

Whitefly Detection in Agriculture Using Artificial Intelligence: A Systematic Review

Núñez Moran, Fabian Alejandro¹; Pingo Lozada, José Felix²; Casaverde Pacherez, Luis Alberto³
^{1,2,3}Universidad Tecnológica del Perú, Perú, U22300503@utp.edu.pe, C28097@utp.edu.pe, lcasaverde@utp.edu.pe

Abstract– Agriculture is one of the most relevant economic activities globally, where pests such as the whitefly (*Bemisia tabaci*) generate significant crop losses. Traditional detection methods, in addition to being labor-intensive, present low effectiveness, which has driven the exploration of alternatives based on artificial intelligence (AI). The development of these technologies has enabled notable advancements in the early identification of *B. tabaci*, improving efficiency and reducing agricultural damage. However, their implementation faces operational challenges—such as foliage occlusion, lighting variability, and high equipment costs—as well as limitations in technical knowledge within the agricultural sector, particularly in Spanish-speaking regions. This systematic review (without meta-analysis) analyzes computer vision methods and drones for the detection and quantification of *B. tabaci* through a non-experimental descriptive design. Thirty-one open-access articles (2020–2025, in English, Spanish, or Chinese) were selected from five databases (EBSCOhost, Web of Science, ResearchGate, Scopus, INEI). These studies employed convolutional neural networks (CNNs), object detection models (Faster R-CNN, YOLOv4/v8), near-infrared spectroscopy (NIR), and hyperspectral imaging. The studies utilized CNNs, Faster R-CNN/YOLOv4/v8 detection models, NIR sensors, and various types of cameras, achieving >90% precision in the detection of adults, eggs, and pre-visual viral symptoms. The most effective techniques were CNNs (95.08%), YOLOv8 (87% on Raspberry Pi), and hyperspectral imaging (98%), consistently exceeding 85% precision. The optimal model selection depends on the type of analysis (leaf surface vs. internal symptoms), the pest's developmental stage, and crop characteristics, especially spectral variation. Hyperspectral systems excelled in early detection, while YOLO offered more accessible solutions for practical implementation.

Keywords– Whitefly, computer vision, early detection, CNN, IA.

Detección de la Mosca Blanca en la Agricultura Mediante Inteligencia Artificial: Una Revisión Sistemática

Nuñez Moran, Fabian Alejandro¹; Pingo Lozada, José Felix²; Casaverde Pacherez, Luis Alberto³
^{1,2,3}Universidad Tecnológica del Perú, Perú, U22300503@utp.edu.pe, C28097@utp.edu.pe, lcasaverde@utp.edu.pe

Resumen— La agricultura es una de las actividades económicas más relevantes a nivel global, donde plagas como la mosca blanca (*Bemisia tabaci*) generan pérdidas significativas en cultivos. Los métodos tradicionales de detección, además de ser laboriosos, presentan baja efectividad, lo que ha impulsado la exploración de alternativas basadas en inteligencia artificial (IA). El desarrollo de estas tecnologías ha permitido avances notables en la identificación temprana de *B. tabaci*, mejorando la eficiencia y reduciendo daños agrícolas. Sin embargo, su implementación enfrenta desafíos operativos —como oclusión por follaje, variabilidad lumínica, costos elevados de equipamiento— y limitaciones en el conocimiento técnico del sector agropecuario, particularmente en regiones hispanohablantes. Esta revisión sistemática (sin metaanálisis) analiza métodos de visión artificial y drones para la detección y cuantificación de *B. tabaci*, mediante un diseño descriptivo no experimental. Se seleccionaron 31 artículos de acceso abierto (2020–2025, en inglés, español o chino) de cinco bases de datos (EBSCOhost, Web of Science, ResearchGate, Scopus, INEI), que emplearon redes neuronales convolucionales (CNN), modelos de detección de objetos (Faster R-CNN, *YOLOv4/v8*), espectroscopía de infrarrojo cercano (NIR) e imágenes hiperespectrales. Los estudios emplearon redes neuronales convolucionales (CNN), modelos de detección Faster R-CNN/YOLOv4/v8, sensores NIR e diversos tipos de cámaras, logrando >90% de precisión en detección de adultos, huevos y síntomas virales pre-visuales. Las técnicas más efectivas fueron CNN (95.08%), YOLOv8 (87% en Raspberry Pi) e hiperespectrales (98%), superando consistentemente el 85% de precisión. La selección óptima del modelo a utilizar depende del tipo de análisis (superficie foliar vs síntomas internos), etapa de desarrollo de la plaga, y características del cultivo, especialmente variación espectral. Los sistemas hiperespectrales destacaron en detección temprana, mientras YOLO ofreció soluciones más accesibles para implementación práctica.

Palabras clave— Mosca blanca, visión artificial, detección temprana, CNN, IA.

I. INTRODUCCIÓN

La agricultura es una de las ocupaciones más antiguas que existen, presente en todo el mundo en diversas formas y orientada al cultivo de múltiples especies. Este sector representa el 4% del Producto Bruto Interno (PBI) mundial, lo que evidencia su importancia en la economía global [1].

En el Perú, el volumen de producción agrícola contribuyó al 6.46% del PBI nacional en el año 2024, con un crecimiento del 7.54% respecto al año 2023, reflejando la importancia del rubro en la economía de nuestro País [2].

No obstante, las plagas son un factor de crítico para el sector agrícola; estas generan pérdidas económicas cercanas al

40% [3]. La mosca blanca (*Bemisia tabaci*), una de las plagas más extendidas en regiones tropicales y subtropicales, afectando a más de 600 especies vegetales en todo el mundo. En los años, la mosca blanca ha causado pérdidas millonarias en cultivos en múltiples agroecosistemas a nivel mundial [4].

Independientemente al método de control utilizado, es fundamental llevar a cabo la intervención durante su fase ninfal, debido a que, en su etapa adulta, tienden a no permanecer en las hojas, lo que genera estimaciones imprecisas el grado de infestación [5].

