

**(06-018) - ARTIFICIAL INTELLIGENCE MODELS BASED ON DEEP LEARNING
APPLIED TO THE DETECTION OF OLIVE FRUITS IN TACNA, PERU**

Oscó Mamani, Erbert Francisco ¹; Yanapa Chicalla, Alejandro Daniel ²; Santana Carbajal, Oliver Israel ²; Chaparro Cruz, Israel N. ²

¹ Universidad Nacional Jorge Basadre G, ² Universidad Nacional Jorge Basadre G.

Climate change, El Niño, infectious diseases, foliage and fruit shade can have a significant impact on automated counting and estimation of productivity in olive fruit plots. With an area of 35,000 ha, the Tacna Region is the main producer with 81% of the olives in Peru and is the second largest exporter and third largest producer of olive oil in South America. The objective of this paper is to compare the performance of AI models for olive fruit detection. This work uses a set of 10,728 images obtained from cropping 447 photographs of olive trees in La Yarada Los Palos, Tacna, Peru. This study compares artificial intelligence models based on deep learning with 3 architectures applied to object detection: "YOLOv8s, Faster R-CNN 101 and RetinaNet 101". The images were divided into 8,549 (80 %) for training and 2,179 (20 %) for validation. The results of the olive fruit detection investigation show that YOLOv8s models improve in mAP "Mean Average Accuracy" of 0.94759, Faster R-CNN101 of 0.78131 and RetinaNet101 of 0.69626.

Keywords: artificial intelligence models; deep learning; olive fruits

**MODELOS DE INTELIGENCIA ARTIFICIAL BASADOS EN APRENDIZAJE
PROFUNDO APLICADOS A LA DETECCIÓN DE FRUTOS DE OLIVO EN TACNA,
PERU**

El cambio climático, el fenómeno del niño, las enfermedades infecciosas, el follaje y la sombra del fruto pueden tener un impacto significativo en el conteo y estimación automatizados de la productividad en parcelas de frutos de olivo. Con una superficie de 35,000 ha., la Región de Tacna es el principal productor con 81% de las aceitunas en Perú y es el segundo exportador y tercer productor de aceite de oliva en América del Sur. El objetivo del presente artículo es comparar el rendimiento de modelos de IA para la detección de frutos de olivo. Este trabajo utiliza un conjunto de 10,728 imágenes obtenidas de recortar 447 fotografías de árboles de olivos en La Yarada Los Palos, Tacna, Perú. Este estudio compara modelos de inteligencia artificial basados en aprendizaje profundo con 3 arquitecturas aplicadas a la detección de objetos: "YOLOv8s, Faster R-CNN 101 y RetinaNet 101". Las imágenes se dividieron en 8,549 (80 %) para entrenamiento y 2,179 (20 %) para validación. Los resultados de la investigación de detección de frutos de olivo muestran que los modelos YOLOv8s mejoran en mAP "Mean Average Precisión" de 0,94759, Faster R-CNN101 de 0,78131 y RetinaNet101 de 0,69626.

Palabras clave: modelos inteligencia artificial; aprendizaje profundo; frutos de olivo

Correspondencia: Vicente Rodríguez Montequín, montequi@uniovi.es

Agradecimientos: Esta investigación tiene apoyo de Canon, Sobrecanon y regalías mineras de la Universidad Nacional Jorge Basadre Grohmann de Tacna, Perú



©2024 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

El olivo (*Olea europaea*) se cultiva en todo el mundo, principalmente en Europa y África, y sus frutos se procesan para obtener aceitunas de mesa y aceite de oliva (Uylaşer & Yildiz, 2014). La producción oleícola es una actividad agroindustrial importante para el desarrollo económico y social de la región sur del Perú. En las regiones áridas y semiáridas, la vulnerabilidad al cambio climático, unida a la sobreexplotación de los recursos hídricos, amenaza la seguridad alimentaria, y los olivos no son ajenos a este problema. (Abahous et al., 2021). El fenómeno del niño diezma la cosecha de aceituna peruana a tal punto que los funcionarios anticipan una disminución del 90 por ciento la cosecha de aceituna peruana y en la producción de aceite de oliva en 2024 debido a temperaturas invernales muy altas (Olive Oil Times, 2024).

