



Visión artificial para la detección de plagas en cultivos de tomate: revisión sistemática de la literatura

Computer vision for pest detection in tomato crops: a systematic literature review

Jesús Alberto Alarcón Luna

Tecnológico Nacional de México/Instituto Tecnológico Superior de Xalapa, Veracruz, México
257O01126@xalapa.tecnm.mx
ORCID: 0009-0001-5208-765X

María Salomé Alejandre Apolinar ✉

Tecnológico Nacional de México/Instituto Tecnológico Superior de Xalapa, Veracruz, México
salome.aa@xalapa.tecnm.mx
ORCID: 0009-0008-0232-8217

Hugo Amores Pérez

Tecnológico Nacional de México/Instituto Tecnológico Superior de Xalapa, Veracruz, México
hugo.ap@xalapa.tecnm.mx
ORCID: 0009-0009-0260-4872

Jacel Adame García

Tecnológico Nacional de México/Instituto Tecnológico de Úrsulo Galván, Veracruz, México
jacel.ag@ugalvan.tecnm.mx
ORCID: 0000-0002-1982-1314

María Angélica Cerdán

Tecnológico Nacional de México/Instituto Tecnológico Superior de Xalapa, Veracruz, México
angelica.cerdan@itsx.edu.mx
ORCID: 0000-0002-4250-8385

<https://doi.org/10.36825/RITI.14.34.010>

Recibido: Junio 08, 2026
Aceptado: Octubre 02, 2026

Resumen: La vigilancia fitosanitaria constituye una actividad esencial para disminuir pérdidas productivas ocasionadas por plagas en cultivos de tomate desarrollados bajo condiciones de agricultura protegida. En años recientes, la visión artificial y los métodos de aprendizaje profundo han adquirido relevancia como herramientas capaces de automatizar procesos de detección y análisis de imágenes agrícolas. A pesar de estos avances, todavía existe la necesidad de conocer qué técnicas se han utilizado, en qué condiciones han sido evaluadas y qué desempeño han reportado, particularmente en contextos de agricultura protegida y producción de pequeña escala. El presente trabajo tiene como finalidad examinar las investigaciones publicadas sobre estas tecnologías y valorar

su posible incorporación en esquemas de monitoreo agrícola participativo. Para ello, se realizó una revisión sistemática de literatura científica publicada entre 2020 y 2026, siguiendo los lineamientos metodológicos de Kitchenham. La revisión se desarrolló mediante las etapas de planificación, búsqueda y selección de estudios, y síntesis de la información, considerando criterios de inclusión y exclusión previamente establecidos. Como resultado, se seleccionaron y analizaron cincuenta estudios relacionados con procesamiento de imágenes, inteligencia artificial y monitoreo fitosanitario. Entre los principales hallazgos de la revisión se identificó que diversos estudios reportan niveles elevados de desempeño de modelos de aprendizaje profundo en tareas de identificación automática de síntomas asociados con plagas y otras afectaciones del cultivo. La síntesis realizada permitió identificar las principales técnicas, datos, contextos de aplicación y desempeños reportados, proporcionando elementos de referencia para valorar su posible incorporación en esquemas de monitoreo agrícola participativo.

Palabras clave: *Agricultura Protegida, Manejo de Plagas, Horticultura, Monitoreo Agrícola, Visión Computacional.*

Abstract: Phytosanitary monitoring is an essential activity for reducing production losses caused by pests in tomato crops grown under protected agriculture conditions. In recent years, computer vision and deep learning methods have gained relevance as tools capable of automating agricultural image detection and analysis processes. Despite these advances, there is still a need to determine which techniques have been used, under what conditions they have been evaluated, and what performance they have reported, particularly in protected agriculture and small-scale production contexts. This study aims to examine research published on these technologies and assess their potential incorporation into participatory agricultural monitoring schemes. To this end, a systematic review of scientific literature published between 2020 and 2026 was conducted following the methodological guidelines proposed by Kitchenham. The review was developed through the stages of planning, study search and selection, and information synthesis, considering previously established inclusion and exclusion criteria. As a result, fifty studies related to image processing, artificial intelligence, and phytosanitary monitoring were selected and analyzed. Among the main findings of the review, several studies reported high-performance levels for deep learning models in tasks involving the automatic identification of symptoms associated with pests and other crop-related conditions. The synthesis identified the main techniques, data, application contexts, and reported performance levels, providing reference elements for assessing their potential incorporation into participatory agricultural monitoring schemes.

Keywords: *Protected Agriculture, Pest Management, Horticulture, Agricultural Monitoring, Computer Vision.*

1. Introducción

La agricultura protegida constituye un contexto relevante para la producción hortícola, ya que permite desarrollar los cultivos bajo estructuras que modifican parcialmente las condiciones ambientales [1], [2], [3], [4], [5], [6]. En estos sistemas, el cultivo de tomate continúa enfrentando problemas fitosanitarios relacionados con la presencia de plagas, enfermedades y daños que pueden afectar el desarrollo de las plantas [7], [8], [9].

En este contexto, la detección oportuna de plagas y de afectaciones fitosanitarias constituye un elemento relevante para el monitoreo del cultivo [7], [9], [10]. Los estudios revisados muestran el desarrollo de diferentes técnicas de visión artificial orientadas a automatizar la identificación de plagas, enfermedades y daños en plantas de tomate [7], [11], [12], [13], [14]. Entre estas propuestas se encuentran modelos basados en redes neuronales convolucionales, arquitecturas YOLO y otros enfoques de aprendizaje profundo [10], [12], [13], [15], [16].

Algunos trabajos se han orientado específicamente a la detección temprana. Por ejemplo, se han desarrollado propuestas para identificar pequeñas plagas, insectos plaga y daños ocasionados por *Tuta absoluta* [7], [8], [9], [10], [16], [17], [18], mostrando el interés de la visión artificial como herramienta de apoyo al monitoreo fitosanitario.

Paralelamente, algunos estudios han incorporado herramientas digitales, como aplicaciones móviles y plataformas de consulta, para acercar los resultados del análisis automatizado al usuario [19], [20], [21], [22]. Estas propuestas muestran una posibilidad de trasladar las capacidades de la visión artificial hacia el contexto de uso;

sin embargo, su incorporación no implica necesariamente un esquema de monitoreo participativo [19], [20], [21], [22].

En este contexto, el cultivo de tomate representa un caso de estudio relevante por la presencia de investigaciones que aplican visión artificial para la identificación de enfermedades, plagas y daños en diferentes condiciones de producción [7], [8], [9], [11], [17], [23]. Considerando la diversidad de técnicas, datos y contextos utilizados, resulta pertinente analizar de manera sistemática los avances alcanzados y las limitaciones que todavía permanecen.

Por ello, la presente revisión sistemática de la literatura tiene como propósito examinar los avances recientes en técnicas de visión artificial orientadas a la detección temprana de plagas en cultivos de tomate, identificando las tecnologías empleadas, los enfoques metodológicos, los tipos de datos utilizados, los contextos de aplicación y los desafíos presentes en la literatura científica. Asimismo, se busca explorar su posible incorporación en sistemas de agricultura protegida y en esquemas de monitoreo orientados al usuario.

