

Bravo Núñez, A.; González, I.; Martín-Alcón, S.; Crespo-Peremarch, P.; Ruiz, L. Clasificación de usos de suelo en las Illes Balears a partir de datos en abierto mediante UNet

Clasificación de usos de suelo en las Illes Balears a partir de datos en abierto mediante UNet

Bravo Núñez, Andrés^{1,2} **González, Isabel**¹ **Martín-Alcón, Santiago**¹ **Crespo-Peremarch, Pablo**² **Ruiz, Luis Ángel**²

¹ Agresta COOP, España

² Universitat Politècnica de València

ORCID: Bravo Núñez 0009-0003-6650-3487 González 0009-0002-1455-9174 Martín-Alcón 0000-0002-5327-5695
Crespo-Peremarch 0000-0003-2241-4493 Ruiz 0000-0003-0073-7259

Correspondencia: abravo@agresta.org igonzaez@agresta.org smalcon@agresta.org pabcrepe@cgf.upv.es
laruiz@cgf.upv.es

RESUMEN

La clasificación de usos del suelo es fundamental para la gestión de territorio y puede abordarse mediante técnicas de aprendizaje profundo. Sin embargo, estos métodos suelen requerir grandes volúmenes de datos de entrenamiento. En este trabajo se presenta un flujo de trabajo para la clasificación de usos del suelo en las Illes Balears utilizando datos en abierto y una arquitectura UNet. Se integran imágenes multiespectrales Sentinel-2 con métricas derivadas de datos LiDAR del PNOA, y se armonizan distintas fuentes cartográficas abiertas (SIGPAC, Mapa Forestal Español y Mapa Topográfico Nacional) para generar las muestras de entrenamiento. Se consideran siete clases de uso del suelo: artificial, cultivos leñosos, cultivos herbáceos, pastizal, matorral, coníferas y frondosas. La evaluación sobre un conjunto independiente de validación alcanza una precisión global del 84,2% y un índice Kappa de Cohen de 0,785, con mejores resultados en las clases artificial y coníferas. Los resultados demuestran el potencial de los datos abiertos para la generación de cartografía de usos del suelo fiable a escala regional.

Palabras clave: Datos abiertos, UNet, Segmentación semántica, LIDAR, Sentinel2


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

Clasificación de usos de suelo en las Illes Balears a partir de datos en abierto mediante UNet



Bravo Núñez, Andrés ⁽¹⁾, González, Isabel ⁽¹⁾, Martín-Alcón, Santiago ⁽¹⁾, Crespo-Peremarch, Pablo ⁽²⁾, Ruiz, Luis Ángel ⁽²⁾

⁽¹⁾ Agresta COOP, España, Universitat Politècnica de València.

 0009-0003-6650-3487, abravo@agresta.org ;  0009-0002-1455-9174, igonzalez@agresta.org

 0000-0002-5327-5695, smalcon@agresta.org

⁽²⁾ Universitat Politècnica de València.

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

Resumen: La clasificación de usos del suelo es fundamental para la gestión de territorio y puede abordarse mediante técnicas de aprendizaje profundo. Sin embargo, estos métodos suelen requerir grandes volúmenes de datos de entrenamiento. En este trabajo se presenta un flujo de trabajo para la clasificación de usos del suelo en las *Illes Balears* utilizando datos en abierto y una arquitectura UNet. Se integran imágenes multispectrales Sentinel-2 con métricas derivadas de datos LiDAR del PNOA, y se armonizan distintas fuentes cartográficas abiertas (SIGPAC, Mapa Forestal Español y Mapa Topográfico Nacional) para generar las muestras de entrenamiento. Se consideran siete clases de uso del suelo: artificial, cultivos leñosos, cultivos herbáceos, pastizal, matorral, coníferas y frondosas. La evaluación sobre un conjunto independiente de validación alcanza una precisión global del 84,2% y un índice Kappa de Cohen de 0,785, con mejores resultados en las clases artificial y coníferas. Los resultados demuestran el potencial de los datos abiertos para la generación de cartografía de usos del suelo fiable a escala regional.

