

Román, A.; Tovar-Sánchez, A.; Xanxo, R.; Vázquez, Á.; Navarro, G. Inteligencia Artificial Aplicada a los Drones: Escalado vs Super-Resolución en el Estudio de Sistemas Costeros

Inteligencia Artificial Aplicada a los Drones: Escalado vs Super-Resolución en el Estudio de Sistemas Costeros

Román, Alejandro ¹ Tovar-Sánchez, Antonio ¹ Xanxo, Roc ¹ Vázquez, Águeda ²
Navarro, Gabriel ¹

¹ Instituto de Ciencias Marinas de Andalucía (ICMAN), Consejo Superior de Investigaciones Científicas (CSIC), Departamento de Ecología y Gestión Costera

² Universidad de Cádiz (UCA), Departamento de Física Aplicada

ORCID: Román 0000-0002-8868-9302 Tovar-Sánchez 0000-0003-4375-1982 Xanxo 0009-0004-2154-1233
Vázquez 0000-0002-5636-2604 Navarro 0000-0002-8919-0060

Correspondencia: a.roman@csic.es a.tovar@csic.es roc.xanxo.prillo@csic.es agueda.vazquez@uca.es
gabriel.navarro@csic.es

RESUMEN

En la última década, la teledetección con drones (UAVs, Unmanned Aerial Vehicles) ha ganado relevancia por su papel en la observación integrada de los sistemas costeros, al complementar algunas limitaciones de la óptica satelital. La reciente irrupción de la Inteligencia Artificial (IA) ha ampliado notablemente las oportunidades para analizar la dinámica y evolución de estos sistemas, destacando los enfoques que integran datos de alta resolución espacial con métodos de aprendizaje automático. En este trabajo presentamos un estudio metodológico que compara dos técnicas emergentes de IA – el escalado (upscaling) y la super-resolución (SR) – empleando datos multiespectrales de un sensor de 10 canales (MicaSense RedEdge-MX) embarcado en un dron, con el objetivo de mejorar los registros del satélite Sentinel-2 MSI sobre una zona de marismas en la Bahía de Cádiz (España). Para el escalado, se desarrolla un flujo de trabajo basado en un modelo XGBoost en dos etapas para la clasificación supervisada de las clases de cobertura del suelo identificadas. En el caso de la SR, se emplea un modelo de aprendizaje profundo basado en redes generativas antagónicas (GAN), entrenado con un amplio conjunto de datos capturado con el dron, que mejora la resolución espacial de Sentinel-2 de 10 m/px a 1 m/px para su posterior clasificación mediante XGBoost. El estudio propone una metodología eficaz para la observación de las dinámicas fluctuantes de los sistemas costeros en un contexto de cambio climático global, así como de los retos ecológicos que estos enfrentan.


Palabras clave: *Aprendizaje Automático; Aprendizaje Profundo; Redes Neuronales; XGBoost; UAVs*


Fecha de recepción: 5 febrero 2026 · Fecha de aceptación: 18 marzo 2026


Inteligencia Artificial Aplicada a los Drones: Escalado vs Super-Resolución en el Estudio de Sistemas Costeros


Román, Alejandro ⁽¹⁾, Tovar-Sánchez, Antonio ⁽¹⁾, Xanxo, Roc ⁽¹⁾, Vázquez, Águeda ⁽²⁾, Navarro, Gabriel ⁽¹⁾

⁽¹⁾ Instituto de Ciencias Marinas de Andalucía (ICMAN), Consejo Superior de Investigaciones Científicas (CSIC), Departamento de Ecología y Gestión Costera, España.


 0000-0002-8868-9302, a.roman@csic.es.

 0000-0003-4375-1982, a.tovar@csic.es.

 0009-0004-2154-1233, roc.xanxo.prillo@csic.es.

 0000-0002-8919-0060, gabriel.navarro@csic.es.

⁽²⁾ Universidad de Cádiz (UCA), Departamento de Física Aplicada, España.

 0000-0002-5636-2604, agueda.vazquez@uca.es.