2. Estado del arte

2.1. Agricultura protegida y monitoreo fitosanitario del tomate

La agricultura protegida comprende sistemas de producción desarrollados bajo estructuras que permiten modificar o regular parcialmente las condiciones ambientales del cultivo, como invernaderos y otras estructuras de protección. Variables como temperatura, humedad, ventilación y radiación pueden ser monitoreadas y, en determinados casos, reguladas, por lo que su caracterización resulta importante para comprender el comportamiento del cultivo y mejorar su manejo [1], [2], [3], [4], [24], [25], [26], [27], [28], [29]. Estos sistemas también han sido considerados en contextos de agricultura urbana, donde la evaluación de su factibilidad técnica y sostenibilidad constituye un aspecto relevante para su implementación [30], [31], [32].

A pesar de las condiciones favorables que pueden ofrecer estos sistemas, el tomate continúa expuesto a problemas fitosanitarios, entre ellos plagas, enfermedades y daños en hojas y frutos. La literatura revisada incluye estudios orientados a la identificación de insectos plaga, daños ocasionados por *Tuta absoluta* y diferentes enfermedades del cultivo [7], [8], [11], [17], [23], [33].

Frente a estas afectaciones, los estudios han explorado métodos automatizados basados en procesamiento de imágenes, aprendizaje automático y aprendizaje profundo para tareas de identificación, clasificación, localización y segmentación [7], [8], [11], [12], [34], [35]. La literatura muestra así dos líneas relacionadas con el monitoreo agrícola: la visión artificial aplicada al análisis fitosanitario y el monitoreo de variables ambientales y microclimáticas en agricultura protegida [1], [2], [3], [4], [24]. Aunque no siempre se encuentran integradas en un mismo sistema, ambas aportan elementos relevantes para el monitoreo del cultivo.

2.2. Visión artificial aplicada al monitoreo agrícola

La visión artificial ha adquirido relevancia en el ámbito agrícola por su capacidad para analizar información visual mediante técnicas computacionales. En los estudios revisados se aplica principalmente a la identificación y clasificación de enfermedades, detección de plagas y daños en las plantas, mediante procesamiento de imágenes y modelos de aprendizaje automático y profundo [7], [11], [12], [13], [14], [23], [36].

Entre los enfoques identificados se encuentran el procesamiento digital de imágenes y las redes neuronales convolucionales (CNN), utilizadas para analizar hojas y otras partes de las plantas e identificar patrones asociados con enfermedades, plagas o daños. Los modelos de aprendizaje profundo pueden aprender representaciones a partir de los datos utilizados durante su entrenamiento. También se identificaron arquitecturas como ResNet, DenseNet y MobileNet, así como estrategias de transferencia de aprendizaje y aumento de datos [12], [23], [34], [37], [38], [39].

Además de los modelos de clasificación, los estudios incorporan arquitecturas de detección de objetos y transformadores visuales. Los modelos YOLO aparecen recurrentemente para localizar plagas, enfermedades o regiones afectadas, mientras que los Vision Transformers se utilizan para analizar y clasificar patrones visuales. También se identificaron propuestas que combinan redes neuronales convolucionales, Vision Transformers y mecanismos de atención para mejorar la identificación de patrones asociados con afectaciones en las hojas [10], [8], [16], [40], [41], [42], [43], [44].

El desempeño de estos modelos debe analizarse considerando las condiciones de obtención de las imágenes. La diferencia entre conjuntos de datos controlados y escenarios agrícolas reales es relevante ante variaciones de iluminación, fondo, resolución, oclusión y disposición de las hojas. Por ello, utilizar datos representativos del contexto de aplicación constituye un aspecto importante para desarrollar soluciones de monitoreo agrícola [17], [18], [33], [42], [45].

2.3. Modelos de aprendizaje profundo para la detección de plagas en tomate

En tomate, los estudios seleccionados muestran aplicaciones del aprendizaje profundo tanto para clasificación como para detección. Rubanga *et al.* [7] utilizaron VGG16, ResNet e Inception-V3 para detectar tempranamente el daño ocasionado por *Tuta absoluta*; Praharsha *et al.* [38] evaluaron ResNet, AlexNet y MobileNet para clasificar imágenes relacionadas con plagas, y Osmenaj *et al.* [23] emplearon una CNN personalizada, VGG16 y VGG19 para identificar enfermedades foliares.

Dentro de los modelos de detección, YOLO aparece recurrentemente. Khalid *et al.* [10] analizaron YOLOv3, YOLOv4, YOLOv6 y YOLOv8 para detectar pequeñas plagas; Jun Liu *et al.* [16] propusieron YOLOv4-TAM para el reconocimiento de plagas del tomate, y Zhang *et al.* [9] emplearon YOLOv5 para su identificación en invernaderos. Para *Tuta absoluta*, Uygun y Ozguven [8] utilizaron YOLOv8-Seg, YOLOv7, YOLOv5, YOLACT y Mask R-CNN para identificar y segmentar el daño en hojas de tomate.

También se identificaron otros modelos, Kamei [17] evaluó Faster R-CNN, SSD, YOLOv3, detectoRS, YOLOX y DETR deformable para detectar mosca blanca considerando la resolución de las imágenes, mientras que Jelali [45] revisó Faster R-CNN, YOLO y CNN con conjuntos de datos agrícolas reales. Aadil Alshammari [46] empleó YOLOv8 para identificar y localizar la presencia y los patrones de daño de *Tuta absoluta* en hojas de tomate, Abdullah *et al.* [14] emplearon YOLOv8s para detectar hojas enfermas en tiempo real, y Jin *et al.* [22] combinaron YOLO, CBAM y BiFPN en una plataforma en línea para el diagnóstico de enfermedades y plagas en invernaderos.

En conjunto, los estudios muestran que no existe una única arquitectura aplicable a todos los escenarios. La selección depende de los datos disponibles, la tarea, las condiciones de captura y los recursos de implementación [8], [17], [22], [42], [45].

2.4. Monitoreo participativo y herramientas digitales en agricultura comunitaria

El monitoreo participativo en agricultura implica incorporar al usuario en la observación y seguimiento del cultivo para apoyar la toma de decisiones. Aunque la mayoría de los estudios revisados se concentra en el desarrollo y evaluación de modelos de visión artificial, algunos trasladan estos resultados hacia herramientas orientadas al usuario [19], [20], [21], [22].

Pandeya *et al.* [19] desarrollaron una aplicación móvil basada en YOLOv5 para identificar enfermedades del tomate y recomendar tratamientos; Foysal *et al.* [20] integraron aprendizaje profundo en una aplicación móvil para el diagnóstico de enfermedades foliares, y Ahmed y Reddy [21] emplearon un sistema móvil para la detección automática de enfermedades. Asimismo, Jin *et al.* [22] desarrollaron una plataforma en línea para el diagnóstico de enfermedades y plagas en invernaderos de tomate.

Sin embargo, una aplicación móvil o plataforma digital no implica por sí misma un esquema de monitoreo participativo. Los estudios revisados muestran principalmente avances para facilitar el acceso a los resultados, mientras que la integración explícita del usuario en el seguimiento del cultivo y la toma de decisiones aparece menos desarrollada. Esta situación representa una oportunidad para plantear sistemas que integren detección automatizada, condiciones reales de uso y participación del usuario [19], [20], [21], [22].

