

Artículo Original

Detección del estado de salud de la lechuga basada en visión por computadora

Computer Vision-Based Detection of Lettuce Health

***Fatima Martinez¹** , **James Brian Romaine¹** , **Adrián Cardona¹** ,
Pablo Millán¹ 

¹Universidad Loyola Andalucía, Grupo de Optimización y control de sistemas distribuidos. Sevilla. España

RESUMEN

La identificación temprana de problemas en la salud de las plantas es clave para un manejo agrícola eficiente y sostenible. No obstante, los métodos tradicionales de inspección visual no son viables a gran escala. Por ello, este trabajo propone un sistema automático de detección del estado de lechugas mediante el uso del detector de objetos YOLOv5.

El modelo fue entrenado con una base de datos de 144 imágenes de lechugas, capturadas en la granja BIOAlverde (Sevilla, España), clasificadas en dos categorías: en buen estado y en mal estado. Las imágenes fueron etiquetadas manualmente, y el modelo se entrenó aplicando técnicas de aumento de datos, ajuste de hiperparámetros y validación cruzada para mejorar la precisión. Los resultados obtenidos demuestran un alto desempeño del sistema. Para lechugas en buen estado, se alcanzó una precisión del 97,9%, un recall del 99,3% y un mAP del 99,5%; mientras que, para lechugas en mal estado, la precisión fue del 95,8%, el recall del 100% y el mAP del 99,5%. En conclusión, el sistema propuesto representa una herramienta eficaz para la detección automática del estado de las lechugas, contribuyendo al desarrollo de una agricultura de precisión mediante la optimización del uso de recursos y la detección oportuna de problemas en los cultivos.

Palabras clave: YOLO, Detección de lechugas, Visión por computadora.

ABSTRACT

Early identification of plant health issues is essential for efficient and sustainable agricultural management. However, traditional visual inspection methods are not feasible on a large scale. Therefore, this study proposes an automated system for detecting the condition of lettuce crops using the YOLOv5 object detector. The model was trained on a dataset comprising 144 images of lettuces, captured at the BIOAlverde farm (Seville, Spain), and classified into two categories: healthy and unhealthy. The images were manually annotated, and the model was trained using data augmentation techniques, hyperparameter tuning, and cross-validation to improve accuracy. The results obtained demonstrate the high performance of the system. For healthy lettuces, the model achieved a precision of 97.9%, a recall of 99.3%, and a mean Average Precision (mAP) of 99.5%; while for unhealthy lettuces, precision reached 95.8%, recall 100%, and mAP 99.5%. In conclusion, the proposed system constitutes an effective tool for the automatic detection of lettuce condition, contributing to the advancement of precision agriculture through the optimisation of resource use and the timely identification of crop issues.

Keywords: YOLO, Lettuce detection, Computer vision.

**Realizado en el marco de la tesis doctoral del PhD en Systems and Sustainable Engineering, con financiación propia, en la Universidad Loyola, Sevilla, España.*

***Autor correspondiente:** **Fátima Martínez.** Universidad Loyola Andalucía, Grupo de Optimización y control de sistemas distribuidos. Sevilla. España.
Email: fbmartinez@al.uloyola.es

Fecha de recepción: 05 de enero de 2025. Fecha de aceptación: 20 de febrero de 2025

Editora responsable: Graciela María Patricia Velázquez de Saldivar . Universidad del Cono Sur de las Américas, UCSA.



Este es un artículo publicado en acceso abierto bajo una licencia Creative Commons

INTRODUCCIÓN

La creciente demanda global de alimentos y los efectos del cambio climático, que limitan recursos esenciales como el agua y las tierras cultivables, resaltan la importancia de optimizar los sistemas de producción agrícola. Identificación temprana de problemas en la salud de las plantas, como enfermedades, deficiencias nutricionales o estrés hídrico, es la clave para reducir pérdidas económicas y ambientales mediante un manejo más eficiente de los insumos agrícolas (Cienfuegos et al., 2025).

