



**2025** | **16-20**  
**GIJÓN** | **JUNIO**

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1744**

Actas del Noveno Congreso Forestal Español  
Edita: **Sociedad Española de Ciencias Forestales. 2025.**  
ISBN: **978-84-941695-7-1**

Organiza





## “Análisis de la evolución del uso del suelo a través de redes neuronales y ortofotografías históricas y actuales”

AVELLA, P. (1), RAMOS, G. (1), PRENDES, C. (1), CABO, C. (2), ORDOÑEZ, C. (2) y CANGA, E. (1)

1. Fundación Centro Tecnológico Forestal y de la Madera de Asturias (CETEMAS).
2. Universidad de Oviedo

### Resumen

El análisis de la evolución territorial es fundamental para la planificación y gestión de los recursos naturales. En este contexto, las imágenes aéreas destacan como herramientas esenciales para detectar cambios en los usos del suelo. En España, se dispone de una amplia colección de imágenes aéreas gratuitas, como las ortofotografías del Plan Nacional de Ortofotografía Aérea (PNOA) y las imágenes históricas del vuelo americano de 1956-1957.

Este estudio propone una metodología basada en Deep Learning (DL) para comparar imágenes históricas del vuelo americano en blanco y negro con ortofotografías actuales del PNOA. El objetivo es detectar cambios en los usos del suelo. Para ello, se entrenaron dos redes neuronales utilizando máscaras que identifican diferentes tipos de uso del suelo: forestal, matorral, agrícola y artificial. Estas redes permitieron generar modelos precisos para clasificar el uso del suelo en ambos periodos.

Los resultados mostraron un aumento en el uso forestal en detrimento del uso agrícola y una tendencia al abandono de tierras, evidenciada por el crecimiento de áreas de matorral. La metodología desarrollada ha demostrado ser eficaz para analizar la evolución territorial y apoyar en la toma de decisiones relacionadas con la gestión de los recursos naturales.

### Palabras clave

Planificación forestal, Deep Learning, Catastro, PNOA, vuelo americano.

**Abreviaturas:** SIG (Sistemas de Información Geográfica), UAV (*Unmanned Aerial Systems*), CNN (*Convolutional Neural Network*), PNOA (Plan Nacional de Ortofotografía Aérea), IA (Inteligencia Artificial), DL (*Deep Learning*), LiDAR (*Light Detection and Ranging*), RADAR (*Radar Detection and Ranging*), ML (*Machine Learning*), ReLU (*Rectified Linear Unit*), CR (Corrección), OA (*Overall Accuracy*)

### 1. Introducción

La actividad humana ha ido modificando el territorio a lo largo del tiempo, adaptándolo a diversas necesidades como la industria, la agricultura y el sector forestal. El interés por cartografiar estos cambios surge para comprender la evolución del uso del suelo (Talukdar *et al.*, 2020). Inicialmente, el mapeo se realizaba de manera tradicional, pero el avance de la tecnología ha evolucionado hacia el uso de imágenes satelitales y sensores remotos, lo que ha reducido los costes.

El progreso tecnológico ha transformado la geografía, haciendo crucial el uso de Sistemas de Información Geográfica (SIG) en la elaboración de cartografía digital y el análisis de procesos socioespaciales (Fuenzalida *et al.*, 2015). La geotecnología,

como herramienta digital, ha facilitado en gran medida la automatización de procesos de análisis espacial, contribuyendo al conocimiento del territorio (Oropeza & Díaz, 2007).

Con la llegada de las nuevas tecnologías como el aprendizaje automático y la inteligencia artificial (IA), se ha impulsado la automatización en el mapeo y clasificación de usos del suelo mediante algoritmos de Deep Learning (DL), los cuales son capaces de reconocer de forma automática estos usos a partir de unos datos previos. Esto da lugar al concepto de “visión artificial”, el cual es capaz de extraer la información relevante de imágenes simulando el funcionamiento del ojo humano.

La ortofotografía aérea, con alta resolución espacial y temporal, ofrece un gran potencial para estas aplicaciones. La clasificación automática del terreno facilita la planificación y gestión territorial, especialmente en áreas forestales y agrícolas, permitiendo además analizar cambios a través de ortofotos históricas. Por ello, este trabajo evalúa el uso de redes neuronales para la clasificación de usos del suelo a partir de ortofotos. En España, el Plan Nacional de Ortofotografía Aérea (PNOA), iniciado en 2004, proporciona ortofotos con una resolución de al menos 25 cm/píxel, mejorando en algunas áreas hasta 15 cm/píxel. Este plan tiene una periodicidad de actualización de tres años y las ortofotos se publican en formato digital, tanto en color verdadero como falso.