2.5. Brechas y desafíos identificados en la literatura

A partir del análisis de los estudios seleccionados, se identificó como principal desafío la disponibilidad de datos representativos de las condiciones reales de aplicación de los modelos de visión artificial. Rubanga *et al.* [7] abordaron la detección temprana del daño ocasionado por *Tuta absoluta*, mientras que Jelali [45] analizó métodos utilizando conjuntos de datos agrícolas reales, lo que evidencia la importancia de considerar el origen de los datos y las condiciones de captura al valorar el desempeño de los modelos. Otra brecha corresponde a la integración de

la visión artificial con las condiciones específicas de la agricultura protegida. Aunque Rehman *et al.* [1] y Albuja-Illescas *et al.* [14] estudiaron invernaderos, estructuras de protección y variables ambientales, sus trabajos se orientan principalmente a la caracterización del ambiente de producción. Esto plantea la necesidad de considerar conjuntamente la visión artificial y factores como iluminación, ventilación, temperatura y humedad.

Una tercera brecha corresponde a la limitada integración de la detección automatizada con herramientas dirigidas al usuario. Pandeya *et al.* [19] y Foysal *et al.* [20] incorporaron modelos de aprendizaje profundo en aplicaciones móviles, mientras que Ahmed y Reddy [21] desarrollaron un sistema móvil para la detección automática de enfermedades. Sin embargo, estas propuestas se concentran principalmente en la automatización del análisis y el uso de dispositivos móviles, por lo que existe una oportunidad para incorporar de manera más explícita al usuario en la recopilación, consulta e interpretación de la información generada durante el monitoreo.

En conjunto, las brechas identificadas se relacionan con tres aspectos: datos representativos de condiciones reales, integración de visión artificial en agricultura protegida e incorporación del usuario en el monitoreo. Por ello, la literatura proporciona elementos técnicos para desarrollar sistemas de detección automatizada, pero también evidencia la necesidad de considerar el contexto de aplicación, el entorno productivo y la participación del usuario [1], [2], [7], [19], [20], [21], [45].

3. Materiales y métodos

3.1. Diseño de la investigación

La investigación se llevó a cabo mediante una revisión sistemática de literatura orientada a identificar, organizar y analizar evidencia científica reciente sobre el empleo de técnicas de visión artificial para la detección temprana de plagas en cultivos de tomate. El estudio incluyó trabajos sobre procesamiento digital de imágenes, aprendizaje profundo y herramientas tecnológicas aplicadas al monitoreo agrícola en sistemas de agricultura protegida.

Para garantizar un procedimiento riguroso y reproducible, se adoptaron los lineamientos metodológicos propuestos por Kitchenham *et al.* [47] como referencia para estructurar la revisión sistemática. El proceso metodológico se organizó en tres fases complementarias. La primera correspondió a la planificación, para delimitar el problema, formular las preguntas de investigación y establecer el alcance del análisis. La segunda comprendió la búsqueda y selección de literatura mediante estrategias de búsqueda y criterios de inclusión y exclusión previamente establecidos. La tercera correspondió a la síntesis y análisis de la evidencia seleccionada, orientada a organizar los hallazgos según las preguntas de investigación e identificar las principales técnicas, tipos de datos, contextos de aplicación, resultados de desempeño y brechas reportadas. La Figura 1 presenta estas fases, cuyo desarrollo se describe en las subsecciones siguientes.




Figura 1. Fases metodológicas de la revisión sistemática planteada.

Dado que el estudio corresponde a una revisión sistemática de literatura, la implementación y validación de sistemas de visión artificial no se realizaron experimentalmente. En su lugar, la tercera fase incorporó el análisis de las implementaciones reportadas en los estudios seleccionados, considerando las técnicas de inteligencia artificial, los tipos de imágenes y datos, los contextos de aplicación, los modelos desarrollados y los resultados de desempeño informados. De esta manera, la revisión permite caracterizar los enfoques utilizados en investigaciones

previas y establecer elementos de referencia para plantear soluciones aplicables al monitoreo fitosanitario del tomate.

3.2. Planificación de la Revisión

Durante la fase inicial de la revisión se formularon las preguntas de investigación que guiaron la recuperación y evaluación de la literatura considerada en el estudio. Estas preguntas permitieron delimitar el alcance del análisis e identificar los enfoques tecnológicos, escenarios de aplicación y principales hallazgos reportados en trabajos relacionados con visión artificial aplicada al monitoreo fitosanitario del tomate.

Las preguntas de investigación consideradas en el presente estudio fueron las siguientes:

1. ¿Qué técnicas de visión artificial se utilizan para la detección temprana de plagas en el cultivo de tomate?
2. ¿Qué tipos de datos e imágenes se emplean para el monitoreo del estado fitosanitario del cultivo?
3. ¿En qué contextos agrícolas se han aplicado estos sistemas, especialmente en agricultura protegida?
4. ¿Qué niveles de precisión reportan los modelos utilizados para la detección de plagas?
5. ¿Cómo puede la visión artificial integrarse en esquemas de monitoreo agrícola participativo?

3.3. Estrategia de búsqueda bibliográfica

La recopilación de publicaciones científicas se efectuó mediante consultas estructuradas en diferentes plataformas académicas especializadas en agricultura, inteligencia artificial y visión computacional. Para asegurar una cobertura amplia de estudios recientes, se consideraron diversas fuentes bibliográficas reconocidas dentro de estas áreas de conocimiento.

Las bases de datos seleccionadas fueron elegidas por su cobertura temática y por la disponibilidad de investigaciones relacionadas con aprendizaje profundo, procesamiento digital de imágenes y aplicaciones tecnológicas para el sector agrícola. Adicionalmente, se incorporaron motores de búsqueda académicos como apoyo para localizar estudios potencialmente relevantes publicados en diferentes repositorios científicos.

La construcción de las estrategias de búsqueda se basó en tres componentes principales: tecnologías de visión artificial, cultivo de tomate y detección de plagas o afectaciones fitosanitarias. A partir de estos ejes temáticos se identificaron palabras clave y términos equivalentes que posteriormente fueron combinados mediante operadores booleanos con el fin de maximizar la recuperación de literatura pertinente.

Las consultas fueron adaptadas a los requerimientos de cada plataforma y complementadas con restricciones relacionadas con periodo de publicación, idioma y áreas temáticas de interés. La Tabla 1 presenta las cadenas de búsqueda y los filtros utilizados para documentar y hacer reproducible el proceso de recuperación bibliográfica. Esta tabla corresponde exclusivamente a la estrategia metodológica de búsqueda y no representa resultados de implementación de modelos de inteligencia artificial.

Tabla 1. Cadenas de búsqueda.

