

Identificación de plagas y cultivos enfermos con aplicación de Inteligencia Artificial usando YOLOv5



Colaboración

Edilberto Vega Lopez; María Guadalupe Pineda Arizmendi, Tecnológico de Estudios Superiores de Tianguistenco; Irvin Uriel Nopalera Ángeles, Universidad Autónoma del Estado de México; Brenda Sunuami González Lopez, Tecnológico de Estudios Superiores de Tianguistenco

Fecha de recepción: 17 de agosto de 2025

Fecha de aceptación: 13 de septiembre de 2025

Resumen: Según la OMS, cada año en el mundo más de 500 millones de personas se enferman por consumir alimentos contaminados por diversos factores, incluidas las plagas. Actualmente, en el Estado de México se cosechan más de 738,069.06 hectáreas con un valor de producción de 33,699.37 millones de pesos, lo que representa un gran desafío para garantizar la producción de estos cultivos ante la presencia de plagas. El proyecto de investigación se enfoca en la detección de plagas como: insecto, saltamontes, gusano cogollero y escarabajo, así como la clasificación de fruto enfermo y fruto sano en cultivos cercanos referente a la comunidad de Santiago Tianguistenco, comenzando con la construcción de un conjunto de datos propio, recopilando imágenes y experimentando con una red neuronal para la detección de plagas.

Para las pruebas realizadas en esta investigación, se utilizó información etiquetada mediante la herramienta pública Roboflow, así como un modelo de red neuronal convolucional basado en YOLOv5, sometido a 50 épocas de entrenamiento en un entorno de Google Colab, obteniendo una precisión del 95.7%.

PALABRAS CLAVE: Plaga, Red neuronal, YOLOv5.

Abstract : According to the World Health Organization (WHO), each year more than 500 million people worldwide become ill from consuming food contaminated by various factors, including pests. Currently, in the State of Mexico, over 738,069.06 hectares are harvested with a production value of 33,699.37 million pesos, which presents a major challenge in ensuring crop production in the presence of pests.

The research project focuses on the detection of pests such as insects, grasshoppers, fall armyworms, and beetles, as well as the classification of diseased and healthy fruit in nearby crops related to the community of Santiago Tianguistenco. The project begins with the construction of a proprietary dataset, collecting images and experimenting with a neural network for pest detection.

For the tests conducted in this research, labeled data was used through the public tool Roboflow, along with a convolutional neural network model based on YOLOv5, trained over 50 epochs in a Google Colab environment, achieving an precision of 95.7%.

KEYWORDS: Plague, Neural Network, YOLOv5.

INTRODUCCIÓN

Actualmente, la agricultura enfrenta numerosos desafíos para maximizar su rendimiento, entre ellos tratamientos inadecuados del suelo, infestaciones de enfermedades y plagas, entre otros. Debido al aumento continuo de la población humana, se estima que la demanda de producción de alimentos deberá incrementarse entre un 70 % y un 100 % en los próximos años. Sin embargo, la seguridad alimentaria de la humanidad se ve afectada por diversos factores, incluidas las plagas [1].

Una plaga es cualquier especie, raza o biotipo de planta, animal o patógeno que resulte perjudicial para las plantas o sus productos [2].

Un cultivo es cualquier planta que se cultiva intencionalmente para ser cosechada con fines alimenticios, forrajeros, de fibra, combustible u otros propósitos económicos [2].

Las enfermedades y plagas vegetales representan una amenaza constante para la disponibilidad y seguridad de los cultivos destinados al consumo humano y animal. Las pérdidas globales de rendimiento en cultivos básicos pueden alcanzar hasta un 30 %, lo que equivale a cientos de miles de millones de dólares en producción alimentaria perdida [3].

El Estado de México cuenta con 738,069.06 hectáreas cosechadas, con un valor de producción de 33,699.37 millones de pesos. Esto representa un reto importante para garantizar el éxito de los cultivos y protegerlos ante la presencia de plagas [4].

La Inteligencia Artificial (IA) es la capacidad de las máquinas para utilizar algoritmos, aprender a partir de datos y aplicar lo aprendido en la toma de decisiones, de forma similar a como lo haría un ser humano [5].

