



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO®

Tecnológico Nacional de México

**Centro Nacional de Investigación
y Desarrollo Tecnológico**

Tesis de Maestría

**Desarrollo de un modelo de Deep Learning para
la detección de plagas en cultivos de maíz
mediante imágenes adquiridas por drones**

presentada por

Ing. Andrea Sánchez Ruiz

como requisito para la obtención del grado de

Maestra en Ciencias de la Ingeniería

Director de tesis

Dr. Vitervo López Caballero

Codirector de tesis

Dr. Noé Alejandro Castro Sánchez



Centro Nacional de Investigación y Desarrollo Tecnológico
Subdirección Académica

Cuernavaca Mor, **10/agosto/2026**

Oficio No. SAC/246/2026

Asunto: Autorización de impresión de tesis

ANDREA SÁNCHEZ RUIZ
CANDIDATA AL GRADO DE MAESTRA EN
CIENCIAS DE LA INGENIERÍA
P R E S E N T E


Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"DESARROLLO DE UN MODELO DE DEEP LEARNING PARA LA DETECCIÓN DE PLAGAS EN CULTIVOS DE MAIZ MEDIANTE IMÁGENES ADQUIRIDAS POR DRONES"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica

"Conocimiento y Tecnología al servicio de México"



CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO

c.c.p. Coordinación de Ciencias de la Ingeniería
Departamento de Servicios Escolares

CMAZ/lmz



2026
año de
Margarita
Maza

cenidet
Centro Nacional de Investigación
y Desarrollo Tecnológico



Interior Internado Palmira S/N, Col. Palmira,
C.P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 4106,
e-mail: acad_cenidet@tecnm.mx | cenidet.tecnm.mx



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Centro Nacional de Investigación y Desarrollo Tecnológico
Coordinación de Ciencias de la Ingeniería

Cuernavaca, Mor., 07/agosto/2026

CENIDET-AC-004-M14-OFICIO
Asunto: Aceptación de documento de tesis

DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de la estudiante **ANDREA SÁNCHEZ RUIZ**, con número de control M24CE103, de la Maestría en Ciencias de la Ingeniería, le informamos que hemos revisado el trabajo de tesis de grado titulado **"DESARROLLO DE UN MODELO DE DEEP LEARNING PARA LA DETECCIÓN DE PLAGAS EN CULTIVOS DE MAIZ MEDIANTE IMÁGENES ADQUIRIDAS POR DRONES"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.


DR. VITERVO LÓPEZ CABALLERO
Director de tesis

DR. NOÉ ALEJANDRO CASTRO SÁNCHEZ
Codirector de Tesis

DR. HUGO ESTRADA ESQUIVEL
Revisor 1

MTRO EMMANUEL OLMOS BARBA
Revisor 2

C.c.p. Depto. Servicios Escolares.
Expediente / Estudiante



2026
año de
Margarita
Maza

cenidet
Centro Nacional de Investigación
y Desarrollo Tecnológico



Interior Internado S/N Col. Palmira
C.P. 62490, Cuernavaca, Morelos Tel. 01 (777) 362 7770
e-mail: coord.ingenieria@cenidet.tecnm.mx | cenidet.tecnm.mx

Dedicatoria

A mi familia:

papá, mamá, Liz, hermanas, Robe y mi par de caos.

Por su amor y confianza.

Agradecimientos

A Dios por ser mi fuerza, mi refugio y mi camino. Por ser claridad y esperanza en la incertidumbre.

A mis padres, por darme las bases para alcanzar esta meta; a Liz, por su cariño de madre; a mis hermanas, por su impulso constante; a Robe, por su tierno cuidado; a Isaí y Santi, por recordarme disfrutar del camino.

A la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (Secihti), por el respaldo económico otorgado durante mi formación académica, el cual hizo posible el desarrollo de esta investigación.

Al Centro Nacional de Investigación y Desarrollo Tecnológico (Cenidet), por brindarme el espacio y la formación académica necesaria.

A mi director de tesis, el Dr. Vitervo López Caballero por su guía académica y la confianza depositada en mí desde el inicio; a mi codirector, el Dr. Noé Alejandro Castro Sánchez, por su disposición y retroalimentación.

A mis revisores, el Dr. Hugo Estrada Esquivel y el Mtro. Emmanuel Olmos Barba, por su dedicación, sus valiosas observaciones y sugerencias, las cuales contribuyeron a fortalecer esta investigación.

A la University of Lincoln, por su amable recibimiento y por contribuir a mi formación; especialmente al Dr. Leonardo Guevara, por su apoyo durante mi estancia y por la oportunidad brindada de esta experiencia.

A mis amistades, por su apoyo, cariño y compañía durante esta travesía en los desafiantes y divertidos momentos.

Resumen

La detección temprana de plagas en cultivos de maíz representa un desafío para la agricultura, ya que los métodos tradicionales de inspección dependen de recorridos manuales, requieren una elevada inversión de tiempo y están sujetos a la experiencia del personal encargado del monitoreo. En este contexto, el presente trabajo propone la implementación de un modelo basado en aprendizaje profundo para la detección de plagas en cultivos de maíz mediante imágenes capturadas por dron y dispositivos móviles en condiciones reales de campo.

Por esto, se creó un conjunto de datos integrado por 2,500 imágenes de cultivos de maíz sanos y con presencia de plagas, obtenidas de parcelas agrícolas ubicadas en los municipios de Emiliano Zapata, Jojutla y Tlaltizapán, Morelos. Posteriormente, se aplicaron técnicas de preprocesamiento y aumentación de datos que incluyó redimensionamiento, normalización, rotación, contraste, zoom y volteo horizontal; con el propósito de incrementar la diversidad del conjunto y favorecer la generalización de los modelos.