Palabras clave: Datos abiertos, UNet, Segmentación semántica, LIDAR, Sentinel2

Classification of land use in the Balearic Islands based on open data using UNet

Abstract: *Land use classification is a key task for territorial management and can be effectively addressed using deep learning techniques, although these approaches usually require large training datasets. This study presents a workflow for land use classification in the Balearic Islands based on open data and a UNet architecture. Multispectral Sentinel-2 imagery is combined with metrics derived from PNOA LiDAR data, while several open cartographic sources (SIGPAC, Spanish Forest Map and National Topographic Map) are harmonized to generate training samples. Seven land use classes are considered: artificial surfaces, woody crops, herbaceous crops, grassland, shrubland, coniferous forest and broadleaf forest. Validation on an independent dataset yields an overall accuracy of 84.2% and a Cohen's Kappa index of 0.785, with particularly strong performance for artificial and coniferous classes. These results highlight the potential of open data for reliable regional-scale land use mapping.*

Keywords: *Open data, UNet, Semantic segmentation, LIDAR, Sentinel2*

1. INTRODUCCIÓN

La monitorización precisa de los usos y coberturas del suelo es fundamental para la gestión del territorio. El conocimiento de cómo se distribuyen los usos del suelo resulta esencial en ámbitos como la planificación urbanística, la gestión de los recursos naturales o la evaluación del impacto del cambio climático. A pesar de su importancia, la actualización de esta información sigue representando un desafío técnico y económico. Esta brecha entre la demanda de información y la capacidad de producción ha favorecido la adopción de técnicas basadas en el aprendizaje profundo (*Deep*

Learning) para la segmentación semántica capaces de generar cartografía de manera casi automática.

Sin embargo, estos métodos necesitan grandes cantidades de datos de entrenamiento y la obtención de estos es costosa tanto en trabajo como económicamente. Para mitigar esta problemática existen diferentes estrategias. Una de ellas conocida como *active learning* busca reducir el esfuerzo de anotación seleccionando de forma iterativa un conjunto estratégico de muestras para ser anotadas por un experto (Chen, 2020). Otras estrategias habituales son la creación de nuevas muestras a partir de las disponibles (*data augmentation*) y la utilización de muestras que no están

completamente etiquetadas conocido como *weakly supervised learning* (Liang, 2020).

En este contexto, este trabajo propone un flujo de trabajo para la clasificación de usos de suelo, integrando datos espectrales de Sentinel-2 con información derivada de nubes de puntos LiDAR del PNOA (Instituto Geográfico Nacional) y el uso de técnicas de aprendizaje profundo. La metodología se centra en la armonización de fuentes cartográficas abiertas existentes con el objetivo de obtener un conjunto de etiquetas robusto que permita entrenar un modelo capaz de generalizar la clasificación en toda la zona de estudio, y se evalúan los resultados obtenidos para un conjunto de datos de las *Illes Balears*.

2. MATERIAL Y MÉTODOS

2.1. Área de estudio

El área de estudio corresponde a las *Illes Balears* con una superficie de 5040 km^2 . Las *Illes Balears* son un archipiélago de islas mediterráneas cuyas principales islas son Mallorca, Menorca, Formentera e Ibiza. A nivel de isla, Menorca posee una cubierta de bosques y de pastos para ganado en explotación extensiva. Formentera es semidesértica con vegetación dispersa dominada por arbustos, sabinas (*Juniperus phoenicea*) y pino carrasco (*Pinus halepensis*); y Mallorca e Ibiza tienen un paisaje similar dominado por tierras agrícolas y bosques de pino carrasco, aunque como particularidad, Mallorca contiene, la sierra de Tramontana. Además, en las últimas décadas las *Illes Balears* han tenido un gran desarrollo turístico. Todo esto causa que sea una región con gran diversidad paisajística lo que se traduce en un mayor desafío a la hora de realizar una clasificación de usos de suelo. Por otra parte, otra ventaja de tomar como zona de estudio las *Illes Balears* es que es una de las regiones que dispone de datos de la tercera cobertura LiDAR-PNOA que es la más actual (2024).

2.2. Fuentes de datos

Se utilizaron datos procedentes de fuentes abiertas, tanto para la construcción de las variables de entrada del modelo como para la generación de las muestras de entrenamiento.

Como datos de entrada se utilizaron datos LiDAR y Sentinel-2. Las imágenes Sentinel-2 corresponden a cuatro compuestos estacionales para el año 2024. Para su construcción se seleccionaron imágenes de 2024 con un porcentaje de nubes inferior al 30% y nivel de procesado L2A. Además, se enmascararon los píxeles cuya probabilidad de nube superaba el 30%. Los compuestos estacionales se construyeron calculando el valor mediano por píxel utilizando todas las imágenes. Se trabajó con 10 bandas (B, G, R, RE1, RE2, RE3, NIR, NNIR, SWIR1 y SWIR2) y un tamaño de píxel de 10 m. Los datos LiDAR provienen de la tercera cobertura del PNOA, corresponden al año 2024 en las *Illes Balears* y tienen una densidad nominal de 5 puntos m^2 . Estos datos se rasterizaron en R utilizando la función *gridmetrics* del paquete *lidR* (Roussel, 2021; Auty, 2023), generando un ráster de 53 métricas LiDAR alineado con la cuadrícula de píxeles de 10 m de Sentinel-2.