El uso de la inteligencia artificial y las nuevas tecnologías ha permitido proteger los cultivos al mejorar su rendimiento frente a diversos factores, como el cambio climático, el crecimiento poblacional y la seguridad alimentaria. Además, ofrece beneficios en el uso adecuado del agua, pesticidas y herbicidas, lo que contribuye a una mayor eficiencia laboral. Todo esto impulsa la productividad, mejora la calidad y ayuda a mantener la fertilidad del suelo [6].

Este proyecto de investigación se enfocará en la detección de plagas en cultivos cercanos a la comunidad de Santiago Tianguistenco, comenzando por la construcción de un conjunto de datos propio hasta la experimentación con una red neuronal para la detección de plagas.

El objetivo de este trabajo es desarrollar y evaluar un sistema automatizado de detección de plagas y enfermedades mediante redes neuronales convolucionales, con captura de imágenes, orientado a cultivos localizados en el Estado de México

Revisión de la literatura

Existen diversos estudios relacionados con la detección de plagas mediante técnicas de inteligencia artificial. Algunos de los trabajos mencionados a continuación están estrechamente relacionados con el enfoque de esta investigación.

SM Samadhi y otros [7].

Realizaron la detección de plagas en cultivos de arroz utilizando un dispositivo ESP32 montado sobre un trípode de 1.5 metros para recolectar su propio conjunto de datos, incluyendo babosas, caracoles, polillas, avispas, tijeretas, orugas y gorgojos. Desarrollaron un modelo de aprendizaje automático para identificar diversas plagas en campo, empleando el método YOLOv8 y entrenándolo durante 100 épocas. Lograron una precisión superior al 90 %, identificando exitosamente las plagas.

Li y otros [8].

Crearon su propio conjunto de datos con imágenes capturadas mediante una cámara Canon Powershot G16 y un teléfono Samsung Galaxy S10, tomadas desde distintos ángulos y distancias (0.3–0.5 m). En total, recopilieron 4,418 imágenes de diversas clases de plagas y enfermedades del yute, como pudrición del tallo, antracnosis y banda negra, entre otras. Estas imágenes fueron utilizadas para entrenar su modelo personalizado, YOLO-JD, basado en YOLOv5, alcanzando una precisión promedio del 96.63 %.

Wen, C y otros [9].

Propusieron un modelo llamado Pest-YOLO, basado en YOLOv3, utilizando un conjunto de datos de imágenes de plagas a gran escala denominado Pest24, que incluye más de 20,000 imágenes con más de 190,000 plagas etiquetadas por expertos agrícolas y categorizadas en 24 clases. Los resultados experimentales muestran que Pest-YOLO alcanzó una precisión del 69.59 %.

Liu et y otros [10].

Propusieron un método basado en YOLOv3, utilizando detección multiescala mediante una pirámide de imágenes, agrupamiento de dimensiones de cuadros delimitadores (bounding boxes) y entrenamiento multiescala. Este método alcanzó una precisión del 92.39 %.

Cabrera [11]

Utilizó un modelo YOLOv3 entrenado durante 200 épocas con su propio conjunto de datos, compuesto por 80 imágenes de mosca blanca y trips. Logró una precisión promedio del 71.42 %.

MATERIAL Y MÉTODOS

Este trabajo propone la identificación de plagas en cultivos cercanos a la comunidad de Santiago Tianguistenco mediante el uso de una red neuronal convolucional basada en YOLOv5, con el fin de optimizar la detección de plagas.

YOLOv5 es la primera versión de código abierto desarrollada por la empresa Ultralytics para la detección de objetos en tiempo real. Esta arquitectura de red neuronal convolucional está basada en el trabajo de Redmon y Farhadi [12].

El desarrollo de este trabajo se basó en la metodología CRISP-DM, la cual consta de seis fases.

De acuerdo con la Figura 1, los pasos a seguir son los siguientes:

1. Desarrollar una red neuronal convolucional basada en YOLOv5 para detectar plagas y cultivos enfermos cerca de la comunidad de Santiago Tianguistenco.
2. Utilizar conjuntos de datos existentes sobre plagas y cultivos enfermos, así como recolectar imágenes personalizadas para crear conjuntos de datos propios.
3. Utilizar la plataforma Roboflow para el etiquetado de datos en formato YOLOv5.
4. Implementar la red neuronal convolucional basada en YOLOv5 en un entorno de Google Colab, utilizando Python como lenguaje de programación.
5. Comparar el rendimiento del modelo con el estado del arte y evaluarlo mediante métricas de rendimiento como precisión, recall y mAP@50.
6. Realizar pruebas con diferentes conjuntos de datos.