La propuesta se basó en aprendizaje por transferencia mediante la evaluación comparativa de tres arquitecturas de redes neuronales convolucionales: ResNet50, EfficientNetB0 y MobileNetV2. Las tres arquitecturas se entrenaron utilizando el mismo conjunto de datos, misma división de entrenamiento y validación, los mismos parámetros experimentales, permitiendo realizar una comparación objetiva de su desempeño de clasificación. La evaluación se realizó mediante las métricas de accuracy, precisión, recall y F1-score, considerando el análisis de la matriz de confusión y curvas ROC y PR.

Los resultados mostraron que la arquitectura ResNet50 obtuvo el mejor desempeño, al clasificar con mayor precisión las imágenes de cultivos con y sin presencia de plagas en entornos agrícolas reales. Estos resultados evidencian el potencial del aprendizaje profundo como herramienta de apoyo para la agricultura de precisión, contribuyendo al monitoreo fitosanitario oportuno y a una toma de decisiones orientada a reducir pérdidas económicas.

Tabla de contenido

RESUMEN	III
LISTA DE FIGURAS.....	VI
LISTA DE TABLAS	VI
CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1 ANTECEDENTES DE LA INVESTIGACIÓN	3
1.2 DESCRIPCIÓN DEL PROBLEMA DE INVESTIGACIÓN.....	3
1.3 OBJETIVOS	4
1.3.1 Objetivo general	4
1.3.2 Objetivos específicos	4
1.4 JUSTIFICACIÓN.....	5
1.5 ALCANCES Y LIMITACIONES	6
1.5.1 Alcances	6
1.5.2 Limitaciones.....	6
1.6 ORGANIZACIÓN DEL DOCUMENTO	7
CAPÍTULO 2. MARCO CONCEPTUAL	8
2.1 CONCEPTOS RELACIONADOS CON INTELIGENCIA ARTIFICIAL.....	9
2.1.1 Inteligencia Artificial (IA)	9
2.1.2 Aprendizaje Automático (Machine Learning, ML)	9
2.1.3 Aprendizaje Profundo (Deep Learning, DL)	9
2.1.4 Aprendizaje por Transferencia (Transfer Learning)	10
2.1.5 Redes Neuronales Convolucionales (Convolutional Neural Networks, CNN).....	10
2.1.6 Arquitectura Red Residual (Residual Networks, ResNet)	10
2.2 CONCEPTOS RELACIONADOS CON LA AGRICULTURA	11
2.2.1 Maíz (zea mays).....	11
2.2.2 Plaga agrícola.....	11
2.2.3 Enfermedades	12
2.2.4 Gusano cogollero (Spodoptera frugiperda).....	12
2.2.5 Agricultura de precisión	12
2.3 CONCEPTOS RELACIONADOS CON LA ADQUISICIÓN, PREPROCESAMIENTO Y AUMENTACIÓN DE LOS DATOS.....	13
2.3.1 Imágenes de cultivos de maíz.....	13
2.3.2 Imágenes capturadas por dron	13
2.3.3 Preprocesamiento de imágenes	13
2.4 CONCEPTOS RELACIONADOS CON LA EVALUACIÓN DE MODELOS	13
2.4.1 Métricas de evaluación.....	13
2.4.2 Matriz de confusión	14
2.4.3 Accuracy.....	14
2.4.4 Precision.....	14
2.4.5 Recall.....	15
2.4.6 F1-score	15
2.4.7 Gráfico Receiver Operating Characteristics ROC.....	15
2.4.8 Gráfico Precision-Recall PR.....	15
CAPÍTULO 3. REVISIÓN DE LA LITERATURA.....	16
3.1 PLANEAR LA REVISIÓN	17
3.1.1 Formular el problema de investigación	17
3.1.2 Formular las preguntas de investigación	18

3.2	DIRIGIR LA REVISIÓN.....	18
3.2.1	Seleccionar los estudios.....	18
3.2.2	Extraer la información	19
3.3	DOCUMENTAR LA REVISIÓN.....	19
3.3.1	Responder preguntas de investigación.....	19
3.3.2	Redactar informe de revisión	19
3.4	ENFOQUE A. MACHINE LEARNING CON IMÁGENES.....	20
3.5	ENFOQUE B. DEEP LEARNING CON IMÁGENES	21
3.6	ENFOQUE C. MODELOS HÍBRIDOS.....	23
3.7	DISCUSIÓN DE LA REVISIÓN DE LA LITERATURA	24
CAPÍTULO 4.	METODOLOGÍA DE SOLUCIÓN	26
4.1	SELECCIÓN DE UN MODELO DE APRENDIZAJE PROFUNDO	27
4.2	RECOLECCIÓN DE DATOS.....	28
4.3	PREPROCESAMIENTO DE IMÁGENES	28
4.4	DISEÑO DEL MODELO.....	30
4.5	ENTRENAMIENTO DEL MODELO.....	30
4.6	VALIDACIÓN DEL MODELO	30
CAPÍTULO 5.	IMPLEMENTACIÓN DE LA SOLUCIÓN	32
5.1	CREACIÓN DEL DATASET.....	33
5.2	PREPROCESAMIENTO DE IMÁGENES	36
5.3	ENTRENAMIENTO Y VALIDACIÓN DEL MODELO	39
5.3.1	Planeación del experimento.....	41
5.3.2	Ejecución y resultados del experimento.....	44
CAPÍTULO 6.	CONCLUSIONES Y TRABAJOS FUTUROS.....	48
6.1	CONCLUSIONES	49
6.2	APORTACIONES.....	50
6.3	TRABAJOS FUTUROS.....	51
6.4	PUBLICACIONES	52
REFERENCIAS.....		53
ANEXOS		60
ANEXO A.	FORMULARIO DE EXTRACCIÓN DE INFORMACIÓN.....	60
ANEXO B.	RESUMEN DE TRABAJOS RELACIONADOS.....	64
ANEXO C.	EVIDENCIA DE IMÁGENES DE CAMPO.....	78

