

Muñoz-Lorite, J.; Torres-Sánchez, J.; Mesas-Carrascosa, F.; Pérez-Porras, F. Generación de imágenes sintéticas para mejorar la clasificación de sistemas de plantación del olivar con YOLOV8

Generación de imágenes sintéticas para mejorar la clasificación de sistemas de plantación del olivar con YOLOV8

Muñoz-Lorite, Juanma ¹ Torres-Sánchez, Jorge ¹ Mesas-Carrascosa, Francisco Javier ¹ Pérez-Porras, Fernando ¹

¹ Universidad de Córdoba. Departamento de Ingeniería Gráfica y Geomática. España

ORCID: Muñoz-Lorite [0009-0001-8651-9924](https://orcid.org/0009-0001-8651-9924) Torres-Sánchez [0000-0003-1420-0145](https://orcid.org/0000-0003-1420-0145) Mesas-Carrascosa [0000-0002-5674-1292](https://orcid.org/0000-0002-5674-1292) Pérez-Porras [0000-0003-4263-2260](https://orcid.org/0000-0003-4263-2260)

Correspondencia: g92muloj@uco.es o22tosaj@uco.es ig2mecaf@uco.es o12pepof@uco.es

RESUMEN

Para la determinación automática del sistema de plantación del olivar se desarrolló una metodología basada en Deep Learning a partir de imágenes sintéticas generadas para la clasificación de estos olivares usando YOLOV8. Muchas redes neuronales de clasificación presentan como principal requisito técnico un tamaño fijo de entrada de 299×299 píxeles, lo que implica que cada imagen debe representar una superficie mínima de 2,23 ha si se trabaja con imágenes de 0,5 m/píxel como las de PNOA. Como consecuencia, las parcelas de menor tamaño quedan excluidas del análisis, lo que limita la aplicabilidad del método a determinadas explotaciones. Con el fin de superar esta limitación, se ha desarrollado una nueva metodología para la generación de imágenes sintéticas que permite reducir el tamaño efectivo de la imagen de entrada sin perder la información estructural necesaria para la clasificación. Gracias a ello, es posible analizar parcelas con una superficie mínima de 0,13 ha. El modelo entrenado con la arquitectura de YOLOV8 alcanzó un F1-Score de 98.3% y una exactitud media del 98,2 % en validación. Este enfoque amplía el rango de parcelas analizables y sienta las bases para una mejor generalización del modelo, incrementando su potencial de aplicación a escala territorial.


Palabras clave: *Olivar, teledetección, imágenes sintéticas, YOLOV8, data augmentation.*


Fecha de recepción: 9 febrero 2026 · Fecha de aceptación: 9 febrero 2026


Generación de imágenes sintéticas para mejorar la clasificación de sistemas de plantación del olivar con YOLOV8


Muñoz-Lorite, Juanma ⁽¹⁾, Torres-Sánchez, Jorge ⁽¹⁾, Mesas-Carrascosa, Francisco Javier ⁽¹⁾, Pérez-Porras, Fernando ⁽¹⁾

⁽¹⁾ Universidad de Córdoba. Departamento de Ingeniería Gráfica y Geomática. España.

 0009-0001-8651-9924, g92muloj@uco.es.

 0000-0003-1420-0145, o22tosaj@uco.es.

 0000-0002-5674-1292, ig2mecaf@uco.es.

 0000-0003-4263-2260, o12pepof@uco.es.