Para la construcción de las muestras de entrenamiento se utilizaron el Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC) del año 2025 (Ministerio de Agricultura, Pesca y Alimentación, s.f.), el Mapa Forestal Español (MFE) a escala 1:25000 (Ministerio para la transición ecológica y el reto demográfico, s.f.) y el Mapa Topográfico Nacional (MTN) 1:25000 (Ministerio de transportes y movilidad sostenible, s.f.). Además, como apoyo al proceso se utilizó la ortoimagen PNOA de máxima actualidad (2024).

2.3. Metodología

2.3.1. Construcción de las muestras de entrenamiento, prueba y validación

Para la generación de las muestras de entrenamiento (definidas como polígonos), se han armonizado el SIGPAC, el MFE y el MTN. Se han considerado siete clases en la clasificación: artificial, cultivo leñoso, cultivo herbáceo, pastizal, matorral, coníferas y frondosas. Habitualmente estas clasificaciones contienen una clase Agua, en nuestro caso se eliminó para simplificar el modelo, considerando la superposición de la clase agua a partir del mapa topográfico para obtener buenos resultados.

A partir de las clases del SIGPAC y el MFE, se realizó un reagrupamiento de clases para que coincidieran con las siete mencionadas. En los casos donde ninguna clase correspondía con las planteadas, se descartó el polígono. Únicamente se conservaron los polígonos con un área mínima de 1000 m^2 . Únicamente se conservaron como polígonos aquellas zonas en las que la clase indicada por el SIGPAC y el MFE coincidía,

Para intentar reducir la heterogeneidad en los polígonos, es decir, minimizar los casos en que el interior de un polígono contuviese más de una clase, se calculó el rango intercuartílico (IQR) del NDVI para cada combinación de cada polígono con cada uno de los cuatro compuestos estacionales. Para cada estación y clase de uso de suelo se eliminó el 20% de polígonos con mayor IQR. Este cálculo se realizó ignorando los píxeles correspondientes a agua y zonas edificadas (cuando el polígono no pertenecía a la clase artificial). Estos píxeles se detectaron con dos máscaras ráster una de agua y otra de zonas edificadas generadas con el Mapa Topográfico Nacional.

Los polígonos finales se dividieron en tres conjuntos: uno de entrenamiento, otro de prueba y un último de validación. Los conjuntos se construyeron mediante muestreo aleatorio estratificado por clase, de forma que representaran el 70%, el 10% y el 20% de la superficie total de cada clase en cada conjunto, respectivamente. La distribución del número y la superficie de los polígonos en las diferentes clases se muestra en la Tabla 1 donde se puede apreciar que las clases están desequilibradas. Concretamente, las clases de cultivo y coníferas tienen un orden de magnitud mayor, tanto en número como en superficie, con respecto al resto de clases.

A partir de la selección de polígonos de entrenamiento, las imágenes Sentinel-2 y el ráster LiDAR se generaron

chips de 128 × 128 píxeles con un solape del 50%, cubriendo toda la superficie de las islas. Las máscaras se limpiaron utilizando las máscaras creadas con el Mapa Topográfico Nacional, de modo que los píxeles de agua se marcaron como sin información y los píxeles artificiales se excluyeron de las clases no artificiales. Solo se conservaron aquellos chips que contenían algún polígono de entrenamiento. Esto dio la cantidad de 11560 chips. Para los polígonos de prueba y validación se realizó el mismo proceso, pero sin solape, obteniendo 2447 y 2694 chips, respectivamente.