Lista de figuras

FIGURA 1. REPRESENTACIÓN DE RED RESIDUAL	11
FIGURA 2. MATRIZ DE CONFUSIÓN.	14
FIGURA 3. PROTOCOLO DE REVISIÓN DE LA LITERATURA.	17
FIGURA 4. DISTRIBUCIÓN DE ESTUDIOS SELECCIONADOS POR ENFOQUES.....	20
FIGURA 5. METODOLOGÍA DE SOLUCIÓN.	27
FIGURA 6. DRON DJI M3 MINI.	34
FIGURA 7. ÁNGULOS DE CAPTURA DE IMÁGENES POR DRON.	35
FIGURA 8. IMAGEN DE CULTIVO DE MAÍZ SANA CAPTURADA POR CELULAR.	35
FIGURA 9. IMAGEN DE CULTIVO DE MAÍZ SANA CAPTURADA POR DRON.	35
FIGURA 11. IMAGEN DE CULTIVO DE MAÍZ CON PLAGA CAPTURADA POR DRON.	36
FIGURA 10. IMAGEN DE CULTIVO DE MAÍZ CON PLAGA CAPTURADA POR CELULAR.	36
FIGURA 12. FLUJO DE PREPROCESAMIENTO Y PREPARACIÓN DE IMÁGENES.	37
FIGURA 13. SUBCONJUNTOS DE ENTRENAMIENTO Y VALIDACIÓN.	39
FIGURA 14. PROCESO DE ENTRENAMIENTO Y CLASIFICACIÓN.....	40
FIGURA 15. MATRIZ DE CONFUSIÓN POR ARQUITECTURA.	46
FIGURA 16. CURVA ROC POR ARQUITECTURA.	46
FIGURA 17. CURVA PR POR ARQUITECTURA.	46

Lista de tablas

TABLA 1. CADENAS DE BÚSQUEDA.	18
TABLA 2. SELECCIÓN DE TRABAJOS RELACIONADOS.	19
TABLA 3. COMPARACIÓN DE LAS ARQUITECTURAS RESNET EVALUADAS CON BASE A LA LITERATURA.	28
TABLA 4. TÉCNICAS DE PREPROCESAMIENTO Y AUMENTACIÓN DE DATOS PRINCIPALES.	29
TABLA 5. CARACTERÍSTICAS DE LA AERONAVE.	34
TABLA 6. CARACTERÍSTICAS DE LA CÁMARA.	34
TABLA 7. TÉCNICAS DE AUMENTACIÓN DE DATOS APLICADAS.	38
TABLA 8. CARACTERÍSTICAS DEL AMBIENTE DE PRUEBA.	42
TABLA 9. VARIABLES CONSIDERADAS EN EL DISEÑO DEL EXPERIMENTO.....	43
TABLA 10. RESUMEN DEL ENTRENAMIENTO POR ARQUITECTURA.	45
TABLA 11. MÉTRICAS DE DESEMPEÑO DE CLASIFICACIÓN POR ARQUITECTURA.....	45

Capítulo 1. Introducción

Este capítulo introduce al tema de detección de plagas en cultivos de maíz con modelos de Aprendizaje Profundo, resaltando: el contexto de la investigación, los objetivos y la estructura de la tesis.

La Agenda 2030 para el Desarrollo Sostenible es un plan de acción implementada por la Organización de las Naciones Unidas, la cual fomenta el crecimiento económico, el bienestar social y la protección social en colaboración con diversos países. De esta surgen los 17 Objetivos para el Desarrollo Sostenible (ODS) los cuales proporcionan una hoja de ruta para brindar soluciones en beneficio de la humanidad, promoviendo el desarrollo sostenible (United Nations, 2015).

En este contexto, el presente trabajo de investigación contribuye al cumplimiento de dos de estos objetivos: el ODS 2, que busca poner fin al hambre, lograr la seguridad alimentaria, mejorar la nutrición y promover una agricultura sostenible; y el ODS 12, que pretende garantizar modalidades de consumo y producción sostenibles, para fortalecer los sistemas agrícolas y fomentar prácticas eficientes en el uso de los recursos naturales.

De acuerdo con la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), contempla al maíz como uno de los cultivos de mayor producción y consumo en el mundo, debido a su adaptabilidad en diferentes entornos (Paliwal, 2001). Del mismo modo, la Secretaría de Agricultura y Desarrollo Rural de México señala que el maíz es cultivado en los 32 estados del país, lo que refuerza su importancia social y cultural, además de ser el cultivo de mayor valor económico a nivel nacional (SADER, 2023).

Con la incorporación de la inteligencia artificial (IA), este trabajo de investigación tiene la finalidad de ofrecer una alternativa ventajosa, en beneficio a los agricultores; debido a que plagas afectan significativamente el rendimiento y la calidad en la producción de maíz. En particular, este trabajo de investigación se centra en detectar la presencia de plagas en cultivos de maíz utilizando técnicas de Aprendizaje Profundo (Xu et al., 2023) Además, el enfoque planteado busca reducir el uso de pesticidas, cuya persistencia en el suelo contribuye significativamente a la contaminación en la tierra (Sánchez-del Cid et al., 2025).

1.1 Antecedentes de la investigación

A continuación, se presenta un trabajo relacionado con el contexto de esta investigación, que sirve como base para desarrollar una propuesta innovadora. En el Centro Nacional de Investigación y Desarrollo Tecnológico (Cenidet) en el área de Ciencias de la Ingeniería, esta iniciativa destaca como pionera en el uso de *Deep Learning* para la detección de plagas en cultivos de maíz, posicionándose entre las primeras de su tipo en esta área.