Resumen: Para la determinación automática del sistema de plantación del olivar se desarrolló una metodología basada en Deep Learning a partir de imágenes sintéticas generadas para la clasificación de estos olivares usando YOLOV8. Muchas redes neuronales de clasificación presentan como principal requisito técnico un tamaño fijo de entrada de 299×299 píxeles, lo que implica que cada imagen debe representar una superficie mínima de 2,23 ha si se trabaja con imágenes de 0,5 m/píxel como las de PNOA. Como consecuencia, las parcelas de menor tamaño quedan excluidas del análisis, lo que limita la aplicabilidad del método a determinadas explotaciones. Con el fin de superar esta limitación, se ha desarrollado una nueva metodología para la generación de imágenes sintéticas que permite reducir el tamaño efectivo de la imagen de entrada sin perder la información estructural necesaria para la clasificación. Gracias a ello, es posible analizar parcelas con una superficie mínima de 0,13 ha. El modelo entrenado con la arquitectura de YOLOV8 alcanzó un F1-Score de 98,3% y una exactitud media del 98,2 % en validación. Este enfoque amplía el rango de parcelas analizables y sienta las bases para una mejor generalización del modelo, incrementando su potencial de aplicación a escala territorial.

Palabras clave: Olivar, teledetección, imágenes sintéticas, YOLOV8, data augmentation.

Synthetic Image Generation to Improve the Identification of Olive Grove Planting Systems with YOLOV8

Abstract: *For the automatic determination of olive grove planting systems, a methodology based on Deep Learning was developed using synthetic images generated for the classification of these groves with YOLOv8. Many classification neural networks require a fixed input size of 299×299 pixels, which means that each image must represent a minimum area of 2.23 ha when working with 0.5 m/pixel imagery such as that provided by PNOA. As a result, smaller plots are excluded from the analysis, limiting the applicability of the method to certain farms. To overcome this limitation, a new methodology for generating synthetic images has been developed, enabling a reduction in the effective size of the input image without losing the structural information required for classification. This makes it possible to analyse plots with a minimum area of 0.13 ha. The model trained with the YOLOv8 architecture achieved an F1-Score of 98.3% and an average accuracy of 98.2% in validation. This approach broadens the range of plots that can be analysed and lays the foundations for improved model generalisation, increasing its potential for application at territorial scale.*

Keywords: *Olive grove, remote sensing, synthetic images, YOLOV8, data augmentation.*

1. INTRODUCCIÓN

La intensificación del olivar en Andalucía ha transformado los sistemas de plantación, pasando de modelos tradicionales (<200 árboles/ha) a intensivos (200-800 árboles/ha) y superintensivos (>800 árboles/ha) (Pastor *et al.*, 2005). Para cuantificar en hectáreas esta evolución del manejo del olivar, se requiere de herramientas objetivas que permitan su caracterización a escala parcela de forma masiva. En trabajos previos, se desarrolló una metodología con

clasificadores como InceptionV3 sobre ortoimágenes PNOA (0,5 m/píxel), alcanzando un 85,91 de F1-score (Muñoz-Lorite *et al.*, 2024). Sin embargo, su requisito de entrada de uso de imágenes de 299×299 píxeles excluían parcelas <2,23 ha. Debido a la resolución espacial de la fuente de entrada, el análisis territorial se sesga hacia explotaciones grandes, generalmente con manejo intensivo, y excluye a las pequeñas, con mayor variabilidad y, sobre todo, presencia de manejo tradicional. Este tipo de redes neuronales no admite datos de entrada con menos de este número de píxeles.

Para superar esta limitación, se propone generar imágenes sintéticas, una estrategia que se ha demostrado clave para ampliar la representatividad en los conjuntos de datos agrícolas donde existe una limitación en las tomas de muestras (Lu *et al.*, 2022), usando el polo de inaccesibilidad que queda definido como el punto interno que maximiza la distancia a los bordes de una geometría (García-Castellanos & Lombardo, 2007), identificando la zona más representativa de esta. Esta novedad geométrica permite analizar parcelas $\geq 0,13$ ha, replicando InceptionV3 pero con otra red neuronal de clasificación como YOLOV8, con gran adaptabilidad a datos sintéticos (Qin *et al.*, 2024). El método amplía la representatividad ya que de aproximadamente 1,6 millones de ha de olivar que hay en Andalucía, con este enfoque se podrían analizar 1,54 millones, mientras que con el tamaño fijo solo se llegaría a 0,99 millones de ha.