Los métodos tradicionales de inspección visual presentan limitaciones por su subjetividad y baja precisión [6]. Dentro de los desafíos destacan el pequeño tamaño de las plagas (<3 mm), su baja reflectividad espectral y su ubicación en el reverso de las hojas. Las trampas pegajosas utilizadas carecen de precisión para discriminar entre especies de insectos, algunas de ellos beneficiosos y requieren intervención humana constante, lo que dificulta su escalabilidad en campos extensos [7]. La utilización de sensores resulta una alternativa costosa para su implementación en la producción en grandes extensiones. Por estas razones, el estudio de visión por computador para la detección de plagas agrícolas es vital [8].

La Inteligencia Artificial (IA) ha demostrado una notable capacidad para revolucionar el sector agrícola, a través de varias aplicaciones, incrementando significativamente la eficiencia y exactitud en la detección de plagas, favoreciendo prácticas agrícolas más sustentables [9]. La adopción de modelos avanzados de visión por computadora incluyendo You Only Look Once (YOLO), Vision Transformers (ViT), Convolutional Neural Networks (CNN) y Recurrent Neural Networks (RNN) junto con algoritmos clásicos como K-Nearest Neighbors (KNN), ha demostrado ser una alternativa efectiva para el monitoreo automático de plagas en la agricultura. Al procesar imágenes de alta resolución, estos enfoques pueden detectar estadios tempranos de infestación, en particular la fase ninfal de *Bemisia tabaci*, con gran precisión.

Sin embargo, pese al creciente volumen de estudios en IA aplicada a la sanidad vegetal [10], [11], aún no existe una revisión que organice de manera exhaustiva y crítica los avances centrados en la identificación temprana de la mosca blanca mediante técnicas de visión computacional. Esta Revisión Sistemática de Literatura (RSL) busca consolidar el conocimiento sobre la aplicación de IA para la detección de la mosca blanca en cultivos a través del análisis de imágenes. Los resultados proporcionarán una guía a investigadores,

agronomos y productores, identificando técnicas prometedoras, limitaciones y desafíos futuros.

II. METODOLOGÍA

A. Estrategia de búsqueda

La presente RSL tuvo como objetivo analizar la influencia de métodos de inteligencia artificial basados en imágenes en la detección de la plaga Mosca Blanca en distintos cultivos. Para ello, se realizó una búsqueda sistemática en bases de datos electrónicas, siguiendo criterios de inclusión y exclusión. La estrategia PICO fue aplicada para formular preguntas específicas y relevantes. Este enfoque metodológico resulta útil para orientar revisiones sistemáticas, ya que promueve claridad conceptual desde el planteamiento de las preguntas de investigación [17].

TABLA I
TABLA PICO

P Problema/ Población	I Intervención	C Comparación	O Resultados
Cultivos afectados por Bemisia tabaci.	Inteligencia artificial y drones	Métodos de detección	Mejorar la precisión y rapidez de la detección
PI: ¿Qué métodos de inteligencia artificial mediante análisis de imágenes existen para la detección temprana de la plaga mosca blanca (Bemisia tabaci) en cultivos?			
PII: ¿Qué tipos de cultivo son afectados por la mosca blanca?			
PI2: ¿De qué manera se utiliza la inteligencia artificial en la detección de la plaga mosca blanca?			
PI3: ¿Qué métodos de inteligencia artificial mediante análisis de imágenes se utilizan actualmente para la detección de la plaga mosca blanca?			
PI4: ¿Qué tipo de inteligencia artificial es la más eficiente para detectar a la plaga mosca blanca en etapas tempranas?			

B. Ecuación de búsqueda

Para llevar a cabo la búsqueda sistemática de literatura, se consultaron cinco bases de datos académicas: ResearchGate, Scopus, EBSCOhost, INEI y Research in Computing Science. Entre estas; ResearchGate desempeña un papel fundamental en la investigación científica debido a su extenso repositorio de publicaciones académicas y su capacidad para evaluar y filtrar estudios pertinentes. Su amplia cobertura multidisciplinaria y su constante actualización permiten a los investigadores acceder a los avances más recientes en sus campos de estudio. Como resultado de esta revisión, se identificaron múltiples estudios que aplican técnicas de visión por computadora para la detección de la mosca blanca en distintos tipos de plantas.

TABLA II
ECUACIÓN DE BÚSQUEDA

Componente PICO		Términos		Ecuación de búsqueda
P	Población / problema	Bemisia tabaci, Mosca Blanca	Bemisia tabaci, Whitefly, White fly	" Bemisia tabaci " OR Whitefly OR " White fly "
I	Intervención	Máquinas de vectores de soporte, K-vecinos más cercanos, Redes neuronales convolucionales, Solo miras una vez, Transformadores de visión, Redes neuronales recurrentes	SVM (Support Vector Machines), K-Nearest Neighbors (KNN), CNN (Convolutional Neural Networks), YOLO (You Only Look Once), Vision Transformers (ViT), Recurrent Neural Networks (RNN)	SVM OR "Support Vector Machines "OR "K-Nearest Neighbors "OR KNN OR "Convolutional Neural Networks "OR YOLO OR "You Only Look Once "OR "Vision Transformers "OR ViT OR "Recurrent Neural Networks "OR RNN
C	Comparación	Spectral, Hiperspectral, Thermal, Camera	Spectral, Hiperspectral, Thermal, Camera	Spectral OR Hiperspectral OR Thermal OR Camera
O	Resultados	Detección	Detection	Detection
Ecuación de búsqueda general: ("Bemisia tabaci "OR Whitefly OR " White fly ") AND (SVM OR "Support Vector Machines "OR "K-Nearest Neighbors "OR KNN OR CNN OR "Convolutional Neural Networks "OR YOLO OR "You Only Look Once "OR "Vision Transformers "OR ViT OR "Recurrent Neural Networks "OR RNN) AND (Spectral OR Hiperspectral OR Thermal OR Camera)				

C. Criterios (Inclusión y Exclusión)

Se definieron estándares de inclusión y exclusión para identificar investigaciones alineadas con los objetivos de nuestra revisión sistemática, manteniendo la correlación con las preguntas de investigación previamente formuladas; eliminando así, aquellas que no alcanzaron los estándares requeridos.