Hernández Solano et al. (2021) presenta un diagnóstico general del cultivo de maíz en México, en la forma de lo que se denomina proyección *business-as-usual* (BAU) del sector maíz y milpa. Dicha proyección consiste del análisis y descripción de las tendencias históricas del sector, además de su trayectoria esperada al mediano y largo plazo, particularmente en el contexto del cambio climático. El estudio abarca un periodo de 70 años entre 1980 a 2050. La proyección BAU aborda las principales variables agronómicas y económicas del sector, es decir, superficie, rendimiento, producción, valor bruto, consumo y comercio. Adicional a ello, sus implicaciones en la nutrición de la población.

1.2 Descripción del problema de investigación

La detección oportuna de plagas en cultivos de maíz sigue representando un desafío para los productores agrícolas. Sin embargo, el monitoreo tradicional basado en inspecciones manuales sigue siendo una práctica común, este proceso resulta ser lento, costoso y dependiente a la experiencia del agricultor para identificar signos de infestación. Este problema se agrava en la etapa de elote/milpa, cuando el crecimiento del cultivo dificulta la visibilidad y el acceso físico para inspeccionar el campo, limitando la capacidad de evaluar con precisión la magnitud de la plaga. Como resultado, las infestaciones suelen detectarse cuando el daño ya está bastante avanzado, afectando el rendimiento del cultivo e incrementando el uso de pesticidas (Amudha & Brindha, 2022).

En los últimos años se han desarrollado diversas soluciones basadas en *Machine Learning* y *Deep Learning* para automatizar la detección de plagas. Aunque el aprendizaje profundo ha mostrado mejores resultados, la literatura evidencia algunas limitaciones para su aplicación en campo, ya que muchos modelos se entrenan con bases de datos controladas, con fondos simples e iluminación uniforme (Pacal et al., 2024). Esto reduce su capacidad de generalización ante las variaciones reales del entorno agrícola, por lo que aún se requiere modelos capaces de mantener un desempeño adecuado en escenarios agrícolas reales que permitan una detección confiable de plagas en cultivos de maíz (Ahmad et al., 2023).

Por lo tanto, existe la necesidad de evaluar modelos de aprendizaje profundo capaces de detectar la presencia de plagas en cultivos de maíz a partir de imágenes capturadas en condiciones agrícolas reales mediante drones y celulares móviles. Esto permitió disponer de una alternativa de monitoreo fitosanitario que contribuya a mejorar una detección oportuna de infestación y apoye a la toma de decisiones en la gestión de una producción agrícola más sostenible (Nakalembe et al., 2021).

1.3 Objetivos

1.3.1 Objetivo general

Implementar una arquitectura de una red neuronal convolucional para la detección de plagas en cultivos de maíz mediante el análisis de imágenes capturadas por dron y celular.

1.3.2 Objetivos específicos

- Diseñar un conjunto de datos de imágenes de alta resolución que permita la identificación y clasificación de plagas en cultivos de maíz.
- Diseñar una arquitectura de una red neuronal convolucional para detectar la presencia de plagas en las áreas de cultivo de maíz.
- Validar la arquitectura de red neuronal diseñada a través del conjunto de pruebas de las imágenes con presencia y ausencia de plagas.

1.4 Justificación

El maíz es uno de los principales alimentos básicos a nivel mundial, desempeñando un papel fundamental en la seguridad alimentaria (Qian et al., 2022). La Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) considera al maíz como uno de los cultivos con mayor producción y consumo en el mundo (Paliwal, 2001). En México, la Secretaría de Agricultura y Desarrollo Rural lo considera como uno de los cultivos de mayor valor económico (SADER, 2023). Sin embargo, la producción de maíz enfrenta amenazas debido a plagas que afectan significativamente su rendimiento y calidad. El control habitual de estas plagas se basa principalmente en la aplicación masiva de pesticidas, aunque puede ser efectivo a corto plazo, genera consecuencias medioambientales, como la contaminación del suelo y los cultivos, así como riesgos para la salud humana (Masood et al., 2023).

Este estudio es esencial para la agricultura moderna, dado que las plagas representan una amenaza crítica para la producción de maíz, un cultivo clave a nivel mundial. Se estima que las plagas reducen entre un 20 y un 40% de la producción agrícola anual, lo que genera pérdidas significativas. Es por esto que los avances en tecnologías en la detección temprana de plagas mediante *Deep Learning* permitirán una gestión más efectiva y sostenible de los cultivos, minimizando pérdidas económicas (Haque et al., 2022).

La implementación de modelos automatizados para la detección de plagas en cultivos de maíz tiene el potencial de beneficiar tanto a pequeños como a grandes agricultores de todo el mundo, especialmente en regiones donde el acceso a tecnologías avanzadas es limitado. Estas herramientas permitirán mejorar el rendimiento y la calidad de los cultivos, al reducir la dependencia a pesticidas y fortalecer la seguridad alimentaria, teniendo un impacto positivo tanto en la salud pública como en la conservación del medio ambiente (Nakalembe et al., 2021).

1.5 Alcances y limitaciones

1.5.1 Alcances

- En este estudio se creó un conjunto de datos de imágenes de cultivos de maíz en etapas de espiga y elote, obtenidas en diferentes condiciones visuales en el entorno agrícola, para el entrenamiento y evaluación del modelo propuesto.
- Este trabajo de investigación diseñó e implementó un sistema basado en una arquitectura de red neuronal convolucional para la detección de plagas en cultivos de maíz.
- El conjunto de datos se formó utilizando imágenes capturadas de parcelas de cultivos de maíz, ubicadas en los municipios de Emiliano Zapata, Jojutla y Tlaltizapán, en el estado de Morelos, con el propósito de evaluar el desempeño de los modelos en el contexto agrícola local.