El uso de tecnologías basadas en Inteligencia Artificial (IA), como el Machine Learning (ML) y DL, se ha integrado de manera creciente en la cartografía, facilitando la creación automatizada de productos sin necesidad de digitalización manual. Las redes neuronales convolucionales (CNN), que son una forma avanzada de DL, se destacan por su capacidad para realizar clasificaciones automáticas no supervisadas de imágenes, lo que las hace útiles para tareas como la clasificación de usos del suelo.

En el ámbito de la clasificación de imágenes, el DL (Figura 1) permite que las máquinas aprendan a reconocer características como bordes y texturas, asignando una serie de probabilidades a diferentes clases.

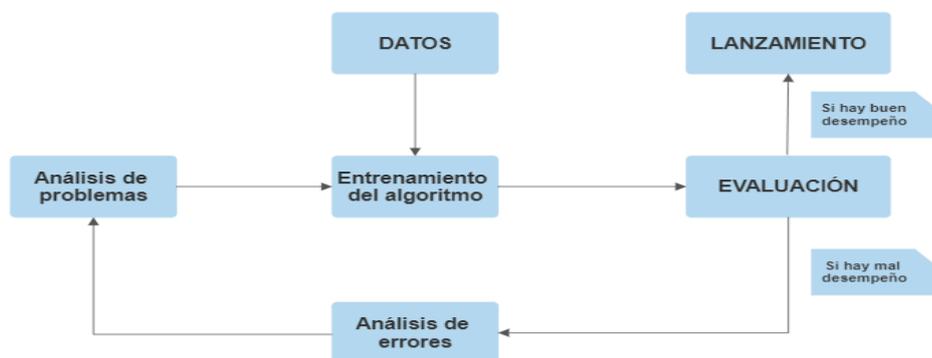


Figura 1. Flujo de procesos del algoritmo de Deep learning.

Las CNN son particularmente efectivas para segmentar imágenes y localizar



objetos, y se han utilizado con éxito en proyectos de clasificación de coberturas vegetales, obteniendo precisiones superiores al 97% (Ghazal *et al.* 2019). Además, este tipo de algoritmos han sido empleados para la clasificación de usos de suelo a partir de ortofotos RGB procedentes de la agencia de información geoespacial letona con una resolución de 0,25 m/píxel devolviendo una clasificación con una precisión del 94% (Stepchenko, 2020). Por otro lado, el muestreo que hace este tipo de algoritmo suaviza las imágenes y no es sensible a los diferentes detalles que se presentan en las imágenes (Lv *et al.* 2023).

En resumen, las redes neuronales y los avances en visión artificial han demostrado ser herramientas poderosas para la clasificación y segmentación de imágenes en la cartografía, con resultados precisos y aplicables en diversos sectores.

## 2. Objetivos

El objetivo general de este trabajo es llevar a desarrollar una herramienta para analizar la evolución de los usos de suelo a través de redes neuronales utilizando ortofotos históricas y actuales.

## 3. Metodología

Se desarrolló un algoritmo programado en lenguaje libre Python de tal manera que realizase la clasificación automática de las ortofotos del vuelo americano y el vuelo de máxima actualidad del PNOA, para posteriormente seleccionar aquellas parcelas catastrales con cambios significativos.

En un primer paso se entrenaron los modelos basados en redes neurales. El conjunto de datos de entrada para este proceso consistió en una serie de imágenes en formato TIF, acompañadas de sus respectivas máscaras en formato PNG, que contienen la clasificación correspondiente de cada elemento dentro de la imagen. Estas imágenes fueron utilizadas para entrenar un modelo basado en el análisis de datos del PNOA (Plan Nacional de Ortofotografía Aérea) y/o del vuelo americano, con el fin de realizar tareas específicas de clasificación o segmentación. Para ello, se utilizaron 300 imágenes de cada fuente, correspondientes a las diferentes fuentes de datos, tanto PNOA, como el vuelo americano. A cada imagen se le asignó una máscara en formato ráster, creada manualmente, que representaba cuatro clases de uso del suelo: superficie forestal o de plantación adulta, matorral, pastos y otros elementos como terrenos desnudos o construcciones (artificial). Las máscaras se elaboraron mediante fotointerpretación sobre las ortofotos y digitalización de polígonos.

Para la elaboración de las máscaras a emplear en ambos modelos se tuvieron en cuenta las siguientes condiciones:

- La máscara debía ser continua y ocupar toda la extensión de la imagen de entrada.
- La máscara debía tener la misma extensión que la imagen.
- Tanto la máscara como la imagen debían de estar situadas correctamente en el espacio.
- Las imágenes y las máscaras debían compartir el mismo nombre para su correcta asociación a la hora de realizar el entrenamiento.

