

PROTOTIPO PARA LA DETECCIÓN DE ARAÑA CRISTALINA EN CULTIVOS DE AGUACATE APLICANDO REDES NEURONALES

García-Palomera Jesús¹, Verduzco-Ramírez Jesús Alberto¹, Barrios-Hernández Carlos Jaime², García-Virgen Juan¹, Morán-López Luis Eduardo³

¹TECNOLÓGICO NACIONAL DE MÉXICO CAMPUS I.T. COLIMA

División de Estudios de Posgrado e Investigación

Av. Tecnológico No. 1, Col. Liberación, Villa de Álvarez, Colima, C.P. 28976

Teléfonos: (312) 312 6393, (312) 312 9920 2

²UNIVERSIDAD INDUSTRIAL DE SANTANDER/ ³UNIVERSIDAD DE COLIMA

{G2346012, averduzco, jgarcia}@colima.tecnm.mx, cbarrios@uis.edu.co, lmoran72@ucol.mx

RESUMEN.

México es el principal productor de aguacate, aportando el 46% de las exportaciones globales. Sin embargo, el cultivo está expuesto a plagas y enfermedades, como la araña cristalina (*Oligonychus perseae*), que interfiere con la fotosíntesis y debilita el follaje, exponiendo los frutos a condiciones adversas. La detección oportuna de esta plaga es crucial para controlar su propagación y sus efectos. Las inspecciones visuales realizadas por personal son costosas, laboriosas y propensas a errores. Este trabajo propone un prototipo para detectar la araña cristalina utilizando el modelo de redes neuronales preentrenado YOLOv5. Para su implementación, se aplicó un proceso organizado en fases de adquisición de imágenes, preprocesamiento, entrenamiento y evaluación de resultados. Los resultados muestran una exactitud del 93% en la clasificación de este patógeno. Además, se implementó una interfaz web para facilitar su uso, permitiendo al productor la visualización, clasificación y manejo de imágenes directamente en el predio de cultivo.

Palabras Clave: Aguacate, Araña Cristalina, Procesamiento de imágenes, YOLOv5

ABSTRACT.

Mexico is the main producer of avocado, contributing with 46% of global exports. However, the crops are exposed to pests and diseases, such as the so called perseae mite (*Oligonychus perseae*), this mite interferes with photosynthesis and weakens the foliage, exposing the fruits to adverse conditions. Early detection of this pest is crucial to control its spread and effects. Visual inspections performed by personnel are costly, laborious, and prone to errors. This work proposes a prototype to detect the perseae mite using the pre-trained YOLOv5 neural network model. For this implementation, the process was organized in several phases: image acquisition, preprocessing, model training and evaluation of results. The results show an accuracy of 93% in classifying this pathogen. Additionally, a web interface was implemented to facilitate its use, allowing the producer to visualize, classify, and manage images directly in the field.

Keywords: Avocado, Perseae-Mite, Image Processing, YOLOv5

1. INTRODUCCIÓN

En los últimos años, la agricultura ha experimentado un crecimiento significativo en términos de producción y exportación, impulsada en gran medida por la creciente demanda

de productos agroalimentarios. En este contexto, el aguacate se ha consolidado como uno de los frutos más exitosos de la exportación agroalimentaria, con países como México liderando su producción y exportación a nivel global. Se estima que para el año 2030, la producción nacional de aguacate alcanzará los 3.16 millones de toneladas, con un crecimiento anual promedio del 3.49% desde 2016, proyectando exportaciones con un valor de 4.65 millones de dólares [1]. Este incremento en la producción ha venido acompañado de un aumento en las superficies sembradas y cosechadas, alcanzando un total de 252,132 hectáreas sembradas en 2022 [2], como se muestra en la Figura 1.




Figura 1. Resumen Nacional de Siembras y Cosechas de Aguacate. (Fuente: Elaboración propia con datos del SIAP [2]).