Base de datos	Cadena de búsqueda aplicada	Filtros utilizados	Total
Google Scholar	("computer vision" OR "deep learning") AND ("tomato plant" OR "Solanum lycopersicum") AND ("pest detection" OR "plant disease detection")	Publicaciones entre 2020–2026; ordenadas por relevancia	6,250
SpringerLink	("computer vision" OR "deep learning") AND tomato AND ("plant disease detection" OR "pest detection")	Publicaciones entre 2020–2026	1,425
ScienceDirect	("computer vision" OR "deep learning") AND ("tomato crop") AND ("plant disease detection" OR "pest detection")	Publicaciones entre 2020–2026	117
Scielo	("computer vision" OR "deep learning") AND ("tomato" OR "Solanum lycopersicum") AND ("plant disease detection" OR "pest detection")	Publicaciones entre 2020–2026	93,653

Semantic Scholar	("computer vision" AND tomato) AND ("pest detection" OR "plant disease detection")	Publicaciones entre 2020–2026	51
Frontiers	("computer vision" OR "deep learning") AND ("tomato plant" OR "Solanum lycopersicum") AND ("pest detection" OR "plant disease detection")	Publicaciones entre 2020–2026	243
MDPI	("computer vision" OR "deep learning") AND (tomato OR "Solanum lycopersicum") AND ("plant disease detection" OR "pest detection") AND (greenhouse OR "protected agriculture" OR "greenhouse agriculture")	Publicaciones entre 2020–2026	97,854
IEEE Xplore	("computer vision" OR "deep learning") AND ("plant disease detection" OR "pest detection") AND ("tomato")	Publicaciones entre 2020–2026	6
Total			199,599

Fuente: Elaboración propia.

3.4. Criterios de inclusión y exclusión

Con el propósito de garantizar la pertinencia y calidad de los estudios analizados, se establecieron criterios de inclusión y exclusión previamente definidos. Estos criterios permitieron seleccionar investigaciones relacionadas con visión artificial aplicada a la detección de plagas y enfermedades en cultivos de tomate, así como descartar trabajos que no cumplieran con los objetivos de la revisión. Los criterios considerados para la selección de artículos se presentan en las Tablas 2 y 3. Estas tablas documentan las condiciones metodológicas utilizadas para determinar la pertinencia de los estudios y no corresponden a configuraciones experimentales ni a resultados de los modelos analizados.

Tabla 2. Criterios de inclusión utilizados en la revisión sistemática.

Criterio	Descripción
Periodo de publicación	Artículos publicados entre 2020 y 2026
Tipo de documento	Artículos científicos revisados por pares
Idioma	Inglés y español
Área temática	Agricultura, visión artificial, inteligencia artificial y aprendizaje profundo
Relación con preguntas de investigación	Estudios que respondieran al menos una de las preguntas de investigación planteadas.
Acceso al estudio	Artículos con acceso al texto completo para su revisión y análisis

Fuente: Elaboración propia.

Tabla 3. Criterios de exclusión utilizados en la revisión sistemática.

Criterio	Descripción
Duplicados	Estudios repetidos entre bases de datos
Publicaciones no científicas	Blogs, tesis no arbitradas, resúmenes o presentaciones
Estudios fuera del tema	Trabajos que no presentaran relación con la visión artificial, inteligencia artificial, monitoreo fitosanitario,

	agricultura protegida o las preguntas de investigación planteadas.
Estudios sin resultados	Trabajos cuyo contenido no proporcionara información suficiente para responder las preguntas de investigación o analizar las variables consideradas en la revisión.
Acceso restringido	Publicaciones sin acceso al texto completo

Fuente: Elaboración propia.

La aplicación de estos criterios permitió organizar y depurar los resultados obtenidos en las bases de datos consultadas, facilitando la identificación de estudios realmente relacionados con el objetivo de la investigación. A partir de ello, se realizó una revisión progresiva de títulos, resúmenes y textos completos para seleccionar los artículos más relevantes y pertinentes para la revisión sistemática.

4. Resultados

El proceso de búsqueda y selección permitió identificar estudios relacionados con la aplicación de visión artificial, aprendizaje profundo y otras tecnologías para el monitoreo fitosanitario del cultivo de tomate. Los 50 estudios incluidos fueron analizados considerando las técnicas utilizadas, los tipos de imágenes y datos empleados, los contextos de aplicación y los resultados de desempeño reportados por los autores.

A partir de los resultados obtenidos en las bases de datos consultadas, se realizó una revisión gradual de los artículos relacionados con el tema de investigación. Durante este proceso se analizaron títulos, resúmenes y, posteriormente, los textos completos de los estudios considerados más relevantes. La selección final se realizó tomando en cuenta los criterios de inclusión y exclusión previamente establecidos, así como la relación de los artículos con las preguntas de investigación planteadas. La Tabla 4 muestra la cantidad de artículos identificados en cada plataforma y permite visualizar el proceso progresivo de depuración y selección realizado durante la revisión sistemática.

Tabla 4. Resultados obtenidos durante el proceso de búsqueda y selección de estudios.

Fuente	Inicial	Filtrado título/resumen	Evaluación texto completo	Incluidos
Google Scholar	6,250	5,950	25	9
ScienceDirect	117	22	10	2
Scielo	93,653	3,181	18	3
Semantic Scholar	51	50	15	5
SpringerLink	1,425	636	12	2
Frontiers	243	98	12	5
MDPI	97,854	30,558	30	18
IEEE Xplore	6	6	6	6
Total de artículos	199,599	40,501	128	50

Fuente: Elaboración propia.

Los estudios seleccionados para el análisis final fueron organizados de acuerdo con las técnicas utilizadas y las aplicaciones abordadas en cada investigación. Con el propósito de organizar el proceso de selección de estudios, se aplicaron diferentes etapas de filtrado durante la revisión bibliográfica. En cada fase se consideraron criterios específicos de inclusión y exclusión para identificar los artículos más relacionados con los objetivos de la investigación y las preguntas planteadas, tal como se muestra en la Tabla 5.

Tabla 5. Fases de filtrado aplicadas durante el proceso de selección de estudios.

Fase	Criterios aplicados
Filtrado por título y resumen	Eliminación de estudios duplicados, artículos fuera del tema, publicaciones no científicas y trabajos sin relación con las preguntas de investigación.
Evaluación de texto completo	Revisión de acceso al artículo, cumplimiento de criterios de inclusión y relación con los objetivos del estudio.
Inclusión final	Selección de estudios con información relevante para responder las preguntas de investigación.

Fuente: Elaboración propia.


La aplicación gradual de estos criterios permitió reducir la cantidad inicial de artículos recuperados y seleccionar únicamente aquellos estudios considerados relevantes para el análisis final de la revisión sistemática.

Los estudios seleccionados permitieron identificar las principales técnicas de visión artificial empleadas para el monitoreo fitosanitario del cultivo de tomate. Entre los enfoques más recurrentes se encuentran las arquitecturas YOLO, utilizadas para la detección y localización de plagas y afectaciones [8], [9], [10], [13], [14], [16], [17], [18], [19], [22], [40], [45] así como las redes neuronales convolucionales (CNN), empleadas principalmente en tareas de clasificación y reconocimiento de patrones visuales [7], [12], [15], [21], [23], [35]. Esta distribución permite observar la diversidad de enfoques utilizados en los estudios analizados y su relación con las diferentes tareas de monitoreo agrícola.

Los resultados obtenidos fueron organizados de acuerdo con las preguntas de investigación planteadas en la revisión sistemática. Esto permitió identificar las principales técnicas de visión artificial utilizadas, los tipos de datos empleados, los contextos agrícolas de aplicación, los niveles de precisión reportados y las posibilidades de integración de estas tecnologías en esquemas de monitoreo agrícola participativo.