En la Región de Tacna, Perú, la industria de la aceituna desempeña un papel fundamental en la agricultura. A nivel nacional se cuenta con 45,000 hectáreas de cultivo de olivo de las cuales 35,000 hectáreas (86%) se encuentran en la región de Tacna (Agraria.pe, 2024). Los agricultores realizan una detección temprana de la cosecha de aceituna mediante seguimiento visual, inspeccionando olivos, observando el color y apariencia del fruto, sin embargo, este método puede resultar inexacto y poco escalable. La utilización de los avances tecnológicos para predecir fecha, maduración y producción de aceitunas permite optimizar la recolección garantizando la calidad del producto.

Los modelos de redes neuronales profundas se han convertido en poderosas herramientas de aprendizaje automático e inteligencia artificial y pueden ser usados para la detección de frutos en general. En el trabajo de Aljaafreh et al. (2023) los modelos se construyen a partir de un conjunto de datos de imágenes digitales de árboles con frutos de olivos para poder entrenar y evaluar la capacidad de detección de aceitunas en tiempo real por los modelos YOLOv5 Y YOLOR.

La detección de la madurez del fruto del olivo (*Olea europaea* L.) en los huertos es importante para garantizar la cantidad y calidad del aceite de oliva. Zhu et al. (2024) resaltó que mayoría de las investigaciones existentes prestan más atención a la detección del fruto del olivo e ignoran los problemas de detección de la madurez del fruto del olivo, y propusieron un modelo llamado Olive-EfficientDet para detectar madurez de frutos de olivo.

Asimismo, la detección de cítricos sigue siendo una tarea difícil debido a la iluminación variable, la oclusión aleatoria y la similitud de color entre frutas y hojas en condiciones naturales. Li et al. (2021) propusieron un método de detección denominado Lemon-YOLO (L-YOLO) para detectar limones con un alto rendimiento y en tiempo real.

El recuento de frutos basado en la visión por ordenador ha también un objeto esencial de investigación, ya que es una forma automática de reconocer frutos densos en la rama. Sin embargo, el recuento completo de frutos de todo un árbol apenas se ha estudiado. Además, se carece de métodos robustos y precisos para el recuento de frutos en situaciones complejas, como cobertura, sombras o agrupación de imágenes. Zhang et al. (2022) empleó una red basada en YOLOX para realizar el conteo de frutas mostrando una alta precisión y una excelente eficacia de inferencia, lo que le confiere un potencial para su aplicación en la gestión de huertos y plantaciones.

La inestabilidad climática y la vecería del olivar, así como las plagas y enfermedades, son factores que impactan directamente en la producción agraria y que, en cada campaña, generan incertidumbres a los olivareros, a las empresas oleícolas y a las industrias almazaras (Ramos et al., 2023). Es necesaria la utilización de la tecnología para la predicción temprana, minimizar la incertidumbre sobre la producción de aceituna, tomar decisiones estratégicas correctas y optimizar recursos en las fases de cultivo y comercialización de la aceituna.

Existen algunos factores que influyen en la detección temprana de aceituna, como son el tipo de aceituna, el ciclo de maduración, el clima donde se cultivan los olivos, el método tradicional o intensivo, la salud del árbol, los nutrientes, el riego.

El estudio se centra en la importancia de realizar estimación precisa y temprana de la producción de aceitunas, específicamente en la olivicultura. Se propone un modelo de algoritmo de visión artificial para detectar frutos de olivo en imágenes de campo con iluminación diurna. Para responder a interrogantes planteadas, ¿Cómo funcionan los modelos de IA en la identificación de frutos de olivo en la Yarada Los Palos de Tacna?

Las principales contribuciones se resumen en: se implementaron tres modelos pre-entrenados de detección de objetos con arquitecturas diferentes, se entrenaron los modelos seleccionados con un conjunto de datos de frutos de olivo de la región de Tacna, se comparó el rendimiento de los modelos entrenados a través de diversas métricas para comprender mejor su rendimiento.