Resumen: En la última década, la teledetección con drones (UAVs, *Unmanned Aerial Vehicles*) ha ganado relevancia por su papel en la observación integrada de los sistemas costeros, al complementar algunas limitaciones de la óptica satelital. La reciente irrupción de la Inteligencia Artificial (IA) ha ampliado notablemente las oportunidades para analizar la dinámica y evolución de estos sistemas, destacando los enfoques que integran datos de alta resolución espacial con métodos de aprendizaje automático. En este trabajo presentamos un estudio metodológico que compara dos técnicas emergentes de IA – el escalado (*upscaling*) y la super-resolución (SR) – empleando datos multispectrales de un sensor de 10 canales (MicaSense RedEdge-MX) embarcado en un dron, con el objetivo de mejorar los registros del sensor multispectral MSI de Sentinel-2 sobre una zona de marismas en la Bahía de Cádiz (España). Para el escalado, se desarrolla un flujo de trabajo basado en un modelo XGBoost en dos etapas para la clasificación supervisada de las clases de cobertura del suelo identificadas. En el caso de la SR, se emplea un modelo de aprendizaje profundo basado en redes generativas antagónicas (GAN), entrenado con un amplio conjunto de datos capturado con el dron, que mejora la resolución espacial de Sentinel-2 de 10 m/px a 1 m/px para su posterior clasificación mediante XGBoost. El estudio propone una metodología eficaz para la observación de las dinámicas fluctuantes de los sistemas costeros en un contexto de cambio climático global, así como de los retos ecológicos que estos enfrentan.

Palabras clave: Aprendizaje Automático; Aprendizaje Profundo; Redes Neuronales; XGBoost; UAVs.

Artificial Intelligence Applied to Drones: Upscaling vs Super-Resolution in the Study of Coastal Systems

Abstract: *Over the past decade, drone-based remote sensing (UAVs, Unmanned Aerial Vehicles) has gained relevance due to its role in the integrated observation of coastal systems, as it complements some of the limitations of satellite imagery. The recent emergence of Artificial Intelligence (AI) has significantly expanded opportunities to analyze the dynamics and evolution of these systems, particularly through approaches that integrate high spatial resolution data with machine learning methods. In this work, we present a methodological study comparing two emerging AI techniques – upscaling and super-resolution (SR) – using multispectral data acquired by a 10-channel sensor (MicaSense RedEdge-MX) mounted on a drone, with the aim of improving Sentinel-2 MSI multispectral observations over a saltmarsh area in the Bay of Cádiz (Spain). For upscaling, a two-stage XGBoost-based workflow is developed to upgrade the supervised classification of the identified land cover classes. In the case of super-resolution, a deep learning model based on generative adversarial networks (GAN), trained on an extensive drone-acquired dataset, is employed to enhance Sentinel-2 spatial resolution from 10 m/pixel to 1 m/pixel prior to supervised classification using XGBoost. The study proposes an effective methodology for observing the fluctuating dynamics of coastal systems in the context of global climate change, as well as the ecological challenges they face.*

Keywords: *Machine Learning; Deep Learning; Neural Networks; XGBoost; UAVs.*

1. INTRODUCCIÓN

Los sistemas costeros se caracterizan por su valor ecológico y económico, debido a los servicios ecosistémicos que proporcionan (*p.ej.* refugio, sumideros de CO₂ o protección costera, entre otros), aunque también por ser altamente vulnerables a los cambios globales (Orth *et al.* 2020). De hecho, las alarmantes tasas de pérdida, degradación y fragmentación de estos hábitats han hecho que el estudio de su evolución y estado sea una prioridad para la ciencia y los paneles gubernamentales (Murray *et al.* 2019). La teledetección por satélite ha permitido realizar observaciones desde ámbitos locales hasta regionales de la extensión y evolución de estos sistemas a diferentes escalas espaciales y temporales (Melet *et al.* 2020). No obstante, la limitada resolución espacial de los sensores satelitales más comúnmente empleados (*p.ej.* Sentinel-2 [S2] o Landsat-8 [L8]) y, en algunos casos, la necesidad de un mayor detalle, así como la heterogeneidad y la distribución espacial de estos hábitats, dificultan su detección precisa e incrementan el sesgo en las estimaciones. Los drones han surgido como una herramienta complementaria de gran potencial, ya que permiten observar estos sistemas a resoluciones espaciales sin precedentes. Sin embargo, su uso sigue estando restringido a observaciones locales, debido a la dificultad de cubrir grandes extensiones como consecuencia de su limitada autonomía de vuelo (Román *et al.* 2026).