El trabajo de Ryan [13] implementa un sistema basado en la red neuronal convolucional YOLOv8 para clasificar arándanos según su madurez. Usaron 666 imágenes de arándanos en tres etapas de maduración: verde, en transición y maduros, utilizando la plataforma Roboflow para el etiquetado de datos y optimizando técnicas de aumento como rotación, ajuste de brillo y cambio de contraste para aumentar la variabilidad y robustez del conjunto de datos.

Roboflow simplifica y optimiza los procesos de etiquetado, aumento y exportación de datos, por lo que es una herramienta ideal para proyectos de detección de objetos, como aquellos que utilizan YOLO.

Por lo tanto, todas las imágenes fueron etiquetadas usando la herramienta Roboflow en formato YOLOv5, el cual es el siguiente: `class id x_center y_center width height` Donde:

- **class id:** Identificador de la clase del objeto (un número entero que empieza desde 0 para la primera clase).
- **x_center:** Coordenada X del centro del cuadro delimitador, normalizada entre 0 y 1, relativa al ancho de la imagen.
- **y_center:** Coordenada Y del centro del cuadro delimitador, normalizada entre 0 y 1, relativa a la altura de la imagen.
- **width:** Ancho del cuadro delimitador, normalizado entre 0 y 1, relativo al ancho de la imagen.
- **height:** Altura del cuadro delimitador, normalizada entre 0 y 1, relativa a la altura de la imagen.

En la Figura 2 se puede observar un etiquetado de caja delimitadora en Roboflow, que proporcionará las etiquetas necesarias en formato YOLOv5.

Una vez etiquetadas todas las imágenes, se descargará el conjunto de datos, el cual contendrá lo siguiente, como se muestra en la Figura 3. Una carpeta para entrenamiento y otra para pruebas, que contienen respectivamente las imágenes y las etiquetas.

Además, el archivo de datos indica el orden en que deben organizarse las clases.

Conjuntos de Datos Utilizados

- **IP102:** Es un conjunto de datos público y uno de los más utilizados en la investigación sobre detección de plagas agrícolas. Fue diseñado para abordar problemas de clasificación y detección de plagas en cultivos, y contiene una gran variedad de imágenes de insectos plaga recolectadas en entornos reales.
- **Tejocote:** Construido usando un dron DJI Mavic Mini. El árbol se ubicaba cerca de la institución, y el dron voló a una altura de 7 a 10 metros, capturando fotos a una resolución de 1080p y a una distancia de 15 a 30 cm.
- **Maíz:** Proporcionado por un colaborador, contiene las principales plagas del maíz, así como hojas sanas y enfermas de la planta.

Los conjuntos de datos pueden ser accedidos en:

<https://github.com/edyvel67/Plagas-.git>

para su uso por parte de la comunidad científica.

Red Neuronal

Las redes neuronales artificiales están basadas en la analogía con el comportamiento y la función del cerebro humano, particularmente del sistema nervioso, compuesto por redes de neuronas biológicas con capacidades de procesamiento limitadas. Sin embargo, toda su capacidad cognitiva se basa en la conectividad de estas neuronas [14].

YOLOv5

YOLOv5 es un modelo muy popular y de alto rendimiento en el campo de la detección de objetos, reconocido como tecnología de vanguardia para detecciones en tiempo real (FPS). Representa la quinta generación de detectores de una sola etapa y está implementado en PyTorch [15].

Arquitectura de YOLOv5

- **Backbone:** Utiliza la estructura CSP-Darknet53, una modificación de la arquitectura DarkNet usada en versiones anteriores, y actúa como extractor de características.
- **Neck:** Conecta el backbone con el head. En YOLOv5 se utilizan las estructuras SPPF y CSP-PAN.
- **Head:** Se encarga de generar la inferencia. YOLOv5 utiliza el mismo head que YOLOv3.