Tabla 1. Distribución de los polígonos en los conjuntos de entrenamiento, prueba y validación y en las clases

Clase		Ent.	Prueba	Validación
Artificial	Nº	3951	638	864
	Área(ha)	4078	581	1164
C. leñoso	Nº	31014	4380	8890
	Área(ha)	21588	3084	6167
C. herbáceo	Nº	55990	7703	16389
	Área(ha)	39345	5620	11239
Pastizal	Nº	1227	200	324
	Área(ha)	1807	258	516
Matorral	Nº	1517	236	468
	Área(ha)	4646	514	1272
Coníferas	Nº	10824	1647	3085
	Área(ha)	17596	2498	5021
Frondosas	Nº	2232	240	688
	Área(ha)	6254	852	1775

2.3.2. Arquitectura del modelo y entrenamiento

Utilizando los datos descritos en el apartado anterior, se entrenó una red UNet desde su comienzo. Esta arquitectura de red convolucional ha demostrado ser efectiva en tareas de clasificación semántica con datos de satélite (Kotaridis, 2022; Solórzano, 2021). Se utilizó la entropía cruzada pesada como función de pérdida para el entrenamiento de la red. Para los píxeles sin clase se hizo que el peso entropía cruzada valiera 0 lo que fuerza al modelo a no tener en cuenta las regiones sin clase durante el entrenamiento. Para las siete clases se utilizó un peso proporcional a la raíz de la inversa de la proporción del área total representada por esa clase en los datos de entrenamiento. Es decir, se penalizó más a la red por los fallos en las clases de las que tenemos menos área en los datos de entrenamiento.

Todas las bandas y métricas fueron estandarizadas restando su media y dividiendo por su desviación típica. Se aumentaron los datos aplicando simetrías verticales y horizontales y rotaciones de 90, 180 y 270 grados de manera aleatoria a los datos. El modelo fue entrenado durante 200 épocas en lotes de 64 unidades y con una tasa de aprendizaje de 0.0001.

2.3.3. Evaluación del modelo

Se utilizó el conjunto de datos de validación, el cual no fue utilizado durante el entrenamiento. Se utilizaron las predicciones del modelo sobre estas zonas para

construir una matriz de confusión normalizada. Además, para cada clase se calculó la fiabilidad de productor y usuario. Debido al desequilibrio entre clases, la precisión global puede ser engañosa. Por ello, se calculó el índice Kappa de Cohen, un índice que mide la precisión global del clasificador, pero descontando los aciertos que podrían darse por puro azar. Un valor de Kappa alto nos indica que el buen comportamiento del modelo no se debe a una predicción sistemática de las clases mayoritarias.

3. RESULTADOS Y DISCUSIÓN

Se obtuvo una precisión del 84,2% sobre los píxeles pertenecientes a los polígonos reservados para la validación. Una descripción más detallada de los resultados, junto con la matriz de confusión puede verse en la Tabla 2 y la Figura 1. De entre todas las clases, la clase artificial y coníferas se clasifican especialmente bien con precisiones superiores al 90%. Las clases de cultivo tienen cierta confusión entre ellas, en torno al 15% de las observaciones de cada cultivo son confundidas con el otro tipo de cultivo. La clase frondosas, matorral y pastizal también tienen confusión entre sí, pero en menor medida. En general la confusión entre clases se sucede entre clases similares. La confusión entre tipos de cultivo puede deberse a la propia incertidumbre que existe en el SIGPAC, cuya base de datos se ha utilizado tanto en el entrenamiento como en la evaluación. La confusión entre matorral y pastizal también es habitual, siendo difícil distinguir entre ambas clases en entornos mediterráneos. Quizás sorprende la cantidad de polígonos de frondosas que se predicen como matorral. Esto puede deberse a que un monte bajo de frondosas puede parecerse estructuralmente a un matorral. La Kappa de Cohen obtenida (0.785) muestra que los resultados no se deben a la sobrepredicción de las clases mayoritarias.

4. CONCLUSIONES

Los resultados muestran que es posible construir un modelo de clases de usos del suelo con una fiabilidad razonable únicamente a partir de datos abiertos, si bien es cierto que el modelo no ha sido validado a partir de datos de campo o manualmente etiquetados. Consideramos que, aunque las fuentes originales de etiquetado (MFE y SIGPAC) no son totalmente fiables para la validación, el resultado obtenido demuestra su utilidad para incrementar o mejorar conjuntos de datos de entrenamiento para uso en modelos de aprendizaje profundo. En el futuro se prevé utilizar conjuntos de validación más fiables ya sean procedentes de campo u obtenidos mediante fotointerpretación.

Una limitación del estudio es la ausencia de comparativa con otros métodos convencionales como pueden ser *random forest* o *support vector machines*. Estudios previos muestran que por la capacidad de las redes neuronales convolucionales para extraer patrones espaciales estas suelen ofrecer resultados superiores a otras aproximaciones en tareas de segmentación semántica (Boston, 2022). Aun así, en el futuro planeamos realizar una comparativa con otras

aproximaciones para determinar si en nuestro caso concreto esto se cumple.

