



Detección de enfermedades en hojas de tomate (*Solanum lycopersicum*) utilizando inteligencia artificial

Detection of diseases in tomato (*Solanum lycopersicum*) leaves using artificial intelligence

Walter Moreno-Castillo ¹ , Jenny Acosta-Procel ² , Gonzalo Ruiz-Mesías ² ,
Gladys Vega-Iza ³ , Manolo Muñoz-Espinoza ^{1*} 

¹ Universidad Técnica de Ambato, Facultad de Ciencias Agropecuarias, Cantón Cevallos vía a Quero, Sector El Tambo-La Universidad, 1801334, Cevallos, Tungurahua, Ecuador EC180150, Ecuador

² Instituto Superior Tecnológico Cotopaxi, Parroquia Tanicuchi Panamericana E35 km 12 vía Latacunga-Quito, Ecuador

³ Instituto Superior Tecnológico Vicente León, Calle Belisario Quevedo y, C. Gral. Maldonado, Latacunga 050102, Ecuador

INFORMACIÓN DEL ARTÍCULO

Recibido: 17/09/2025

Aceptado: 11/10/2025

CONFLICTO DE INTERESES

Los autores declaran no existir conflicto de intereses

CORRESPONDENCIA

Manolo Muñoz-Espinoza
mmunoz@uta.edu.ec



CF: cag141252462

RESUMEN

Contexto: La susceptibilidad del cultivo de tomate a enfermedades ha generado pérdidas en la producción, por ello se requiere métodos rápidos y precisos para su detección temprana. **Objetivos:** Desarrollar un sistema automático de identificación de enfermedades en hojas de tomate mediante inteligencia artificial. **Métodos:** La investigación se enmarca en un diseño metodológico experimental y cuantitativo, con un enfoque aplicado y nivel descriptivo-predicativo. Se utilizó un conjunto de 11000 imágenes etiquetadas con la ayuda del modelo GroundingDINO, distribuidas en 10000 para entrenamiento y 1000 para validación, cubriendo nueve enfermedades comunes y hojas sanas. Se entrenó el modelo YOLOv11n, seleccionado por su eficiencia computacional y alta precisión en tareas de detección. **Resultados:** Se encontró un rendimiento excepcional, con una precisión global de 0,9967, un *recall* de 0,99604 y un mAP50 de 0,99446, superando en precisión y robustez a enfoques convencionales. **Conclusiones:** Este método es altamente efectivo para la detección automática de enfermedades en hojas de tomate, lo que permite una intervención más precisa y oportuna en el campo. Esta tecnología puede contribuir significativamente a la agricultura sostenible al reducir el uso innecesario de pesticidas. Futuras investigaciones deberían validar el modelo en condiciones de campo real y con otras especies vegetales.

Palabras clave: Agricultura sostenible, aprendizaje profundo, cultivos, rendimiento, salud

ABSTRACT

Context: The increasing losses in tomato crops due to foliar diseases has created an urgent need for rapid and accurate methods for early detection. **Objective:** To develop an automated system for identifying diseases in tomato leaves using artificial intelligence. **Methods:** This study employed an experimental and quantitative methodological design with an applied, descriptive-predictive approach. A dataset of 11000 labeled images was generated using the GroundingDINO model, divided into 10000 images for training and 1000 for validation, covering nine common diseases and healthy leaves. The YOLOv11n model was trained due to its computational efficiency and high accuracy in object detection tasks. **Results:** Exceptional performance was achieved, with an overall precision of 0.9967, a *recall* of 0.99604, and an mAP50 of 0.99446, outperforming conventional approaches in both accuracy and robustness. **Conclusions:** This method is highly effective for the automated detection of diseases in tomato leaves, enabling more precise and timely field interventions. This technology can significantly contribute to sustainable agriculture by reducing unnecessary pesticide use. Future research should validate the model under real-field conditions and extend its application to other crop species.