Asimismo, el presente trabajo está organizado de la siguiente manera: Sección 2, se presenta los materiales y métodos, marco teórico, equipos y materiales y flujo de trabajo. En la sección 3 se presentan los resultados de investigación realizada para los tres modelos de IA relevantes: YOLOv8, RetinaNet y Faster R-CNN aplicados a identificar frutos de olivo, en el conjunto de datos de la Yarada Los Palos, Tacna - Perú, y evaluando el mejor rendimiento de los modelos entrenados, en la sección 4 se presentan las discusiones. Por último, en la sección 4, se indican las conclusiones de la presente investigación.


2. Materiales y métodos

2.1 Base teórica

YOLOv8

YOLO es un popular algoritmo de detección de objetos en tiempo real que ha sido mejorado a través del tiempo, siendo su primera versión (YOLOv1) propuesta en 2015 y la más reciente YOLOv8 propuesta en 2023. YOLOv8 introduce mejoras significativas como una nueva arquitectura de red neuronal que utiliza Feature Pyramid Network (FPN), Path Aggregation Network (PAN) y una nueva herramienta de etiquetado que simplifica el proceso de anotación de imágenes (Reis et al. 2023).

Figura 1: Arquitectura YOLOv8 (Butt, Glas, Monsuur, Stoop, & de Keijzer, 2023)



En la figura 1, se muestra una visualización detallada de la arquitectura de la red YOLOv8, toda la arquitectura se puede dividir en dos partes principales, la columna vertebral y la cabeza (Butt et al., 2023).

RetinaNet

RetinaNet, es una red única y unificada compuesta por una red de base y dos subredes específicas de tarea. La red base es responsable de calcular un mapa de características convolucionales sobre la imagen de entrada y es una red convolucional preexistente. La primera subred realiza la clasificación convolucional de objetos en la salida de la red base y

la segunda subred realiza la regresión convolucional de cuadros delimitadores. Ambas subredes presentan un diseño simple que se propone específicamente para la detección densa de una sola etapa (Lin et al., 2020).

Faster R-CNN

Faster R-CNN es una arquitectura de detección de objetos que aborda el problema de la generación de propuestas de regiones de interés (ROIs) de manera eficiente y precisa. Consiste en tres componentes principales: Red convolucional compartida, Región proposal Network (RPN), Módulo de detección (Ren et al., 2017).

Detectron 2

Fue lanzado por Facebook AI Research el 2019, como una actualización del framework original detectron. Este framework está diseñado principalmente para tareas de detección de objetos y segmentación de instancias. (Butt et al., 2023)

COCO

Common Objects in COntext (COCO) es un dataset que contiene más de 328 mil imágenes con etiquetas para detección de objetos y segmentación, y es utilizado usualmente como punto de referencia para comparar modelos de detección de objetos con propósitos generales. (Lin et al., 2014)

2.2 Metodología

Plataforma Experimental

Como hardware para ejecutar los experimentos detallados anteriormente se contó con una workstation de alto rendimiento con las siguientes características: Procesador Intel® Xeon® Silver 4214 2.20 GHz, Memoria RAM: 64 GB DDR4 2933 366 MHz, Almacenamiento de 1 TB SSD, Aceleración por GPU con una tarjeta NVIDIA A5000 de 24GB.

Como software para entrenar los modelos de Faster R-CNN, RetinaNet se utilizó el framework Detectron 2 y para el modelo YOLOv8 se utilizó el framework Ultralytics YOLOv8, estos se entrenaron en el entorno de Jupyter-Lab v4.0.6 con CUDA v12.2.

