

Garrido Sáenz de Tejada, J.; Ballester García-Asenjo, E.; Puchol Sola, G. Cambio de modelo productivo en el PNOA-LiDAR: clasificación semántica automática a escala nacional

Cambio de modelo productivo en el PNOA-LiDAR: clasificación semántica automática a escala nacional

Garrido Sáenz de Tejada, Jesús María ¹ Ballester García-Asenjo, Ernesto ¹ Puchol Sola, Guillermo ¹

¹ Instituto Geográfico Nacional, España

ORCID: Garrido Sáenz de Tejada [0009-0003-6632-5422](https://orcid.org/0009-0003-6632-5422) Ballester García-Asenjo [0009-0003-3991-0706](https://orcid.org/0009-0003-3991-0706) Puchol Sola [0009-0006-1841-3403](https://orcid.org/0009-0006-1841-3403)

Correspondencia: jmgarrido@transportes.gob.es isdefe.eballesteros@externomf.es gpuchol@transportes.gob.es

RESUMEN

La tercera cobertura del Plan Nacional Observación Aérea LiDAR (PNOA-LiDAR) incrementa significativamente la densidad de puntos y el número de clases objetivo, haciendo inviable mantener el flujo tradicional de clasificación basado en edición manual exhaustiva. Para abordar esta limitación, el Instituto Geográfico Nacional evaluó la implantación de un modelo de producción basado en clasificación semántica automática mediante aprendizaje profundo. Se desarrolló un proceso progresivo de validación que incluyó el análisis del estado del arte, tres proyectos piloto en ámbitos representativos del territorio (Castilla y León, Extremadura y Aragón) y su posterior incorporación al flujo productivo. Los pilotos permitieron comprobar la viabilidad inicial, la capacidad de generalización territorial y la estabilidad del modelo ante el aumento del número de clases. El análisis comparativo identificó como factores determinantes la calidad y representatividad del conjunto de entrenamiento, el entrenamiento iterativo y la integración de pre y postprocesado espacial. Las clases mayoritarias alcanzaron valores de F1 superiores a 0,90 y el postprocesado mejoró significativamente las clases minoritarias. Tras la validación, la clasificación automática se incorporó a producción, permitiendo generar productos multinivel (NPC1-NPC3) con más de veinte fenómenos geográficos y fiabilidad compatible con los estándares cartográficos oficiales. La producción se encuentra en ejecución para la totalidad del territorio nacional. La experiencia demuestra la madurez tecnológica de la clasificación automática y su viabilidad operativa a escala nacional, constituyendo un cambio de modelo productivo desde la edición manual hacia un sistema automatizado supervisado.

Palabras clave: LiDAR, PNOA-LiDAR, IA, nube de puntos.

Fecha de recepción: 16 febrero 2026 · Fecha de aceptación: 18 marzo 2026

Cambio de modelo productivo en el PNOA-LiDAR: clasificación semántica automática a escala nacional

Garrido Sáenz de Tejada, Jesús María ⁽¹⁾, Puchol Sola, Guillermo ⁽¹⁾, Ballestero García-Asenjo, Ernesto ⁽²⁾

⁽¹⁾ Instituto Geográfico Nacional, España.

 0009-0003-6632-5422, jmgarrido@transportes.gob.es;  0009-0006-1841-3403, gpuchol@transportes.gob.es.

⁽²⁾ Ingeniería de Sistemas para la Defensa.

 0009-0003-3991-0706, isdefe.eballesteros@externomf.es.