1.5.2 Limitaciones

- Esta investigación se enfocó en el análisis del desempeño de la arquitectura de aprendizaje profundo para la detección de plagas a partir de imágenes de campo en las que no siempre es posible observar directamente al insecto, sino únicamente las marcas, daños o evidencias que revelan su presencia.
- El análisis se realizó utilizando imágenes obtenidas durante las etapas de espiga y elote, por lo que los resultados reportados corresponden únicamente a estas condiciones.
- La validación del modelo se basó en el conjunto de datos preparado en esta investigación, por lo cual, las condiciones ambientales, las prácticas del manejo del cultivo, la variedad de cultivo y las condiciones de captura podrían variar de otros contextos agrícolas.

1.6 Organización del documento

La presente tesis se encuentra organizada por seis capítulos, además de este capítulo introductorio. En el segundo capítulo se presentan los conceptos fundamentales para brindar una mejor contextualización al desarrollo de la presente investigación. En el tercer capítulo se desarrolla la revisión de la literatura, donde se analizan los trabajos más relevantes relacionados con la detección de plagas mediante visión por computadora. El cuarto capítulo describe la metodología de solución, detallando las etapas seguidas para el desarrollo de la propuesta. El quinto capítulo se presenta la implementación de la solución, así como los casos de prueba realizados para evaluar la propuesta y analizar los resultados obtenidos. Finalmente, el sexto capítulo se detallan las conclusiones obtenidas de la investigación y trabajos futuros propuestos.

Capítulo 2. Marco conceptual

Este capítulo describe los conceptos clave y su relación en el ámbito de la agricultura de precisión. Esto permite comprender y contextualizar los términos teóricos y técnicos que se utilizan en esta investigación

2.1 Conceptos relacionados con inteligencia artificial

2.1.1 Inteligencia Artificial (IA)

Campo de estudio y desarrollo tecnológico dedicado a la creación de sistemas que repliquen procesos de inteligencia. La IA busca simular el comportamiento y pensamiento humano, centrándose en la fidelidad a los procesos cognitivos y conductuales del ser humano (Russell & Norvig, 2022).

La IA se puede definir como el esfuerzo de construir máquinas capaces de realizar tareas como si fueran realizadas por humanos. Esto incluye la capacidad de aprender, utilizar lenguaje natural, y resolver problemas de manera similar a los humanos, e incluso mejorar sus propias capacidades. Menciona que todos los aspectos de la inteligencia humana pueden realizarse con la precisión suficiente para ser simulados por máquinas (McCarthy et al., 1955).

2.1.2 Aprendizaje Automático (*Machine Learning, ML*)

Campo de la informática que se enfoca en desarrollar algoritmos y sistemas capaces de aprender a partir de datos, sin la necesidad de ser programados explícitamente para realizar tareas específicas. Es el área de estudio que otorga a las computadoras la habilidad de aprender de forma autónoma. El machine learning no implica simplemente tener acceso a grandes cantidades de datos, sino también la capacidad de procesarlos y adaptarse a partir de ellos para mejorar en tareas específicas (Géron, 2022).

2.1.3 Aprendizaje Profundo (*Deep Learning, DL*)

Es un enfoque de Aprendizaje Automático que utiliza arquitecturas de redes neuronales con múltiples capas (redes neuronales profundas) para identificar características y patrones en un gran conjunto de datos, simulando el funcionamiento del cerebro humano. Estas redes son capaces de aprender representaciones jerárquicas de la información, lo que las hace especialmente efectivas para tareas como la clasificación, la detección de objetos, el procesamiento del lenguaje natural, el reconocimiento de voz, la visión por

computadora y los sistemas de recomendación, permitiendo manejar datos no estructurados como imágenes y texto (IBM, 2024).

2.1.4 Aprendizaje por Transferencia (*Transfer Learning*)

Técnica que utiliza el conocimiento adquirido por un modelo de un contexto previo para mejorar su rendimiento en un nuevo entorno, basándose en factores comunes, como patrones o características. Por ejemplo, un modelo entrenado para clasificar imágenes de gatos y perros puede reutilizarse para identificar otras categorías visuales, como hormigas y avispas. Si la primera tarea dispone de un gran volumen de datos, el modelo puede desarrollar representaciones generales, como la detección de bordes, formas o efectos de cambios de iluminación, lo que facilita su adaptación a la nueva tarea incluso con pocos datos (Goodfellow et al., 2016).

2.1.5 Redes Neuronales Convolucionales (*Convolutional Neural Networks, CNN*)

Tipo especializado de red neuronal diseñado para procesar datos con una estructura de tipo rejilla, como series temporales (una rejilla unidimensional) o imágenes (una rejilla bidimensional de píxeles). Su principal característica es el uso de una operación matemática llamada convolución, que sustituye la multiplicación matricial general en al menos una de sus capas. Este enfoque ha demostrado ser altamente efectivo en aplicaciones prácticas, especialmente en tareas relacionadas con datos estructurados espacial o temporalmente (Goodfellow et al., 2016).

2.1.6 Arquitectura Red Residual (*Residual Networks, ResNet*)

Arquitectura de red profunda que incorpora conexiones de atajo o residuales, las cuales permiten que la información y los gradientes fluyan a través de la red. La idea central es en lugar de aprender una función directamente, la red aprende la diferencia (residual) entre la entrada y salida deseada, observar la Figura 1 para una mejor interpretación visual (K. He et al., 2015). Esta arquitectura presenta una mayor capacidad de generalización frente a redes tradicionales (Li et al., 2023).

Red Residual, Residual Network (ResNet)




Figura 1. Representación de Red Residual

Nota: Imagen generada con inteligencia artificial (Chat GPT, OpenAI, 2026).