A medida que la superficie cultivada de aguacate sigue en expansión, la necesidad de implementar soluciones tecnológicas innovadoras para optimizar la producción y minimizar las pérdidas adquiere mayor relevancia. A pesar de los esfuerzos realizados por los productores y las autoridades para monitorear y controlar las plagas y enfermedades que afectan los cultivos de aguacate, las pérdidas económicas derivadas de estos problemas continúan siendo significativas. La detección temprana de plagas sigue siendo un reto que impacta negativamente la productividad, afectando no solo a los productores, sino también a la competitividad del sector a nivel global [1].

El monitoreo y la detección de plagas en la agricultura han evolucionado con el avance de tecnologías emergentes, tales como la visión computacional y el aprendizaje automático. Estas herramientas, anteriormente limitadas a aplicaciones de investigación, han encontrado un nuevo campo de acción en la agricultura de precisión. En particular, los modelos de redes neuronales, como YOLOv5 (You Only Look Once) [3], han demostrado ser eficientes en la detección y clasificación de objetos, permitiendo un análisis preciso y rápido de imágenes de cultivos para identificar la presencia de plagas. YOLOv5 es un modelo de red neuronal convolucional utilizado para la detección y clasificación de objetos que emplea un enfoque basado en problemas de regresión. Este modelo escanea la imagen completa durante el tiempo de prueba para codificar tanto información contextual como su apariencia.

La implementación de técnicas avanzadas para la detección temprana de plagas es fundamental para garantizar la productividad y la rentabilidad en el cultivo de aguacate. Aunque actualmente existen métodos de monitoreo mediante personal capacitado, la automatización de este proceso a través de modelos de visión computacional puede reducir costos, mejorar la precisión y reducir el tiempo de respuesta ante amenazas potenciales. Por ello, la integración de herramientas como YOLOv5 en la cadena de producción de aguacate podría ofrecer una solución efectiva y escalable para mitigar las pérdidas ocasionadas por plagas.

El objetivo de este artículo es explorar el uso de tecnologías de visión computacional, específicamente el modelo YOLOv5, para la detección temprana de plagas en cultivos de aguacate. Mediante el desarrollo de un prototipo y el análisis de su aplicabilidad y desempeño, se busca demostrar cómo estas herramientas tecnológicas pueden mejorar el monitoreo de los cultivos y optimizar la producción.

El artículo está organizado de la siguiente manera: en la primera sección, se presenta un análisis de los trabajos relacionados con el uso de visión computacional y redes neuronales para la detección de plagas. En la segunda sección, se detallan la metodología y las herramientas empleadas en el desarrollo del prototipo, que incluye las fases de adquisición y etiquetado de imágenes, preprocesamiento de datos, configuración del modelo YOLOv5, entrenamiento y evaluación de los resultados. Posteriormente, se describe el desarrollo y los componentes de la interfaz de usuario y, finalmente, se presentan las conclusiones y una propuesta de trabajo futuro.

2. TRABAJOS RELACIONADOS

A continuación, se resumen algunos trabajos de investigación que han evidenciado la efectividad del uso de modelos de redes neuronales para la detección de patógenos en cultivos.

Lagos K. [5] propone un sistema inteligente de apoyo a la toma de decisiones utilizando ontologías y tecnologías semánticas para el control y prevención de enfermedades en cultivos de arroz. El sistema cuenta con una interfaz web en la que el usuario ingresa imágenes, y, una vez procesadas, se emite un diagnóstico de la afección junto con recomendaciones para su cuidado y control.

Medina Y. et al. [6] desarrollaron un sistema experto para diagnosticar plagas y enfermedades en el cultivo de arroz mediante la evaluación de su sintomatología. Para ello, se almacenaron reglas de diagnóstico obtenidas de la revisión de literatura, como libros, artículos, revistas y de entrevistas con especialistas.

Morelo R. [7] desarrolló un sistema de visión artificial para identificar plagas y enfermedades en cultivos de sandía utilizando aprendizaje automático. El sistema analiza las plantas mediante cámaras en busca de signos y síntomas característicos de plagas o enfermedades. El 82.6% de los usuarios señaló que el sistema mejora el nivel de información disponible para la toma de decisiones.

Villasana, E. et al. [8] propusieron un sistema de monitoreo para la detección temprana de enfermedades en plantas ornamentales. La propuesta detecta irregularidades como manchas utilizando un clasificador de colores basado en lógica difusa, y cuenta con una interfaz que permite al usuario interpretar los resultados.