Resumen: La tercera cobertura del Plan Nacional Observación Aérea LiDAR (PNOA-LiDAR) incrementa significativamente la densidad de puntos y el número de clases objetivo, haciendo inviable mantener el flujo tradicional de clasificación basado en edición manual exhaustiva. Para abordar esta limitación, el Instituto Geográfico Nacional evaluó la implantación de un modelo de producción basado en clasificación semántica automática mediante aprendizaje profundo. Se desarrolló un proceso progresivo de validación que incluyó el análisis del estado del arte, tres proyectos piloto en ámbitos representativos del territorio (Castilla y León, Extremadura y Aragón) y su posterior incorporación al flujo productivo. Los pilotos permitieron comprobar la viabilidad inicial, la capacidad de generalización territorial y la estabilidad del modelo ante el aumento del número de clases. El análisis comparativo identificó como factores determinantes la calidad y representatividad del conjunto de entrenamiento, el entrenamiento iterativo y la integración de pre y postprocesado espacial. Las clases mayoritarias alcanzaron valores de F1 superiores a 0,90 y el postprocesado mejoró significativamente las clases minoritarias. Tras la validación, la clasificación automática se incorporó a producción, permitiendo generar productos multinivel (NPC1-NPC3) con más de veinte fenómenos geográficos y fiabilidad compatible con los estándares cartográficos oficiales. La producción se encuentra en ejecución para la totalidad del territorio nacional. La experiencia demuestra la madurez tecnológica de la clasificación automática y su viabilidad operativa a escala nacional, constituyendo un cambio de modelo productivo desde la edición manual hacia un sistema automatizado supervisado.

Palabras clave: LiDAR, PNOA-LiDAR, IA, nube de puntos.

Implementation of Artificial Intelligence methodologies for point cloud classification in the PNOA-LiDAR project

Abstract: *The third coverage of the Spanish National Aerial LiDAR Observation Plan (PNOA-LiDAR) significantly increases point density and the number of target classes, making the traditional classification workflow based on exhaustive manual editing no longer feasible. To address this limitation, the Spanish National Geographic Institute evaluated the implementation of a production model based on automatic semantic classification using deep learning. A progressive validation process was carried out, including a state-of-the-art review, three pilot projects in representative areas (Castilla y León, Extremadura and Aragón), and their subsequent integration into the production workflow. The pilots allowed verification of initial feasibility, territorial generalization capability, and model stability when increasing the number of classes. Comparative analysis identified the most relevant factors as the quality and representativeness of the training dataset, iterative training, and the integration of spatial pre- and post-processing. Major classes achieved F1 scores above 0.90, while post-processing significantly improved minority classes. After validation, automatic classification was incorporated into production, enabling multi-level products (NPC1–NPC3) with more than twenty geographic phenomena and reliability compatible with official cartographic standards. Production is currently underway for the entire national territory. The experience demonstrates the technological maturity of automatic classification and its operational feasibility at national scale, representing a shift from manual editing towards a supervised automated production model.*

Keywords: LiDAR, PNOA-LiDAR, AI, pointcloud

evaluar la viabilidad técnica del modelo, su capacidad de generalización territorial y su estabilidad ante el aumento del número de clases.

En 2023 se desarrolló una primera prueba en el suroeste de Castilla y León (19.345 km²), utilizando datos de la segunda cobertura PNOA-LiDAR con una densidad similar a la tercera cobertura. En esta fase se entrenó un modelo con ocho clases semánticas (Tabla 2) a partir de nubes previamente clasificadas mediante metodología convencional y sometidas a un control de calidad, con el objetivo de comprobar la viabilidad del entrenamiento en condiciones controladas.

Tabla 2. Clases semánticas. Prueba piloto 1.

Clases	Descripción	Clases	Descripción
2	Suelo	9	Torres eléctricas
3	Veg. Baja (<30cm)	10	Vehículos
4	Veg media/alta	11	Cables eléctricos
6	Edificios	17	Puentes

Durante 2024 se ejecutaron dos nuevas pruebas en Extremadura y Aragón, (41.774 km²) con datos correspondientes a la tercera cobertura, ampliando el número de clases a catorce categorías (Tabla 3) y comparando distintos enfoques de entrenamiento basados en KPConv y Point Transformer.

Tabla 3. Clases semánticas. Prueba piloto Extremadura y Aragón

Clases	Descripción	Clases	Descripción
2	Suelo	11	Carreteras
3	Veg. Baja	64	Vehículos
4	Veg media	66	Señalización vertical carreteras
5	Veg. alta	7/18	Ruido/Artefactos
6	Edificios	1	S/C
9	Agua	14	Cables eléctricos
12	Exceso densidad	15	Torres eléctricas
17	Puentes	67	Paneles solares
10	Vías ffcc	68	Aerogeneradores

Las métricas obtenidas mediante F1-score mostraron resultados homogéneos entre las diferentes regiones, confirmando la capacidad de generalización territorial del modelo. Los resultados permitieron comprobar la estabilidad del entrenamiento y evaluar la clasificación de los fenómenos con una mayor complejidad semántica.