Una vez preparados los datos de entrada se entrenaron dos modelos, uno para cada tipo de ortofoto y se obtuvieron dos archivos PATH que contienen las firmas de los entrenamientos. Estos archivos de firma incluyen los parámetros de



los modelos ajustados y permite clasificar otras imágenes sin necesidad de volver a entrenar la red neuronal.

El modelo de clasificación empleó una red neuronal ResNet-50, conocida por su buen rendimiento en problemas multiclase. El entrenamiento del modelo se centró en ajustar parámetros como la tasa de aprendizaje para minimizar el error, utilizando herramientas de procesamiento gráfico para acelerar los cálculos. La red aplicó filtros convolucionales para extraer características de las imágenes, seguidos de funciones de activación ReLU (*Rectified Linear Unit*) y procesos de agregación (*pooling*) para simplificar los datos mientras se mantenían los patrones clave.

Para la evaluación del entrenamiento y validación de la red en ambos modelos, se evaluó la matriz de confusión y estadísticos asociados: corrección (CR) (Ecuación 1) que devuelve el ratio de aciertos por clase y la precisión global (OA, *overall accuracy*) (Ecuación 2) que proporciona información sobre el número de píxeles que son asignados correctamente en su clase (Roces-Díaz *et al.* 2020).

$$CR = nCorr/nPred \quad (\text{Ecuación 1})$$

$$OA = \sum nCorr / \sum nPred \quad (\text{Ecuación 2})$$

donde  $nCorr$  fue el número de píxeles asignados correctamente a su clase (verdaderos positivos) y  $nPred$  el número total de píxeles asignados a una clase.

Finalmente, se contrastaron visualmente las clasificaciones realizadas por la red neuronal frente a las clasificaciones manuales (verdad terreno).

Una vez validados los modelos, el siguiente paso consistió en evaluar la evolución de las zonas, mediante un análisis temporal con el resultado de las predicciones de ambos modelos (con una ligera edición manual para minimizar errores).

El algoritmo realiza la diferencia entre la situación actual (PNOA RGB) y la situación pasada (vuelo americano) obteniendo cartografía de las zonas con cambios y del tipo de cambios que se han producido. Comienza por una reclasificación de los valores de las predicciones de ambos modelos, para así realizar una resta y obtener como producto un ráster con valores que indican el cambio de clase, siendo capaz así de establecer también el sentido del cambio. El flujo de procesos de la herramienta es el siguiente:

1. Preparación y reclasificación de los ráster predicción de cada modelo.
2. Resta de ambas clasificaciones.
3. Reabsorción de polígonos de menor tamaño (“ruido”).

A su vez, el algoritmo incorpora una serie de procesos que permiten cruzar esta cartografía con las parcelas catastrales, reabsorber superficies menores a 150 m<sup>2</sup> que carecen de sentido por si solas y resumir toda esta información a nivel de parcela. Finalmente se establecen una serie de criterios para seleccionar parcelas con cambios significativos, identificando asimismo el cambio que se produce (por ejemplo, de pasto a forestal).

#### 4. Resultados

En el presente trabajo, se entrenó una red neuronal para la clasificación de usos del suelo a partir de ortofotografías en un número de épocas que varía en función de la evolución de los valores que es capaz de obtener el algoritmo en cada una de las épocas, por un lado, para ortofotografías a color real RGB y, por otro lado, en blanco y negro. Ambos entrenamientos se han realizado orientando la red hacia

un reconocimiento de las masas principales, dejando de lado la diferenciación de elementos a nivel individual, por lo que la clasificación en zonas muy heterogéneas en las que los elementos no se encuentran agrupados, no fue tan precisa como en las zonas más homogéneas (Figura 2).

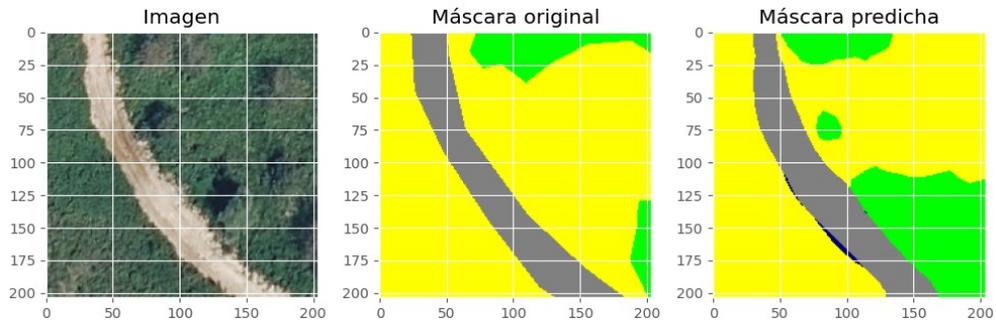


Figura 2. Máscara creada por el usuario frente a la predicha para una zona heterogénea.