2. MATERIAL Y MÉTODOS

2.1. Área de estudio y datos de entrada

El área de estudio se localiza en el denominado Eje del Olivar en Andalucía, una de las principales regiones productoras de aceite de oliva a escala mundial (Junta de Andalucía. Consejería de Agricultura, 2025), caracterizada por una elevada heterogeneidad en los sistemas de plantación y marcos de cultivo (Figura 1). Esta diversidad convierte al territorio en un entorno idóneo para evaluar metodologías orientadas a la identificación automática de sistemas de plantación mediante técnicas de teledetección y aprendizaje profundo.

Como fuente principal de información se emplearon ortoimágenes aéreas procedentes del Plan Nacional de Ortofotografía Aérea (IGN, n.d.), seleccionándose aquellas campañas con resoluciones espaciales de 0,5 m, las cuales se adaptan mejor para determinar patrones de plantación como ya se demostró (Muñoz-Lorite *et al.*, 2026). La delimitación de las parcelas de olivar se realizó a partir de recintos vectoriales proporcionados por SIGPAC (Junta de Andalucía-Spain, n.d.) determinados como olivar, sobre los que se desarrolló un preprocesado espacial orientado a la extracción de información representativa del sistema de plantación.

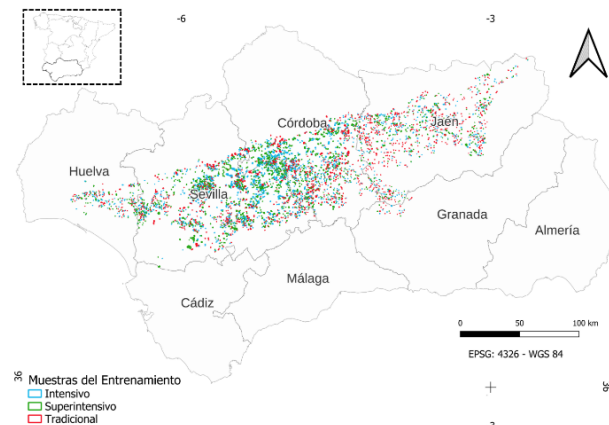


Figura 1 Localización de las muestras para el entrenamiento del modelo.

2.2. Generación de imágenes sintéticas

La generación de imágenes sintéticas constituye una etapa clave del flujo metodológico propuesto. Con el objetivo de evitar el sesgo a grandes plantaciones, maximizar el aprovechamiento de la información espacial disponible y predecir sobre casi el total de las parcelas de olivar de Andalucía, se desarrolló una metodología específica para la generación de imágenes sintéticas, orientada a preservar los patrones estructurales del cultivo independientemente del tamaño de la parcela. El procedimiento se basa en la identificación de la zona más representativa de cada parcela y en la generación automática de un recorte óptimo que pueda ser posteriormente adaptado al tamaño de entrada requerido por los modelos de Deep Learning. En una primera fase, se determinó para cada parcela el denominado polo de inaccesibilidad, este concepto geométrico garantiza que el área seleccionada se sitúe en la zona menos influenciada por los límites parcelarios, maximizando la representatividad del patrón de plantación. El cálculo de este punto ' $dist_{pole}$ ' se realizó sobre geometrías proyectadas en UTM, utilizando métricas euclidianas. La distancia euclidiana d entre un punto (X_p, Y_p) y el punto más cercano (X_s, Y_s) de un segmento del borde se calcula mediante la Ecuación 1.

A partir del polo de inaccesibilidad, se calculó el lado del mayor cuadrado que puede inscribirse dentro de cada parcela y centrarse en dicho punto, generándose un nuevo atributo geométrico denominado '**Side**' (Ecuación 2). Este valor define las dimensiones máximas del recorte espacial que puede obtenerse sin exceder los límites de la parcela. Con el fin de garantizar la calidad del conjunto de datos, se estableció un umbral mínimo de 25 m para el valor '**Side**', asegurando que, incluso en los sistemas de plantación más extensivos, cada imagen contuviera al menos 2 copas de olivo. Para sistemas de plantación intensivos, se garantiza que el parche contenga al menos 9 copas de olivo, mientras que para el caso de superintensivo se aseguran al menos 7 filas de árboles. Este criterio se fundamenta en el conocimiento agronómico de los marcos de plantación del olivar, donde las distancias entre árboles rara vez superan los 14–15 metros en sistemas tradicionales (Barranco, 2008).