En este contexto, la lechuga, un cultivo ampliamente consumido, requiere herramientas avanzadas para garantizar su productividad y sostenibilidad. Sin embargo, los métodos tradicionales de inspección visual, aunque precisos, no son viables a gran escala debido a su alta demanda de tiempo y recursos. En respuesta a estas limitaciones, han surgido tecnologías basadas en inteligencia artificial que permiten un monitoreo continuo, preciso y automatizado, proporcionando datos en tiempo real que mejoran la toma de decisiones (Martínez et al., 2025).

Diferentes enfoques han sido desarrollados para abordar estos desafíos. Martínez et al. (2019) emplearon cámaras multiespectrales y técnicas de Support Vector Machines (SVM) combinadas con análisis de componentes principales (PCA) para detectar estrés hídrico y deficiencias nutricionales mediante el análisis de reflectancia. Este enfoque demostró ser efectivo para identificar problemas en etapas tempranas. Por otro lado, Fernández et al. (2021) utilizaron redes neuronales profundas con arquitecturas ResNet, entrenadas con miles de imágenes de hojas de lechuga, para clasificar enfermedades foliares con alta precisión, facilitando diagnósticos rápidos y efectivos. Adicionalmente, López et al. (2018) aplicaron algoritmos como Random Forest y k-Nearest Neighbors (k-NN) al análisis de datos hiperespectrales, permitiendo la detección no invasiva de enfermedades antes de que los síntomas sean visibles. García et al. (2022) implementaron YOLO (You Only Look Once) para identificar plagas comunes en la lechuga, como pulgones y orugas, mediante un sistema de detección en tiempo real basado en visión por computadora.

Entre estas técnicas, YOLO se destaca por su velocidad y eficiencia. A diferencia de modelos como Faster R-CNN, que presentan una alta precisión, pero son más lentos debido a su elevada demanda computacional (Sarma et al., 2024), YOLO procesa imágenes completas en una sola pasada, lo que permite la detección simultánea de múltiples objetos (Liu et al., 2016). Además, YOLO mantiene una alta precisión en la detección de objetos mientras reduce la tasa de falsos positivos, superando a métodos como SSD y RetinaNet, conocidos por su capacidad para identificar objetos pequeños, pero con velocidades más bajas (Huang et al., 2017; Tan et al., 2021).

Dadas estas ventajas, este estudio implementa un detector de objetos basado en YOLO para abordar la detección del estado de salud de las lechugas.

Se plantea como hipótesis de investigación que es posible identificar de manera precisa y automatizada si las lechugas se encuentran en buen estado o en mal estado, mediante el uso de un modelo de inteligencia artificial basado en YOLOv5.

Tratando de responder si es posible, en primer lugar, recolectar una base de datos robusta para llevar a cabo el entrenamiento del modelo. En segundo lugar, se pretende analizar la factibilidad de realizar dicho entrenamiento utilizando recursos disponibles en plataformas accesibles como Google Colab. Asimismo, se examina si el algoritmo empleado puede operar con un costo computacional reducido, permitiendo su implementación en dispositivos de bajo coste. Finalmente, se intenta determinar si el algoritmo desarrollado puede identificar de forma precisa las condiciones de las lechugas, posibilitando una detección

temprana que facilite una intervención oportuna en el cultivo. Este enfoque no solo busca mejorar la precisión y adaptabilidad del sistema en entornos agrícolas complejos, sino también ofrecer una solución escalable y eficiente para el monitoreo y manejo de cultivos.

Por lo tanto, el objetivo de este trabajo es desarrollar un sistema automático capaz de identificar el estado de salud de las lechugas, clasificándolas en buen estado o en mal estado, mediante la aplicación del detector de objetos YOLOv5.

Además, se espera demostrar la precisión y eficiencia del sistema propuesto, así como su potencial para el monitoreo y manejo de cultivos.