Keywords: Agriculture sustainable, deep learning, crops, health, yield

INTRODUCCIÓN

El tomate (*Solanum lycopersicum*) es uno de los cultivos hortícolas más importantes a nivel mundial tanto por su relevancia económica como por su valor nutricional (Kumar *et al.*, 2020). En el año 2022 su producción mundial alcanzó aproximadamente 192 millones de toneladas, según datos de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2023). Este fruto es una fuente rica en vitaminas, minerales y compuestos bioactivos como licopeno, los cuales poseen propiedades antioxidantes y contribuyen a la prevención de diversas enfermedades en los seres humanos (Khan *et al.*, 2021), destacándolo como un cultivo esencial para la seguridad alimentaria y los ingresos agrícolas.

Sin embargo, la productividad del tomate está constantemente amenazada por una amplia gama de enfermedades que afectan sus hojas, tallos y frutos, generando pérdidas significativas en el rendimiento y la calidad del cultivo (Gatahi, 2020; Panno *et al.*, 2021).

Entre las principales enfermedades que atacan al tomate se encuentran las causadas por hongos, bacterias y virus, como el mildiú vellosa (*Phytophthora infestans*), el oídio (*Oidium* spp.), la mancha bacteriana (*Xanthomonas* spp.) y el tomate mosaic virus (ToMV) (de Wit, 2024), entre otras. Estas enfermedades no solo disminuyen la producción, sino que

también incrementan el uso de insumos químicos para su control, con consecuencias negativas para el medio ambiente y la salud humana.

La detección temprana y precisa de estas afecciones es crucial para mitigar su impacto, pero los métodos tradicionales basados en inspección visual son laboriosos, subjetivos y dependen de la experiencia del observador (John *et al.*, 2023).

En este contexto, la inteligencia artificial (IA) ha emergido como una herramienta poderosa para abordar estos desafíos, ofreciendo soluciones rápidas, precisas y escalables para la detección de enfermedades en cultivos agrícolas (Elbasi *et al.*, 2023). En particular, las redes neuronales convolucionales han demostrado un desempeño sobresaliente en tareas de clasificación y detección de objetos en imágenes (Bangari *et al.*, 2022; Yu *et al.*, 2023).

Entre estas, la arquitectura YOLO (*You Only Look Once*) se ha consolidado como una de las más eficientes y precisas para la detección en tiempo real (Redmon *et al.*, 2016). La versión más reciente, YOLOv11, ofrece mejoras significativas en términos de velocidad y precisión, lo que la convierte en una elección ideal para aplicaciones agrícolas (Khanam y Hussain, 2024).

El presente estudio propone desarrollar un sistema automático de identificación de enfermedades en hojas de tomate mediante inteligencia artificial, un

enfoque innovador para la detección de nueve enfermedades comunes que afectan las hojas del tomate, así como la identificación de hojas sanas.

MATERIALES Y MÉTODOS

La presente investigación se enfocó en el uso de IA, concretamente técnicas de Deep Learning (DL), como es la arquitectura YOLOv11 para la detección de enfermedades en hojas de tomate. Los pasos para lograr la detección de enfermedades fueron la adquisición de los datos, etiquetado y por último la implementación del modelo con la arquitectura YOLOv11 para entrenar y evaluar el modelo.

Conjunto de datos

El conjunto imágenes se obtuvieron de la plataforma Kaggle (Kaggle, 2020), y en el etiquetado se utilizó el modelo GroundingDINO (Liu *et al.*, 2024), para garantizar la precisión en la asignación de las etiquetas. Además, se normalizaron en un tamaño de 640 x 640 píxeles para ser compatibles con el modelo específico YOLOv11n (Jocher y Qiu, 2024).

A continuación, se detalla la distribución de las imágenes:

- Entrenamiento: 1000 imágenes por categoría (9 enfermedades + 1 categoría de hojas sanas)
- Validación: 100 imágenes por categoría (9 enfermedades + 1 categoría de hojas sanas)

En la tabla 1 se detallan los nombres y las etiquetas.

Arquitectura del modelo YOLOv11

YOLOv11n, es el último modelo de la serie YOLO que introduce una serie de mejoras debido a su balance entre precisión y eficiencia computacional, así como redefine los límites de la detección de objetos en tiempo real con avances en atención espacial, optimización de parámetros y escalabilidad (Khanam y Hussain, 2024).