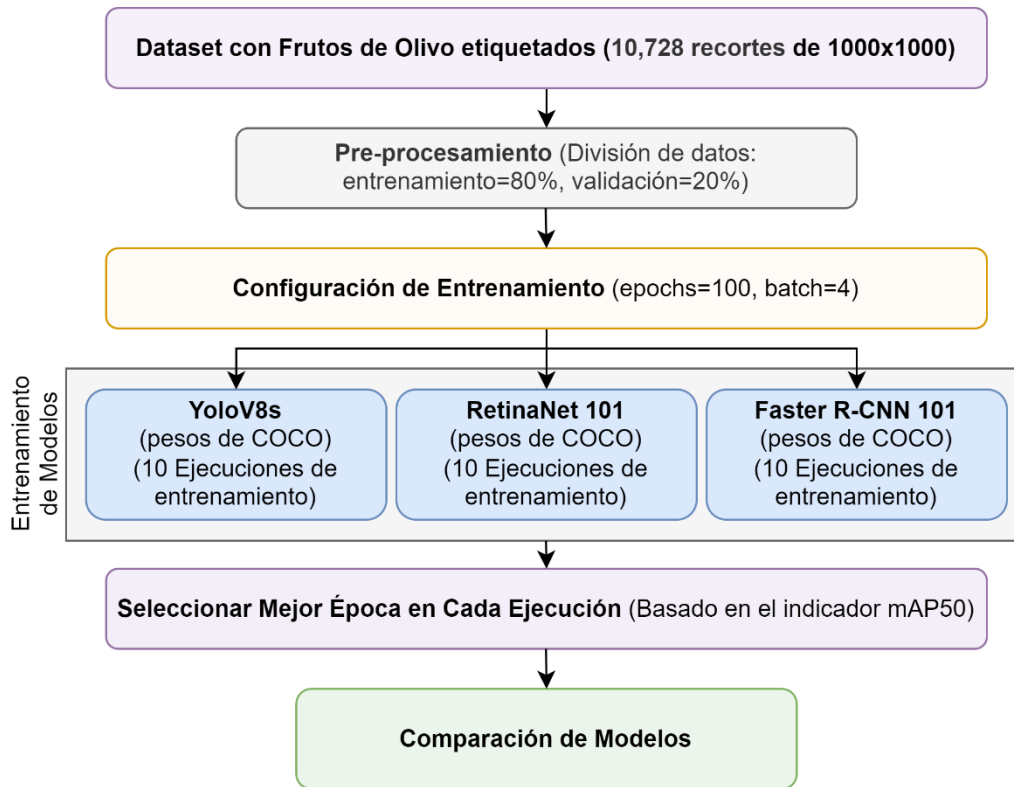
Recolección y Pre-procesamiento de Datos

Las imágenes fueron obtenidas del Proyecto de Investigación: “Estimación de productividad de olivares usando técnicas de visión artificial y aprendizaje profundo en la Región de Tacna” de la Universidad Nacional Jorge Basadre Grohmann; el conjunto de datos consiste en 10,728 recortes de 1000x1000 píxeles de 447 imágenes de tamaño 4000x6000 píxeles de árboles de olivos de La Yarada Los Palos, Tacna, Perú, las imágenes se tomaron con variaciones de horario e iluminación diurna natural. En los recortes con formato “.png” se procedió al tratamiento de datos y eliminación de duplicados, y junto con los recortes se encuentran archivos codificados “.json” de las coordinas de los cuadros delimitadores que enmarcan aceitunas. El objetivo de dividir los datos es evitar el sobre-ajuste (Muraina, 2022), el conjunto de datos se dividió de forma aleatoria en 8,549 (80%) imágenes para el entrenamiento de los modelos y 2,179 (20%) imágenes para la validación de los modelos.

Configuración Experimental

Se entrenaron los siguientes modelos de detección de objetos pre-entrenados en COCO: YOLOv8s, RetinaNet 101 y Faster R-CNN 101. Cada uno de los modelos fue entrenado con el conjunto de datos de entrenamiento de frutos de olivo en árbol descrito anteriormente durante 100 épocas con un tamaño de lote igual a 4. Luego, se ejecutó 10 veces cada uno de los entrenamientos a fin de tener resultados más fiables. Finalmente, se compararon los resultados de todos los entrenamientos a fin de presentar los resultados de la presente investigación.

Figura 2: Flujo de trabajo y entrenamiento



En la figura 2, se muestra el flujo de trabajo y entrenamiento desarrollado para el presente estudio.