MATERIALES Y MÉTODOS

El estudio se centra en identificar el estado de la lechuga a lo largo de su vida antes de su cosecha. Para ello, en primer lugar, se debe contar con una base de datos para poder emplear YOLOv5, ya que la familia de YOLO es una red neuronal que necesita un conjunto de datos para realizar un aprendizaje previo antes de ejecutar una identificación automática.

El dispositivo utilizado, desarrollado por el grupo ODS de la Universidad Loyola y presentado por primera vez por Martínez et al. (2024), tiene la capacidad de capturar imágenes, analizarlas de manera local y enviar los resultados de este análisis a un servidor para su posterior visualización en una página web.

Se aplicó YOLOv5, un algoritmo de detección de objetos utilizado para identificar el estado de la lechuga. Para implementar el mencionado algoritmo, fue necesario contar con una base de datos, la cual se recolectó en una granja llamada BIOAlverde, ubicada en Sevilla, España. Esta base de datos contiene 144 imágenes con una resolución de 1920x1080 píxeles. Para su construcción, se capturaron imágenes de las lechugas con una frecuencia de dos veces al día durante un período de un mes.

Para aplicar el algoritmo YOLOv5, esta base de datos debe prepararse mediante un proceso de etiquetado. Las imágenes recopiladas fueron etiquetadas manualmente utilizando la plataforma Roboflow, que permite anotar la posición del objeto dentro de las imágenes y asignar la clase correspondiente. El mencionado proceso de etiquetado se ilustrado en la Fig. 1, donde el rectángulo morado corresponde a la etiqueta de una lechuga en mal estado. Se consideraron lechugas en mal estado aquellas que no presentaban un perfecto estado visible de salud, caso contrario se clasifican como lechugas en mal estado.

En este caso, las lechugas en buen estado fueron denotadas con la etiqueta "0", mientras que las lechugas en mal estado se marcaron con la etiqueta "1". De esta manera, el detector de objetos utiliza las etiquetas durante el proceso de aprendizaje.

Además, el sistema ofrece un valor de precisión que indica el grado de confianza en la predicción realizada.



Figura 1: Etiqueta realizada en Roboflow.

PARÁMETROS DE YOLOv5

Para trabajar con YOLOv5, es esencial tener en cuenta algunos parámetros clave, que se exponen a continuación:

Épocas (epochs): una época es un ciclo completo a través de todo el conjunto de datos durante el proceso de entrenamiento. Esto significa que el modelo procesa cada punto de datos del conjunto una vez antes de comenzar la siguiente época.

Tamaño del lote (batch size): define la cantidad de datos procesados por el modelo antes de que se actualicen sus parámetros.

Tasa de aprendizaje (learning rate): determina el tamaño de los pasos que el modelo da durante el ajuste de sus parámetros para minimizar el error.

Intersección sobre la Unión (Intersection over Union, IoU): esta métrica se aplica para evaluar cuánto se superponen dos cajas delimitadoras. Se calcula dividiendo el área de intersección entre las dos cajas por el área total cubierta por ambas.

Puntaje F1 (F1-Score): el cálculo del F1-Score se realiza de manera individual para cada categoría, y luego los resultados se combinan para crear una curva general. Esta curva proporciona una visión clara de cómo cambian la precisión y el recall en diferentes niveles de confianza. Es particularmente útil para seleccionar el umbral de confianza más adecuado para el modelo, especialmente donde el F1-Score alcanza su valor máximo. Este enfoque asegura un equilibrio óptimo entre precisión y recall, permitiendo que el modelo funcione de manera efectiva en todas las categorías. El F1-Score se calcula como:

$$F1 = \frac{Precision \times Recall}{Precision + Recall}$$

EVALUACIÓN DEL MODELO

- **Precision:** evalúa cuán precisas son las predicciones positivas del modelo.
- **Recall:** mide qué tan bien el modelo identifica correctamente las instancias positivas reales.

