-IV km. 396 C.P. 14071, Córdoba, España.

ORCID: Morales-Martín 0000-0003-1133-237X Mesas-Carrascosa 0000-0002-5674-1292 Pérez-Porras 0000-0003-4263-2260 Vargas 0000-0002-0700-275X Moreno-Cano 0009-0004-8992-5938 Gutiérrez 0000-0002-2657-776X

Correspondencia: g52moma@uco.es ig2mecaf@uco.es o12pepof@uco.es vvargas@uco.es i02mocaf@uco.es pagutierrez@uco.es

RESUMEN

La identificación y reconocimiento de especies forestales es crucial en el sector agroforestal para garantizar una gestión adecuada de los recursos naturales, promover la conservación de la biodiversidad, optimizar los servicios ecosistémicos y mejorar la productividad y sostenibilidad de los ecosistemas forestales. Los avances en Deep Learning (DL) han revolucionado esta tarea, permitiendo el procesamiento y el análisis de datos LiDAR aéreos y terrestres. En este contexto, el presente estudio evalúa el potencial de dos redes neuronales, PointNet y PointNet++, para clasificar individuos en áreas forestales donde coexisten principalmente tres géneros: Eucalyptus, Pinus y Quercus. Dos técnicas de muestreo efectivas (FPS y SMOTE) se aplicaron para determinar la densidad de puntos óptima por árbol. Los análisis estadísticos basados en Kolmogorov-Smirnov y la prueba t de Student revelaron que el número de puntos y la metodología óptimas fueron 1.024, 2.048 y 4.096, y PointNet++, respectivamente. Por lo tanto, la metodología propuesta servirá como base para futuros trabajos que requieran una clasificación precisa, tales como cambios en hábitat y ecosistemas, secuestro de carbono e inventarios forestales.



Palabras clave: nube de puntos LiDAR, Deep Learning, clasificación de árboles, técnicas de muestreo.

Fecha de recepción: 7 febrero 2026 · Fecha de aceptación: 7 febrero 2026

Evaluación del potencial de los modelos de Deep Learning para la clasificación de árboles a nivel de género utilizando datos LiDAR

Morales-Martín, Alejandro ⁽¹⁾, Mesas-Carrascosa, Francisco Javier ⁽²⁾, Pérez-Porras, Fernando ⁽²⁾, Vargas, Víctor Manuel ⁽¹⁾, Moreno-Cano, Francisco ⁽¹⁾, Gutiérrez, Pedro Antonio ⁽¹⁾

⁽¹⁾ Universidad de Córdoba. Departamento de Ciencia de la Computación e Inteligencia Artificial., España.

 0000-0003-1133-237X, g52momaa@uco.es ;  0000-0002-0700-275X, vvargas@uco.es.

 0009-0004-8992-5938, i02mocaf@uco.es ;  0000-0002-2657-776X, pagutierrez@uco.es.

⁽²⁾ Universidad de Córdoba. Departamento de Ingeniería Gráfica y Geomática., España.

 0000-0002-5674-1292, ig2mecaf@uco.es ;  0000-0003-4263-2260, o12pepof@uco.es.

Resumen: La identificación y reconocimiento de especies forestales es crucial en el sector agroforestal para garantizar una gestión adecuada de los recursos naturales, promover la conservación de la biodiversidad, optimizar los servicios ecosistémicos y mejorar la productividad y sostenibilidad de los ecosistemas forestales. Los avances en *Deep Learning* (DL) han revolucionado esta tarea, permitiendo el procesamiento y el análisis de datos LiDAR aéreos y terrestres. En este contexto, el presente estudio evalúa el potencial de dos redes neuronales, PointNet y PointNet++, para clasificar individuos en áreas forestales donde coexisten principalmente tres géneros: *Eucalyptus*, *Pinus* y *Quercus*. Dos técnicas de muestreo efectivas (FPS y SMOTE) se aplicaron para determinar la densidad de puntos óptima por árbol. Los análisis estadísticos basados en Kolmogorov-Smirnov y la prueba *t* de Student revelaron que el número de puntos y la metodología óptimas fueron 1.024, 2.048 y 4.096, y PointNet++, respectivamente. Por lo tanto, la metodología propuesta servirá como base para futuros trabajos que requieran una clasificación precisa, tales como cambios en hábitat y ecosistemas, secuestro de carbono e inventarios forestales.