#### 4.1. Resultados del modelo de clasificación del PNOA.

En la Figura 3 se muestra el gráfico que representa la pérdida del set de entrenamiento frente a la pérdida de la validación, donde se puede ver que el modelo del PNOA ha convergido mostrando una pérdida razonable en ambos conjuntos de datos, aunque elevada en el caso de la validación.

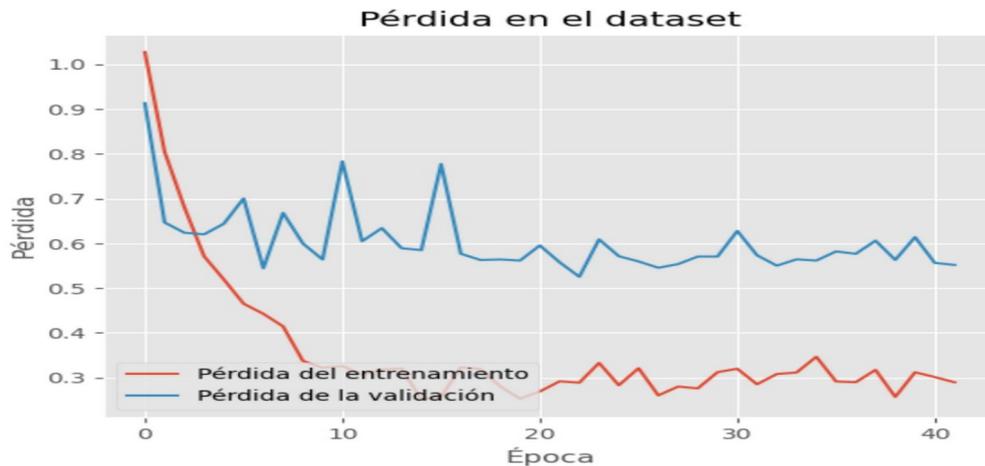


Figura 3. Gráfico de pérdida del set de entrenamiento y validación.

Tanto la curva de pérdida del entrenamiento como la validación descienden hasta un momento en que se estabilizan (época 7 comienza la estabilización) y como era de esperar, la pérdida en la muestra de entrenamiento es menor que en la de validación, produciéndose una disminución de ambas a medida que aumentan las épocas llegando a estar entre 0,2 y 0,55 para el entrenamiento y la validación respectivamente.

En la Figura 4 se presenta la gráfica de la evolución de la precisión (*accuracy*) en el entrenamiento y validación del modelo PNOA a medida que aumenta el número de

épocas. En ambas curvas la precisión aumenta estabilizándose a partir de un número de épocas (7), siendo la precisión mayor en el caso del entrenamiento tal y como era de esperar, en torno a un 95% frente al 85% de la validación.

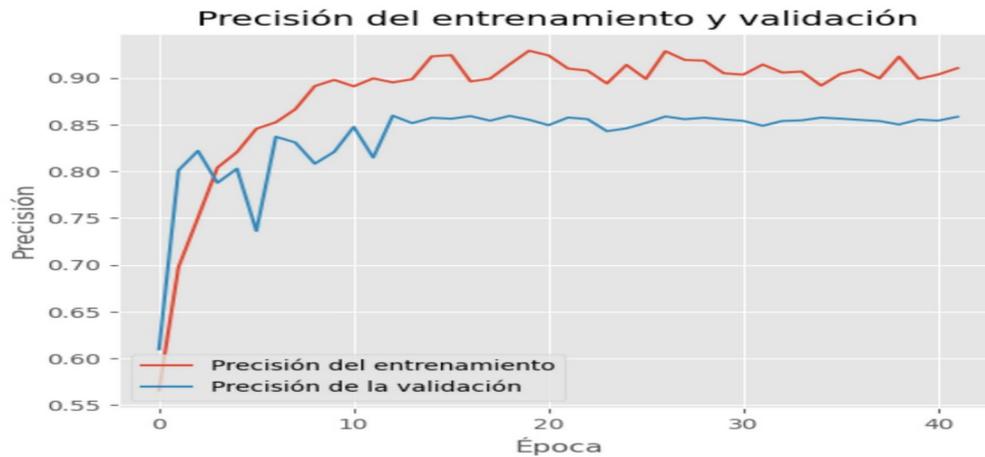


Figura 4. Gráfico de la precisión del set de entrenamiento y de la validación.