Métricas de Evaluación

Las métricas que se tomaron en cuenta para la comparación de los modelos son:

M1: Mean Average Precision (mAP), El Valor (mAP) se calcula tomando la media de los valores AP de todas las clases (Butt et al., 2023). Está determinado por la fórmula 1:

$$mAP = \frac{1}{n} \sum_{i=1}^n [AP_i] \quad (1)$$

Donde AP es el valor de precisión media y n es el número total de clases. mAP50 hace referencia a Mean Average Precision (mAP) con un umbral de IoU de 0,5.

M2: Precisión, es la capacidad de un modelo para identificar sólo los objetos relevantes (Padilla et al., 2020). Este indicador está determinado por la fórmula 2:

$$P = \frac{TP}{TP + FP} \quad (2)$$

Donde P es la Precisión, mientras que TP son los verdaderos positivos (detección correcta de un recuadro de delimitación) y FP representa los falsos positivos (detección incorrecta de un objeto inexistente o detección errónea de un objeto existente).

M3: Recuperación (Recall), es la capacidad de un modelo para encontrar todos los casos relevantes (todos los recuadros de delimitación etiquetados) (Padilla et al., 2020). Este indicador está determinado por la fórmula 3:

$$R = \frac{TP}{TP + FN} \quad (3)$$

Donde R es la recuperación (Recall), mientras que TP son los verdaderos positivos (detección correcta de un cuadro de delimitación) y FN representa los falsos negativos (un cuadro delimitador no detectado)

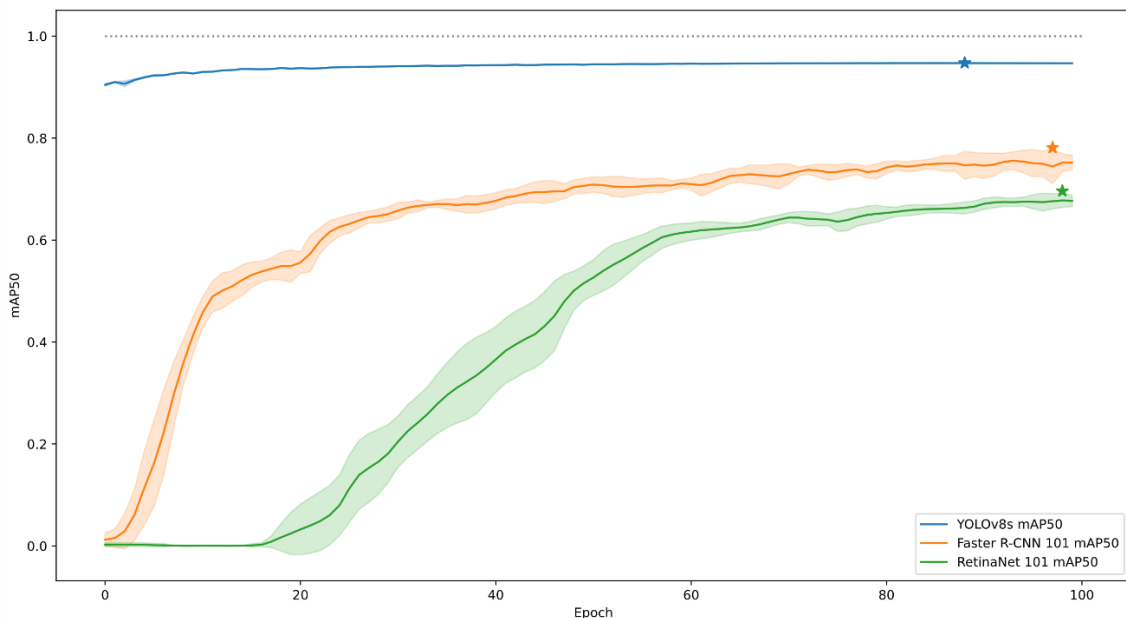
3. Resultados

En esta sección se muestran los resultados de los experimentos realizados con los modelos: YOLOv8, RetinaNet, Faster R-CNN entrenados en el conjunto de datos y métricas descritos.