Cada piloto permitió validar de forma progresiva la viabilidad inicial, la generalización territorial y la estabilidad del modelo antes de su implantación operativa.

4. RESULTADOS Y LECCIONES APRENDIDAS

El análisis comparativo de los proyectos piloto permitió identificar factores determinantes para la implantación operativa del proceso en producción.

El factor más determinante en la calidad del resultado fue el conjunto de entrenamiento: calidad del etiquetado, número de muestras y, especialmente, su diversidad

territorial; influyendo directamente en la capacidad del modelo para generalizar comportamientos. Se evaluaron distintas estrategias de selección de muestras para cada zona piloto, adoptándose finalmente un enfoque similar al descrito en el dataset FRACTAL del IGN francés por ofrecer el mejor rendimiento en paisajes heterogéneos.

La variabilidad intrínseca asociada a la densidad en las nubes LiDAR, hizo necesario homogeneizar los ejemplos de entrenamiento mediante la subdivisión de las muestras en tiles con un número fijo de puntos. Este proceso permitió evitar sesgos derivados de la variabilidad geométrica de los datos durante el aprendizaje del modelo.

Asimismo, la normalización de las características resultó fundamental para el entrenamiento. Las coordenadas se ajustaron a rangos homogéneos, utilizando una normalización relativa en X e Y respecto al tamaño del tile y una normalización relativa en Z respecto a la cota mínima local, evitando dependencias de posición absoluta.

El entrenamiento se realizó de forma iterativa. En cada iteración se evaluaron las predicciones sobre el conjunto de validación mediante métricas objetivas, incorporando nuevas muestras representativas hasta alcanzar los umbrales de calidad definidos en la especificación.

Las métricas obtenidas mostraron que las clases básicas mayoritarias alcanzaban valores de F1-score superiores a 0,90. Para clases más avanzadas, la aplicación de técnicas de aumento de datos y postprocesado espacial mejoró significativamente los resultados.

Tabla 4. Métricas modelos DL Proyectos Piloto

	Modelo Dataset 1 Extremadura		Modelo Dataset 2 Aragón		Media F1	
	KPConv	PT	KPConv	PT		
Suelo	90,69		99,00			
Ferrocarril	80,54	89,60	95,30	58,40 97,92	98,78	95,40
Carreteras	79,48		70,10			
Veg. Baja	33,31		75,20			
Veg. Media	85,88	73,59	91,22	95,20 95,81	96,11	89,18
Veg. Alta	91,15		99,30			
Edificios	95,85	96,05	97,90	97,62		96,86
Agua	96,09					96,09
Puentes	88,57	83,18	76,70	71,38		79,96
Vehículos	74,41	77,72	88,50	89,41		82,51
Torres eléctricas	78,01	91,14	48,70	57,58		68,86
Cables eléctricos	91,60	96,73	94,20	96,60		94,78
Paneles solares	87,45	85,83	98,60	98,70		92,64
Aerogeneradores	67,74	90,85	80,70	96,34		83,91

Los resultados mostraron estabilidad en clases mayoritarias y mejora progresiva en clases minoritarias, lo que confirma la aplicabilidad del modelo en entornos heterogéneos.

La inferencia se ejecutó en centros de supercomputación mediante GPU, con un tiempo medio aproximado de 10 minutos por km², con escalabilidad

lineal respecto al número de nodos disponibles (por ejemplo, aproximadamente diez días para procesar más de 20.000 km² con 16 máquinas).

El postprocesado mediante técnicas GIS —basadas en análisis de vecindad, estadística espacial y reglas de decisión— permitió mejorar sensiblemente la calidad final, especialmente en clases lineales y elementos singulares como carreteras, ferrocarriles, torres eléctricas y aerogeneradores. La disponibilidad de fuentes cartográficas auxiliares resultó clave para la detección de errores y control de calidad.

En conjunto, los valores obtenidos y su estabilidad entre zonas piloto demostraron que la calidad alcanzada es compatible con los estándares de producción cartográfica oficial, permitiendo sustituir la fase de edición manual exhaustiva por un proceso de validación y control de calidad.