Los trabajos analizados comparten la característica de requerir una gran cantidad de información para generar la base de conocimiento, así como de recursos computacionales significativos. Estos factores incrementan su costo y los hacen de difícil acceso para los agricultores de pequeña escala que cuentan con recursos económicos limitados. Además, no ofrecen una solución que pueda aplicarse capturando imágenes directamente en cultivos de aguacate.

Este trabajo tiene la finalidad de implementar un sistema de detección de plagas utilizando el modelo YOLOv5, enfocado en la detección de la plaga araña cristalina (*Oligonychus perseae*). De esta manera, se busca evaluar si la aplicación puede ser útil para su implementación directa en campo. Los resultados obtenidos se pretenden utilizar como parte de un proyecto que permita optimizar el monitoreo y detección de plagas en cultivos de aguacate. La solución propuesta está dirigida a productores con reducida capacidad económica que requieren herramientas eficientes y fáciles para la detección oportuna de esta plaga.

3. METODOLOGÍA Y HERRAMIENTAS

Las herramientas utilizadas para el desarrollo de este trabajo incluyeron el modelo YOLOv5 v7.0, el repositorio de imágenes públicas Roboflow [8], una computadora equipada con sistema operativo Windows 11, 8 GB de RAM, procesador AMD Athlon Silver 3050U @2.30GHz y el entorno de desarrollo de software Anaconda Navigator [9].

Con el fin de organizar las actividades de este proyecto, se utilizaron las pautas del proceso que se ilustran en la Figura 2.




Figura 2. Proceso utilizado para el desarrollo del trabajo.
(Fuente: Propia).

3.1 Adquisición y etiquetado de imágenes

Se recolectó un conjunto de 70 imágenes disponibles públicamente, de las cuales 35 muestran hojas de cultivos de aguacate con presencia de araña cristalina y 35 corresponden a hojas saludables. Para el etiquetado y almacenamiento de las imágenes se utilizó la herramienta Roboflow.




Figura 3. Selección y etiquetado de imágenes utilizando Roboflow (Fuente: Propia).

3.2 Preprocesamiento

Posteriormente, se aplicó a cada imagen el preprocesamiento y redimensionamiento a un tamaño de 224 x 224 píxeles, generando

un total de 180 imágenes. Los parámetros utilizados se muestran en la Figura 4.




Figura 4. Preprocesamiento y redimensionamiento de imágenes utilizando Roboflow (Fuente: Propia).

3.3 Configuración del modelo

A continuación, se realizó la configuración del modelo YOLOv5 utilizando los valores que se muestran en la Tabla 1.

Tabla 1. Configuración de los parámetros de entrenamiento para el modelo YOLOv5 (Fuente: Propia).

Conjunto de datos	Imágenes públicas
Imágenes de entrenamiento	165
Imágenes de prueba	15
Tamaño de imagen (píxeles)	224 x 224
Épocas	60
Tasa de aprendizaje (α)	0.001
Batch	64
Optimizador	SGD (Stochastic Gradient Descent)

3.4 Entrenamiento

Una vez generado el conjunto de imágenes y configurado el modelo YOLOv5, se procedió con el entrenamiento utilizando la plataforma Spyder IDE. El conjunto de imágenes fue importado desde el repositorio Roboflow. La Figura 5 muestra las últimas 11 épocas del proceso de entrenamiento.

Epoch	train_loss	test_loss	top1_acc
50/60	0.342	0.304	0.867
51/60	0.38	0.289	0.933
52/60	0.403	0.281	0.933
53/60	0.359	0.292	0.933
54/60	0.37	0.309	0.933
55/60	0.41	0.313	0.867
56/60	0.35	0.316	0.867
57/60	0.355	0.309	0.867
58/60	0.376	0.293	0.933
59/60	0.352	0.284	0.933
60/60	0.338	0.279	0.933

Figura 5. Resultados del entrenamiento del modelo YOLOv5
(Fuente: Propia).




Figura 7. Pérdida del modelo YOLOv5 en 60 épocas
(Fuente: Propia).