3.1 Resultados para el indicador de Mean Average Precision (mAP50)

En la figura 3, se presenta un diagrama de líneas de la métrica Mean Average Precision (mAP50) en el conjunto de datos de validación a través de 100 épocas para las 10 repeticiones de entrenamiento de cada modelo. Las estrellas indican el mejor valor de mAP50 obtenido por cada modelo. Se observa como el modelo YOLOv8s obtuvo el mejor resultado (0.94759) en la época 88, seguido por Faster R-CNN 101 (0.78131) en la época 97 y RetinaNet 101 (0.69626) en la época 98. Se observa que la arquitectura RetinaNet 101 a partir de la época 18 al 50 tiene una mayor varianza y la arquitectura YOLOv8s muestra una varianza mínima. Así mismo, se puede observar que se obtiene mayor varianza cuando los resultados son de menor rendimiento.


Figura 3: Mean Average Precision (mAP50) de los modelos para todas las repeticiones



3.2 Resultados del mejor modelo obtenido YOLOv8s (mAP50, Precisión, Recuperación)

La Figura 4, se presenta un diagrama de líneas que muestra los resultados para las métricas mAP50, precisión y recuperación de las 10 repeticiones de entrenamiento con de YOLOv8s durante las 100 épocas de ejecución de entrenamiento en el conjunto de datos de validación. El valor de mAP50 punto marcado con “estrella” representa el más alto con 0.94759 en la época 88, el valor de precisión de 0.88003 y recuperación de 0.86451. Podemos encontrar una varianza similar entre precisión y recuperación, y una varianza mínima en la métrica mAP50.

Figura 4: Ejecución de YOLOv8s con sus indicadores: mAP50, Precisión y Recuperación (recall) para todas las repeticiones



3.3 Resultados para comparación de los tres modelos:

En la figura 5 se presente el diagrama de caja de la métrica mAP50. Se observa como el modelo YOLOv8s es el que mayor rendimiento tuvo. Los valores para la métrica mAP50 a través de las 10 repeticiones son muy superiores y de menor varianza que la distribución de resultados de los otros 2 modelos (Faster R-CNN 101 y RetinaNet 101).

Figura 5: Diagrama de cajas de mean Average Precision (mAP50) de los tres modelos




Tabla 1: Métricas del modelo YOLOv8s

Modelo	mAP50	mAP50-95	Precisión	Recall	Speed (ms)
YOLOv8s	0.94759	0.77517	0.88003	0.86451	3.2

En la tabla 1 se muestra el rendimiento de la mejor época (88) del modelo YOLOv8s de las 10 repeticiones basado en el mayor valor mAP50. Se describe el rendimiento basado en las métricas de precisión y recuperación (recall), mAP50 (mide que tan bueno es el modelo), mAP50-95 (promedio de mAPs usando IoU entre 0.5 a 0.95 en intervalos de 0.05) y de velocidad de inferencia (speed), que se incluye porque nos permite estimar si es posible ejecutar la tarea de identificación de frutos de olivo en tiempo real. Al respecto, los recortes de 1000x1000 píxeles son parte de una foto de un árbol/olivo de 4000x6000 píxeles, siendo que 24 recortes conforman una imagen completa. Si el tiempo de procesamiento por cada recorte es de 3.2 ms, el tiempo total de procesamiento de una foto completa requerirá 76.8 ms. Pudiendo procesarse un total de 13 fotos por segundo o 13 frames por segundo (fps). Por tanto, es posible llevar a cabo la identificación de frutos de olivo en tiempo real.