Ambas métricas son cruciales porque proporcionan una visión integral del rendimiento del modelo. Estas métricas suelen analizarse utilizando la curva *precision-recall*, que ofrece una perspectiva equilibrada de la capacidad del modelo para hacer predicciones precisas e identificar correctamente casos positivos. Se definen de la siguiente manera:

$$Precision = \frac{TP}{TP + FP}, \quad Recall = \frac{TP}{TP + FN}$$

Donde:

Verdaderos positivos (TP): se registran cuando el modelo identifica correctamente una instancia positiva. En detección de objetos, esto significa que el modelo encuentra y clasifica un objeto dentro de una imagen y coloca correctamente una caja delimitadora alrededor de él. Las condiciones para un TP generalmente incluyen un umbral de confianza y una IoU mínima entre la caja predicha y la real.


Falsos positivos (FP): ocurren cuando el modelo predice incorrectamente un resultado positivo. En tareas de clasificación, esto sucede cuando una instancia es asignada erróneamente a una clase incorrecta. En detección de objetos, un FP puede surgir si el modelo clasifica mal el objeto o identifica correctamente la

clase, pero posiciona la caja delimitadora de manera incorrecta, como cuando hay poca o ninguna superposición con el objeto real.

Falsos negativos (FN): se producen cuando el modelo no detecta una instancia positiva que debería haber sido identificada correctamente. En clasificación, esto significa que un ejemplo positivo se etiqueta como negativo o no se reconoce como parte de la clase correcta. En detección de objetos, un FN ocurre cuando el modelo no detecta un objeto o no cumple con los requisitos para un TP, como no alcanzar la confianza suficiente o que la IoU no sea adecuada.

Una vez entrenado el modelo de redes neuronales convolucionales (CNN), este puede ser validado con nuevas imágenes. Dada una nueva imagen proporcionada al modelo, su salida contiene una caja delimitadora sobre las clases detectadas (Lechuga en buen y mal estado). La caja delimitadora predicha es obtenida del modelo y corresponde a un rectángulo que se utiliza para definir la ubicación de un objeto dentro de una imagen (Jiang et al., 2022).

En los modelos previos de YOLO, para validar el modelo, la intersección sobre la unión (IoU) se define de la siguiente manera. Dada una imagen de validación cuya clase real está etiquetada con una caja delimitadora, ambas cajas delimitadoras (la real y la predicha) se comparan utilizando dos índices: A_o denota el área de superposición, que mide la intersección entre ambas cajas y A_u mide el área de unión entre ambas cajas. Posteriormente, el IoU se calcula como el coeficiente entre estas áreas, como se muestra en la Figura 2.



$$IoU = \frac{A_o}{A_u} = \frac{\text{Área de intersección}}{\text{Área total}}$$

Figura 2: Definición de IoU.

ENTRENAMIENTO

Para el entrenamiento de la red neuronal se ha empleado Google Colab, una herramienta que ofrece recursos gratuitos y también la opción de contratar recursos adicionales en caso de necesitar mayor capacidad para actividades más complejas. La complejidad de estas actividades depende de las características a ser detectadas, la resolución de las imágenes y la cantidad de datos a procesar.

Entre los recursos gratuitos disponibles en Google Colab se incluyen una CPU estándar para ejecutar código sin necesidad de una máquina local, acceso a GPUs como NVIDIA Tesla K80, T4 o P100, que aceleran significativamente el entrenamiento de modelos de aprendizaje profundo, y aproximadamente 12-16 GB de RAM.

Durante el entrenamiento, existen ciertos índices que permiten evaluar si el modelo está aprendiendo correctamente las características de las imágenes de entrada. Entre estos, destacan la probabilidad de que una caja delimitadora contenga un objeto (obj_loss) y la precisión en la ubicación de la caja delimitadora (box_loss). Estos son aspectos cruciales para evaluar el rendimiento del modelo (Redmon et al., 2016). La probabilidad del objeto se utiliza para estimar la probabilidad de que una caja detectada encierre correctamente el objeto deseado.

A medida que avanza el entrenamiento, se espera que ambos valores de pérdida disminuyan, lo que indicaría que el modelo está aprendiendo con éxito a reconocer y localizar objetos con precisión dentro del conjunto de datos. Esta reducción en la pérdida refleja la mejora del modelo al ajustar sus predicciones en la capa final del modelo preentrenado.