4.1. Técnicas de visión artificial utilizadas para la detección temprana de plagas en tomate

Como parte del análisis, se identificó que el proceso de tratamiento de imágenes en la mayoría de las investigaciones sigue una secuencia compuesta por adquisición de imágenes, preprocesamiento, segmentación, extracción de características y clasificación mediante modelos de inteligencia artificial. En varios estudios, el preprocesamiento incluyó técnicas de reducción de ruido, ajuste de contraste y mejora de iluminación con el objetivo de incrementar la calidad visual de las imágenes y optimizar el desempeño de los modelos de detección [8], [11], [12], [17], [33], [37]. La Figura 2 resume las principales fases identificadas en el tratamiento de imágenes.

**Figura 2.** Proceso general de tratamiento y análisis de imágenes utilizado en sistemas de visión artificial aplicados al monitoreo agrícola.

A partir de las técnicas identificadas, el análisis de los estudios también consideró la forma en que estos enfoques fueron implementados y evaluados por los autores. Debido a que la presente investigación corresponde a una revisión sistemática de literatura, no se realizó una implementación experimental propia. En su lugar, se revisaron las arquitecturas utilizadas, los tipos de imágenes y datos empleados, los contextos de aplicación y las métricas de desempeño reportadas en los estudios seleccionados. Esto permitió identificar las características de los enfoques utilizados y las condiciones en las que fueron evaluados.

Tabla 6. Técnicas de inteligencia artificial identificadas en los estudios revisados.

Técnica	Aplicación
CNN	Clasificación y detección de plagas/enfermedades en hojas de tomate
YOLO	Detección de objetos y monitoreo fitosanitario en tiempo real
<i>Vision Transformers</i>	Identificación avanzada y clasificación contextual
MobileNet	Aplicaciones móviles y sistemas ligeros de monitoreo
<i>Deep Learning</i>	Clasificación automática y análisis de imágenes agrícolas
<i>Machine Learning</i>	Diagnóstico agrícola y clasificación automatizada
<i>Cycle-GAN</i>	Mejora y aumento de imágenes agrícolas
Sensores inteligentes	Monitoreo ambiental y agricultura protegida
Agricultura protegida	Monitoreo microclimático y optimización de cultivos
Aplicaciones móviles	Diagnóstico agrícola en tiempo real
IoT y sistemas inteligentes	Monitoreo automatizado y agricultura inteligente

Fuente: Elaboración propia.

Las técnicas identificadas muestran un predominio de enfoques basados en aprendizaje profundo para automatizar tareas de clasificación, identificación y detección de afectaciones fitosanitarias [8], [11], [37], [41], [48]. Entre los modelos recurrentes se encuentran las redes neuronales convolucionales (CNN), las arquitecturas YOLO y los Vision Transformers, mientras que MobileNet aparece en aplicaciones que requieren modelos más ligeros. Asimismo, los estudios revisados incorporan estrategias complementarias, como el aumento de imágenes mediante Cycle-GAN, además de herramientas de monitoreo ambiental y agricultura protegida. En conjunto, estos enfoques muestran que la selección de la técnica depende tanto de la tarea que se pretende resolver como de las características de los datos y del contexto de aplicación.

4.2. Tipos de datos e imágenes empleados para el monitoreo fitosanitario

El análisis de los estudios permitió identificar que la calidad de las imágenes es un factor determinante para el desempeño de los sistemas de visión artificial. Aspectos como resolución, iluminación, contraste, ruido, complejidad del fondo y superposición de hojas influyen en la generalización y precisión de los modelos. Por ello, diversos autores destacan la necesidad de utilizar conjuntos de datos más diversos y condiciones reales de captura para mejorar la robustez de los sistemas [42],[49],[17],[45],[18]. La Figura 3 resume los principales factores identificados en la literatura que afectan la calidad de las imágenes agrícolas.




Figura 3. Principales factores que influyen en la calidad de imágenes utilizadas en sistemas de visión artificial agrícola.

En relación con el origen de los datos, los estudios revisados muestran diferencias entre imágenes obtenidas en condiciones controladas y aquellas provenientes de escenarios reales de producción. Las imágenes de ambientes reales presentan mayor variabilidad en iluminación, fondo, posición de las hojas y elementos ajenos al objeto de interés. Jelali [45] analizó investigaciones de detección de enfermedades y plagas con conjuntos de datos reales de campo y comparó *datasets* reales y controlados para aplicaciones de detección agrícola. Estos estudios muestran

que la evaluación de los modelos debe considerar tanto la precisión obtenida como las condiciones de generación de las imágenes y su posible aplicación en escenarios productivos [6].

Otro enfoque identificado corresponde al uso de Cycle-GAN para la mejora y aumento de imágenes agrícolas. El estudio de Yu *et al.* [37] incorporó Cycle-GAN junto con segmentación y transferencia de aprendizaje para analizar imágenes de hojas de tomate. Esta estrategia constituye un recurso complementario al procesamiento de imágenes, al permitir trabajar con variaciones adicionales de los datos. Su presencia muestra que el procesamiento previo y el aumento de la variabilidad también forman parte de las estrategias utilizadas para mejorar los sistemas de análisis agrícola.

4.3. Niveles de precisión reportados en los modelos de detección

Entre las arquitecturas identificadas se encontraron redes neuronales convolucionales, modelos de detección como YOLO y arquitecturas basadas en transformadores visuales. Los estudios emplearon métricas como *accuracy*, *precision*, *recall*, F1 y mAP según la tarea, por lo que los resultados no se presentan como un único rango de precisión [41],[37],[8],[14]. La Tabla 7 resume las principales arquitecturas, sus aplicaciones y algunos resultados de desempeño.

Tabla 7. Comparativa de arquitecturas de aprendizaje profundo utilizadas en estudios de detección de plagas y enfermedades en tomate.

Arquitectura	Tipo de modelo	Aplicación principal	Desempeño reportado	Ventajas reportadas
ResNet	CNN profunda	Clasificación e identificación de afectaciones fitosanitarias	Se reportan resultados de clasificación en los estudios analizados, sin un rango único comparable	Resultados de clasificación reportados en los estudios analizados
DenseNet	CNN profunda	Identificación de patrones fitosanitarios	Se reportan resultados en estudios comparativos de diagnóstico agrícola	Resultados reportados en estudios comparativos
MobileNet	CNN ligera	Clasificación de enfermedades y aplicaciones con recursos computacionales limitados	98.61 % de <i>accuracy</i> (E17)	Menor complejidad computacional y posibilidad de implementación en dispositivos con recursos limitados
YOLO	Detector de objetos	Detección y localización de plagas y afectaciones	92.5 % de mAP (E36) y 93.5 % de mAP0.5 (E32)	Detección y localización de objetos en una misma etapa
Vision Transformers	Transformador visual	Identificación y clasificación de patrones visuales	96.5 % de <i>accuracy</i> y 93.9 % de <i>precision</i> (E10)	Captura de relaciones globales y características contextuales

Fuente: Elaboración propia.