Este proceso se implementó mediante un protocolo sistemático de revisión documental, analizando siete bases de datos académicas especializadas (ResearchGate, Scopus, EBSCOhost, INEI y Research in Computing Science). La implementación de esta herramienta no solo aseguró la transparencia y trazabilidad en la selección, sino que también reforzó la fiabilidad e integridad de la investigación al vincular los criterios establecidos (detallados en las tablas III y IV) con un enfoque estructurado.

TABLA III
CRITERIOS DE INCLUSIÓN APLICADOS

C1	Estudios que apliquen métodos de Inteligencia Artificial para la detección de la mosca blanca en cultivos agrícolas.
C2	Estudios que empleen técnicas de procesamiento de datos visuales con el fin de detectar infestaciones de plagas.
C3	Estudios publicados entre los años 2020-2025
C4	Estudios indexados y de acceso abierto.
C5	Estudios disponibles en idiomas inglés, español y chino.
C6	Se incluyó un artículo del 2001 y uno del 2018 como casos excepcionales por su relevancia.

TABLA IV
CRITERIOS DE EXCLUSIÓN APLICADOS

C1	Estudios que no consideren la Inteligencia Artificial en cultivos agrícolas.
C2	Estudios basados en métodos tradicionales, manuales, químicos o biológicos.
C3	Estudios publicados fuera de los periodos establecidos (2020-2025)
C4	Estudios duplicados y de acceso restringido.
C5	Estudios en idiomas que no correspondan al inglés, español y chino.

D. Proceso de selección de estudios

Con el fin de desarrollar la revisión sistemática, se adoptaron elementos de metodología PRISMA, iniciando con la definición de parámetros de selección, fuentes de consulta y estrategias de filtrado. La búsqueda inicial arrojó 291 registros (206 de ResearchGate, 54 de Scopus, 18 de EBSCOhost, 12 de Research in Computing Science y 1 de INEI), de los cuales se eliminaron 72 duplicados. Finalmente, se seleccionaron 31 artículos para el análisis, consolidando un proceso riguroso que incluyó múltiples etapas de depuración, tal como se ilustra en el diagrama PRISMA adjunto, (Fig. 1).




Fig. 1 Diagrama Prisma.

III. RESULTADOS

La presente investigación abordó el análisis de la información desde dos perspectivas complementarias: una de carácter bibliométrico y otra centrada en el contenido. La primera permitió trazar un panorama general del desarrollo científico relacionado con la detección temprana de la mosca blanda mediante el uso de inteligencia artificial, identificando tendencias, autores y fuentes más relevantes.

En paralelo, el enfoque de contenido permitió un análisis más profundo de los aspectos técnicos, metodológicos y prácticos presentes en los estudios analizados.

A. Resultados del análisis bibliométrico

Como punto de partida del estudio, se llevó a cabo una evaluación bibliométrica de los trabajos seleccionados en la revisión sistemática como podemos observar en la tabla V.

TABLA V
ARTÍCULOS INCORPORADOS EN LA REVISIÓN SISTEMÁTICA
SOBRE LA DETECCIÓN TEMPRANA DE LA PLAGA MOSCA BLANCA

Autor(s)	Título del artículo	Año
M. R. Al Mamun [1]	"The Importance of Agriculture in Present World"	2020
INEI [2]	Informe Técnico Producción Nacional	2025
S. Gautam [3]	The Role of Agriculture in Nepal's Economic Development: Challenges, Opportunities, and Pathways for Modernization	2024
M. R. V. Oliveira, T. J. Henneberry, and P. Anderson [4]	History, current status, and collaborative research projects for Bemisia tabaci	2001
D. K. Jacobo-Rubio and M. G. Medina-Meléndrez [5]	"Sistema inteligente para la detección de ninfas de mosca blanca presentes en hojas de plantas"	2023
Y. Sun, X. Liu, M. yuan, L. Ren, J. Wang, and Z. Chen [6]	"Automatic in-trap pest detection using deep learning for pheromone-based Dendroctonus valens monitoring"	2018
N. Nguyen [7]	"Avances en la Detección de la Mosca Blanca mediante la Aplicación de Técnicas de Inteligencia Artificial: Un Comprensivo Estado del Arte"	2024
N. Wang, S. Fu, Q. Rao, G. Zhang, and M. Ding [8]	"Insect-YOLO: A new method of crop insect detection"	2025
Gastesi et al, [9]	"Aplicaciones de la inteligencia artificial en la agricultura: Una revisión"	2024
Y. Bai et al, [10]	"A Lightweight Pest Detection Model for Drones Based on Transformer and Super-Resolution Sampling Techniques"	2023
W. Li, X. Han, Z. Lin, and A.-U. Rahman, [11]	"Enhanced pest and disease detection in agriculture using Deep Learning-Enabled drones"	2024
J. Agrawal and M. Y. Arafat, [12]	"Transformando la agricultura: Una revisión de las tecnologías de vehículos aéreos no tripulados (UAV) impulsadas por IA en la agricultura de precisión"	2024
S. Chinnasamy and R. Baskar, [13]	"Investigations on the identification of pests in horticultural crops under greenhouse conditions"	2024
S. Wang, D. Chen, J. Xiang, and C. Zhang, [14]	"A Deep-Learning-Based Detection Method for Small Target Tomato Pests in Insect Traps"	2024
Z. Feng et al. [15]	"Enhancing cotton whitefly (Bemisia tabaci) detection and counting with a cost-effective deep learning approach on the Raspberry Pi"	2024
C. Lytridis and T. Pachidis, [16]	"Recent advances in agricultural robots for automated weeding"	2024
K. Kolaski, I.R Logan y JPA Ioannidis [17]	"Guidance to best tools and practices for systematic reviews",	2023