5. IMPLANTACIÓN Y PRODUCCIÓN NACIONAL

Tras la validación en los proyectos piloto, la clasificación semántica automática se incorporó al flujo productivo oficial del PNOA - LiDAR.

La implantación de la inteligencia artificial ha permitido ampliar el número de clases respecto a coberturas anteriores, identificándose más de veinte tipos de fenómenos geográficos en el nivel de procesamiento avanzado (NPC3), con fiabilidad superior al 90 % en trece clases básicas (NPC2) y superior al 70 % en las clases minoritarias adicionales.

Tabla 5. Niveles NPC y clases y fiabilidad

Clasificación	Clases	Fiabilidad F1 (%)
NPC1. Clasificación Automática	2 – Suelo	90,0 %
	3,4,5 – Veg. b/m/a	90,0 %
	6 – Edificios	90,0 %
NPC2. Clasificación Básica	2 – Suelo	95,0 %
	3,4,5 – Veg. b/m/a	95,0 %
	6 – Edificios	95,0 %
	9 – Agua	90,0 %
	14 – Cables eléctricos	90,0 %
	15 – Torres eléctricas	90,0 %
	17 – Puentes	90,0 %
	64 - Vehículos	90,0 %
	67 – Paneles solares	90,0 %
	68 - Aerogeneradores	90,0 %
NPC3. Clasificación Avanzada	65 – Cerramientos / muros	85,0 %
	69 – Presas	85,0 %
	71 – Cubierta edificio plana	70,0 %
	72 – Cubierta edificio inclinada	70,0 %
	73 – Cubierta edificio vegetal	70,0 %
	74 – Fachada	70,0 %
	75 – Patio interior	70,0 %

Adicionalmente, se publica de forma temprana una versión preliminar automática de la nube de puntos en

cinco clases (NPC1) con un nivel de fiabilidad estadística cercano al 90 %, permitiendo el acceso anticipado a la información por parte de los usuarios.

Para estos nuevos productos se han definido especificaciones técnicas que incluyen precisiones, definición de clases y procedimientos de control de calidad. La mejora de las capacidades del producto de nube de puntos clasificada permite dar respuesta a nuevas demandas de usuarios y ampliar sus aplicaciones.

Actualmente se dispone de producto NPC2 en las comunidades autónomas de Cantabria, Illes Balears, Extremadura, Aragón y Canarias, encontrándose en producción País Vasco, Galicia, La Rioja, Andalucía y Madrid. La producción se irá completando progresivamente durante los años 2026 y 2027 empleando infraestructuras de supercomputación, entre ellas el centro SCAYLE de la Junta de Castilla y León.

La automatización del proceso permite generar información clasificada de forma temprana y reduce la necesidad de edición manual exhaustiva, que pasa a centrarse en tareas de control de calidad.

La disponibilidad de resultados operativos a gran escala confirma la transición desde un proceso de clasificación manual asistida hacia un sistema de producción automatizado supervisado.

6. CONCLUSIONES

La aplicación de estas técnicas a la clasificación semántica de nubes de puntos LiDAR ha demostrado una madurez tecnológica suficiente para su implantación en una producción cartográfica oficial a escala nacional.

Los resultados obtenidos en los proyectos piloto muestran que la calidad final depende principalmente de la representatividad del conjunto de entrenamiento, del proceso iterativo de validación y de la integración de técnicas de pre y post procesado espacial, más que de la arquitectura concreta utilizada.

La implantación operativa ha permitido ampliar el número de clases disponibles, mejorando la precisión temática y permitiendo generar productos preliminares de forma temprana, manteniendo niveles de fiabilidad compatibles con los estándares de producción, reduciendo la dependencia de la edición manual exhaustiva, pasando a centrarse en tareas de control de calidad.

La implantación en curso para la totalidad del territorio nacional confirma el paso de un modelo de producción basado en clasificación manual a un modelo automatizado supervisado. Este cambio permite aumentar el nivel semántico del producto, mejorar la disponibilidad temporal de la información y optimizar los costes de producción por unidad de superficie, constituyendo una evolución estructural en la generación de información altimétrica oficial del PNOA-LiDAR.