2.2 Conceptos relacionados con la agricultura

2.2.1 Maíz (*zea mays*)

En el contexto mesoamericano, el maíz ocupa un papel importante como alimento, símbolo cultural y social de identidad tan profundo para los pueblos. Su producción colectiva y tradicional ha influido en las formas de trabajar el campo y en la organización social. Este cultivo es muy diverso y tiene la capacidad de adaptarse a diferentes ambientes. El maíz es un elemento clave que integra la naturaleza, la cultura, la alimentación, la economía y la identidad en la vida de los pueblos mesoamericanos (Carrillo, 2009).

2.2.2 Plaga agrícola

En el contexto de la agricultura, una plaga se define como cualquier organismo no deseado, incluyendo insectos, hongos, bacterias, virus, malezas, microorganismos o agentes patógenos que ocasiona efectos negativos sobre la producción y calidad

de los cultivos (Jara Calvo, 2014; Ha, 2014). Representan una amenaza debido a las pérdidas económicas, daños ambientales que ocasionan, por lo que su manejo requiere estrategias sostenibles que integren métodos preventivos, tecnológicos y biológicos (Gurr et al., 2003). En el caso específico del maíz, las plagas se pueden clasificar en los siguientes grupos, según sus hábitos alimenticios: las que se alimentan del follaje, las que atacan a la mazorca y las que afectan la raíz (SADER, s. f.)

2.2.3 Enfermedades

Las enfermedades foliares de importancia global del maíz son los tizones, las manchas y las royas de las hojas. Estas enfermedades son visibles y afectan principalmente la superficie fotosintética de las hojas, reduciendo la reproducción de la planta. Aunque no suelen causar la muerte total de la planta, disminuyen su capacidad fotosintética y en el caso del maíz, reducen tanto la cantidad como la calidad del forraje (Paliwal, 2001).

2.2.4 Gusano cogollero (*Spodoptera frugiperda*)

Plaga invasiva que afecta principalmente los cultivos de maíz, causando daños severos en hojas y estructuras de crecimiento de la planta. Debido a su rápida propagación y capacidad destructiva, es esencial su monitoreo y detección temprana (H. Zhang et al., 2022) (Chulu et al., 2019).

2.2.5 Agricultura de precisión

Enfoque tecnológico orientado a optimizar la producción agrícola mediante el uso de herramientas digitales, sensores, drones, imágenes y algoritmos de inteligencia artificial (Gupta & Kumar Pal, 2025). Su propósito es mejorar la toma de decisiones relacionadas con cultivos, plagas y recursos agrícolas, incrementando la productividad y reduciendo el impacto ambiental a través del monitoreo y análisis preciso de los campos agrícolas (Tiwari & Prakash, 2024).

2.3 Conceptos relacionados con la adquisición, preprocesamiento y aumentación de los datos

2.3.1 Imágenes de cultivos de maíz

Las imágenes de cultivos de maíz son representaciones visuales obtenidas mediante cámaras, drones o sensores remotos utilizadas para analizar características del cultivo, como el estado de las hojas, presencia de plagas o condiciones del suelo. Estas imágenes crean una base de datos fundamental para la investigación (M et al., 2025).

2.3.2 Imágenes capturadas por dron

Las imágenes capturadas por dron son fotografías aéreas obtenidas mediante vehículos aéreos no tripulados (UAVs), utilizadas para el monitoreo y análisis de cultivos agrícolas (Bouguettaya et al., 2022). Estas imágenes ofrecen alta resolución espacial y cobertura rápida de grandes áreas, facilitando aplicaciones de agricultura de precisión (J. Zhang et al., 2026).

2.3.3 Preprocesamiento de imágenes

El preprocesamiento de imágenes es una etapa fundamental en los sistemas de Aprendizaje Profundo que consiste en aplicar técnicas para mejorar la calidad, claridad e interpretabilidad de las imágenes antes del entrenamiento del modelo (Koresh, 2024). Este proceso incluye acciones como reducción de ruido, mejora de contraste, segmentación y normalización, con el objetivo de extraer información más relevante y optimizar el desempeño de las redes neuronales en tareas de clasificación y detección (Singh et al., 2023).

2.4 Conceptos relacionados con la evaluación de modelos

2.4.1 Métricas de evaluación

Las métricas de evaluación son medidas utilizadas para analizar el desempeño de un modelo en tareas de clasificación y detección. Esto permiten identificar fortalezas y debilidades del modelo, evaluando la calidad de las predicciones realizadas y su capacidad para reconocer correctamente las clases de interés (Timilsina et al., 2025).

2.4.2 Matriz de confusión

Evalúa el desempeño de modelos de clasificación, comparando las predicciones realizadas por el modelo con las clases reales. Esta matriz permite identificar aciertos y errores en cuatro componentes: verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP) y falsos negativos (FN) (Manai et al., 2024). Su estructura se presenta en la Figura 2.

Verdaderos Negativos	Falsos Positivos
Falsos Negativos	Verdaderos Positivos

Figura 2. Matriz de confusión.