En las Tabla 2 se muestra la matriz de confusión de la muestra de validación en la que se puede ver en la diagonal el número de píxeles correctamente clasificados (verdaderos positivos) por la red neuronal.

Tabla 2. Matriz de confusión de la muestra de validación del modelo PNOA.

Forestal	Matorral	Pastos	Artificial	n	
<b>Predicho Forestal</b>	1.423.345	51.420	37.113	15.813	1.527.691
<b>Matorral</b>	95.311	203.995	41.865	22.087	363.258
<b>Pastos</b>	66.809	16.743	837.205	52.207	972.964
<b>Artificial</b>	12.153	10.874	27.469	206.791	257.287
n	1.597.618	283.032	943.652	296.898	

En la Tabla 3 se presentan los valores de la corrección calculada por clases y la OA en el modelo PNOA donde se puede ver que la corrección es menor al 90% en las clases de matorral, de pastos y artificial (clases 1, 2 y 3 respectivamente). Esto se puede deber a que la muestra inicial no está bien representada en el caso de la clase artificial además de estar mezcladas diferentes coberturas (infraestructuras, suelo desnudo, urbano...) y a la presencia de sombras en la clase matorral.

Tabla 3. Estadísticos por clase y globales del modelo PNOA.

Validación	
Corrección clase 0 (forestal) (%)	93,17 %
Corrección clase 1 (matorral) (%)	56,16 %
Corrección clase 2 (pastos) (%)	86,05 %
Corrección clase 3 (artificial) (%)	80,37 %
OA (%)	85,6 %

#### 4.2. Resultados del modelo de clasificación del vuelo americano.

En la Figura 5 se muestra el gráfico que representa la pérdida del set de entrenamiento frente a la pérdida de la validación, donde se puede ver que el modelo del vuelo americano ha convergido mostrando una pérdida razonable en ambos conjuntos de datos, aunque elevada en el caso de la validación.

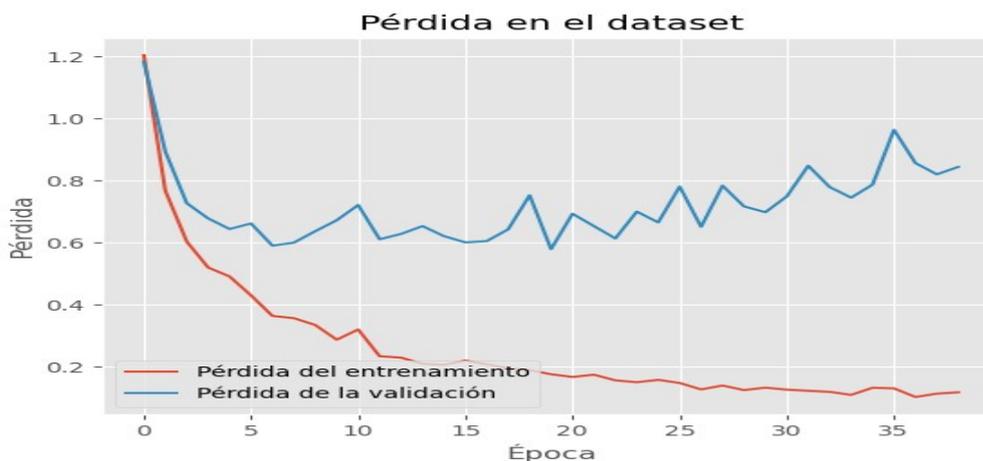


Figura 5. Gráfico de pérdida del set de entrenamiento y validación.

Tanto la curva de pérdida del entrenamiento como la validación descienden hasta un momento en que se estabilizan (época 20 comienza la estabilización) y como era de esperar, la pérdida en la muestra de entrenamiento es menor que en la de validación, produciéndose una disminución de ambas a medida que aumentan las épocas llegando a estar entre 0,15 y 0,59 para el entrenamiento y la validación respectivamente.

En la Figura 6 se presentan las gráficas de la evolución de la precisión (*accuracy*) en el entrenamiento y validación del modelo del vuelo americano a medida que aumenta el número de épocas. En ambas curvas la precisión aumenta estabilizándose a partir de un número de épocas (20), siendo la precisión mayor en el caso del entrenamiento tal y como era de esperar, en torno a un 95% frente al 83% de la validación.