Dron

El dron es un dispositivo de navegación autónoma con características técnicas específicas, diseñado para realizar una amplia variedad de tareas. Puede utilizarse tanto en exteriores como en algunos espacios interiores. Se le pueden integrar distintos tipos de sensores ópticos, como cámaras de video, cámaras de espectro visible, cámaras infrarrojas, entre otros. Además, pueden incorporarse otros tipos de sensores. Los drones pueden operar a diversas altitudes mediante vuelos completamente automáticos, preprogramados, controlados remotamente o manejados manualmente con un sistema de radio control [16].

Características del Dron Utilizado (DJI Mavic Mini 1)**• Diseño y Portabilidad:**

Peso: 249 gramos (cumple con regulaciones que lo exentan de registro en varios países).

Dimensiones:

- Plegado: 140 × 82 × 57 mm

- Desplegado: 160 × 202 × 55 mm

• Cámara y Video:

Sensor: 12 MP, CMOS de 1/2.3"

Resolución de fotos: 4000 × 3000 píxeles

Full HD: 1920 × 1080 a 60 fps

Ángulo de visión (FOV): 83°

Apertura: f/2.8

• Alcance y Conectividad:

Alcance de control: Hasta 4 km (en zonas sin interferencia, con FCC)

Conectividad: Wi-Fi

Google Colab

Google Colaboratory (también conocido como Colab) es un servicio basado en la nube que utiliza Jupyter Notebooks para promover la educación e investigación en aprendizaje automático. Proporciona un entorno completamente configurado para el aprendizaje profundo [17].




Figura 1: Fases de la metodología Crisp-Dm.

Fuente: Elaboración Propia.




Figura 2: Etiquetado de caja en Roboflow.

Fuente: Elaboración Propia.

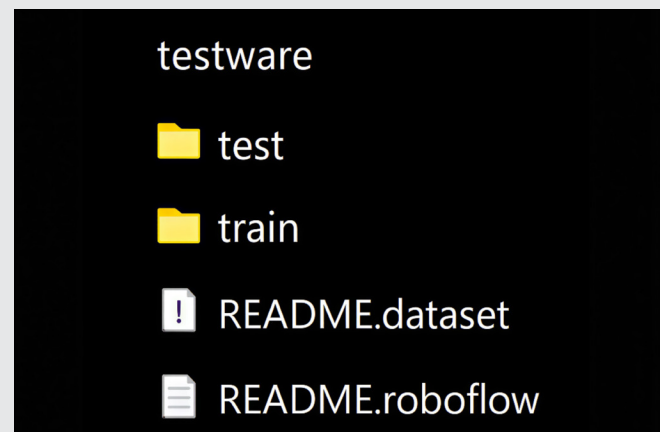


Figura 3: Contenido de conjunto de datos Roboflow.

Fuente: Elaboración Propia.



Figura 4: Ejemplo detección Prueba 1.

Fuente: Elaboración Propia.

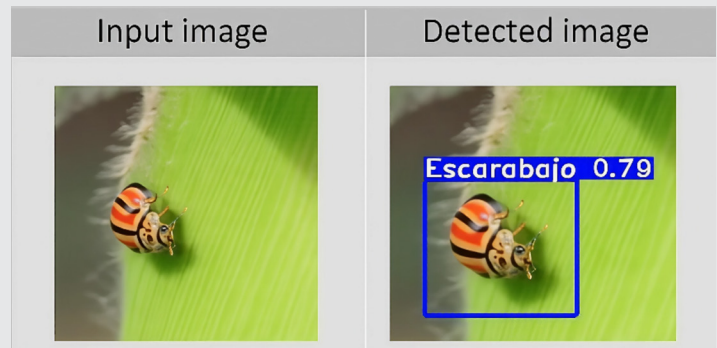



Figura 5: Ejemplo detección Prueba 3.

Fuente: Elaboración Propia.

Gráfica 1. Resultados de Pruebas



Fuente: Elaboración Propia.

Tabla 1. Conjuntos de datos de imágenes de plagas y enfermedades.