T. Tsouros, A. Bibi, and P. Sarigiannidis, [18]	"Applications and recent advances in artificial intelligence for soil data analysis"	2024
M. Alsharif, K. N. Salama, and A. Farouk [19]	"Integrating artificial intelligence into an automated irrigation system"	2025
F. A. Alzubi, M. A. Khamis, and H. M. Almalki, [20]	"Incorporating artificial intelligence technology in smart greenhouses"	2023
S.-C. Liu, Q.-Y. Jian, H.-Y. Wen, and C.-H. Chung [21]	"Un modelo de predicción del tiempo de cosecha para una mejor sostenibilidad, integrando la selección de características y métodos de inteligencia artificial"	2022
A. Suthakaran and S. Premaratne [22]	"Detection of the affected area and classification of pests using convolutional neural networks from the leaf images"	2020
H. Kukadiya and D. Meva [23]	"Automatic cotton leaf disease classification and detection by convolutional neural network"	2022
A. Fuentes, S. Yoon, and D. S. Park [24]	"Deep Learning-Based Techniques for Plant Diseases Recognition in Real-Field Scenarios"	2020
C. U. Parab et al, [25]	"Comparison of Single-Shot and Two-Shot Deep Neural Network Models for Whitefly Detection in IoT Web Application"	2022
Y. Peng et al, [26]	"Early detection of plant virus infection using multispectral imaging and spatial-spectral machine learning"	2022
M. Krüger et al, [27]	"Hyperspectral imaging for pest symptom detection in bell pepper"	2024
J. P. Molin, H. C. Bazame, L. Maldaner [28]	"Precision agriculture and the digital contributions for site-specific management of the fields"	2020
N. MacLeod, R. J. Canty, and A. Polaszek [29]	"Morphology-Based Identification of Bemisia tabaci Cryptic Species Puparia via Embedded Group-Contrast Convolution Neural Network Analysis"	2022
X. Wu et al, [30]	"Image segmentation for pest detection of crop leaves by improvement of regional convolutional neural network"	2024
M. G. Devi et al., [31]	"Eggsplore: a rapid plant-insect resistance determination tool using an automated whitefly egg quantification algorithm"	2023

Cantidad de artículos publicados por año (2020-2025)


Año	Cantidad de artículos
2001	1
2018	1
2020	4
2022	5
2023	5
2024	12
2025	3

Por otro lado, al analizar el conjunto de estudios seleccionados, se observó que 28 de los artículos fueron redactados en idioma inglés, mientras que sólo tres fueron redactados en español.

En cambio, las palabras con menor frecuencia que aparecieron una sola vez fueron los términos como “ovary”, y “quantification”.



RESEARCHGATE resultó ser la fuente más consultada durante la búsqueda de artículos, con un total de 21 estudios recopilados. En contraste, EBSCOhost, RCS e INEI fueron las menos utilizadas, como se muestra a continuación.



Según la tipología de los estudios analizados, el 74% de las publicaciones incluidas en la revisión sistemática corresponden a investigaciones experimentales, mientras que el 26% se clasifican como estudios descriptivos, como se muestra a continuación.



A continuación, podemos resaltar como la fuente con mayor número de publicaciones a China, con un total de nueve estudios que abordan la temática en cuestión. Le sigue India, con cinco investigaciones que reflejan un creciente interés regional.

24th LACCEI International Multi-Conference for Engineering, Education, and Technology: “*Engineering without Borders: Artificial Intelligence, Knowledge, Innovation, and Alliances for a Future from the Americas*”. Hybrid Event, Santiago-Chile, July 15 - 17, 2026



Fig. 6 Distribución geográfica de los artículos incluidos en la revisión sistemática.

B. Resultados por contenido

Esta sección sintetiza los hallazgos clave de la RSL sobre los métodos de IA para la detección de la mosca blanca, destacando los aspectos más relevantes para facilitar su comprensión.

C. ¿Qué tipos de cultivos son afectados por la mosca blanca?

La mosca blanca afecta una amplia variedad de grupos de cultivos debido a su naturaleza polífaga y su capacidad para adaptarse a nuevas plantas hospedadoras y regiones geográficas. Dentro de los grupos afectados tenemos a las hortalizas, donde destacan el tomate, pimiento, berenjena, calabaza, melón, sandía, lechuga, okra y repollo; cultivos de campo como algodón, frijol, soja, tabaco y sésamo; cultivos tropicales y subtropicales como la yuca, (mandioca), camote (batata) y papaya; cultivos ornamentales como la flor de pascua y las plantas de invernadero; y cultivos industriales como el algodón, café y cítricos en general [12].

Los estudios revisados mencionan especies hortícolas como el tomate, chile y pepino [13] [14]. Asimismo, cultivos de algodón [15].

En entornos controlados, como los invernaderos, se reportan infestaciones recurrentes, especialmente en cultivos como pimiento, las cuales presentan humedad y temperatura constantes que benefician su ciclo reproductivo [13].

Estos cultivos comparten características agronómicas como alta densidad foliar y condiciones de humedad elevadas, las cuales favorecen el desarrollo y la reproducción de la plaga [15].




Fig. 7 Cultivos afectados por la mosca blanca.

D. ¿Qué métodos de inteligencia artificial se utilizan en la agricultura?

La inteligencia artificial está transformando el sector agrícola mejorando significativamente su eficiencia, productividad y sostenibilidad. Su aplicación resulta especialmente útil, ya que muchas de las tareas en este sector son repetitivas y tienden a la automatización.