$$dist_{pole} = \sqrt{((X_p - X_s)^2 + (Y_p - Y_s)^2)} \quad (1)$$

$$Side = 2 \times dist_{pole} \times \sin(45^\circ) \quad (2)$$

Una vez definido el valor Side, se procedió a la generación automática del cuadrado. Posteriormente, se cortó la imagen PNOA con este cuadrado ofreciendo como resultado una imagen sin un tamaño fijo de píxeles. Esta es la base de la imagen sintética, la cual sirve como tesela para generar la imagen final de 299x299, uniendo consecutivamente tesela tras tesela hasta completar una imagen del tamaño requerido. Las que eran mayores a 299x299 píxeles se recortaron, garantizando así la homogeneidad dimensional del conjunto de datos sin pérdida de coherencia espacial. Este enfoque permitió ampliar significativamente el número de parcelas analizadas. El proceso se describe en la Figura 2.

2.3. Entrenamiento del modelo YOLOV8

Para la detección del sistema de plantación en el olivar, se entrenó YOLOV8 de Ultralytics utilizando un dataset compuesto por 6.000 imágenes pertenecientes cada una a una parcela diferente (2.000 muestras por clase: i) Tradicional, ii) Intensivo y iii) Superintensivo) procedentes de la ortofotografía del PNOA con una resolución de 0,5m pixel y mediante el proceso de generación de imágenes sintéticas generadas mediante el proceso anteriormente descrito.

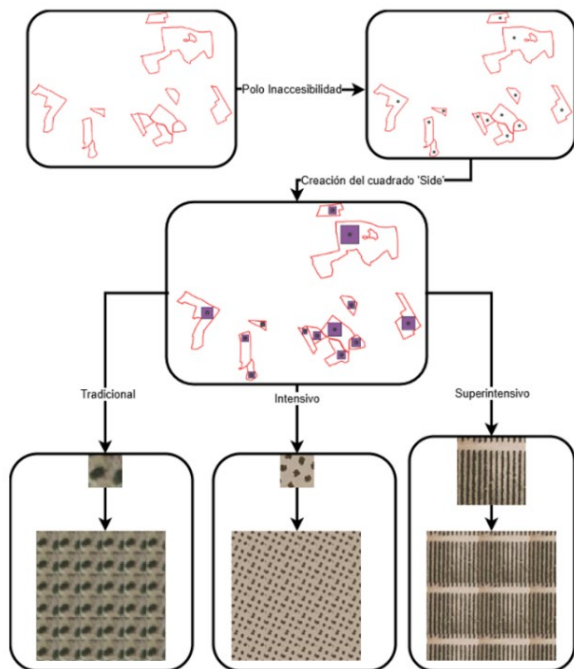


Figura 2 Proceso de obtención de la imagen sintética.

El dataset se particionó en 3 conjuntos elegidos aleatoriamente, para entrenamiento, validación y testeo con una proporción del 70/20/10.

3. RESULTADOS Y DISCUSIÓN

Los resultados para la validación del modelo ofrecieron unos resultados en Precisión de 98,5%, Recall 98,1% y F1-score 98,3%, métrica utilizada como referencia para la comparativa de modelos (Figura 3). Se observa que el F1-score en validación aumenta rápidamente, alcanzando su máximo en la época 3 después del fine tuning dónde posteriormente disminuye ligeramente y aumentando hasta estabilizarse. Otras arquitecturas con YOLOv8 con objetivos similares en agricultura los resultados son similares a los de otros autores (Zhu *et al.*, 2025) y se obtienen métricas parecidas a las obtenidas con la anterior metodología usando imágenes con una extensión mínima de 2,23 ha en vez de 0,13 ha (Muñoz-Lorite *et al.*, 2026). En cuanto a la exactitud en validación, se obtuvo un resultado del 98,2%.