Palabras clave: nube de puntos LiDAR, *Deep Learning*, clasificación de árboles, técnicas de muestreo.

Assessment of the potential of Deep Learning models for tree classification at genus level using LiDAR data

Abstract: Identifying and recognizing forest tree species is important in the agroforestry sector to ensure proper management of natural resources, promote biodiversity conservation, optimize ecosystem services, and ameliorate productivity and sustainability of forest ecosystems. Advances in *Deep Learning* (DL) have revolutionized this task, allowing the processing and analysis of aerial and terrestrial LiDAR data. In this context, this study assesses the potential of two neural networks, PointNet and PointNet++, to classify trees in forest areas where three main genera coexist: *Eucalyptus*, *Pinus*, and *Quercus*. Two effective sampling techniques (FPS and SMOTE) were applied to determine the optimal point density per tree. Statistical analyses based on Kolmogorov-Smirnov and Student's *t*-test revealed that the optimal number of points and methodology were 1,024, 2,048, and 4,096, and PointNet++, respectively. Thus, the proposed methodology will serve as a basis for future work requiring accurate classification, such as changes in habitat and ecosystems, carbon sequestration, and forest inventories.

Keywords: LiDAR point cloud, *Deep Learning*, tree classification, sampling techniques.

1. INTRODUCCIÓN

La tecnología de detección y rango de luz (LiDAR) se ha consolidado como una herramienta clave para la adquisición precisa de información tridimensional del entorno. En paralelo, los avances recientes en el campo de la Inteligencia Artificial, y en particular del *Deep Learning* (DL), han proporcionado metodologías eficaces para la clasificación y segmentación automática de nubes de puntos 3D (Qi *et al.*, 2017a; Qi *et al.*, 2017b). En el sector agroforestal, el LiDAR permite caracterizar los ecosistemas forestales, su estructura y composición, gracias a su despliegue desde plataformas terrestres, móviles y aéreas (Wang & Menenti, 2021). Estos sistemas permiten una descripción precisa de la geometría de las copas, la distribución vertical de la vegetación y la estructura forestal interna, constituyendo una herramienta importante para la gestión forestal, la estimación de la biomasa, el inventario forestal y el monitoreo ecológico (Allen *et al.*, 2023). La creciente disponibilidad del escáner láser aerotransportado (ALS) ha permitido la expansión de estos análisis a áreas de gran escala, manteniendo la suficiente resolución como para llevar a cabo estudios a nivel de árbol individual y la caracterización de sus atributos estructurales individuales.

A pesar de los avances en esta línea de investigación, la clasificación de árboles en áreas forestales sigue siendo un desafío ya que tradicionalmente se ha hecho por métodos geométricos y estadísticos diseñados para caracterizar masas forestales o estructuras globales, los cuales resultan limitados cuando se pretende discriminar y clasificar árboles a nivel individual (Fassnacht *et al.*, 2016). La alta heterogeneidad en la densidad de puntos LiDAR presente en cada árbol dificulta la extracción de características y patrones complejos en los modelos de DL de forma estandarizada. Por ello, es indispensable el uso de diferentes técnicas de muestreo que, sin alterar la información geométrica y espacial de la muestra, solucionen este problema para el uso y aplicación de DL.

Por tanto, los objetivos de este trabajo son: (1) evaluar el potencial de las redes neuronales PointNet y PointNet++ en la clasificación de árboles a nivel de género y (2) determinar y validar la densidad de puntos sintéticos óptima por árbol requerida en dichas redes neuronales mediante dos técnicas de muestreo: *Farthest Point Sampling* (FPS) y *Synthetic Minority Oversampling Technique* (SMOTE).

2. MATERIAL Y MÉTODOS

2.1. Área de estudio y adquisición datos LiDAR

Las nubes de puntos LiDAR empleadas fueron generadas a partir del vuelo realizado el 18 de febrero de 2018 en la provincia de Lugo, España (Fig. 1). Para ello, se utilizó un helicóptero tripulado (Eurocopter AS-350 B2), equipado con un escáner láser terrestre de alto rendimiento (RIEGL modelo VQ-480i) y una cámara óptica (Phase One).