En la figura 6 se presenta una foto completa constituida por 24 recortes procesados por YOLOv8s

Figura 6: Imagen de un árbol de olivo completo procesado por YOLOv8s



Tabla 2: Métricas de modelos Faster R-CNN 101 y RetinaNet 101

Modelo	mAP50	mAP50-95	mAP75	mAPs	mAPm	AR
Faster R-CNN 101	0.78131	0.50590	0.59911	0.49417	0.54756	0.60000
RetinaNet 101	0.69626	0.41748	0.45114	0.37408	0.54343	0.52000

En la tabla 2, se muestran diferentes métricas de precisión promedio (mean average precision) para los modelos Faster R-CNN 101 y RetinaNet 101. Las métricas incluyen variaciones de recuperación promedio (AR), estas variaciones de (mean average precision) mAP capturan las capacidades de recuperación de los modelos en varios umbrales de IoU (intersección sobre la unión), lo que refleja las capacidades para localizar un fruto de olivo con precisión. Siendo que entre ambos modelos (Faster R-CNN 101 y RetinaNet) el modelo que obtuvo mejores resultados fue Faster R-CNN 101. Cabe mencionar que no se pudo obtener estas métricas del modelo YOLOv8s debido a restricciones del framework de entrenamiento, sin embargo, se muestran los resultados para los 3 modelos a fin de realizar una comparación final.

Tabla 3: Métricas de tres modelos

Modelo	mAP50	mAP50-95	AR/Recall
YOLOv8s	0.94759	0.77517	0.86451
Faster R-CNN 101	0.78131	0.50590	0.59911
RetinaNet 101	0.69626	0.41748	0.45114

En la tabla 3, se observan las métricas de mAP50, mAP50-95, AR/Recall de los modelos que obtuvieron mejor mAP50 de cada arquitectura. Asimismo, se muestra que el modelo YOLOv8s obtuvo el mejor valor de mAP50 con 0.94759; para el indicador mAP50-95 con 0.77517 y para AR/Recall con 0.86451 respectivamente. Siendo que para todas las métricas de precisión promedio (mean average precision) de los 03 modelos, YOLOv8s presenta los mejores resultados.

4. Discusión

Los modelos de detección de objetos no sólo son útiles para la detección de frutos, sino que también pueden ser una referencia para evaluar la productividad del olivo. Este estudio compara tres modelos de inteligencia artificial de última generación. Los resultados de la prueba mostraron que el mAP50 de los 3 experimentos principales en cada arquitectura fueron: YOLOv8s (94.759%), Faster R-CNN 101 (78.131%), RetinaNet 101 con (69.626%).

La velocidad de inferencia de YOLOv8s (tiempo de detección promedio) es de 3,2 ms por cada recorte de 1000x1000 píxeles. En comparación con RetinaNet 101 y Faster R-CNN 101, el modelo YOLOv8s ha logrado resultados superiores en la detección de aceitunas basados en mAP50, mAP50-95 y AR/Recall. Así mismo, se ha observado que el modelo de arquitectura YOLOv8s tiene menor varianza en comparación con los otros modelos estudiados.

5. Conclusión

La investigación demostró que es posible la identificación de frutos de olivo en imágenes RGB usando modelos de inteligencia artificial para la detección de objetos.

El trabajo realizado para evaluar el rendimiento de los diferentes modelos de inteligencia artificial para la identificar de frutos de olivo en la Yarada Los Palos, Tacna demostró que el modelo YOLOv8s alcanzó el mayor valor en la métrica mAP50 (94.759%) en comparación de los modelos Faster R-CNN 101 (78.131%), y RetinaNet 101 (69.626%).

De los resultados obtenidos se demostró experimentalmente que el modelo YOLOv8s, que es el mejor modelo para la tarea de detección de objetos en el conjunto de datos COCO, también fue el mejor en la tarea de identificación de frutos de olivo en el conjunto de datos de olivo; por lo tanto, existe una correlación entre ambos rendimientos que ha sido demostrada en el trabajo.

Si aumenta la calidad de la imagen y la frecuencia de detecciones se deberá considerar un equipo de procesamiento con mayores prestaciones para obtener tiempos de respuesta adecuados, además de evaluar la factibilidad de desplegar el modelo en dispositivos de borde para poder ejecutar la identificación de frutos de olivo en campo.