La comparación muestra que la utilización de las arquitecturas depende de la tarea y las condiciones de aplicación. Las CNN se emplean principalmente para clasificación y reconocimiento de patrones, mientras que YOLO permite detectar y localizar objetos. MobileNet presenta características favorables para dispositivos con recursos limitados, y los Vision Transformers permiten analizar relaciones más amplias en las imágenes. Por ello, los resultados deben interpretarse considerando la arquitectura, la tarea, los datos, las condiciones de captura y los recursos disponibles, y no únicamente la precisión reportada [8], [14], [37], [41].

Los estudios revisados muestran escenarios diversos, desde imágenes obtenidas en condiciones controladas hasta datos de condiciones reales, así como aplicaciones móviles, plataformas de monitoreo en tiempo real e investigaciones en invernaderos y sistemas de agricultura protegida. Pandeya *et al.* [19] y Foyal *et al.* [20]

integraron modelos de aprendizaje profundo con aplicaciones móviles; Jelali [45] y Loyani [33] utilizaron conjuntos de datos reales, y Jin *et al.*

En [22] se desarrolló una plataforma para el diagnóstico de enfermedades y plagas en invernaderos de tomate. Estas diferencias muestran que las condiciones de captura, el dispositivo y el entorno de aplicación pueden influir en el desempeño y en la viabilidad de los sistemas diseñados.

4.4 Integración de visión artificial en esquemas de monitoreo agrícola participativo

En relación con la implementación de los sistemas analizados, los estudios revisados muestran el empleo de recursos tecnológicos asociados con el procesamiento de imágenes, el aprendizaje automático y el desarrollo de aplicaciones digitales. Sin embargo, el Anexo A no permite identificar de manera uniforme las herramientas o bibliotecas de programación utilizadas en todos los estudios. Por ello, el análisis se centra en los enfoques tecnológicos y las formas de integración reportadas en las investigaciones seleccionadas.

Los estudios revisados muestran diferentes formas de implementar soluciones de visión artificial. León *et al.* [50] incorporó OpenCV, aprendizaje automático y Random Forest para detectar daños causados por plagas; Pandeya *et al.* [19] integraron YOLOv5 en una aplicación móvil para identificar enfermedades del tomate y recomendar tratamientos; Foysal *et al.* [20] combinaron una CNN con una aplicación móvil para el diagnóstico de enfermedades foliares; y Ahmed y Reddy [21] desarrollaron un sistema móvil basado en aprendizaje profundo. Estas propuestas muestran diferentes alternativas para trasladar los resultados del análisis automatizado hacia herramientas de consulta y apoyo al monitoreo.

Desde esta perspectiva, la integración de visión artificial con herramientas accesibles puede fortalecer el monitoreo fitosanitario y facilitar la participación del usuario en la recopilación y consulta de información. Sin embargo, los estudios revisados muestran una presencia limitada de propuestas que integren conjuntamente la detección automatizada, las condiciones específicas de agricultura protegida y la participación del usuario. Esta situación representa una oportunidad para desarrollar sistemas orientados al monitoreo temprano de plagas en cultivos de tomate bajo condiciones de macrotúnel.

5. Conclusiones

En la presente revisión sistemática se analizaron 50 artículos científicos seleccionados mediante un proceso de búsqueda, filtrado y evaluación de texto completo. Los estudios abordaron aplicaciones de visión artificial, aprendizaje automático y aprendizaje profundo para la detección, identificación y monitoreo de plagas y afectaciones fitosanitarias, con especial atención al tomate y a la agricultura protegida. La revisión permitió identificar las principales técnicas, tipos de datos, contextos de aplicación y desafíos asociados con su implementación.

Entre las técnicas identificadas destacan las redes neuronales convolucionales (CNN), YOLO, Vision Transformers y MobileNet, además de estrategias de segmentación, transferencia de aprendizaje y Cycle-GAN. Estas técnicas se emplean para clasificación, identificación, detección y localización de afectaciones en imágenes agrícolas. También se identificaron aplicaciones móviles y plataformas digitales orientadas a facilitar el acceso a los resultados.

Los estudios muestran diferencias entre imágenes obtenidas en condiciones controladas y escenarios reales. Factores como calidad, resolución, iluminación, fondo y condiciones de captura influyen en el desempeño de los modelos, especialmente al trasladarlos hacia invernaderos y macrotúneles. Asimismo, persisten desafíos relacionados con datos representativos, variabilidad ambiental, recursos computacionales y limitada incorporación del usuario. Son menos frecuentes las propuestas que integran detección automatizada, herramientas dirigidas al usuario y condiciones específicas de agricultura protegida.

Finalmente, la revisión proporciona elementos para orientar soluciones de monitoreo fitosanitario del tomate, entre ellos el uso de datos representativos, la selección de arquitecturas según la tarea y los recursos disponibles, la consideración de los ambientes protegidos y la incorporación del usuario en el monitoreo. Estos resultados proporcionan una base para plantear sistemas de detección temprana que, además de reconocer una afectación, puedan integrarse en esquemas accesibles y adaptados a condiciones productivas reales.

6. Agradecimientos

Este trabajo se realizó con el apoyo de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) y del Instituto Tecnológico Superior de Xalapa. Los autores agradecen el respaldo académico brindado para el desarrollo de este artículo.