2.4.3 Accuracy

Accuracy o exactitud es una métrica de evaluación que representa la proporción de predicciones correctas realizadas por un modelo respecto al total de predicciones realizadas, es decir, permite medir el desempeño general del modelo (Manai et al., 2024). Esta métrica puede calcularse mediante la siguiente fórmula:

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

2.4.4 Precision

Precision o precisión indica la proporción de casos clasificados correctamente como positivos respecto al total de predicciones positivas efectuadas por el modelo, evalúa la confiabilidad de las predicciones positivas (Manai et al., 2024). Se calcula siguiendo la fórmula:

$$Precision = \frac{VP}{VP + FP}$$

2.4.5 Recall

Recall o cobertura/sensibilidad mide la capacidad de un modelo para identificar correctamente todos los casos positivos presentes en un conjunto de datos, pretende encontrar la mayor cantidad de casos positivos reales (Manai et al., 2024). A continuación, se presenta su expresión matemática:

$$Recall = \frac{VP}{VP + FN}$$

2.4.6 F1-score

Esta métrica combina precisión y sensibilidad, evaluando el equilibrio entre la capacidad del modelo para detectar correctamente plagas y reducir errores de clasificación (Manai et al., 2024). Su cálculo se representa a través de la siguiente fórmula:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

2.4.7 Gráfico Receiver Operating Characteristics ROC

La curva de Características Operativa del Receptor (ROC, por sus siglas en inglés) es una métrica gráfica utilizada para evaluar el rendimiento del modelo en diferentes umbrales de decisión. Esta curva representa la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos, permitiendo analizar la capacidad del modelo para distinguir entre clases (Miao & Zhu, 2022).

2.4.8 Gráfico Precision-Recall PR

La curva Precision-Recall (PR) es una representación gráfica que evalúa la relación entre precisión y sensibilidad en distintos criterios. Esta curva analiza el comportamiento de un modelo respecto a la identificación de casos positivos y la confiabilidad de las predicciones realizadas (Miao & Zhu, 2022).

Capítulo 3. Revisión de la literatura

Este capítulo presenta el análisis de diversos trabajos relacionados con el tema de investigación desarrollado. Identificando los principales enfoques empleados en los estudios.

Para garantizar un enfoque estructurado en la revisión de la literatura de esta investigación, se adoptó la metodología propuesta por Pearl Brereton (Brereton et al., 2007), la cual se presenta en la Figura 3. Este proceso se compone de tres fases principales: planear la revisión, dirigir la revisión y documentar la revisión.




Figura 3. Protocolo de revisión de la literatura.

En la fase de planeación, se define el problema de investigación y se formulan las preguntas de investigación que orienten al estudio. Durante la fase de dirección, de identifican las fuentes de información y se seleccionan los estudios primarios de acuerdo a la cadena de búsqueda definida y aplicando criterios de inclusión. Además, en esta etapa se diseña un formulario de extracción de información, facilitando el análisis de los estudios seleccionados.

Finalmente, en la fase de documentación, se realiza un análisis detallado de los estudios seleccionados, respondiendo a las preguntas formuladas en la etapa de planear y se redacta el informe de la revisión.

A continuación, se describe lo que se realiza en cada una de las fases de metodología empleada.

3.1 Planear la revisión

3.1.1 Formular el problema de investigación

La detección de plagas en cultivos de maíz depende principalmente de inspección manual, la cual es lenta y poco eficiente especialmente en etapas de crecimiento avanzado del cultivo, donde la visibilidad y el acceso al campo es limitado. Esto provoca un diagnóstico a destiempo y pérdidas significativas en la producción.

En este trabajo se revisa la literatura específicamente en el uso de técnicas de Machine Learning y Deep Learning para detectar plagas y/o enfermedades en la producción agrícola.

3.1.2 Formular las preguntas de investigación

Las investigaciones seleccionadas buscan responder cinco preguntas principales, las cuales se describen a continuación:

- Q1. ¿Qué enfoque metodológico utilizan los autores del artículo para la detección de plagas en cultivos de maíz mediante imágenes?
- Q2. ¿Qué tipos específicos de plagas y/o enfermedades son abordados en el estudio del artículo?
- Q3. ¿Qué conjunto de datos o dataset utilizan los autores para validar la solución propuesta en su investigación?
- Q4. ¿Qué arquitectura de red neuronal o modelo de Deep Learning emplean los autores para la detección de plagas?
- Q5. Para la detección de plagas, ¿Qué métricas son abordadas en el artículo?

3.2 Dirigir la revisión

3.2.1 Seleccionar los estudios

Para llevar a cabo la búsqueda de trabajos relacionados con las preguntas de investigación, se seleccionaron cuatro bases de datos: Google Scholar, IEEE Xplore y ScienceDirect. Asimismo, se emplean tres cadenas de búsqueda, las cuales se observan en la Tabla 1.

Tabla 1. Cadenas de búsqueda.

Cadena	Descripción general
1	"machine learning" AND crops AND (pest OR disease) AND (detection OR classification)
2	"deep learning" AND crops (pest OR disease) AND (detection OR classification)
3	("machine learning AND "deep learning" AND "hybrid approach") AND crops AND (pest OR disease) AND (detection OR classification)

Se establecen los criterios de inclusión considerando artículos relevantes al tema de investigación, redactados en inglés, disponibles públicamente y publicados en

los últimos cinco años. Se aplica un primer filtro de revisión del título, resumen, palabras clave e introducción. Posteriormente, se evalúa el contenido completo de los textos, analizando el enfoque del estudio, la metodología empleada, los resultados obtenidos y las conclusiones presentadas. La Tabla 2 muestra la cantidad de estudios que cumplen con estos criterios de inclusión, alineados a las cinco preguntas de investigación formuladas en la sección 3.1.2.

Tabla 2. Selección de trabajos relacionados.

Base de datos	Cadenas de búsqueda	Estudios encontrados	Estudios candidatos	Estudios seleccionados
Google Académico	1, 2 y 3	562,700	30	14
ScienceDirect	1, 2 y 3	36,522	27	14
IEEE Xplore	1, 2 y 3	8,362	43	19

3.2.2 Extraer la información

Para obtener información relevante de los estudios seleccionados, se emplea un formulario de extracción, el cual se encuentra disponible en el Anexo A.

3.3 Documentar la revisión

3.3.1 Responder preguntas de investigación

En esta actividad se analizó y sintetizó la información recopilada a partir de los estudios seleccionados para ofrecer respuestas claras y fundamentadas en cada pregunta planteada en la sección 3.1.2, considerando los criterios de inclusión. Con el fin de destacar la importancia que tienen los estudios en el contexto de la investigación.