NOMBRE	TIPO	TAMAÑO	AUTOR	DESCRIPCIÓN
IP102	PLAGAS	75,000 imágenes	Wang y otros	Conjunto de imágenes publico ip102 Este es uno de los conjuntos de datos más grandes para la identificación de plagas de insectos. Contiene más de 75,000 imágenes de 102 categorías de plagas.
TEJOCOTE	ENFERMEDAD	20 IMÁGENES	PROPIO	20 imágenes tomadas de un árbol de tejocote, tomadas con un drone dji mavic mini.
MAÍZ	ENFERMEDADES Y PLAGAS	7,000 IMÁGENES	PROPIO	5 diferentes clases de plagas en maíz (saltamontes, gusano cogollero, escarabajo e insecto), así como hojas de maíz sanas y enfermas.

Fuente: Elaboración propia.

Tabla 2. Resultados de Pruebas.

#	Autor	Accuracy
1	Samadhi	95%
2	Wen	69.59%
3	Liu	92.39%
4	Li	96.63%
5	Cabrera	71.42%
6	Propio	95.7%

Fuente: Elaboración propia.

RESULTADOS

Usando los conjuntos de datos previamente descritos en la Tabla 1, se realizaron 3 pruebas, obteniendo los siguientes resultados (Véase gráfica 1). Para cada prueba, los datos se dividieron en un 80 % para entrenamiento y un 20 % para pruebas.

Para la prueba 1 se utilizó el conjunto de datos "IP102" usando dos clases, abejas y hormigas usando un total de 50 imágenes para cada clase respectivamente extraídas del conjunto de datos sometida a 50 épocas de entrenamiento.

Para la prueba dos se utilizó el conjunto de datos "Tejocote" usando una sola clase: "fruto enfermo" usando el total de imágenes del conjunto de datos sometida a 50 épocas de entrenamiento.

En la prueba 3 se utilizó el conjunto de datos "Maíz" usando 4 clases: insecto, saltamontes, gusano cogollero y escarabajo usando 25 imágenes para cada clase respecti-

vamente extraídas del conjunto de datos sometida a 50 épocas de entrenamiento.

Todos los conjuntos de datos fueron etiquetados con Roboflow usando técnicas de aumento como rotación, rotar y recortar para aumentar la variabilidad y robustez del conjunto de datos.

De acuerdo con las pruebas realizadas, como se muestra en la gráfica 1, la Prueba 1 fue la mejor, con una precisión de 0.957. Sin embargo, las otras dos pruebas también muestran un buen desempeño, afectando factores como la calidad de las imágenes y el tamaño de los conjuntos de datos.

Discusión

Esto, en comparación con los trabajos realizados por otros autores, como se muestra en la Tabla 2, demuestra que el modelo YOLOv5 utilizado en este trabajo permite una buena precisión, ya que arroja resultados competitivos con los obtenidos por los autores conocidos en la revisión de la literatura.

Este trabajo propone un método basado en YOLOv5 para la detección de plagas en cultivos cercanos a la comunidad de Santiago Tianguistenco, iniciando con la construcción de conjuntos de datos personalizados, así como el desarrollo de la red neuronal. La calidad y cantidad de imágenes en un conjunto de datos desempeñan un papel crucial en su construcción. Cuantas menos imágenes haya y peor sea su calidad, menor será la precisión del modelo en la detección o su rendimiento será bajo, en comparación con un conjunto de datos que contenga más imágenes y de mejor calidad.

Con el método propuesto en este trabajo, se observó que YOLOv5 es capaz de detectar plagas exitosamente. Además, presenta un alto grado de optimización en comparación con otros modelos utilizados para la detección de plagas. Como trabajo futuro, se propone ampliar los conjuntos de datos, así como aumentar las épocas de entrenamiento del modelo.

CONCLUSIONES

La aplicación de inteligencia artificial, en particular el uso del modelo YOLOv5, representa un avance significativo en la identificación temprana de plagas y enfermedades en cultivos agrícolas. Esta tecnología permite una detección rápida, precisa, lo cual resulta fundamental para mitigar pérdidas económicas, reducir el uso excesivo de pesticidas y mejorar la toma de decisiones en el manejo agrícola.

Los resultados obtenidos en esta investigación demuestran que los modelos de detección basados en redes neuronales convolucionales son altamente eficientes en la clasificación y localización de elementos visuales clave en las plantas. Además, el uso de herramientas como drones o cámaras móviles para la recolección de imágenes

permite una mayor cobertura de terreno y facilita la implementación práctica de este sistema en campo.