Uno de los principales campos de aplicación es la agricultura de precisión, donde se integran vehículos aéreos no tripulados (UAV), sensores espectrales, hiperspectrales y térmicos, junto con algoritmos basados en IA para el monitoreo de cultivos, riego inteligente y, en algunos casos, la recomendación automatizada de prácticas agronómicas [16]. Asimismo, la detección de plagas mediante IA se ha convertido en una herramienta clave. Diversos sistemas utilizan cámaras multispectrales o RGB y algoritmos de reconocimiento de patrones visuales para identificar síntomas asociados a enfermedades y plagas en tiempo real [14].

Por otro lado, los modelos de predicción de rendimiento agrícola basados en IA emplean Big Data y redes neuronales convolucionales (CNN) para analizar información proveniente de sensores o imágenes satelitales. Estos modelos permiten estimar el rendimiento esperado de los cultivos, así como optimizar los tiempos de siembra y cosecha [21].

En el ámbito de la robótica agrícola, se ha avanzado en el desarrollo de robots autónomos capaces de realizar tareas como la siembra, el deshierbe, la cosecha y la aplicación de pesticidas. Estos robots integran sensores de posicionamiento en tiempo real, cámaras para navegación, software de aprendizaje profundo y mecanismos especializados para la eliminación de malezas. Se ha demostrado que presentan una alta tasa de efectividad en el control de malas hierbas y un bajo impacto sobre los cultivos [18].

En cuanto al control de suelos y agua, gracias a la IA, se pueden gestionar volúmenes extensos de datos y procesarlos al momento de su captura mediante sensores, tecnologías de teledetección y análisis de big data. Las variables medidas incluyen humedad, temperatura, pH y contenido de nutrientes

del suelo. Estos datos permiten desarrollar modelos predictivos con algoritmos de aprendizaje automático y profundo, generando recomendaciones personalizadas para la fertilización, el riego y el control fitosanitario [19]. A partir de estos datos, los sistemas pueden enviar instrucciones automáticas a los mecanismos de riego, ajustando los tiempos y volúmenes según las necesidades específicas del cultivo [20].

Finalmente, la implementación de IA en sistemas agrícolas controlados, como los invernaderos inteligentes, ha permitido integrar tecnologías de la información y comunicación (TIC) e Internet de las Cosas (IoT). Sensores digitales recopilan datos ambientales —como luz, temperatura, humedad y niveles de nutrición— que son enviados a servidores en la nube, donde se procesan mediante algoritmos para optimizar las condiciones de cultivo. Esta integración mejora notablemente la eficiencia operativa, aunque conlleva altos costos asociados a la tecnología empleada y a la relación entre la inversión y el área cultivada [21].

TABLA VI.
TÉCNICAS DE IA APLICADAS A LA AGRICULTURA

Aplicación	Técnica de IA	Referencias
Agricultura de precisión	Aprendizaje automático, visión computacional	[25]
Detección de plagas	Reconocimiento de patrones visuales (CNN, YOLO, R-CNN)	[13], [14], [22]
Predicción de cosecha	Redes neuronales convolucionales (CNN), Big Data	[21]
Robótica agrícola	Aprendizaje profundo en robots para deshierbe	[18]
Gestión de suelos y agua	Aprendizaje automático y profundo	[19]
Automatización del riego	Modelos predictivos con IA	[20]
Invernaderos inteligentes	IA integrada con sensores IoT	[21]

E. ¿Qué métodos de inteligencia artificial se utilizan en la detección de la plaga mosca blanca?

Dentro de los métodos de IA se destacan principalmente las técnicas de análisis de imágenes. Uno de los enfoques más representativos es el uso de algoritmos de aprendizaje profundo, en particular, redes neuronales convolucionales (CNN), que han demostrado alta precisión en el reconocimiento de patrones visuales complejos presentes en hojas infestadas [12], [13], [22], [23], [24]. Se destacan modelos de detección de objetos como YOLOv4, YOLOv8 y Faster R-CNN, los cuales permiten identificar de forma automática y en tiempo real a los adultos y ninfas de la mosca blanca en imágenes Red – Green – Blue (RGB) [14], [15], [25]. Estos métodos son aplicables tanto en ambientes naturales como en condiciones controladas como

invernaderos, y han sido probados en plataformas ligeras y económicas como Raspberry Pi para facilitar su implementación en campo [15].

Otros estudios se han centrado en el uso imágenes multispectrales e hiperespectrales, procesadas mediante modelos espaciales-espectrales basados en aprendizaje profundo, para detectar la plaga de forma indirecta a través de síntomas virales en las plantas [26], [27], [28]. Esto es particularmente útil en etapas tempranas de infestación, donde los signos visibles aún no son evidentes.

Además, se han desarrollado clasificadores morfológicos basados en CNN para la identificación de especies crípticas de *B. tabaci*, entrenados con imágenes de puparios de alta resolución, lo cual es útil para estudios taxonómicos y vigilancia entomológica [29]. Para mejorar la segmentación de áreas afectadas, se han implementado técnicas de segmentación semántica, como redes R-CNN jerárquicas, que permiten aislar con precisión las zonas foliares infestadas, incrementando así la exactitud en la clasificación [30].

Por último, se han desarrollado sistemas especializados como Eggsplorer, un modelo que cuantifica y clasifica huevos de mosca blanca con alta precisión, automatizando esta laboriosa tarea [31].




Fig. 8 Métodos de IA aplicados a la detección de la Bemisia Tabaci.

F. ¿Qué tan eficiente son estos tipos de inteligencia artificial en la detección de la plaga mosca blanca en etapas tempranas?

Según el análisis de los estudios científicos incluidos, los sistemas de visión artificial aplicados a la detección de *Bemisia tabaci* han demostrado una alta precisión en etapas tempranas de infestación. Entre los modelos evaluados, Faster R-CNN alcanzó una exactitud del 95.08 % en promedio para la detección de adultos en trampas adhesivas, superando significativamente a YOLOv4, que obtuvo solo un 71.77 % en condiciones similares [25]. Asimismo, la implementación de YOLOv8 mejorado con el módulo Swin-Transformer en una plataforma de bajo costo (Raspberry Pi), logra una precisión del 87 % en entornos de baja capacidad computacional [15].