En vista de las limitaciones descritas, una solución emergente ampliamente propuesta para mejorar las observaciones remotas de los sistemas costeros consiste en la adopción de enfoques multifacéticos que combinan bases de datos de alta resolución espacial (incluidos datos de drones) con técnicas de IA, siendo especialmente populares los modelos de aprendizaje automático y profundo (*p.ej.* redes neuronales). Este estudio, realizado en una marisma y planicie intermareal situada en la Bahía de Cádiz (España), explora las ventajas y limitaciones de dos aproximaciones emergentes de IA con el fin de mejorar las observaciones satelitales de Sentinel-2: el escalado y la super-resolución (SR).

2. MATERIAL Y MÉTODOS

2.1. Área de estudio

El estudio se desarrolla en las proximidades del caño mareaal de La Carraca, dentro del Parque Natural Bahía de Cádiz (España), uno de los humedales costeros más importantes de Europa por la gran diversidad de ecosistemas que alberga. El área de interés, monitorizada mediante drones, corresponde a una marisma y planicie intermareal de unas 156 hectáreas, que incluye marismas transformadas para la extracción de sal (salina activa y abandonada), áreas en avanzado proceso de renaturalización tras la actividad salinera, y zonas naturales inalteradas (Fig.1a). La vegetación está dominada por *Sarcocornia* spp. y *Sporobolus maritimus* (Curcio *et al.* 2023). En la zona intermareal se observa una presencia minoritaria de fanerógamas marinas como

Zostera noltei y *Cymodocea nodosa*, así como parches de microfitobentos (Haro *et al.* 2022).

2.2. Recolección de los datos

2.2.1. Datos de la aeronave y sensor multiespectral

Se empleó un multirrotor DJI Matrice 300 operando en condiciones de RTK, y equipado con el sensor multiespectral de 10 canales MicaSense RedEdge-MX – azul 444±28 nm y 475±32 nm, verde 531±14 nm y 560±27 nm, rojo 650±16 nm y 668±14 nm, e infrarrojo cercano (NIR) 705±10 nm, 717±12 nm, 740±18 nm y 842±57 nm. Este sensor cuenta con un panel de calibración y DLS (*Downwelling Light Sensor*) para el proceso de calibración radiométrica. Se ejecutaron vuelos mensuales en el área de estudio a 120 m de altura (80-75% solapamientos frontal y lateral), alcanzando un GSD medio de 8.2 cm/px. Los mapas de reflectancia (adimensional, 0-1) fueron generados con el software Pix4D Mapper (Lausanne, Suiza, v.4.8.3).

2.2.2. Datos del satélite Sentinel-2 (S2)

Los datos de S2 MSI BOA (*Bottom of Atmosphere*) armonizados y remuestreados a 10 m/px se descargaron a través de *Google Earth Engine*. Las bandas descargadas fueron de la misma longitud de onda (± 10 nm) que las del sensor de MicaSense, sincronas con las operaciones con drones (a fecha 14/07/2025), y adquiridos en condiciones de bajar.

2.3. Modelo de escalado dron-satélite

Para la generación de predicciones escaladas de cada clase de cobertura del suelo, se empleó un flujo de trabajo basado en la aplicación del algoritmo XGBoost. Se utilizaron bandas espectrales e índices normalizados (NDVI y GNDVI) como entrada, y porcentajes de cobertura fraccionaria como salida, agregando clasificaciones de dron dentro de píxeles de S2. XGBoost minimiza la función objetivo regularizada (Ec. 1):

$$L(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (1)$$

donde $l(y_i, \hat{y}_i)$ es la función de pérdida entre valores observados y predichos, y $\Omega(f_k)$ es el término de regularización de cada árbol del modelo. El modelo multisalida predice tres clases de cobertura simultáneamente y las predicciones se normalizan para que sumen el 100% en cada píxel. Los hiperparámetros se optimizaron mediante búsqueda aleatoria con validación cruzada de cinco pliegues, considerando rangos definidos para: número de árboles (100-1000), profundidad máxima (3-10), gamma (0-5), y términos de regularización L1 (alpha, 0-1) y L2 (lambda, 0-1), que controlan la penalización sobre la complejidad del modelo. La configuración final seleccionada correspondió al conjunto de parámetros que minimizó el error de validación. Se aplicó *early stopping* tras 150 rondas sin mejora, y se entrenó un *ensamble* de 20 particiones 70/30 para cuantificar la incertidumbre. La precisión de clasificación se evaluó mediante la precisión global (OA) y el índice Kappa de Cohen.