3.5 Evaluación de resultados

La Figura 6 ilustra el comportamiento de la exactitud de clasificación del modelo YOLOv5 en 60 épocas de entrenamiento. Como se observa, el valor de exactitud aumenta conforme se incrementan las épocas, llegando a un valor máximo del 93% entre las épocas 45 y 60.




Figura 6. Exactitud de clasificación del modelo YOLOv5 en 60 épocas de entrenamiento (Fuente: Propia).

La Figura 7 muestra la pérdida durante el entrenamiento, la cual refleja la medida en que el modelo mejora en la predicción. En las primeras etapas, la pérdida se reduce rápidamente a medida que el modelo aprende los patrones básicos de las imágenes. Entre las épocas 10 y 40, la disminución es gradual y presenta algunas fluctuaciones, lo que indica que el modelo sigue aprendiendo, pero a un ritmo más lento. Finalmente, entre las épocas 40 y 60, los valores de pérdida se estabilizan, lo que demuestra que el modelo ha alcanzado un rendimiento constante.

La Figura 8 muestra la matriz de confusión obtenida después de evaluar el modelo YOLOv5 para la clasificación de hojas de aguacate en un dataset de prueba de 15 imágenes, distinguiendo entre hojas saludables y hojas afectadas con araña cristalina.

- **Verdaderos Positivos (TP):** El modelo identificó correctamente seis imágenes de hojas afectadas por la plaga araña cristalina.
- **Verdaderos Negativos (TN):** El modelo clasificó correctamente ocho imágenes de hojas saludables.
- **Falsos Positivos (FP):** No se registraron falsos positivos, lo que significa que el modelo no clasificó incorrectamente ninguna hoja saludable como afectada por la plaga.
- **Falsos Negativos (FN):** El modelo clasificó incorrectamente una hoja afectada por la plaga como saludable.




Figura 8. Matriz de confusión obtenida con el de prueba.

3.6 Desarrollo de la interfaz de usuario

Se desarrolló una interfaz gráfica que permite a los usuarios ingresar, visualizar y clasificar imágenes. La interfaz incluye una opción para buscar y seleccionar las imágenes almacenadas localmente.




Figura 9. Vista principal de la interfaz de usuario (Fuente: Propia).

Una vez cargadas en el sistema, el usuario podrá visualizar la galería y clasificar las imágenes ingresadas.




Figura 10. Vista de la galería de imágenes ingresadas para su clasificación (Fuente: Propia).




Figura 11. Vista de la galería de imágenes clasificadas (Fuente: Propia).

4. CONCLUSIONES

Este trabajo presenta la aplicación de redes neuronales para la detección de la plaga araña cristalina en cultivos de aguacate, demostrando que el modelo YOLOv5 es una herramienta eficaz para su identificación. La contribución principal de esta investigación es el desarrollo y entrenamiento del modelo YOLOv5, utilizando imágenes públicas, que alcanzó una exactitud del 93% tras 60 épocas de entrenamiento.

Los resultados obtenidos indican que la combinación de este modelo con una interfaz web intuitiva permitirán a los productores de aguacate visualizar, clasificar y manejar imágenes de manera eficiente directamente en el campo. Esta herramienta es clave para facilitar la adopción de tecnología por parte de usuarios que no están familiarizados con estos sistemas, lo que podría contribuir a una mejor gestión de plagas en los cultivos.

Los hallazgos muestran que los modelos de redes neuronales pueden ser efectivos en la detección de plagas, lo que abre nuevas posibilidades para mejorar la productividad en la agricultura. En trabajos futuros, se propone evaluar el rendimiento de la interfaz web utilizando imágenes obtenidas directamente de los campos de cultivo, así como mejorar la precisión del modelo al incorporar imágenes de las distintas etapas de evolución de la plaga bajo diversas condiciones ambientales.