En cuanto a etapas no adultas del insecto, una red neuronal convolucional embebida fue capaz de identificar

especies crípticas de *B. tabaci* a partir del análisis de púpas, con una exactitud del 100% [29]. Otro desarrollo notable es el sistema Eggsplorer, orientado al conteo y clasificación automática de huevos mediante visión por computadora, el cual alcanzó una precisión del 94 %, siendo especialmente eficaz en fases iniciales de infestación [31].

Por otro lado, modelos de aprendizaje profundo aplicados sobre imágenes hiperespectrales, combinando información espacial y espectral, han demostrado ser capaces de detectar infecciones virales transmitidas por *B. tabaci* con una exactitud de hasta el 98 %, incluso antes de que aparezcan síntomas visuales evidentes en la planta [26].

En el caso de aplicaciones con cámaras RGB convencionales tenemos precisiones superiores al 90 % en la detección de adultos de *B. tabaci* en trampas adhesivas [14]. Sin embargo, se han identificado limitaciones en el reconocimiento de huevos y ninfas debido a condiciones de iluminación desfavorables, bajo contraste de fondo y oclusión por el follaje [21], [22]. Esto se debe a que las cámaras RGB capturan únicamente tres bandas del espectro visible, lo que restringe su sensibilidad ante signos fisiológicos tempranos, en contraste con los sistemas multispectrales que ofrecen mayor capacidad de discriminación espectral [26], [27].

A pesar de estas restricciones, los modelos de visión artificial evaluados han alcanzado precisiones promedio entre el 89 % y el 96 % en entornos controlados, superando ampliamente a los métodos tradicionales de monitoreo visual, los cuales presentan sesgos humanos y baja eficacia en fases tempranas [25], [29], [31]. No obstante, se reconoce que factores como la oclusión de insectos por hojas, la variabilidad lumínica del ambiente, el movimiento del follaje y la resolución de los sensores aún representan desafíos para la implementación robusta en condiciones de campo.




Fig. 9 Precisión promedio de cada método de Inteligencia Artificial aplicado.

Cabe destacar que, independientemente al modelo de procesamiento utilizado; existen factores como la densidad foliar, la cantidad de hojas por nudo, el tamaño de la planta, el ángulo de la toma de las imágenes y el tipo de cámara utilizada, que influyen directamente en la precisión alcanzada.

Por lo tanto, los datos de esta tabla deben interpretarse como una unificación de resultados obtenidos bajo diversos tipos de cultivo y métodos en la adquisición de las imágenes.

IV. DISCUSIÓN

Al reflexionar sobre los hallazgos obtenidos en esta revisión, resulta evidente como la inteligencia artificial (IA) ha comenzado a transformar profundamente las plagas agrícolas. A diferencia de los métodos tradicionales que empleaban métodos manuales o visuales, los cuales suelen presentar sesgos humanos y baja eficacia en fases iniciales de infestación [22], los sistemas automatizados basados en CNN embebidas lograron identificar especies crípticas de *Behemisia tabaci* con una precisión del 100 % mediante el análisis de púpas, la cual es la última etapa inmadura antes de que la mosca se convierta en adulta [29]. Esta capacidad representa un avance significativo en la vigilancia entomológica, especialmente en escenarios donde la detección temprana es clave para evitar daños económicos en cultivos vulnerables como tomate, algodón o pimientos [13], [14], [15].

En aplicaciones recientes, los estudios evidencian mejoras en el desempeño de los modelos de detección basados en inteligencia artificial. Mientras que investigaciones anteriores reportaban una mayor precisión en arquitecturas de dos etapas como Faster R-CNN, con valores superiores al 95%, en comparación con modelos de una etapa como YOLOv4, que alcanzaban aproximadamente un 72% [25], investigaciones más recientes han demostrado mejoras significativas en estos últimos. La incorporación de mecanismos de detección en arquitecturas de una etapa, como Insect-YOLO [3] y YOLOv8-Swin [15], ha permitido alcanzar precisiones superiores al 90% en la detección de *B. tabaci* en hojas, un entorno con mayor complejidad visual que las trampas adhesivas. Estos resultados evidencian la importancia de emplear modelos de aprendizaje profundo optimizados para la detección de objetos pequeños.

Además, los estudios revisados evidencian un esfuerzo importante por desarrollar y adaptar tecnologías que sean más accesibles y asequibles para pequeños y medianos productores agrícolas, quienes muchas veces no cuentan con grandes presupuestos ni infraestructura tecnológica avanzada. En este contexto, ejemplo destacado es Eggsplorer, una herramienta basada en Deep Learning, diseñada específicamente para el conteo automático de huevos de mosca blanca, una tarea que, de forma manual, es lenta y propensa a errores. Este sistema logró una precisión del 94 % ($R^2=99$) [31], lo que resulta crucial para cuantificar la plaga en sus primeras fases reproductivas y, así, intervenir de forma temprana y localizada, reduciendo pérdidas económicas y la necesidad de aplicar tratamientos químicos indiscriminados.

De forma complementaria, se observa una tendencia a optimizar el uso de hardware de bajo costo, como las placas Raspberry Pi, que funcionan como microcomputadoras portátiles y económicas. Al combinar estas plataformas con modelos de inteligencia artificial mejorados, como YOLOv8

potenciado con Swin Transformer, se alcanzaron precisiones de hasta 87 % incluso en entornos con baja capacidad de procesamiento [15]. Esta combinación es especialmente relevante para zonas rurales o regiones agrícolas con recursos limitados, ya que permite implementar sistemas de monitoreo automatizado sin necesidad de adquirir equipos costosos o infraestructura sofisticada.