Figura 6. Gráfico de la precisión del set de entrenamiento y de la validación.

En la Tabla 4 se muestra la matriz de confusión de la muestra de validación en la que se puede ver en la diagonal el número de píxeles correctamente clasificados (verdaderos positivos) por la red neuronal.

Tabla 4. Matriz de confusión de la muestra de validación del modelo del vuelo americano.

Forestal	Matorral	Pastos	Artificial	n		
<b>Predicho Forestal</b>		768.787	22.916	45.080	4.557	841.340
<b>Matorral</b>	107.699	298.469	51.885	6.945		464.998
<b>Pastos</b>	39.298	7.099	648.134	13.723		708.25
<b>Artificial</b>	3.334	3.525	28.400	30.949		66.208
n	919.118	332.009	773.499	56.174		

Por otro lado, en el modelo del vuelo americano, los valores de corrección calculada por clases y la precisión global fueron superiores al 90% en dos de las 4 clases, siendo inferior en las clases 1 y 3 (matorral y artificial) debido a la limitación visual que presentan este tipo de datos tanto por su resolución como por la falta de color (Tabla 5).

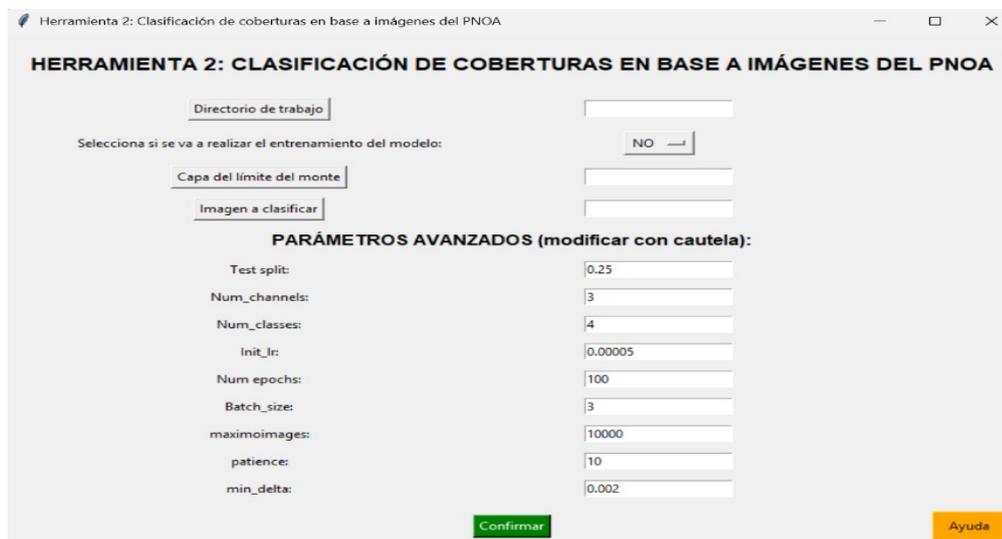
Tabla 5. Estadísticos por clase y globales del modelo del vuelo americano.

Validación	
Corrección clase 0 (forestal) (%)	91,38 %
Corrección clase 1 (matorral) (%)	64,19 %
Corrección clase 2 (pastos) (%)	91,51 %
Corrección clase 3 (artificial) (%)	46,74 %
OA (%)	83,93 %

En total se desarrollaron 3 algoritmos en lenguaje Python 3.11.9, para cada uno de los cuales se elaboró una interfaz de usuario que permite la selección de los datos de entrada y parámetros correspondientes, así como la ubicación de los resultados. A su vez se incluyó la capacidad de limitar el análisis a una zona específica mediante un archivo vectorial.

Los algoritmos desarrollados fueron los siguientes:

- Herramienta 1: Clasificación de coberturas en base a imágenes del vuelo americano
- Herramienta 2: Clasificación de coberturas en base a imágenes del PNOA (Figura 2).
- Herramienta 3: Análisis temporal de cambios de uso del suelo (Figura 3).



Herramienta 2: Clasificación de coberturas en base a imágenes del PNOA

**HERRAMIENTA 2: CLASIFICACIÓN DE COBERTURAS EN BASE A IMÁGENES DEL PNOA**

Directorio de trabajo:

Selección si se va a realizar el entrenamiento del modelo:

Capa del límite del monte:

Imagen a clasificar:

**PARÁMETROS AVANZADOS (modificar con cautela):**

Test split:

Num\_channels:

Num\_classes:

Init\_lr:

Num epochs:

Batch\_size:

maximoimages:

patience:

min\_delta:

Figura 7. Interfaz del usuario de la herramienta de clasificación del PNOA y vuelo americano



Figura 8. Interfaz del usuario de la herramienta 3 para el análisis multitemporal de cambios.