RESULTADOS

En este apartado se presentan los resultados del uso del método YOLOv5 para la identificación del estado de la lechuga.

Las imágenes de la base de datos utilizadas se distribuyeron en conjuntos de prueba, entrenamiento y validación en proporciones de aproximadamente el 68 %, el 20 % y el 12 %, respectivamente.

En las Figura 3(a) y Figura 3(b), las curvas de `box_loss` ilustran el desempeño del modelo en la predicción de la ubicación y el tamaño de las cajas delimitadoras. Durante las primeras 50 épocas, las curvas muestran una tendencia descendente pronunciada, lo que indica que el modelo aprende rápidamente a posicionar y dimensionar correctamente las cajas delimitadoras. Después de esta fase inicial, la pérdida disminuye a un ritmo más lento, lo cual es típico mientras el modelo ajusta finamente sus predicciones. Para la época 200, la pérdida se estabiliza en un punto bajo, reflejando un modelo bien entrenado en la predicción de cajas delimitadoras.




Figura 3: Curvas de aprendizaje: a) `train/box_loss` b) `val/box_loss`.

De manera similar, las curvas de `object_loss` en las Figura 4(a) y Figura 4(b) evalúan el rendimiento de clasificación dentro de las cajas delimitadoras. Al igual que la pérdida de las cajas delimitadoras, la pérdida de los objetos disminuye drásticamente durante las primeras épocas, lo que indica una mejora rápida en la precisión de clasificación. La curva de validación de la pérdida de objetos es más uniforme y se estabiliza en un valor más bajo, lo que sugiere que el modelo generaliza correctamente a datos no vistos.




Figura 4: Curvas de aprendizaje: a) train/obj_loss b)val/obj_loss.

En la Figura 5 se observa la curva de F1 en función de la confianza, de la cual se obtiene un valor de confianza óptimo de 0,3. Un valor de confianza más alto reduce la probabilidad de falsos positivos, pero podría incrementar la de falsos negativos.




Figura 5: Curva F1-confidence.

En la Figura 6 se observa la curva de *Precision* vs *Recall* obtenida con un valor de confianza de 0,3. Los valores de *precision*, *recall* y mAP para la clase de lechugas en buen estado son 97,9%, 99,3% y 99,5%, respectivamente; mientras que, para la clase de lechugas en mal estado, estos valores son 95,8%, 100% y 99,5%, respectivamente.




Figura 6: Curva Precision vs Recall.

En las Figura 7(a) y Fig. 8(a) se muestran los resultados de la inferencia en imágenes nuevas, donde el detector de objetos clasificó estas imágenes como pertenecientes a la clase "0" (lechugas en buen estado), con una precisión del 93% y 95%, respectivamente. Por otro lado, en las Fig. 7(b) y Fig. 8(b), las imágenes fueron clasificadas como clase "1" (lechugas en mal estado), con una precisión del 90% y 83%, respectivamente.




Figura 7: Identificación del estado de la lechuga: a) Lechuga sana b) Lechuga insalubre.



Figura 8: Identificación del estado de la lechuga: a) Lechuga sana b) Lechuga insalubre.

Se ha calculado el tiempo que le toma al detector inferir las imágenes, obteniéndose un promedio de 0,007 segundos para la clase "0" y 0,007 segundos para la clase "1". En términos de precisión, se alcanzó un promedio del 90,2% en la primera clase mencionada y del 90,9% en la segunda clase. El resumen de estos valores se presenta en la Tabla 1.

Tabla 1. Tabla con los tiempos y la precisión promedio de las imágenes inferidas.