De manera similar, aunque con un enfoque metodológico distinto, los modelos de aprendizaje espacial-espectral aplicados a imágenes hiperespectrales han demostrado una 10 capacidad superior para el diagnóstico pre-sintomático de infecciones virales asociadas a la plaga, incluso antes de la manifestación de síntomas visibles, alcanzando niveles de exactitud superiores al 98 % en la identificación temprana de estrés biótico [26]. Estos resultados contrastan con las limitaciones observadas en sistemas basados en imágenes RGB, los cuales presentan dificultades bajo condiciones de iluminación variable, oclusión por el follaje y bajo contraste [21], [22]. No obstante, pese a sus ventajas diagnósticas, la adopción de sensores hiperespectrales continúa restringida por su elevado costo y la necesidad de plataformas de adquisición robustas, en comparación con las cámaras RGB comúnmente empleadas en modelos basados en YOLO.

Sin embargo, esta revisión también identificó ciertas limitaciones. La mayoría de los artículos analizados fueron publicados en idioma inglés, y no se hallaron estudios significativos en español, lo que podría limitar el acceso de investigadores de habla hispana al conocimiento actual [29]. Por otro lado, aunque las técnicas estudiadas han mostrado buenos resultados en condiciones controladas (como invernaderos), su rendimiento aún varía en ambientes abiertos debido a factores ambientales no controlables como la luz, el viento y el movimiento natural de las hojas [21], [22].

Finalmente, si bien existe una tendencia creciente hacia la implementación de IA en el monitoreo fitosanitario, todavía se requiere avanzar en la estandarización de datasets, interoperabilidad entre sensores y algoritmos, y validación de estas tecnologías en escenarios de producción reales. Es evidente que los avances logrados hasta ahora constituyen una base sólida para el desarrollo de sistemas agrícolas más eficientes, sustentables e inclusivos.

V. CONCLUSIÓN

El estudio analizó los métodos de visión artificial aplicados a la detección y cuantificación temprana de la plaga *Bemisia tabaci*. Se determinó que los modelos de redes neuronales convolucionales (CNN), los algoritmos de detección como Faster R-CNN y YOLOv8, así como el uso de sensores hiperespectrales y del infrarrojo cercano (NIR), demostraron eficiencias superiores al 85 % en la identificación de huevos, adultos y síntomas virales asociados. De todos ellos, se destaca la aplicación de imágenes hiperespectrales en combinación con algoritmos de aprendizaje profundo, que alcanzaron precisiones superiores al 98 % en la detección precoz de infecciones virales en hojas de cultivos, mientras

que el uso de cámaras RGB tradicionales con YOLOv4 o v8 logró resultados cercanos al 90 %, dependiendo del entorno de prueba.

El método hiperespectral ofrece mayores precisiones independientemente del estado fisiológico de la planta, permitiendo detectar signos invisibles al ojo humano. Sin embargo, su aplicación es más costosa y requiere condiciones controladas para su funcionamiento óptimo. Por otro lado, las técnicas basadas en imágenes RGB, aunque menos precisas, resultan más accesibles y viables para implementaciones rurales de bajo costo, especialmente al integrarse con UAV y microcontroladores como Raspberry Pi. Los métodos de visión artificial han demostrado ser eficaces para captar tanto características internas (infecciones, estrés vegetal) como externas (presencia física de plaga) de las hojas infestadas, permitiendo un monitoreo automatizado, continuo y no invasivo.

Por lo tanto, se debe tener en cuenta que la aplicación de estos métodos está limitada principalmente por las condiciones ambientales (iluminación, viento, oclusión de hojas) y por la disponibilidad de equipos en zonas agrícolas con bajos recursos tecnológicos. Para futuras investigaciones, sería útil profundizar en la creación de sistemas que fusionen la inteligencia artificial con tecnologías de imagen avanzada. Estos sistemas no solo facilitarían la identificación de la mosca blanca (*B. tabaci*), sino que también tendrían la capacidad de prever con mayor precisión cómo impactará en el rendimiento de los cultivos. Este método facilitaría a los agricultores la toma de decisiones más fundamentadas para salvaguardar sus cosechas y reducir las pérdidas financieras.

Además, resulta crucial evaluar estas tecnologías en situaciones reales, particularmente en zonas con recursos escasos, donde su aplicación podría generar un enorme cambio. Una alternativa alentadora sería emplear drones dotados de sensores accesibles, como cámaras térmicas o multispectrales, que proporcionan información exacta sin necesidad de inversiones considerables. Esta solución podría simplificar el seguimiento de plagas para los agricultores de escasos recursos, manteniendo simultáneamente la eficiencia en la administración fitosanitaria y fomentando una agricultura más sustentable.

REFERENCIAS

- [1] M. R. Al Mamun, "The Importance of Agriculture in Present World," ResearchGate, Aug. 2020. DOI:10.13140/RG.2.2.14008.78080
- [2] INEI, "Informe Técnico Producción Nacional," Gob.Pe, 2024. Accessed: Apr. 14, 2025. [Online]. Available: https://www.inei.gob.pe/media/MenuRecursivo/boletines/informe-tecnico_produccion_nacional.pdf
- [3] S. Gautam, The Role of Agriculture in Nepal's Economic Development: Challenges, Opportunities, and Pathways for Modernization, ResearchGate, 2024. Doi: DOI: 10.1016/j.heliyon. 2025.e41860
- [4] M. R. V. Oliveira, T. J. Henneberry, and P. Anderson, "History, current status, and collaborative research projects for *Bemisia tabaci*," Crop Protection (Guildford, Surrey), vol. 20, no. 9, pp. 709–723, 2001, doi: 10.1016/s0261-2194(01)00108-9.
- [5] D. K. Jacobo-Rubio and M. G. Medina-Meléndrez, "Sistema inteligente para la detección de ninfas de mosca blanca presentes en hojas de