La detección es una labor que implica localizar y clasificar los objetos presentes en una imagen o secuencia de imágenes (*videos*). El resultado de esta labor consiste en un conjunto de cuadros delimitadores (*bounding boxes*) que rodean a los objetos de la imagen, acompañadas de sus etiquetas de clase y niveles de confianza para cada cuadro ((Jocher y Qiu, 2024) (Figura 1).

Además, mediante YOLOv11 se pueden realizar tareas de segmentación y pose. Específicamente, YOLOv11n, admite imágenes que tengan un tamaño de 640x640 píxeles.

Métricas de evaluación

La precisión del modelo fue evaluada utilizando tres métricas principales:

Precisión (*Precision*): Medida del porcentaje de predicciones correctas entre todas las predicciones realizadas.

$Precision = \frac{\text{Verdaderos Positivos (VP)}}{VP + \text{Falsos Positivos (FP)}}$

Tabla 1. Nombres y siglas para el etiquetado.

Nombre en inglés	Nombre en español	Siglas para el etiquetado
Bacterial_spot	Mancha bacteriana	BS
Early_blight	Tizón temprano	EB
Healthy	Saludable	H
Late_blight	Tizón tardío	LB
Leaf_mold	Moho foliar	LM
Mosaic_virus	Virus del mosaico	MV
Septoria_leaf_spot	Mancha foliar de Septoria	SLS
Spider_mites_two_spotted_spider_mites	Ácaros araña (araña de dos manchas)	SMT
Target_spot	Mancha objetivo	TS
Yellow_leaf_curl_virus	Virus del enrollamiento amarillo de la hoja	YLCV



Figura 1. Detección de hojas con su etiqueta y su nivel de confianza.

Exhaustividad (*Recall*): Proporción de casos positivos correctamente identificados.

$Recall = (\text{Verdaderos Positivos (VP)}) / (\text{VP} + \text{Falsos Negativos (FN)})$

Precisión media promediada (*mean Average Precision*, mAP): Métrica estándar para evaluar modelos de detección de objetos que considera tanto la precisión como el *recall* en diferentes umbrales de intersección sobre unión.

El modelo fue entrenado y validado en Google Colab, utilizando un entorno de cómputo acelerado con GPU para garantizar resultados óptimos y tiempos de ejecución razonables.

RESULTADOS

Para la detección de enfermedades foliares en hojas de tomate se empleó el modelo propuesto YOLOv11, entrenado y validado sobre un conjunto de datos balanceado que incluye las clases BS, EB, Healthy, LB, LM, MV, SLS, SMT, TS, YLCV y una clase adicional de *background*.

Los hiperparámetros de entrenamiento fueron:

- *Learning rate* (tasa de aprendizaje): 0,000714

- Número de épocas: 40

- Optimizador: AdamW

Rendimiento global: Tal como se detalla a continuación:

- Precisión: 0,9967

- *Recall*: 0,99604

- mAP50: 0,99446

Estudios similares, con YOLOV5 obtuvieron una precisión de 90,1%, *recall* de 87,1%, y mAP de 89,6% y con YOLOV8s una precisión de 93,2%, *recall* de 90,3%, y mAP de 92,5% (Abdullah *et al.*, 2024).

Estos resultados sugieren que la arquitectura YOLOv11, ajustada para este dominio, consigue una alta capacidad de generalización, con un muy bajo índice de falsos positivos y falsos negativos.

Matriz de confusión

En la figura 2, en la diagonal principal se observa un acierto cercano al 100% en la mayoría de las clases, con solo unas pocas confusiones mínimas, en instancias mal clasificadas en algunas categorías. Esto reafirma el rendimiento casi perfecto del modelo y pone de manifiesto su fiabilidad en situaciones de




Figura 2. Matriz de confusión.

campo, donde cada categoría de enfermedad debe distinguirse con elevada precisión.