Tipo de lechuga	Tiempo (segundos)	Precisión (%)
Lechugas sanas	0,007199798	90,20
Lechugas insalubres	0,007065398	90,91

DISCUSIÓN

- Se logró construir una base de datos robusta, compuesta por imágenes representativas del ciclo de vida de las lechugas, capturadas en distintas condiciones de iluminación y estado de salud, mediante un dispositivo autónomo. Este enfoque permitió obtener un conjunto de datos diverso y de calidad, adecuado para entrenar el modelo de manera eficiente y garantizar su aplicabilidad en escenarios agrícolas reales. A diferencia de otras soluciones más complejas y costosas, como el robot agrícola BoniRob, que emplea múltiples sensores y cámaras para el monitoreo en campo (Chebrolu et al., 2017), o los UAV utilizados para imágenes de alta resolución (Terven et al., 2023), el sistema de captura propuesto en este trabajo representa una alternativa sencilla y accesible, que no requiere intervención humana ni equipos de alto coste.
- Durante el entrenamiento, el modelo demostró ser compatible con los recursos gratuitos ofrecidos por Google Colab, completando el proceso sin agotar dichos recursos, lo que confirma la viabilidad de esta plataforma como una opción accesible para el desarrollo de modelos de detección de objetos. En caso de superar los límites gratuitos, YOLOv5 permite retomar el entrenamiento desde el punto guardado y Colab ofrece opciones para ampliar los recursos disponibles, como también lo señala Fernández Marcos (2023).
- En cuanto al rendimiento del modelo, las inferencias se realizaron con un tiempo de respuesta muy bajo, lo que indica que puede implementarse en dispositivos de bajo coste y con un consumo energético reducido, ideal para aplicaciones agrícolas en campo. Esto coincide con lo reportado por Muñiz (2021), quien evidenció que Google Colab supera en rendimiento a hardware limitado como la Raspberry Pi, reafirmando su utilidad como plataforma accesible para el desarrollo de soluciones basadas en inteligencia artificial.
- El modelo mostró una alta capacidad para identificar de manera precisa el estado de salud de las lechugas, lo que confirma su aplicabilidad en agricultura de precisión para una intervención oportuna. Comparado con otros estudios, como el de Haque et al. (2022), donde YOLOv5 presentó dificultades para detectar todas las instancias de enfermedades en hojas de arroz, el desempeño de nuestro modelo resulta superior, destacando la robustez de la propuesta.

En conjunto, estos resultados evidencian que el sistema propuesto no solo es preciso y eficiente, sino que también constituye una solución escalable y accesible para el monitoreo continuo de cultivos, con potencial de aplicación directa en la agricultura de precisión.

CONCLUSIÓN

En conclusión, se ha demostrado que es posible identificar de manera precisa y automatizada el estado de salud de las lechugas, clasificándolas en buen estado o en mal estado mediante el uso del modelo YOLOv5. Los resultados obtenidos validan la hipótesis planteada y confirman la viabilidad de utilizar inteligencia artificial para el monitoreo agrícola. La recolección y etiquetado de una base de datos adecuada, junto con un entrenamiento eficiente en plataformas accesibles como Google Colab, permitieron desarrollar un sistema robusto y adaptable. Asimismo, la baja demanda computacional del modelo posibilita su implementación en dispositivos de bajo coste, lo que representa una solución escalable y práctica para la agricultura de precisión. Por tanto, el sistema propuesto no solo mejora la capacidad de intervención temprana en los cultivos, sino que también ofrece una herramienta eficiente para el manejo sostenible de los recursos agrícolas.

Estos resultados demuestran que el sistema propuesto puede integrarse como una herramienta práctica en la agricultura de precisión, facilitando el monitoreo y manejo eficiente de cultivos.

Contribución de autores

F. Martínez: Fue responsable de la aplicación del algoritmos, etiquetado, entrenamiento e inferencia. Se encargó de la redacción del artículo.

A. Cardona: Fue responsable de la supervisión del dispositivo que capture las imágenes, realizando modificaciones en los horarios de captura y de la descarga de estas.

J. Romaine: Colaboró en el desarrollo de la metodología, participó en la corrección del manuscrito.

P. Millán: Colaboró supervisando el desarrollo de la metodología.

Conflicto de intereses: Los autores no tienen potenciales conflictos de intereses que declarar.