- plantas,” *Research on Computing Science*, vol. 152, pp. 187–200, 2023, doi: 10.13053/rcs-152-13.
- [6] Y. Sun, X. Liu, M. yuan, L. Ren, J. Wang, and Z. Chen, “Automatic in-trap pest detection using deep learning for pheromone-based *Dendroctonus valens* monitoring,” *Biosystems Engineering*, vol. 176, pp. 140–150, 2018, doi: 10.1016/j.biosystemseng.2018.10.012.
- [7] N. Nguyen, “Avances en la Detección de la Mosca Blanca mediante la Aplicación de Técnicas de Inteligencia Artificial: Un Comprensivo Estado del Arte,” *Revista Científica Multidisciplinaria*, vol. 8, no. 2, 2024. Doi: 10.37811/cl_rcm.v8i2.10750
- [8] N. Wang, S. Fu, Q. Rao, G. Zhang, and M. Ding, “Insect-YOLO: A new method of crop insect detection,” *Computers and Electronics in Agriculture*, vol. 232, no. 110085, p. 110085, 2025, doi: 10.1016/j.compag.2025.110085.
- [9] Gastesi et al., “Aplicaciones de la inteligencia artificial en la agricultura: Una revisión,” *Tecnología en Marcha*, vol. 37, no. 1, p. 10, 2024, doi: 10.18845/tm.v37i1.6777.
- [10] Y. Bai et al., “A lightweight pest detection model for drones based on transformer and Super-Resolution sampling techniques,” *Agriculture*, vol. 13, no. 9, p. 1812, Sep. 2023, doi: 10.3390/agriculture13091812.
- [11] W. Li, X. Han, Z. Lin, and A.-U. Rahman, “Enhanced pest and disease detection in agriculture using Deep Learning-Enabled drones,” *Acadlore Transactions on AI and Machine Learning*, vol. 3, no. 1, pp. 1–10, Jan. 2024, doi: 10.56578/ataim1030101.
- [12] J. Agrawal and M. Y. Arafat, “Transformando la agricultura: Una revisión de las tecnologías de vehículos aéreos no tripulados (UAV) impulsadas por IA en la agricultura de precisión,” *Drone*, vol. 8, no. 11, p. 664, 2024. [Online]. Available: <https://doi.org/10.3390/drones8110664>
- [13] S. Chinnasamy and R. Baskar, “Investigations on the identification of pests in horticultural crops under greenhouse conditions,” 2024.
- [14] S. Wang, D. Chen, J. Xiang, and C. Zhang, “A Deep-Learning-Based Detection Method for Small Target Tomato Pests in Insect Traps,” 2024.
- [15] Z. Feng et al., “Enhancing cotton whitefly (*Bemisia tabaci*) detection and counting with a cost-effective deep learning approach on the Raspberry Pi,” 2024.
- [16] C. Lytridis and T. Pachidis, “Recent advances in agricultural robots for automated weeding,” *AgriEngineering*, vol. 6, no. 3, pp. 3279–3296, Sep. 2024. doi: 10.3390/agriengineering6030187.
- [17] K. Kolaski, I.R Logan y JPA Ioannidis, “Guidance to best tools and practices for systematic reviews”, *Systematic Reviews*, vol. 12, n.º 1, junio de 2023, doi: 10.1186/s13643-023-02255-9.
- [18] T. Tsouros, A. Bibi, and P. Sarigiannidis, “Applications and recent advances in artificial intelligence for soil data analysis,” *Agricultural Reviews*, vol. 4, no. 4, pp. 668–678, 2024. doi: 10.50908/arr.4.4.668.
- [19] M. Alsharif, K. N. Salama, and A. Farouk, “Integrating artificial intelligence into an automated irrigation system,” *Sensors*, vol. 25, no. 4, p. 1199, Feb. 2025. doi: 10.3390/s25041199.
- [20] F. A. Alzubi, M. A. Khamis, and H. M. Almalki, “Incorporating artificial intelligence technology in smart greenhouses,” *Applied Sciences*, vol. 13, no. 1, p. 14, Jan. 2023. doi: 10.3390/app13010014.
- [21] S.-C. Liu, Q.-Y. Jian, H.-Y. Wen, and C.-H. Chung, “Un modelo de predicción del tiempo de cosecha para una mejor sostenibilidad, integrando la selección de características y métodos de inteligencia artificial,” *Sustainability*, vol. 14, no. 21, p. 14101, Oct. 2022. doi: 10.3390/su142114101.
- [22] A. Suthakaran and S. Premaratne, “Detection of the affected area and classification of pests using convolutional neural networks from the leaf images,” 2020.
- [23] H. Kukadiya and D. Meva, “Automatic cotton leaf disease classification and detection by convolutional neural network,” 2022.
- [24] A. Fuentes, S. Yoon, and D. S. Park, “Deep Learning-Based Techniques for Plant Diseases Recognition in Real-Field Scenarios,” 2020.
- [25] C. U. Parab et al., “Comparison of Single-Shot and Two-Shot Deep Neural Network Models for Whitefly Detection in IoT Web Application,” 2022.
- [26] Y. Peng et al., “Early detection of plant virus infection using multispectral imaging and spatial-spectral machine learning,” 2022.
- [27] M. Krüger et al., “Hyperspectral imaging for pest symptom detection in bell pepper,” 2024.
- [28] J. P. Molin, H. C. Bazame, L. Maldaner, L. de P. Corredo, M. Martello, and T. F. Canata, “Precision agriculture and the digital
- [29] N. MacLeod, R. J. Canty, and A. Polaszek, “Morphology-Based Identification of *Bemisia tabaci* Cryptic Species Puparia via Embedded Group-Contrast Convolution Neural Network Analysis,” 2022.
- [30] X. Wu et al., “Image segmentation for pest detection of crop leaves by improvement of regional convolutional neural network,” 2024.
- [31] M. G. Devi et al., “Eggexplorer: a rapid plant-insect resistance determination tool using an automated whitefly egg quantification algorithm,” 2023.