La Figura 2 ilustra a modo de esquema el flujo de trabajo seguido en este estudio. Tras adquirir las nubes de puntos 3D, se delimitaron las áreas de interés

correspondientes a los géneros objeto de estudio (*Eucalyptus*, *Pinus* y *Quercus*) mediante fotointerpretación gracias a las ortofotos generadas en el mismo vuelo. Posteriormente, se realizó la segmentación de árboles, un paso esencial porque PointNet y PointNet++ están diseñados para procesar objetos discretos individuales.

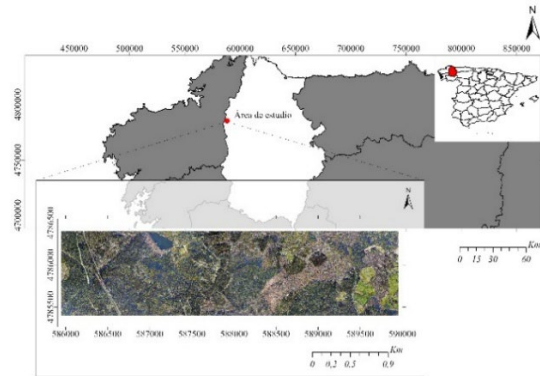


Figura 1. Área de estudio (ETRS89/UTM zona 29N).

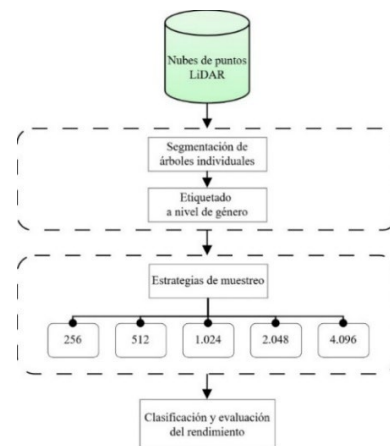


Figura 2. Proceso para la clasificación de árboles a nivel de género.

En primer lugar, los datos LiDAR fueron sometidos a un preprocesado (eliminación de ruido, filtrado de puntos de suelo y normalización) y, posteriormente, una segmentación de árboles individuales mediante el paquete *lidR* de R (Roussel *et al.*, 2020). Para la segmentación de los árboles se usó algoritmo de Dalponte y Coomes (2016), los cuales se refinaron y etiquetaron manualmente con CloudCompare (<https://www.cloudcompare.org/>).

Una vez aisladas las copas de los árboles individuales para disponer de ellas como verdad terreno, cada árbol segmentado recibió una etiqueta taxonómica a nivel de género mediante clasificación supervisada. En total, se extrajeron 2.849 árboles del área de estudio, incluyendo cada uno de los géneros dominantes: *Eucalyptus* (779 árboles), *Pinus* (1.134 árboles) y *Quercus* (937 árboles). En el caso de *Quercus*, en la zona de vuelo sólo había presencia de especies dominantes caducifolias. Este conjunto de datos se dividió de manera estratificada en entrenamiento (60%), validación (20%) y test (20%), respectivamente.

2.2. Estrategias de muestreo

Dado que PointNet y PointNet++ (Qi *et al.*, 2017a; Qi *et al.*, 2017b) requieren un número fijo de puntos por árbol, se emplearon dos técnicas de muestreo, FPS (Qi *et al.*, 2017b) y SMOTE (Kovács, 2019). Las densidades medias de puntos por árbol fueron 350 (*Eucalyptus*), 2.500 (*Pinus*) y 3.000 (*Quercus*). Se usó SMOTE para incrementar la densidad y FPS en los casos que hubo que reducir dicha métrica. Para evaluar cómo las variaciones en el tamaño de la muestra afectan la precisión y confiabilidad de la clasificación, este estudio probó cinco densidades diferentes: 256, 512, 1.024, 2.048 y 4.096 puntos por árbol. Mientras que el algoritmo FPS reduce uniformemente el número de puntos, el algoritmo SMOTE lo aumenta mediante la selección de los puntos vecinos más cercanos de cada punto minoritario y la interpolación de nuevas coordenadas en el espacio tridimensional (Fig. 3).

Estos conjuntos se utilizaron como entradas de los dos modelos de DL basados en puntos. Finalmente, se evaluó el rendimiento de cada uno para determinar qué combinación de modelo y tamaño de muestreo logra los mejores resultados de clasificación.