Distribución de instancias y de cajas delimitadoras

En la figura 3a, las barras confirman que el conjunto de datos está razonablemente balanceado, con 1000 instancias por cada clase. Este balance contribuye a que el modelo no se sesgue hacia ninguna enfermedad en particular. El diagrama de *bounding boxes* ilustra la posición y dimensiones de las detecciones en el plano normalizado (0 – 1) de cada imagen (Figura 3b). Se aprecia que la mayoría de las anotaciones se concentran hacia el centro ($x \sim 0,5$, $y \sim 0,5$) (Figura 3c), mientras que la variación en *width* y *height* se extiende desde valores muy pequeños ($\sim 0,1$) hasta valores cercanos a 0,9 (Figura 3d), lo que indica que el modelo se ha entrenado con éxito sobre una amplia variedad de tamaños de hojas y posiciones en la imagen.

Curvas de entrenamiento y validación

En la figura 4 se observan en las curvas superiores (train/box_loss, train/cls_loss y train/df_loss), una clara tendencia decreciente de las pérdidas, convergiendo de manera estable a valores bajos tras ~40 épocas. De manera paralela se aprecia, en las gráficas

de precisión y *recall* (metrics/precision(B), metrics/recall(B)), un incremento pronunciado al inicio del entrenamiento, estabilizándose finalmente cerca de 0,99–1,00.

En las curvas inferiores (val/box_loss, val/cls_loss y val/df_loss), la evolución muestra una trayectoria coherente con las curvas de entrenamiento, con descensos significativos de las pérdidas en validación. Además, los valores de mAP50 y mAP50-95 (últimas dos gráficas de la fila inferior) confirman la consistencia del desempeño en datos no vistos, superando el 0,98 en mAP50-95, en las últimas épocas.

DISCUSIÓN

Los resultados obtenidos evidencian el alto potencial de la arquitectura YOLOv11 para la detección de enfermedades en hojas de tomate. El desempeño promedio cercano al 100% en precisión y *recall*, junto con valores de mAP superiores al 0,99, indican que el modelo logra distinguir de manera confiable cada patología foliar evaluada. Esta eficacia se ve reforzada por la homogeneidad en las distintas curvas (mAP, precisión, *recall*) a lo largo de un amplio rango de umbrales de confianza, lo cual sugiere robustez ante variaciones en las condiciones del entorno o en la calidad de las imágenes de entrada. Uno de los aspectos más destacables es la escasa presencia




Figura 3. Distribución de instancias y de cajas delimitadoras. Distribución de instancias por clase (3a); Visualización de cajas delimitadoras (3b); Mapa de calor – Posición central de las cajas (3c); Mapa de calor – Relación ancho vs alto de las cajas (3d).

de falsos positivos y falsos negativos. Para aplicaciones reales en la industria agrícola, esto implica que el sistema sería capaz de detectar hojas enfermas con altas tasas de acierto, reduciendo los costos y el

tiempo asociados a un diagnóstico manual. Además, permite una respuesta temprana frente a brotes de enfermedades, factor crítico para prevenir pérdidas de rendimiento y daños extensivos en cultivos




Figura 4. Curvas de entrenamiento y validación.

comerciales. A pesar de los resultados favorables, es relevante señalar algunas limitaciones.

Primero, si bien el conjunto de datos se observa balanceado, las condiciones de iluminación, la variación genética de la planta y el posible traslape de síntomas entre distintas enfermedades son factores que podrían desafiar la generalización del modelo en escenarios de campo aún más complejos.

Segundo, la buena generalización en el ámbito experimental no siempre se traduce de forma directa a entornos de producción, donde factores como la heterogeneidad del suelo, clima, manejo agronómico y resolución de las cámaras pueden incidir en la precisión de la detección. Asimismo, la adopción de este sistema a gran escala requiere considerar los requerimientos computacionales y de infraestructura para la captura de imágenes en tiempo real. En este sentido, futuros trabajos podrían explorar la integración de YOLOv11 con plataformas de baja potencia (e.g. dispositivos embebidos o drones agrícolas) y evaluar métodos de compresión o cuantización de redes neuronales, con el fin de optimizar el desempeño y reducir el consumo de recursos.