7. Referencias

- [1] Rehman, H. U., Bashir, O., Dar, S. A., Paul, S., Rafiq, A., Mir, I. A., Bashir, U., Simnani, S. (2025). Protected cultivation of horticultural crops: Practices, opportunities and challenges-a review. *International Journal of Research in Agronomy*, 8 (10S), 177-187. <https://doi.org/10.33545/2618060X.2025.v8.i10Sc.4068>
- [2] Albuja-Illescas, L. M., Gómez-Cabezas, M., Jácome-Aguirre, G., Aragón-Suárez, J. P., Jiménez-Lao, R., Peña-Fernández, A., Lao, M. T. (2025). Microclimate Characterization of a Low-Tech Greenhouse During a Tomato Crop (*Solanum lycopersicum* L.) Production Cycle in Chaltura, Imbabura. *Plants*, 14 (23), 1-25. <https://doi.org/10.3390/plants14233702>
- [3] Jerszurki, D., Saadon, T., Zhen, J., Agam, N., Tas, E., Rachmilevitch, S., Lazarovitch, N. (2021). Vertical microclimate heterogeneity and dew formation in semi-closed and naturally ventilated tomato greenhouses. *Scientia Horticulturae*, 288. <https://doi.org/10.1016/j.scienta.2021.110271>
- [4] Yang, L., Liu, H., Cohen, S., Gao, Z. (2022). Microclimate and Plant Transpiration of Tomato (*Solanum lycopersicum* L.) in a Sunken Solar Greenhouse in North China. *Agriculture*, 12 (2), 1-21. <https://doi.org/10.3390/agriculture12020260>
- [5] Khapte, P., Kumar, P., Singh, A., Wakchaure, G., Saxena, A., Sabatino, L. (2022). Integrative Effect of Protective Structures and Irrigation Levels on Tomato Performance in Indian Hot-Arid Region. *Plants*, 11 (20), 1-16. <https://doi.org/10.3390/plants11202743>
- [6] Moreno-Teruel, M. D. L. Á., Molina-Aiz, F. D., Peña-Fernández, A., López-Martínez, A., Valera-Martínez, D. L. (2021). The Effect of Diffuse Film Covers on Microclimate and Growth and Production of Tomato (*Solanum lycopersicum* L.) in a Mediterranean Greenhouse. *Agronomy*, 11 (5), 1-24. <https://doi.org/10.3390/agronomy11050860>
- [7] Rubanga, D. P., Loyani, L. K., Richard, M., & Shimada, S. (2020). A Deep Learning Approach for Determining Effects of Tuta Absoluta in Tomato Plants. *arXiv*. <https://doi.org/10.48550/arXiv.2004.04023>
- [8] Uygun, T., Ozguven, M. M. (2024). Determination of tomato leafminer: Tuta absoluta (Meyrick) (Lepidoptera: Gelechiidae) damage on tomato using deep learning instance segmentation method. *European Food Research and Technology*, 250 (6), 1837-1852. <https://doi.org/10.1007/s00217-024-04516-w>
- [9] Zhang, X., Bu, J., Zhou, X., Wang, X. (2023). Automatic pest identification system in the greenhouse based on deep learning and machine vision. *Frontiers in Plant Science*, 14, 1-13. <https://doi.org/10.3389/fpls.2023.1255719>
- [10] Khalid, S., Oqaibi, H. M., Aqib, M., Hafeez, Y. (2023). Small Pests Detection in Field Crops Using Deep Learning Object Detection. *Sustainability*, 15 (8), 1-19. <https://doi.org/10.3390/su15086815>
- [11] Das, A., Pathan, F., Jim, J. R., Kabir, M. M., Mridha, M. F. (2025). Deep learning-based classification, detection, and segmentation of tomato leaf diseases: A state-of-the-art review. *Artificial Intelligence in Agriculture*, 15 (2), 192-220. <https://doi.org/10.1016/j.aiaa.2025.02.006>
- [12] Trivedi, N. K., Gautam, V., Anand, A., Aljahdali, H. M., Villar, S. G., Anand, D., Goyal, N., Kadry, S. (2021). Early Detection and Classification of Tomato Leaf Disease Using High-Performance Deep Neural Network. *Sensors*, 21 (23), 1-15. <https://doi.org/10.3390/s21237987>
- [13] Vilar-Andreu, M., García, L., García-Sánchez, A.-J., Asorey-Cacheda, R., García-Haro, J. (2024). Enhancing Precision Agriculture Pest Control: A Generalized Deep Learning Approach With YOLOv8-Based Insect Detection. *IEEE Access*, 12, 84420-84434. <https://doi.org/10.1109/ACCESS.2024.3413979>
- [14] Abdullah, A., Amran, G. A., Tahmid, S. M. A., Alabrah, A., AL-Bakhrani, A. A., & Ali, A. (2024). A Deep-Learning-Based Model for the Detection of Diseased Tomato Leaves. *Agronomy*, 14 (7), 1-13. <https://doi.org/10.3390/agronomy14071593>
- [15] Mustofa, S., Munna, M. H., Emon, Y. R., Rabbany, G., Ahad, T. (2023). A comprehensive review on Plant Leaf Disease detection using Deep learning. *arXiv*. <https://doi.org/10.48550/arXiv.2308.14087>

- [16]Liu, J., Wang, X., Miao, W., Liu, G. (2022). Tomato Pest Recognition Algorithm Based on Improved YOLOv4. *Frontiers in Plant Science*, 13, 1-10. <https://doi.org/10.3389/fpls.2022.814681>
- [17]Kamei, M. (2023). Effect of image resolution on automatic detection of whitefly (Hemiptera: Aleyrodidae) species on tomato leaflets using deep learning. *Smart Agricultural Technology*, 6, 1-8. <https://doi.org/10.1016/j.atech.2023.100372>
- [18]Wang, X., Liu, J., Liu, G. (2021). Diseases Detection of Occlusion and Overlapping Tomato Leaves Based on Deep Learning. *Frontiers in Plant Science*, 12, 1-14. <https://doi.org/10.3389/fpls.2021.792244>
- [19]Pandeya, Y. R., Karki, S., Dangol, I., Rajbanshi, N. (2023). Deep Learning based Tomato Disease Detection and Remedy Suggestions using Mobile Application. *arXiv*. <https://doi.org/10.48550/arXiv.2310.05929>
- [20]Foyisal, A. H., Ahmed, F., Haque, Z. (2024). Multi-Class Plant Leaf Disease Detection: A CNN-based Approach with Mobile App Integration. *International Journal of Computer Applications*, 186 (41), 62- 68. <https://doi.org/10.5120/ijca2024924026>
- [21]Ahmed, A. A., Reddy, G. H. (2021). A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning. *AgriEngineering*, 3 (3), 478-493. <https://doi.org/10.3390/agriengineering3030032>
- [22]Jin, X., Zhu, X., Ji, J., Li, M., Xie, X., Zhao, B., (2024). Online diagnosis platform for tomato seedling diseases in greenhouse production. *International Journal of Agricultural and Biological Engineering*, 17 (1), 80-89. <https://doi.org/10.25165/j.ijabe.20241701.8433>
- [23]Osmanaj, Z., Tseliki, E.-M., Kapellaki, S. H., Tselikis, G., Tselikas, N. D. (2025). From Pixels to Diagnosis: Implementing and Evaluating a CNN Model for Tomato Leaf Disease Detection. *Information*, 16 (3), 1-21. <https://doi.org/10.3390/info16030231>
- [24]Šalagovič, J., Vanhees, D., Verboven, P., Holsteens, K., Verlinden, B., Huysmans, M., Van De Poel, B., Nicolaï, B. (2024). Microclimate monitoring in commercial tomato (*Solanum Lycopersicum* L.) greenhouse production and its effect on plant growth, yield and fruit quality. *Frontiers in Horticulture*, 3, 1-17. <https://doi.org/10.3389/fhort.2024.1425285>
- [25]Sharaf-Eldin, M. A., Yaseen, Z. M., Elmetwalli, A. H., Elsayed, S., Scholz, M., Al-Khafaji, Z., Omar, G. F. (2023). Modifying Walk-In Tunnels through Solar Energy, Fogging, and Evaporative Cooling to Mitigate Heat Stress on Tomato. *Horticulturae*, 9 (1), 1-20. <https://doi.org/10.3390/horticulturae9010077>
- [26]Kim, H.-K., Lee, S.-Y., Kwon, J.-K., Kim, Y.-H. (2022). Evaluating the Effect of Cover Materials on Greenhouse Microclimates and Thermal Performance. *Agronomy*, 12 (1), 1-15. <https://doi.org/10.3390/agronomy12010143>
- [27]Banjare, C., Mahanta, D., Sahu, P., Choudhary, R. (2024). A Comprehensive Review on Protected Cultivation: Importance, Scope and Status. *International Journal of Environment and Climate Change*, 14 (7), 46-55. <https://doi.org/10.9734/ijec/2024/v14i74250>
- [28]Espitia, J. J., Amado, G., Rodriguez, J., Gomez, L., Gil, R., Flores-Velasquez, J., Baeza, E., Aguilar, C. E., Akrami, M., Arias, L. A., Villagran, E. (2025). CO2 Enrichment in Protected Agriculture: A Bibliometric Review on Greenhouses, Controlled Environment Systems, and Vertical Farms—Part 1. *Horticulturae*, 11 (5), 1-37. <https://doi.org/10.3390/horticulturae11050476>
- [29]Ortiz Rocha, G. A., Pichimata, M. A., Villagran, E. (2021). Research on the Microclimate of Protected Agriculture Structures Using Numerical Simulation Tools: A Technical and Bibliometric Analysis as a Contribution to the Sustainability of Under-Cover Cropping in Tropical and Subtropical Countries. *Sustainability*, 13 (18), 1-40. <https://doi.org/10.3390/su131810433>
- [30]Ramírez-Pérez, N. V., Padilla-Medina, J. A., Cárdenas-Manriquez, M., Araujo-Rodríguez, J. A., Barranco-Gutiérrez, A. I., Prado-Olivarez, J. (2025). Agricultura urbana en México: evaluación sobre su factibilidad y viabilidad técnica, política, económica y eficiencia energética. *Agricultura, Sociedad y Desarrollo*, 22 (4), 553–575. <https://doi.org/10.22231/asyd.v22i4.1741>
- [31]Li, Y., Zhao, S., Dai, A., Zhang, J., Fan, Z., Ding, T. (2024). Study on the Natural Ventilation Model of a Single-Span Plastic Greenhouse in a High-Altitude Area. *Agronomy*, 14 (9), 1-22. <https://doi.org/10.3390/agronomy14092166>
- [32]Gao, Z., Li, W., Li, W., Ding, X. (2024). Experimental research on the microclimate in the naturally ventilated multi-span greenhouse. *International Journal of Agricultural and Biological Engineering*, 17 (3), 68-74. <https://doi.org/10.25165/j.ijabe.20241703.7073>