La metodología propuesta se implementó en PyTorch Lightning utilizando el método de retención, con 20 ejecuciones independientes y 20 semillas distintas. El proceso de entrenamiento consistió en 100 épocas, con un tamaño de lote de 32. Además, se empleó el método de optimización Adam con una tasa de aprendizaje de 0,001 (Kingma & Ba, 2015).




Figura 3. Resultado de la aplicación de los algoritmos de muestreo FPS (a) y SMOTE (b).

Finalmente, se aplicaron distintas métricas de evaluación con el fin de comparar y analizar cuantitativamente el rendimiento de cada modelo:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

donde TP representa los verdaderos positivos, TN los verdaderos negativos, FP los falsos positivos y FN los falsos negativos.

3. RESULTADOS Y DISCUSIÓN

Se emplearon los análisis estadísticos de Kolmogorov-Smirnov y la prueba *t* de Student para evaluar el efecto de la densidad de puntos en PointNet y PointNet++. Como se muestra en la Figura 4, se observaron diferencias significativas en el rendimiento promedio de todas las métricas descritas, influenciadas por el número de puntos (256, 512, 1.024, 2.048 y 4.096) y la metodología escogida (PointNet y PointNet++). Como resultado, el número de puntos y la metodología óptimos resultaron ser 1.024, 2.048 y 4.096 y PointNet++, respectivamente, en los cuales no se observaron diferencias significativas entre ellos.

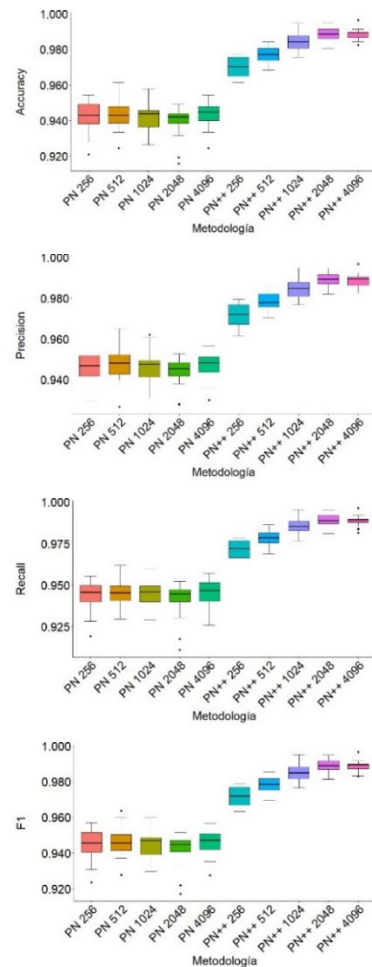


Figura 4. Efecto de la densidad de puntos en PointNet (PN) y PointNet++ (PN++).

Asimismo, en la Figura 5 se muestran las matrices de confusión de PointNet y PointNet++ para 1.024 puntos. Al utilizar la red neuronal de PointNet++, se predijeron con alta fiabilidad las tres clases (*Eucalyptus*, *Pinus* y *Quercus*), obteniendo una exactitud global del 98,7%. Esto demuestra que las técnicas de generación de datos sintéticos, son óptimas para un uso previo a la clasificación con redes neuronales basadas en nubes de puntos.




Figura 5. Matrices de confusión de las redes neuronales PointNet (a) y PointNet++ (b).

Otros autores han empleado diversas técnicas de submuestreo en datos LiDAR, e.g., FPS, K-means, muestreo aleatorio, muestreo en cuadrículas uniformes y muestreo en cuadrículas no uniformes, siendo FPS la opción más adecuada según Liu *et al.* (2022). No obstante, el uso de técnicas de sobremuestreo es poco frecuente, ya que la mayoría de los estudios previos trabajan con nubes de puntos LiDAR de alta densidad o con otros algoritmos que no necesitan una densidad fija de puntos por árbol. Por lo tanto, si la densidad de la nube de puntos LiDAR es baja, conviene utilizar la metodología propuesta para aumentarla y disponer de un número mínimo de puntos para la clasificación de especies.