Por último, se sugiere la aplicación de técnicas de interpretación de modelos de DL como Grad-CAM o análisis de visualización, para garantizar una mayor confianza de parte de los usuarios finales y posibilitar la identificación de regiones específicas de la hoja afectadas. También, sería pertinente ampliar el conjunto de datos con nuevas variedades de tomate o incluir otras enfermedades emergentes. Finalmente, aunque el modelo identifica síntomas visuales, no distingue entre causas bióticas (hongos, virus) y abióticas (deficiencias nutricionales, estrés hídrico) que puedan presentar manifestaciones similares, lo que requiere validación adicional por parte de un experto agrónomo en casos ambiguos.

De esta manera, se reforzaría la robustez del sistema y se facilitaría la adopción de una agricultura de precisión más sostenible y eficiente. En resumen, la elevada precisión, recall y estabilidad de YOLOv11 en la detección de enfermedades foliares de tomate la posicionan como una alternativa viable en sistemas automatizados de apoyo a la toma de decisiones en el ámbito agrícola. No obstante, se recomienda profundizar en la validación en entornos reales y continuar con investigaciones que aborden las limi-

taciones mencionadas, a fin de garantizar una implementación exitosa.

CONCLUSIONES

Los resultados obtenidos confirman que la combinación de GroundingDINO, para el etiquetado, y YOLOv11n, para el entrenamiento, es altamente efectiva en la detección de enfermedades en hojas de tomate. La precisión y el recall cercanos al 100% destacan la robustez del enfoque propuesto. Se demuestra la efectividad de la arquitectura YOLOv11 en la tarea de detección automática de enfermedades de hojas de tomate, sugiriendo su aplicabilidad en escenarios reales de la industria agrícola. Los resultados obtenidos permiten una detección temprana y precisa que puede mejorar significativamente el manejo de los cultivos y reducir el impacto ambiental asociado con el uso excesivo de pesticidas.

AGRADECIMIENTOS

Agradecemos el apoyo de la Dirección de Investigación y Desarrollo de la Universidad Técnica de Ambato (UTA), al Instituto Superior Tecnológico Cotopaxi, y al Instituto Superior Tecnológico Vicente León.

CONTRIBUCIÓN DE LOS AUTORES

Gestión de proyecto: Manolo Muñoz-Espinoza

Conceptualización: Gladys Vega-Iza, Walter Moreno Castillo

Conservación de datos: Gladys Vega-Iza

Análisis formal: Walter Moreno Castillo

Investigación: Gladys Vega-Iza, Jenny Acosta-Procel, Gonzalo Ruiz-Mesías

Metodología: Gonzalo Ruiz-Mesías, Jenny Acosta-Procel

Software: Jenny Acosta-Procel, Gonzalo Ruiz-Mesías

Validación: Gonzalo Ruiz-Mesías, Walter Moreno Castillo

Redacción – primera redacción: Manolo Muñoz-Espinoza

Redacción – revisión y edición: Manolo Muñoz-Espinoza, Gladys Vega-Iza, Walter Moreno Castillo