La aplicación de la metodología propuesta para la generación de imágenes sintéticas tendrá un impacto directo y significativo en la escala y representatividad del análisis territorial de los sistemas de plantación del olivar a escala Andalucía (Tabla 1). Para esta Comunidad

Autónoma, las parcelas menores de 2,23 ha representan 1.277.067 parcelas y 649.196,94 ha, es decir, el 39,59% de la superficie total olivarera considerada. De las parcelas que se podrán clasificar, 130.775 parcelas concentran el 60,41% de la superficie (990.423,50 ha). La exclusión sistemática de las parcelas pequeñas, derivada de los requisitos geométricos de los modelos de Deep Learning, habría supuesto descartar casi el 40% de la superficie de olivar analizable en Andalucía, lo que dificultaría calcular una evaluación precisa del manejo del olivar en los últimos 10 años. Mediante la metodología basada en las imágenes sintéticas, será posible analizar 769.202 parcelas, que suman 1.540.326,61 ha, aumentando unas quinientas cincuenta mil hectáreas respecto a la solución anterior. En total, quedarán unas cien mil hectáreas, un 6,06% del total sin predecir, debido a que son unas parcelas muy pequeñas o con formas tan irregulares que no permiten recortar una imagen con al menos 25 metros de lado para contener la mínima información exigida sobre la parcela.




Figura 3. F1-score en el entrenamiento del modelo YOLOv8.

En términos relativos, la propuesta conserva aproximadamente el 94% de la superficie total inicial de Andalucía, reduciendo el impacto de las limitaciones geométricas sobre el conjunto de datos. La incorporación masiva de parcelas de menor tamaño, especialmente relevantes en el olivar tradicional, mejorará de forma notable la representatividad espacial y tipológica de los análisis evolutivos, reforzando la validez de los resultados obtenidos en estudios de carácter regional y territorial. Desde el punto de vista metodológico, la principal innovación del trabajo radica en el enfoque adoptado para la generación de imágenes sintéticas.

Tabla 1. Distribución de las superficies en Andalucía bajo los dos enfoques distintos

Escenario	Parcelas	Superficie (ha)	% Total
TOTAL	1.407.842	1.639.620,44	100%
Metodología imágenes sintéticas			
Side ≥25m	769.202	1.540.326,61	93,94%
Side <25m	638.640	99.293,83	6,06%
Resumen parcelas por tamaño anterior/actual			
≥2,23 ha	130.775	990.423,50	60,41%
<2,23 ha	1.277.067	649.196,94	39,59%

En el contexto agrícola, diversas investigaciones han explorado la generación de imágenes sintéticas porque no se disponen de datos suficientes. Usando imágenes sintéticas se han resuelto problemas para la detección de plantas de pimiento, identificar flores, segmentar raíces o lesiones foliares (Afonso & Giufrida, 2023). Otros estudios como el de Giakoumoglou *et al.* (2023) emplean modelos de difusión para generar artificialmente instancias de insectos plaga (como la mosca blanca) y las insertan en posiciones arbitrarias sobre fondos de hojas para entrenar algoritmos de detección. A diferencia de estos enfoques y de los métodos tradicionales basados en estrategias de colocación aleatoria (random crop-and-paste) (Ghiasi, 2022), la metodología propuesta se apoya en criterios geométricos avanzados teniendo en cuenta el sistema de plantación. Aunque en la literatura se subraya la constante necesidad de generar datos sintéticos de mayor realismo (Afonso & Giufrida, 2023), las aproximaciones previas no incorporan de forma explícita la estructura espacial ni las restricciones geométricas propias de los sistemas de cultivo reales. La selección óptima de imágenes para garantizar la identificación precisa del sistema de plantación ha sido el mayor reto técnico del procedimiento necesitando conocer correctamente mediante fotointerpretación todos los sistemas de cultivo. En contraste, el presente trabajo integra métricas geométricas avanzadas permitiendo identificar posiciones internas óptimas dentro de cada parcela.