2.4. Modelo de super-resolución (SR)

Para mejorar la resolución espacial de imágenes de S2 a 1 m/px, se implementó un flujo de trabajo basado en redes neuronales generativas (GAN) empleando la arquitectura ESRGAN (*Enhanced Super-Resolution Generative Adversarial Network*). Para ello, se utilizaron imágenes de S2 a 10 m/px como variables de entrada del modelo, generándose versiones de alta resolución mediante un generador profundo que minimiza una función de pérdida combinada (Ec. 2):

$$L_{total} = L_{perceptual} + \lambda_{adv}L_{adv} + \lambda_{pixel}L_{pixel} \quad (2)$$

donde $L_{perceptual}$ mide la similitud perceptual en el espacio de características, L_{adv} corresponde a la pérdida adversarial del discriminador, L_{pixel} es la pérdida a nivel de píxel, y λ_{adv} y λ_{pixel} son coeficientes que ponderan su contribución en la función total. El modelo emplea bloques residuales densos (RRDB) sin normalización por lotes para preservar detalles finos y texturas realistas. Se optimizaron hiperparámetros como tasa de aprendizaje, pesos de pérdida (λ_{adv} , λ_{pixel}) y arquitectura del discriminador mediante búsqueda sistemática. Se aplicó un entrenamiento progresivo en dos fases: preentrenamiento con pérdida de píxeles L1 y refinamiento adversarial con pérdida perceptual basada en características VGG (*Visual Geometry Group*, una red neuronal convolucional preentrenada utilizada para extraer características de alto nivel). La precisión de clasificación se evaluó mediante la OA y el índice Kappa de Cohen.

3. RESULTADOS Y DISCUSIÓN

La precisión del modelo XGBoost sobre vuelo de dron (Fig.1b) reveló estadísticos robustos (OA=86% y kappa=0.78), separando entre una cobertura del 20.97% para agua (32.71 ha), 34.20% (53.35 ha) para vegetación, y 44.52% (69.45 ha) para sedimento fangoso cubierto por microfitobentos.

Tras la aplicación del modelo de escalado (Fig. 2a), se obtuvieron extensiones de cada una de las clases de cobertura terrestre (16.93% y 26.41 ha agua; 34.46% y 53.76 ha vegetación; 48.61% y 75.83 ha sedimento), a una resolución espacial de 10 m/px. Lógicamente, el análisis estadístico arroja unos valores más alejados de lo que se obtiene con tecnología de drones (OA=75% y kappa=0.61). Sin embargo, este método demuestra ser más rápido y eficiente que la ejecución de clasificaciones específicas para cada escena de S2, ya que no depende de la selección manual de regiones de entrenamiento, y puede aplicarse para predecir en otras regiones de similar naturaleza con un grado de confianza aceptable.

En la aplicación del modelo de SR a 1 m/px (Fig. 2b) es donde sí se han apreciado claras mejorías en los estadísticos de precisión de clasificación (OA=0.82% y kappa=0.70). Como resultado, la cobertura espacial de cada clase objetivo se acerca más a las estimaciones centimétricas del dron que con el método de escalado, arrojando un 18.10% (28.24 ha) para agua, 38.54% (60.12 ha) para vegetación, y un 43.36% (67.64 ha) para sedimento.

Sin duda, estos resultados sugieren un gran avance en la teledetección de los sistemas costeros intermareales, ya que no sólo se genera un modelo capaz de separar mejor entre los ecotopos de estos ecosistemas tan complejos a una escala de cobertura espacial más amplia, sino que permiten retraerse en el tiempo y elaborar series temporales robustas para analizar con mayor precisión fenologías y tendencias ante los distintos escenarios de cambio climático (Davies *et al.* 2024).