El uso de YOLOv5 en la agricultura inteligente no solo optimiza el monitoreo fitosanitario, sino que también abre la puerta a sistemas de producción más sostenibles, autónomos y resilientes frente a los desafíos que enfrenta el sector agrícola actual.

Como contribución a la comunidad científica, se comparan los conjuntos de datos recolectados para que puedan ser utilizados en estudios posteriores con enfoques similares al de este trabajo.

AGRADECIMIENTOS

Quisiera agradecer al Tecnológico de Estudios Superiores de Tianguistenco por su apoyo y colaboración en el desarrollo de este trabajo.

BIBLIOGRAFÍA

[1] L. X. Zelaya-Molina, I. F. Chávez-Díaz, S. De los Santos-Villalobos, C. I. Cruz-Cárdenas, S. Ruíz-Ramírez y E. Rojas-Anaya, «Control biológico de plagas en la agricultura mexicana», *Revista mexicana de ciencias agrícolas*, vol. 13, nº SPE27, pp. 69-79, 2022.

[2] FAO, «The State of Food and Agriculture», 2021.

[3] D. Rizzo, M. Lichtveld, J. A. Mazet, E. Togami y S. A. Miller, «Plant health and its effects on food safety and security in a One Health framework: four case studies», *One Health Outlook*, pp. 3-6, 2021.

[4] Secretaría del Campo, «Estadísticas Secretaría del Campo», 2023. [En línea]. Available: <https://secampo.edomex.gob.mx/estadisticas>.

[5] L. Rouhiainen, «Inteligencia Artificial», de *Inteligencia artificial*, Madrid, Alienta, 2018, pp. 20-21.

[6] J. S. B. R. F. A. D. & Q. M. W. V. Segovia, «Estudio del uso de técnicas de inteligencia artificial aplicadas para análisis de suelos para el sector agrícola», *RECIMUNDO*, pp. 4-19, 2021.

[7] K. Herath y H. M. Samadhi Chathuranga Rathnayaka, «Smart agriculture: Real-time pest detection in rice crops with YOLOv8 and ESP-32 camera technology», *International Research Journal of Innovations in Engineering and Technology*, p. 705, 2023.

[8] F. A. Li Dawei, N. Wu y A. S. Sethi, «YOLO-JD: A Deep Learning Network for Jute Diseases and Pests Detection from Images», *Plants*, p. 937, 2022.

[9] C. C. H. M. Z. Z. T. Y. C. S. H. & C. H. Wen, «Pest-YOLO: A model for large-scale multi-class dense and tiny pest detection and counting», *Frontiers in Plant Science*, p. 13, 2022.

[10] L. Jun y X. Wang, «Tomato diseases and pests detection based on improved Yolo V3 convolutional neural network», *Frontiers in Plant Science*, p. 11, 2020.

[11] C. Cabrera Zúñiga, «Identificador de plagas con Deep Learning», *Universidad Nacional Autónoma de México, FES Cuautitlán*, 2021.

[12] V. A. Avaria, D. Diego-Tortosa y S. Morell-Monzó, «Detección de silbidos de mamíferos marinos en espectrogramas utilizando yolo-v5», *Tesis de licenciatura, Universidad Técnica Federico Santa María, Valparaíso, Chile*, 2023.

[13] G. Rongli, L. Yong y X. Guohui, «TL-YOLOv8: A Blueberry Fruit Detection Algorithm Based on Improved YOLOv8 and Transfer Learning», *IEEE Access*, pp. 86378-86390, 2024.

[14] R. Salas, «Redes neuronales artificiales», *Universidad de Valparaíso. Departamento de Computación*, pp. 1-7, 2024.

[15] B. Montenegro y M. Flores-Calero, «Detección de peatones en el día y en la noche usando YOLO-v5», *Ingenius. Revista de Ciencia y Tecnología*, pp. 85-95, 2022.

[16] S. f. M. Mini, «DJI», 2019. [En línea]. Available: <https://www.dji.com/mx/support/product/mavic-mini>.

[17] L. Esnaola, «Experiencia de uso de Google Colaboratory en Sistemas Inteligentes», 2022.