5. REFERENCIAS

- [1] Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación. (2017). Planeación Agrícola Nacional 2017-2030. Accedido: 6 de octubre de 2023. [En línea]. Disponible en: <https://www.gob.mx/agricultura/documentos/planeacion-agricola-nacional-2017-2030?state=published>.
- [2] Servicio de Información Agroalimentaria y Pesquera. (2023). Producción Agrícola Nacional. Accedido: 4 de septiembre de 2023. [En línea]. Disponible en: <https://www.gob.mx/siap/acciones-y-programas/produccion-agricola-33119>.
- [3] Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. Accedido: 23 de septiembre de 2023. [En línea]. Disponible en: <https://arxiv.org/abs/1506.02640>.
- [4] K. Lagos, "Sistema de ayuda a la decisión basado en ontologías para el diagnóstico y prevención de las enfermedades en cultivos," Tesis doctoral, Escuela Internacional de Doctorado, Universidad de Murcia, España, 2020. <https://digitum.um.es/digitum/bitstream/10201/94672/1/TesisKattyLagosOrtiz.pdf>.
- [5] Y. Medina Carbó, C. M. Alonso Echevarría, y I. Reinoso Castillo, "Sistema inteligente para el diagnóstico de plagas y enfermedades en el cultivo del arroz," *Didáctica y Educación*, vol. 12, no. 4, pp. 141-155, 2021. <https://revistas.ult.edu.cu/index.php/didascalía/article/view/1210>.
- [6] R. Cueto Morelo, J. Atencio Flórez, y J. E. Gómez Gómez, "Sistema de identificación de enfermedades y plagas en el cultivo de sandía," *REVISTA COLOMBIANA DE TECNOLOGIAS DE AVANZADA*, vol. 2, no. 42, pp. 93-104, 2023. <https://doi.org/10.24054/rcta.v2i42.2674>.
- [7] M. C. Villasana-Montes, E. Hernández-Rojas, R. L. Palomino-Reséndiz, K. F. Maya-Gress, y S. I. Palomino-Reséndiz, "Diseño de sistema de monitoreo para detección temprana de enfermedades y plagas superficiales en plantas mediante visión artificial," *Pädi Boletín Científico De Ciencias Básicas E Ingenierías Del ICBI*, vol. 11, pp. 221-230, 2023. <https://doi.org/10.29057/icbi.v11iEspecial4.11369>.
- [8] A. Doshi, B. Patel, y K. Patel, "Sistema de monitoreo basado en IoT para la detección de plagas en cultivos de invernadero," *Revista Internacional de Innovación en Ciencias y Tecnologías de la Computación*, vol. 14, no. 6, pp. 298-305, 2022. <https://doi.org/10.1007/s13198-022-01561-w>.
- [9] M. Orozco-Ayala, J. L. Martínez-Sánchez, y L. J. Barrera-Rodríguez, "Redes neuronales profundas para la clasificación de enfermedades en cultivos de café utilizando imágenes de drones," *Revista Latinoamericana de Tecnología Agrícola*, vol. 23, no. 2, pp. 178-190, 2023. <https://doi.org/10.18385/rlta.2023.2.6>.
- [10] J. H. Camacho-Muñoz, R. Castillo-Paredes, y D. L. Hernández-Gómez, "Sistema basado en inteligencia artificial para la detección de enfermedades en hojas de tomate," *Revista Iberoamericana de Computación*, vol. 16, no. 3, pp. 341-356, 2022. <https://doi.org/10.5565/rev/ribc.158>.
- [11] L. Pérez-González, P. Sánchez-Peña, y C. Vargas-Arias, "Aplicación móvil para la detección automática de plagas en cultivos de maíz mediante procesamiento de imágenes," *Agronomía y Desarrollo Sostenible*, vol. 9, no. 4, pp. 265-280, 2023. <https://doi.org/10.2307/agrdev2023>.
- [12] J. H. Camacho-Muñoz, R. Castillo-Paredes, y D. L. Hernández-Gómez, "Sistema basado en inteligencia artificial para la detección de enfermedades en hojas de tomate," *Revista Iberoamericana de Computación*, vol. 16, no. 3, pp. 341-356, 2022. <https://doi.org/10.5565/rev/ribc.158>.
- [13] Roboflow. (s.f). Accedido: 18 de septiembre de 2023. [En línea]. Disponible en: <https://roboflow.com>.
- [14] Anaconda, Inc., (s.f). Accedido: 2 de octubre de 2023. [En línea]. Disponible en: <https://www.anaconda.com/products/distribution>.