Recursos: Gladys Vega-Iza

Supervisión: Manolo Muñoz-Espinoza

BIBLIOGRAFÍA

- ABDULLAH, A., AMRAN, G. A., AHANAF TAHMID, S. M., ALABRAH, A., AL-BAKHRANI, A. A. and ALI, A. 2024. A Deep-Learning-Based Model for the Detection of Diseased Tomato Leaves. *Agronomy*, 14 (7): 1593.
- BANGARI, S., RACHANA, P., GUPTA, N., SUDI, P. S. and BANIYA, K. K. (2022). A Survey on Disease Detection of a potato Leaf Using CNN. *Proceedings of the 2nd International Conference on Artificial Intelligence and Smart Energy ICAIS*, 2022: 144–149.
- DE WIT, P. J. G. M. 2024. The tomato crop. *En: Richard P. O. (Ed.). Agrios' Plant Pathology*, Sixth Edition, Academic Press, pp. 795–801.
- ELBASI, E., MOSTAFA, N., ALARNAOUT, Z., ZREIKAT, A. I., CINA, E., VARGHESE, G., SHDEFAT, A., TOPCU, A. E., ABDELBAKI, W., MATHEW, S. and ZAKI, C. (2023). Artificial Intelligence Technology in the Agricultural Sector: A Systematic Literature Review. *IEEE Access*, 11: 171–202.
- FAO. 2023. FAOSTAT - Crops and livestock products. Disponible en: <https://www.fao.org/faostat/en/#data/QCL>. Consultado 26/10/2025.
- GATAHI, D. M. 2020. Challenges and Opportunities in Tomato Production Chain and Sustainable Standards. *International Journal of Horticultural Science and Technology*, 7 (3): 235–262.
- JOCHER, G. AND QIU, J. 2024. Ultralytics. Disponible en: <https://github.com/ultralytics/assets/releases/download/v8.3.0/yolo11n.pt>. Consultado 23/09/2025.
- JOHN, M. A., BANKOLE, I., AJAYI-MOSES, O., IJILA, T., JEJE, T., and LALIT, P. (2023). Relevance of Advanced Plant Disease Detection Techniques in Disease and Pest Management for Ensuring Food Security and Their Implication: A Review. *American Journal of Plant Sciences*, 14 (11): 1260–1295.
- Kaggle. 2020. Data Science Platform. Disponible en: <https://www.kaggle.com/datasets/kaustubhb999/tomatoleaf/data>. Consultado 14/05/2025.
- KHAN, U. M., SEVINDIK, M., ZARRABI, A., NAMI, M., OZDEMIR, B., KAPLAN, D. N., SELAMOGLU, Z., HASAN, M., KUMAR, M., ALSHEHRI, M. M. and SHARIFI-RAD, J. 2021. Lycopene: Food Sources, Biological Activities, and Human Health Benefits. *Oxidative Medicine and Cellular Longevity*, 2021: 2713511.
- KHANAM, R. AND HUSSAIN, M. 2024. YOLOV11: An overview of the key architectural enhancements. *arXiv preprint arXiv:2410.17725*.
- KUMAR, A., KUMAR, V., GULL, A. and NAYIK, G. A. 2020. Tomato (*Solanum Lycopersicum*). *En: Nayik, G. A. and Gull, A. (Eds.). Antioxidants in Vegetables and Nuts - Properties and Health Benefits*. Springer, Singapore, pp. 191–207.
- LIU, S., ZENG, Z., REN, T., LI, F., ZHANG, H., YANG, J., JIANG, Q., LI, C., YANG, J., SU, H., ZHU, J., and ZHANG, L. 2024. Grounding DINO: Marrying DINO with Grounded Pre-Training for Open-Set Object Detection. <https://arxiv.org/abs/2303.05499>.
- PANNO, S., DAVINO, S., CARUSO, A. G., BERTACCA, S., CRNOGORAC, A., MANDIĆ, A., NORIS, E. and MATIĆ, S. 2021. A review of the most common and economically important diseases that undermine the cultivation of tomato crop in the mediterranean basin. *Agronomy*, 11 (11): 2188.
- REDMON, J., DIVVALA, S., GIRSHICK, R. and FARHADI, A. 2016. You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition*, 27-30 June 2016, Las Vegas, USA.
- YU, F., ZHANG, Q., XIAO, J., MA, Y., WANG, M., LUAN, R., LIU, X., PING, Y., NIE, Y., TAO, Z. and ZHANG, H. 2023. Progress in the Application of CNN-Based Image Classification and Recognition in Whole Crop Growth Cycles. *Remote Sensing*, 15 (12): 2988.

CITAR COMO:

MORENO-CASTILLO, W., ACOSTA-PROCEL, J., RUIZ-MESÍAS, G., VEGA IZA, G., MUÑOZ-ESPINOSA, M. 2025. Detección de enfermedades en hojas de tomate (*Solanum lycopersicum*) utilizando inteligencia artificial. *Centro Agrícola*, 52 (2025) e2462



Artículo de **libre Acceso** bajo los términos de una *Licencia Creative Commons Atribución-NoComercial-SinDerivar 4.0 Internacional*. Se permite, sin restricciones el uso, distribución, traducción y reproducción del documento, siempre que la obra sea debidamente citada.