- [33]Loyani, L. (2024). Segmentation-based quantification of *Tuta absoluta*'s damage on tomato plants. *Smart Agricultural Technology*, 7, 1-10. <https://doi.org/10.1016/j.atech.2024.100415>
- [34]Ngugi, H. N., Akinyelu, A. A., Ezugwu, A. E. (2024). Machine Learning and Deep Learning for Crop Disease Diagnosis: Performance Analysis and Review. *Agronomy*, 14 (12), 1-39. <https://doi.org/10.3390/agronomy14123001>
- [35]David, H. E., Ramalakshmi, K., Gunasekaran, H., Venkatesan, R. (2021). *Literature Review of Disease Detection in Tomato Leaf using Deep Learning Techniques*. 7th International Conference on Advanced Computing and Communication Systems (ICACCS), Coimbatore, India. <https://doi.org/10.1109/ICACCS51430.2021.9441714>
- [36]Rodríguez-Vazquez, E., Hernández-Rodríguez, M., Aguirre-Uribe, L. A., Castro-del Ángel, E., Lara-Viveros, F. M., Hernández-Juárez, A. (2025). Sistemas automáticos de monitoreo, nueva herramienta para la detección temprana de insectos plaga. Revisión bibliográfica. *ITEA-Información Técnica Económica Agraria*, 121 (4), 331-353. <https://doi.org/10.12706/itea.2025.011>
- [37]Yu, A., Xiong, Y., Lv, Z., Wang, P., She, J., Wei, L. (2024). New Method for Tomato Disease Detection Based on Image Segmentation and Cycle-GAN Enhancement. *Sensors*, 24 (20), 1-17. <https://doi.org/10.3390/s24206692>
- [38]Praharsha, C. H., Poullose, A., Badgujar, C. (2024). Comprehensive Investigation of Machine Learning and Deep Learning Networks for Identifying Multispecies Tomato Insect Images. *Sensors*, 24 (23), 1-136. <https://doi.org/10.3390/s24237858>
- [39]Jafar, A., Bibi, N., Naqvi, R. A., Sadeghi-Niaraki, A., Jeong, D. (2024). Revolutionizing agriculture with artificial intelligence: Plant disease detection methods, applications, and their limitations. *Frontiers in Plant Science*, 15, 1-20. <https://doi.org/10.3389/fpls.2024.1356260>
- [40]Gao, Q., Shi, C., Ji, Y., Wang, M. (2026). Crop Pest Identification and Real-Time Monitoring System Design Based on Improved YOLOv8s. *Sensors*, 26 (2), 1-18. <https://doi.org/10.3390/s26020404>
- [41]Karimanzira, D. (2025). Context-Aware Tomato Leaf Disease Detection Using Deep Learning in an Operational Framework. *Electronics*, 14 (4), 1-30. <https://doi.org/10.3390/electronics14040661>
- [42]Wang, S., Chen, D., Xiang, J., Zhang, C. (2024). A Deep-Learning-Based Detection Method for Small Target Tomato Pests in Insect Traps. *Agronomy*, 14 (12), 1-31. <https://doi.org/10.3390/agronomy14122887>
- [43]Zou, F., Hua, J., Zhu, Y., Deng, J., He, R. (2024). ECVNet: A Fusion Network of Efficient Convolutional Neural Networks and Visual Transformers for Tomato Leaf Disease Identification. *Agronomy*, 14 (12), 1-19. <https://doi.org/10.3390/agronomy14122985>
- [44]Shafay, M., Hassan, T., Owais, M., Hussain, I., Khawaja, S. G., Seneviratne, L., Werghi, N. (2025). Recent advances in plant disease detection: Challenges and opportunities. *Plant Methods*, 21 (1), 1-44. <https://doi.org/10.1186/s13007-025-01450-0>
- [45]Jelali, M. (2024). Deep learning networks-based tomato disease and pest detection: A first review of research studies using real field datasets. *Frontiers in Plant Science*, 15, 1-20. <https://doi.org/10.3389/fpls.2024.1493322>
- [46]Alshammari, A. (2024). A convolutional neural network for detecting *Tuta absoluta* effects in tomato crops using YOLOv8. *Journal of Electrical Systems*, 20 (3), 4241–4247. <https://journal.esrgroups.org/jes/article/view/5622>
- [47]Kitchenham, B., Pearl Brereton, O., Budgen, D., Turner, M., Bailey, J., Linkman, S. (2009). Systematic literature reviews in software engineering – A systematic literature review. *Information and Software Technology*, 51 (1), 7-15. <https://doi.org/10.1016/j.infsof.2008.09.009>
- [48]Wang, S., Xu, D., Liang, H., Bai, Y., Li, X., Zhou, J., Su, C., Wei, W. (2025). Advances in Deep Learning Applications for Plant Disease and Pest Detection: A Review. *Remote Sensing*, 17 (4), 1-30. <https://doi.org/10.3390/rs17040698>
- [49]Popowski, J., Warma, L., Cifuentes, A. A., Bleeker, P., Jalaal, M. (2025). Glandular Trichome Rupture in Tomato Plants is an Ultra-Fast & Sensitive Defense Mechanism Against Insects. *Journal of Experimental Botany*, 76(21), 6508-6519. <https://doi.org/10.1093/jxb/eraf257>
- [50]León, R., Díaz, M., Rodríguez, L. (2020). Management of an artificial vision system for the detection of damage caused by pests in avocado crop using a drone. *Revista Ciencia y Tecnología*, 16 (4), 145-151. <https://doi.org/10.17268/rev.cyt.2020.04.14>