4. CONCLUSIONES

Se ha desarrollado una metodología basada en la generación de imágenes sintéticas que permite superar las limitaciones geométricas de tamaño de los modelos de aprendizaje profundo aplicados al análisis de sistemas de plantación del olivar. Este enfoque posibilita la incorporación de parcelas de pequeño tamaño a la clasificación de imágenes, tradicionalmente excluidas, eliminando sesgos y mejorando la representatividad territorial del análisis.

La principal contribución del trabajo reside en la integración del polo de inaccesibilidad, y en la generación de datos sintéticos, frente a enfoques aleatorios predominantes en la literatura. La metodología propuesta es escalable y transferible a otros cultivos leñosos y contextos agrícolas fragmentados, constituyendo una base sólida para futuros análisis territoriales a gran escala. Como futuros trabajos se propone hacer un estudio para la predicción de los sistemas de plantación a nivel regional con el 100% de las parcelas de olivar en Andalucía, para estudiar la evolución multitemporal de la intensificación del olivar en Andalucía y su relación con el consumo de agua.

5. AGRADECIMIENTOS

Esta investigación se enmarca en la Cátedra Internacional ENIA en Agricultura de la Universidad de Córdoba (TSI-100921-2023-3), financiada por la Secretaría de Estado de Digitalización e Inteligencia Artificial y por la Unión Europea – Next Generation EU,

en el marco del Plan de Recuperación, Transformación y Resiliencia.

6. REFERENCIAS

- Barranco, D. F.-E. R. R. L. (2008). El cultivo del olivo (6th ed.). Mundi-Prensa.
- García-Castellanos, D., & Lombardo, U. (2007). Poles of inaccessibility: A calculation algorithm for the remotest places on earth. *Scottish Geographical Journal*, 123(3), 227–233. <https://doi.org/10.1080/14702540801897809>
- IGN. (n.d.). PNOA IGN. Retrieved April 15, 2025, from <https://surl.li/npynbj>
- Junta de Andalucía. Consejería de Agricultura, P. A. y D. R. (CAPADR). (2025). Primera Estrategia Andaluza para el Sector del Olivar: Horizonte 2027, from <https://surl.li/bftsxh>
- Junta de Andalucía-Spain. (n.d.). SIGPAC. Retrieved <https://surl.li/gmiitb>
- Lu, Y., Chen, D., Olaniyi, E., & Huang, Y. (2022). Generative adversarial networks (GANs) for image augmentation in agriculture: A systematic review. *Computers and Electronics in Agriculture*, 200. <https://doi.org/10.1016/j.compag.2022.107208>
- Muñoz-Lorite, J., Torres-Sánchez, J., Cantón-Martínez, S., Mesas, F. J., & Pérez Porras, F. (2026). Automatic detection of olive grove planting systems using Deep Learning algorithms. <https://doi.org/10.2139/ssrn.6183764>
- Muñoz-Lorite, J., Torres-Sánchez, J., Mesas-Carrascosa, F. J., & Pérez-Porras, F. (2024). Clasificación de sistemas de plantación del olivar en Andalucía mediante ortoimágenes y modelos de aprendizaje profundo En Teledetección y Cambio Global: Retos y Oportunidades para un Crecimiento Azul, Actas del XX Congreso de la Asociación Española de Teledetección. <http://www.aet.org.es/?q=congresos>
- Pastor, M., Vega, V., & Hidalgo, J. C. (2005). Trials in super-intensive and intensive olive groves. *Vida Rural*, 218, 30–34.
- Qin, R., Wang, Y., Liu, X., & Yu, H. (2024). Advancing precision agriculture with deep learning enhanced SIS-YOLOv8 for Solanaceae crop monitoring. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1485903>
- Zhu, H., Wang, D., Wei, Y., Wang, P., & Su, M. (2025). YOLOv8-CMS: a high-accuracy deep learning model for automated citrus leaf disease classification and grading. *Plant Methods*, 21(1). <https://doi.org/10.1186/s13007-025-01396-3>