En relación con el tamaño de la muestra, para este tipo de problema es innecesario considerar más de 1.024 puntos. Estos resultados contrastan con los reportados en otros estudios, que recomiendan el muestreo de 2.048 puntos por árbol (Liu *et al.*, 2022; Fan *et al.*, 2023). Esta discrepancia podría explicarse por la baja densidad observada en los árboles del género *Eucalyptus*, lo que hizo necesario aplicar técnicas de sobremuestreo para generar puntos sintéticos. Según estos investigadores, el incremento del número de puntos en la muestra no conlleva una mejora significativa en la precisión de clasificación del modelo y, en la mayoría de los casos, conduce al sobreajuste. Por todo ello, la selección de un tamaño de muestra óptimo permite preservar la geometría del árbol, al tiempo que se controlan los requisitos computacionales y de memoria.

4. CONCLUSIONES

Gracias a la utilización de las técnicas de muestreo, se optimizaron las redes neuronales de PointNet y PointNet++ para la clasificación de árboles en entornos complejos como son las áreas forestales. La metodología propuesta sirve como base de futuros trabajos forestales que requieran una clasificación precisa del arbolado.

5. AGRADECIMIENTOS

Esta investigación ha sido financiada por la Agencia Estatal de Investigación (AEI), del Ministerio de Ciencia, Innovación y Universidades (PID2023-150663NB-C22/AEI/10.13039/501100011033); la Comisión Europea, proyecto *Test and Experiment Facilities for the Agri-Food Domain*, AgriFoodTEF (DIGITAL-2022-CLOUD-AI-02, 101100622) y la Cátedra Internacional ENIA de Inteligencia Artificial y Agricultura (TSI-100921-2023-3). Alejandro Morales es investigador pre-doctoral FPU (FPU21/03433).

6. REFERENCIAS

Allen, M. J., Grieve, S. W., Owen, H. J., & Lines, E. R. (2023). Tree species classification from complex laser scanning data in Mediterranean forests using deep learning. *Methods in Ecology and Evolution*, 14(7), 1657-1667. <https://doi.org/10.1111/2041-210X.13981>.

Dalponte, M., Coomes, D.A. (2016). Tree-centric Mapping of Forest Carbon Density from Airborne Laser Scanning and Hyperspectral Data. *Methods in Ecology and Evolution*, 7, 1236-1245. <https://doi.org/10.1111/2041-210X.12575>.

Fan, Z., Wei, J., Zhang, R., & Zhang, W. (2023). Tree Species Classification Based on PointNet++ and Airborne Laser Survey Point Cloud Data Enhancement. *Forests*, 14(6), 1246. <https://doi.org/10.3390/f14061246>.

Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., ... & Ghosh, A. (2016). Review of studies on tree species classification from remotely sensed data. *Remote sensing of environment*, 186, 64-87. <https://doi.org/10.1016/j.rse.2016.08.013>.

Kingma, D. P., Ba, J. (2015). Adam: A method for stochastic optimization. En *3rd International Conference for Learning Representations*. San Diego.

Kovács, G. (2019). An empirical comparison and evaluation of minority oversampling techniques on a large number of imbalanced datasets. *Applied Soft Computing*, 83, 105662. <https://doi.org/10.1016/j.asoc.2019.105662>.

Liu, B., Chen, S., Huang, H., & Tian, X. (2022). Tree Species Classification of Backpack Laser Scanning Data Using the PointNet++ Point Cloud Deep Learning Method. *Remote Sensing*, 14(15), 3809. <https://doi.org/10.3390/rs14153809>.

Qi, C.R., Su, H., Mo, K., Guibas, L. (2017a). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. En *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 77-85). Honolulu, HI, USA.

Qi, C.R., Yi, L., Su, H., Guibas, L.J. (2017b). PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space. En I. Guyon., U. Von Luxburg., S. Bengio., H. Wallach., R. Fergus., S. Vishwanathan., R. Garnett., (Eds), *Advances in Neural Information Processing Systems 30 (NIPS 2017)* (pp. 5099-5108).

Roussel, J.R., Auty, D., Coops, N.C., Tompalski, P., Goodbody, T.R., Meador, A.S., Bourdon, J.F., de Boissieu, F., Achim, A. (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251, 112061. <http://dx.doi.org/10.1016/j.rse.2020.112061>.

Wang, Z., & Menenti, M. (2021). Challenges and opportunities in Lidar remote sensing. *Frontiers in Remote Sensing*, 2, 641723. <https://doi.org/10.3389/frsen.2021.641723>.