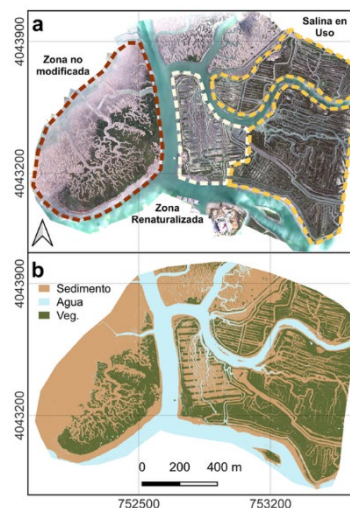


Figura 1. a) Composición RGB del vuelo de dron sobre La Carraca el 14 de julio de 2025. b) Clasificación supervisada XGBoost del vuelo. Se distinguen tres clases: agua, vegetación y sedimento.

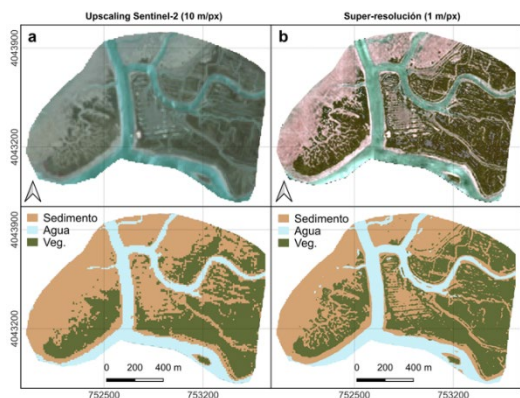


Figura 2. Clasificación XGBoost sobre: a) Escalado a resolución 10 m/px; b) SR a 1 m/px. Se distinguen tres clases: agua, vegetación y sedimento.

Aproximaciones previas basadas en imágenes S2 de resolución espacial media permitieron cartografiar la zonación intermareal del saco interno de la Bahía de Cádiz (Haro *et al.* 2022; Davies *et al.* 2024). Estos resultados se pueden refinar mediante la aplicación del presente modelo de SR a 1 m/px. El elevado valor ecológico de estos sistemas, derivado de la amplia gama de servicios ecosistémicos que proporcionan, junto con su vulnerabilidad frente a las presiones antropogénicas y la regresión de su distribución, ha suscitado un notable interés y ha impulsado diversos esfuerzos de conservación. Además, modelos como el desarrollado

en este estudio pueden contribuir a mejorar la eficacia de las acciones de restauración, ya que una monitorización precisa permite comprender con mayor detalle su fenología, dinámica y tendencias. Esto facilita la toma de decisiones orientadas a incrementar sus probabilidades de supervivencia y establecimiento (Davies *et al.* 2024).

El análisis de correlación espectral (Fig. 3) muestra que el modelo ESRGAN reproduce la respuesta radiométrica del dron con una precisión moderada (R^2 entre 0.53 y 0.75). No obstante, la comparación entre bandas revela una tendencia sistemática a subestimar las reflectancias, especialmente en los rangos medios y altos de los valores normalizados. Esta desviación, situada por debajo de la línea 1:1 ideal y con errores cuadráticos medios que oscilan entre 0.14 y 0.46, sugiere que el proceso de SR no alcanza a replicar totalmente la intensidad radiométrica capturada por el sensor del dron, posiblemente debido a una atenuación de la señal durante la reconstrucción de las características de alta frecuencia. No obstante, pese a los resultados obtenidos con estas aproximaciones, existen otros modelos de SR con mucho potencial y que ya han demostrado estar bien adaptados a los datos satelitales de S2 (*p.e.* modelos de difusión como el DiffFuSR de Sarmad *et al.* 2025 u otras redes neuronales como las empleadas por Major *et al.* 2025). De hecho, algunas de estas aproximaciones buscan refinar aún más el valor espectral del píxel en la mejora de la resolución satelital (Aybar *et al.* 2026).