Financiamiento: Financiado por los autores.

REFERENCIAS BIBLIOGRÁFICAS

- Chebrolu, N., Lottes, P., Schaefer, A., Winterhalter, W., Burgard, W., & Stachniss, C. (2017). Agricultural robot dataset for plant classification, localization and mapping on sugar beet fields. *The International Journal of Robotics Research*, 36(10), 1045-1052.
- Cienfuegos, S. M. U., & Rivas, J. J. B. (2025). Inteligencia Artificial: Machine Learning, para detección temprana de plagas y enfermedades de cultivos básicos, *Nicaragua. INGENIO*, 8(1), 24-34.
- Fernández, L. J., Morales, D. R., & Sánchez, P. H. (2021). Implementación de redes neuronales profundas para la clasificación de enfermedades en hojas de lechuga. *Journal of Agricultural Informatics*, 12(3), 67-75.
- Fernández Marcos, S. (2023). *Sistema de reconocimiento de patrones en imágenes satelitales para la detección de objetos* [Artículo científico]. <https://gredos.usal.es/bitstream/10366/158423/1/Memoria.pdf>.
- García, S. L., Pérez, N. M., & Rodríguez, V. H. (2022). Sistema basado en visión artificial para la detección automática de plagas en cultivos de lechuga. *Tecnología Agrícola Aplicada*, 14(1), 33-41.
- Gómez, J. A., Pérez, L. M., & Rodríguez, S. F. (2020). Detección de enfermedades en lechuga mediante análisis de imágenes y aprendizaje profundo. *Revista de Tecnología Agrícola*, 15(2), 45-53.
- Haque, M. E., Rahman, A., Junaid, I., Hoque, S. U., & Paul, M. (2022). Rice leaf disease classification and detection using yolov5. *arXiv preprint arXiv:2209.01579*.

- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., ... & Murphy, K. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7310–7311.
- Jiang, P., Ergu, D., Liu, F., Cai, Y., & Ma, B. (2022). A review of YOLO algorithm developments. *Procedia Computer Science*, 199, 1066–1073.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. *European Conference on Computer Vision*, 21–37.
- López, M. A., García, J. C., & Torres, E. F. (2018). Evaluación de la salud de la lechuga mediante análisis hiperspectral y aprendizaje automático. *Ciencia y Tecnología Agrícola*, 10(2), 89-97.
- Martínez, R. P., López, A. G., & Hernández, M. T. (2019). Aplicación de técnicas de visión por computadora para el monitoreo de la salud de cultivos de lechuga. *Agricultura Digital*, 8(1), 22-30.
- Martinez, F., Romaine, J. B., Johnson, P., Cardona, A., & Millan, P. (2025). Novel Fusion Technique for High-Performance Automated Crop edge Detection in Smart Agriculture. *IEEE Access*.
- Martinez, F., Romaine, J. B., Manzano, J. M., Ierardi, C., & Millan, P. (2024). Deployment and verification of custom autonomous low-budget IoT devices for image feature extraction in wheat. *IEEE Access*.
- Muñiz, L. (2021). Viabilidad y rendimiento de YOLOv5 en Raspberry Pi 4 modelo B. *Obtenido de <https://idus.us.es/bitstream/handle/11441/126961/TFG-3731-MU%20GARCIA.pdf>*.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Sarma, K. S. R. K., Sasikala, C., Surendra, K., Erukala, S., & Aruna, S. L. (2024, June). A comparative study on faster R-CNN, YOLO and SSD object detection algorithms on HIDS system. In *AIP Conference Proceedings (Vol. 2971, No. 1)*. AIP Publishing.
- Tan, L., Huangfu, T., Wu, L., & Chen, W. (2021). Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. *BMC Medical Informatics and Decision Making*, 21, 1-11.
- Terven, J., Córdova-Esparza, D. M., & Romero-González, J. A. (2023). A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas. *Machine learning and knowledge extraction*, 5(4), 1680-1716.