La herramienta 3 implementa el algoritmo de análisis temporal de cambios en la cobertura del suelo, utilizando los resultados obtenidos con las herramientas 1 y 2.

### 5. Discusión

La red neuronal ajustada fue incapaz de clasificar correctamente zonas donde no existía clara diferencia entre los elementos o con tonos diferentes a las imágenes empleadas para los diferentes entrenamientos, por lo que es recomendable emplear imágenes con condiciones de luminosidad similares. Al tratarse de un método basado en el procesamiento de imágenes, la presencia de sombras en ellas podría impedir el correcto funcionamiento de los algoritmos desarrollados (Figura 9), ya que el usuario será capaz de diferenciar dichas sombras al crear las máscaras, pero los algoritmos no.

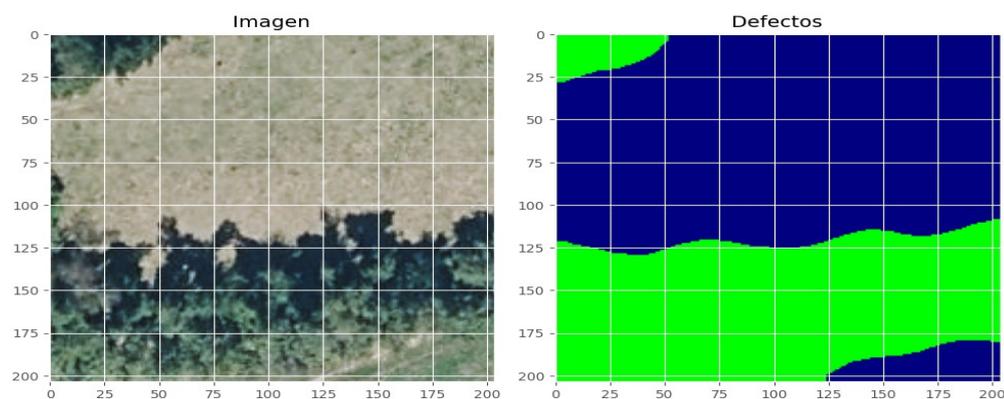


Figura 9. Imagen con sombra de arbolado sobre pastos (izda.) y su máscara (dcha.).

A la vista de los resultados obtenidos en la función de pérdida en ambos modelos, cabe reseñar que, a pesar de ser unos valores elevados, ambos llevan a cabo unas predicciones aceptables. Este resultado estadístico es debido a la forma en la que están entrenados ambos, buscando una generalización de las clasificaciones y no



orientarlos al reconocimiento más específico (a nivel de individuos o elementos de la imagen). A pesar de ello, el modelo no se ha sobreentrenado, pues se ha establecido un umbral, a partir del cual, el modelo deja de mejorar y se detiene en el entrenamiento. En el caso del modelo del PNOA en la época 7 y en el modelo del vuelo americano, en la época 20.

Los resultados de OA obtenidos en la validación fueron satisfactorios, alcanzando un 85,6 % y 83,93 % para los modelos del PNOA y vuelo americano respectivamente. Estos valores son comparables con los obtenidos en estudios similares utilizando metodologías de segmentación basadas en DL: Yu *et al.* (2018) con 96,97%, Yao *et al.* (2019) con 89,48%, y Bhatnagar *et al.* (2020) con 91,00%. Estos resultados cercanos permiten concluir que la precisión global obtenida en este trabajo es adecuada.

Además, al comparar con otros estudios que emplean metodologías similares, pero con diferentes tipos de datos, como el trabajo de Roces-Díaz *et al.* (2020) con una precisión de 92,8% usando nubes de puntos LiDAR para la clasificación de áreas forestales, la precisión global de este proyecto es también similar.

El uso de ortofotos del PNOA tiene la ventaja de un corto período de actualización (3 años) en comparación con las nubes de puntos LiDAR, cuyo intervalo entre coberturas puede ser de hasta 10 años. Aunque las ortofotos tienen una mayor resolución espacial que los datos satelitales, presentan la desventaja de una menor resolución espectral y temporal. Sin embargo, las ortofotos del PNOA ofrecen un gran potencial para la clasificación de usos del suelo, tanto para actualizaciones como para análisis históricos. A su vez, la posibilidad de poder emplear ortofotografías en blanco y negro como las del vuelo americano, posibilita un posterior análisis multitemporal de la evolución de los paisajes.