Una última debilidad de la aproximación es que habitualmente hay grupos contiguos de polígonos. Esto provoca que pueda haber información de los polígonos de entrenamiento en los de prueba y validación debido a la autocorrelación espacial. Como solución tentativa a este problema se plantea agrupar polígonos cercanos de tal manera que estos grupos acaben de manera completa en los conjuntos de entrenamiento, test o validación.

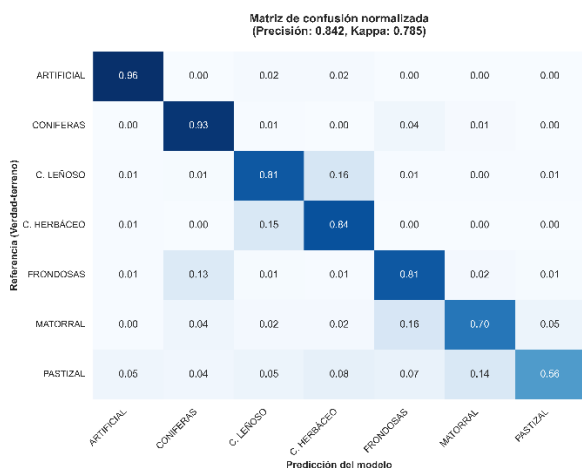


Figura 1. Matriz de confusión normalizada, precisión total (84,2%) y Kappa de Cohen (0.785)

Tabla 2. Comparación de la fiabilidad del productor y del usuario

Clase	Fiabilidad del productor	Fiabilidad del usuario
Artificial	0.958	0.881
C. leñoso	0.811	0.738
C. herbáceo	0.837	0.896
Pastizal	0.561	0.591
Matorral	0.698	0.794
Coníferas	0.932	0.921
Frondosas	0.812	0.755

5. AGRADECIMIENTOS

El trabajo que se recoge en esta publicación es parte de las ayudas DIN2024-013484 y PID2024-158591OB-100, financiadas por el MICUI/AEI/10.13039/501100011033 y por el FSE+.

Se agradece a la Subdirección General Cartografía y Observación del Territorio, Instituto Geográfico Nacional, Ministerio de Transportes y Movilidad Sostenible el acceso temprano a la tercera cobertura del PNOA.

6. REFERENCIAS

Auty, J.-R. R. (2023). Airborne LiDAR Data Manipulation and Visualization for Forestry Applications. <https://cran.r-project.org/package=lidR>

Boston, T. a. (2022). Comparing CNNs and Random Forests for Landsat Image Segmentation Trained on a Large Proxy Land Cover Dataset. *Remote Sensing*, 14(14). <https://doi.org/10.3390/rs14143396>

Chen, W. a. (2020). Accelerating the Training of Convolutional Neural Networks for Image Segmentation with Deep Active Learning. IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC) (págs. 1-7). IEEE .

Instituto Geográfico Nacional. (s.f.). Plan Nacional de Ortofotografía Aérea. Recuperado el 9 de 2 de 2026, de <https://pnoa.ign.es/>

Kotaridis, I. &. (2022). Semantic segmentation using a UNet architecture on Sentinel-2 data. The International Archives of the Photogrammetry, *Remote Sensing and Spatial Information Sciences*(43), 119-126.

Liang, B. L. (2020). Weakly Supervised Semantic Segmentation Based on Deep Learning. Proceedings of the 11th International Conference on Modelling, Identification and Control (ICMIC2019).

Ministerio de Agricultura, P. y. (s.f.). Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC). Fondo Español de Garantía Agraria (FEGA). <https://www.fega.gob.es/es/banner/sigpac>

Ministerio de transportes y movilidad sostenible. (s.f.). Mapa topográfico nacional 1:25000. <https://centrodedescargas.cnig.es/CentroDescargas/mapa-topografico-nacional>

Ministerio para la transición ecológica y el reto demográfico. (s.f.). Mapa Forestal de España a escala 1:25.000 (MFE25). https://www.miteco.gob.es/es/biodiversidad/temas/inventarios-nacionales/mapa-forestal-espana/mfe_25.html

Roussel, J. A. (Agosto de 2021). lidR : An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251(112061). <https://doi.org/10.1016/j.rse.2020.112061>

Solórzano, J. V.-C. (2021). Land use land cover classification with U-net: Advantages of combining sentinel-1 and sentinel-2 imagery. *Remote Sensing*(13(18)), 3600.

Ye, R. L. (2025). Strategic sampling for training a semantic segmentation model in operational mapping: Case studies on cropland parcel extraction. *Remote Sensing of Environment*, 331, 115034.