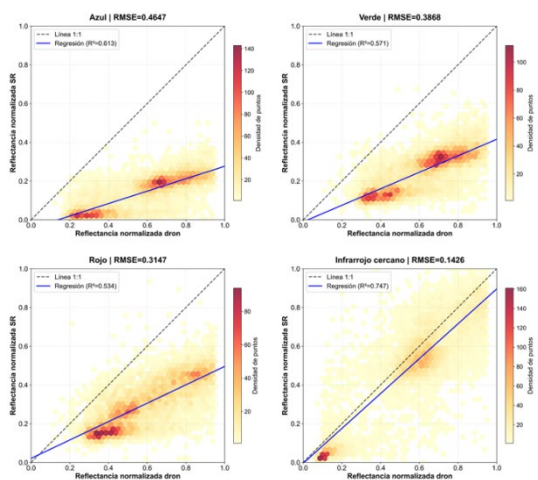


Figura 3. Análisis de correlación espectral entre los valores de reflectancia normalizados de dron y SR.

4. CONCLUSIONES

Los resultados de este estudio ponen de manifiesto el potencial de integrar herramientas de IA mediante modelos multifunción con datos de teledetección a diferentes resoluciones. De las dos aproximaciones evaluadas, la SR de S2 a 1 m/px demuestra una mayor eficiencia cualitativa (especialmente en la definición espacial de estructuras), lo que favorece la clasificación supervisada de coberturas del suelo. No obstante, a nivel cuantitativo, si bien el escalado logra una aproximación a la firma espectral del dron, se observa una tendencia sistemática a la subestimación radiométrica que debe ser considerada en estudios de alta precisión. Sin duda,

estas aproximaciones y la exploración de arquitecturas emergentes contribuirán a mejorar la observación de los sistemas costeros, amenazados ante los efectos del cambio climático.

5. AGRADECIMIENTOS

Esta investigación ha sido posible gracias a los proyectos REWRITE EU (Proyecto nº 101081357) y DIGIDRON (MMT24-ICMAN-01). A. Román, personal contratado bajo la iniciativa Generación D, promovida por Red.es, organismo adscrito al Ministerio de Transformación Digital y Función Pública, destinada a la atracción y retención de talento mediante becas y contratos de formación, financiada por el Plan de Recuperación, Transformación y Resiliencia a través de los fondos Next Generation de la Unión Europea.

6. REFERENCIAS

- Aybar, C. et al. (2026). A radiometrically and spatially consistent super-resolution framework for sentinel-2. *Remote Sensing of Environment*, 334, 115222. <https://doi.org/10.1016/j.rse.2025.115222>
- Curcio, A.C. et al. (2023). UAV-Hyperspectral Imaging to Estimate Species Distribution in Salt Marshes: A Case Study in the Cadiz Bay (SW Spain). *Remote Sensing*, 15(5), 1419. <https://doi.org/10.3390/rs15051419>
- Davies, B.F.R. et al. (2024) A sentinel watching over intertidal seagrass phenology across Western Europe and North Africa. *Communications Earth & Environment*, 5, 382. <https://doi.org/10.1038/s43247-024-01543-z>
- Haro, S. et al. (2022). Microphytobenthos spatio-temporal dynamics across an intertidal gradient using Random Forest classification and Sentinel-2 imagery. *Science of the Total Environment*, 804, 149983. <https://doi.org/10.1016/j.scitotenv.2021.149983>
- Major, D. et al. (2025) A holistic approach for multi-spectral Sentinel-2 super-resolution and spectral evaluation. *International Journal of Remote Sensing*, 46(20). <https://doi.org/10.1080/01431161.2025.2549132>
- Melet, A. et al. (2020). Earth Observations for Monitoring Marine Coastal Hazards and Their Drivers. *Surveys in Geophysics*, 41, 1489-1534. <https://doi.org/10.1007/s10712-020-09594-5>
- Murray, N.J. et al. (2019). The global distribution and trajectory of tidal flats. *Nature*, 565, 222-225. <https://doi.org/10.1038/s41586-018-0805-8>
- Román, A., et al. (2026). Unveiling the large coverage of red snow algae blooms in antarctic coastal snowfields. *Communications Earth & Environment*. <https://doi.org/10.1038/s43247-025-03156-6>
- Sarmad, M. et al. (2025). DiffFuSR: Super-Resolution of all Sentinel-2 Multispectral Bands using Diffusion Models. arXiv. <https://doi.org/10.48550/arXiv.2506.11764>
- Orth, R.J., et al. (2020). Restoration of seagrass habitat leads to rapid recovery of coastal ecosystem services. *Science Advances*, 6(41), eabc6434. <https://doi.org/10.1126/sciadv.abc6434>