En futuros trabajos se podrán implementar modelos que sean entrenados a partir de ortofotografías además de diferentes

## 5. Conclusiones

Las principales conclusiones que se pueden extraer del presente trabajo son las siguientes:

- Se entrenaron dos modelos de red neuronal para la clasificación automática de los usos del suelo logrando una precisión global (OA) de 85,6 % y del 83,93% para la validación con los datos del PNOA y del vuelo americano respectivamente.
- Se ajustaron los parámetros de ambas redes neuronales ResNet-50 presentando una función de pérdida del 52% y del 57 % para validación con los datos del PNOA y del vuelo americano respectivamente. A pesar de arrojar unos valores de pérdida elevados, el algoritmo es capaz de predecir de manera correcta a nivel global, pues estos son debidos a la forma en la que están generalizando las predicciones ambos modelos.
- Se analizó el número de épocas necesarias para que los modelos sean estables en función de las pérdidas de entrenamiento y validación obteniendo como umbral 7 y 20 para los modelos del PNOA y del vuelo americano respectivamente.
- Las correcciones por clase fueron superiores al 90% en el caso de la muestra de validación para ambos modelos, descendiendo en el caso del PNOA en las clases de matorral, pastos y artificial y por otro lado, para el modelo del vuelo americano en las clases de matorral y artificial.



- Con el uso de 300 imágenes para el entrenamiento de una red neuronal ya se obtienen resultados satisfactorios, aunque los resultados en la validación parecen indicar que el aumento del volumen de datos de aprendizaje podría mejorar los resultados. Además, la muestra de entrenamiento ha de seleccionarse de manera más balanceada, mejorando el número de muestras de entrenamiento en las clases de matorral y artificial.
- Se han desarrollado 3 herramientas aplicables para la clasificación de coberturas de usos del suelo y el análisis temporal de cambios permitiendo la automatización de los procesos y su uso en procedimientos de análisis de la propiedad.

### 6. Agradecimientos

Este trabajo se ha desarrollado en el marco del Convenio de colaboración entre la Administración del Principado de Asturias, a través de la Consejería de Presidencia, Reto Demográfico, Igualdad y Turismo y la Fundación Centro Tecnológico Forestal y de la Madera (CETEMAS) para la realización de un proyecto piloto de innovación abierta de alto impacto ligado a la identificación, regularización, reordenación y gestión de la propiedad rural.

### 7. Bibliografía

BHATNAGAR, S., GILL, L., GHOSH, B., 2020. Drone image segmentation using machine and deep learning for mapping raised bog vegetation communities. *Remote Sensing*, ol. 12, no 16, p. 2602.

FUENZALIDA, M.; BUZAI, G.D.; MORENO JIMÉNEZ, A.; GARCÍA DE LEÓN, A., 2015. Geografía, geotecnología y análisis espacial: tendencias, métodos y aplicaciones. Editorial Triángulo, Santiago de Chile.

GHAZAL, M.A, MAHMOUD, A., ASLANTAS, A., SOLIMAN, A., SHALABY, A., BENENDIKTSSON, J.A, EL-BAZ, A. 2019. Vegetation cover estimation using convolutional neural networks. *IEEE Access*, vol. 7, p. 132563-132576.

LV, J., SHEN, Q., LV, M., LI Y., SHI, L., ZHANG, P., 2023. Deep learning-based semantic segmentation of remote sensing images: a review. *Frontiers in Ecology and Evolution*, 2023, vol. 11, p. 1201125.

OROPEZA, M.; DÍAZ, N., 2007. La geotecnología y su inserción en el pensamiento geográfico, *Terra*. Vol. XXIII, No. 34, pp. 71-95.

STEPCHENKO, AM., 2021. Land-Use Classification Using Convolutional Neural Networks. *Automatic Control and Computer Sciences*, vol. 55, p. 358-367.

TALUKDAR, S., SINGHA, P.; MAHATO, S., SHAHFAHAD, PAL, S., LIOU, Y.-A., RAHMAN, A., 2020. Land-use land-cover classification by machine learning classifiers for satellite observations—A review. *Remote Sensing*, vol. 12, no 7, p. 1135.

YU, L., SU, J., LI, C., WANG, L., LUO, Z., YAN, B., 2018. Improvement of moderate resolution land use and land cover classification by introducing adjacent region features. *Remote Sensing*, vol. 10, no 3, p. 414.

YAO, X., YANG, H., WU, Y., WU, P., WANG, B., ZHOU, X., WANG, S., 2019.. Land use classification of the deep convolutional neural network method reducing the loss of spatial features. *Sensors*, vol. 19, no 12, p. 2792.