6. Referencias Bibliográficas

- Agraria.pe. (29 de febrero de 2024). *Tacna: piden declarar en emergencia la producción de olivo*. Agraria.pe. <https://agraria.pe/noticias/tacna-piden-declarar-en-emergencia-a-la-produccion-de-olivo--34936>
- Abahous, H., Bouchaou, L., & Chehbouni, A. (2021). Global climate pattern impacts on long-term olive yields in northwestern Africa: Case from Souss-Massa region. *Sustainability*, 13(3), 1340. <https://doi.org/10.3390/SU13031340>
- Aljaafreh, A., Elzagzoug, E. Y., Abukhait, J., Soliman, A. H., Alja'afreh, S. S., Sivanathan, A., & Hughes, J. (2023). A Real-Time Olive Fruit Detection for Harvesting Robot Based on YOLO Algorithms. *Acta Technologica Agriculturae*, 26(3), 121–132. <https://doi.org/10.2478/ata-2023-0017>
- Butt, M., Glas, N., Monsuur, J., Stoop, R., & de Keijzer, A. (2023). Application of YOLOv8 and Detectron2 for Bullet Hole Detection and Score Calculation from Shooting Cards. *AI*, 5(1), 72–90. <https://doi.org/10.3390/ai5010005>
- Li, G., Huang, X., Ai, J., Yi, Z., & Xie, W. (2021). Lemon-YOLO: An efficient object detection method for lemons in the natural environment. *IET Image Processing*, 15(9), 1998–2009. <https://doi.org/10.1049/ipr2.12171>
- Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2020). Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 318–327. <https://doi.org/10.1109/TPAMI.2018.2858826>
- Lin Tsung-Yi, Maire Michael, Belongie Serge, Hays James, Perona Pietro, Ramanan Deva, Dollár Piotr, and Zitnick C. Lawrence. 2014. Microsoft COCO: Common objects in context. In *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13*. Springer, 740–755. https://doi.org/10.1007/978-3-319-10602-1_48
- Muraina, I. (2022). Ideal dataset splitting ratios in machine learning algorithms: general concerns for data scientists and data analysts. In *7th International Mardin Artuklu Scientific Research Conference* (pp. 496-504).
- Olive Oil Times. (16 de enero de 2024). *El niño diezma la cosecha de aceituna peruana*. Olive Oil Times. <https://es.oliveoiltimes.com/production/el-nino-decimates-peruvian-olive-harvest/127929>
- Padilla, R., Netto, S. L., & Da Silva, E. A. (2020, July). A survey on performance metrics for object-detection algorithms. In *2020 international conference on systems, signals and image processing (IWSSIP)* (pp. 237-242). IEEE. <https://doi.org/10.1109/IWSSIP48289.2020.9145130>
- Ramos, M., Cubillas, J., Jurado, J., Andrés, A., Parra, A. & Feito, F. (2023). PREDIC I, Sistema de predicción temprana de las cosechas de olivar. *4to. Trimestre 2023 Revista Olivermca*, 47, 79. https://issuu.com/olimerca/docs/olimerca-n47_web?fr=sZGI2MTYzNDg0Nzg

Reis, D., Kupec, J., Hong, J., & Daoudi, A. (2023). Real-time flying object detection with YOLOv8. *arXiv preprint arXiv:2305.09972*.

Ren, S., He, K., Girshick, R., & Sun, J. (2016). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>

Uylaşer, V., & Yildiz, G. (2014). The Historical Development and Nutritional Importance of Olive and Olive Oil Constituted an Important Part of the Mediterranean Diet. *Critical Reviews in Food Science and Nutrition*, 54(8), 1092–1101. <https://doi.org/10.1080/10408398.2011.626874>

Zhu, X., Chen, F., Zhang, X., Zheng, Y., Peng, X., & Chen, C. (2024). Detection the maturity of multi-cultivar olive fruit in orchard environments based on Olive-EfficientDet. *Scientia Horticulturae*, 324(35), 112607. <https://doi.org/10.1016/j.scienta.2023.112607>

Zhang, Y., Zhang, W., Yu, J., He, L., Chen, J., & He, Y. (2022). Complete and accurate holly fruits counting using YOLOX object detection. *Computers and Electronics in Agriculture*, 198, 107062. <https://doi.org/10.1016/j.compag.2022.107062>

Comunicación alineada con los Objetivos de Desarrollo Sostenible