3.3.2 Redactar informe de revisión

Para la redacción del informe se organizó y presentó toda la información recopilada de manera clara y ordenada. Por lo que, con el análisis de los estudios seleccionados se detectaron tres enfoques principales que se muestran en la Figura 2. El nombre de estos enfoques se adopta en relación a cada estudio analizado, agrupando estudios que comparten técnicas utilizadas de estos enfoques.




Figura 4. Distribución de estudios seleccionados por enfoques.

El **enfoque A** corresponde a los estudios que utilizaron Machine Learning en imágenes.

El **enfoque B** corresponde a los trabajos que aplicaron Deep Learning a imágenes.

El **enfoque C** corresponde a la fusión de ambas técnicas (Machine Learning y Deep Learning) utilizadas en imágenes.

A continuación, se presenta una descripción resumida de cada estudio organizada de acuerdo al enfoque identificado.

3.4 Enfoque A. Machine Learning con imágenes

Los primeros avances en la detección automatizada de plagas y enfermedades agrícolas se apoyaron en algoritmos tradicionales de aprendizaje automático combinados con técnicas de procesamiento de imágenes. Esta metodología se centra en que las características relevantes deben identificarse y extraerse antes de utilizarse por algoritmos de clasificación.

Estos estudios utilizan segmentación de imágenes, extracción de textura, análisis espectral, índices de vegetación y algoritmos de clasificación supervisada. Entre los métodos más empleados destaca Máquina de Soporte Vectorial (SVM), por su

capacidad de trabajar con pocas muestras y una amplia cantidad de características en la imagen (Bagheri, 2020).

Dentro de este enfoque, los resultados muestran que se puede alcanzar niveles de desempeño competitivos. Diversos estudios han demostrado que las investigaciones basadas en teledetección multiespectral e índices de vegetación lograron identificar enfermedades en cultivos con exactitudes cercanas al 96%. De igual manera, la aplicación de técnicas de segmentación y análisis morfológico permitió detectar insectos en imágenes agrícolas, lo cual evidencia su potencial para apoyar en tareas de monitoreo fitosanitario (Kilaru & Raju, 2022).

3.5 Enfoque B. Deep Learning con imágenes

Con el avance de las redes neuronales convolucionales, diversos estudios comenzaron a orientarse en modelos capaces de aprender automáticamente atributos principales a partir de imágenes agrícolas (Kasinathan et al., 2021) (Zarboubi et al., 2023). Entre estos trabajos destacan los desarrollados por Kundu et al. (2022) y B. Wang (2022) quienes obtuvieron niveles de precisión superiores a 90%.

Actualmente, el aprendizaje profundo representa la principal tendencia de investigación en la detección automática de plagas y enfermedades agrícolas (Bonilla & Duke, 2024) (Yu et al., 2021). A diferencia de los enfoques tradicionales, estas técnicas permiten aprender automáticamente características relevantes directamente desde los datos, eliminando la necesidad de definir previamente qué aspectos visuales deben analizarse como el color, la textura o la forma (Arun & Umamaheswari, 2022), (Deb & Rahman, 2025).

La literatura analizada muestra una amplia adopción de arquitecturas CNN para la clasificación de plagas y enfermedades foliares en maíz. Modelos como VGG16 (Santhi et al., 2024), ResNet50 (I. Khan et al., 2024), DenseNet (Phan et al., 2022), InceptionV3 (Haque et al., 2022), GoogleNet (Pan et al., 2022) y EfficientNet (O'Halloran et al., 2024) han sido ampliamente utilizados debido a sus capacidad para identificar patrones visuales complejos asociados a síntomas fitopatológicos.

Una de las líneas más investigadas corresponde a la clasificación de enfermedades en hojas de maíz. Los resultados reportados demuestran un desempeño altamente satisfactorio y consistente en la identificación de enfermedades (Wahyuningrum et al., 2023), lo que demuestra la capacidad que tienen estos modelos para distinguir con precisión diferentes tipos de síntomas foliares (Xu et al., 2023) (J. He et al., 2023). Estas mejoras han sido favorecidas por la incorporación de mecanismos de atención espacial y de canal, técnicas de aprendizaje por transferencia (Albahli & Masood, 2022) (Vijaykanth Reddy & Sashi Rekha, 2021), las cuales buscan dirigir el proceso de aprendizaje hacia regiones relevantes en las imágenes, reduciendo el impacto del ruido de fondo y las variaciones ambientales (Masood et al., 2023) (Qian et al., 2022). En este contexto, propuestas como Mobile-DANet, MaizeNet, EANet y modelos basados en ResNet demostraron mejoras significativas en precisión y capacidad de generalización (Chen et al., 2021) (Ji et al., 2024).

Los modelos basados en ResNet y DenseNet han demostrado un desempeño sólido al adaptarse a diferentes conjuntos de datos y escenarios de evaluación (I. Khan et al., 2024) (Al-Shahari et al., 2024), mientras que las arquitecturas EfficientNet han permitido mejorar la precisión y eficiencia computacional (O'Halloran et al., 2024). Estudios como los de Jasrotia et al. (2023) y S. Zhang et al. (2024) han mostrado ventajas significativas en la identificación de síntomas y diferenciar enfermedades con características similares, siendo este un problema frecuentemente reportado en entornos agrícolas reales.

Otra línea de investigación importante, se orienta hacia la detección de plagas mediante técnicas de reconocimiento de objetos (F. Khan et al., 2023) (Ali et al., 2023). En este contexto, arquitecturas como YOLO, Faster R-CNN y MobileNet han sido utilizadas para localizar insectos bajo condiciones de campo. Estos estudios buscan superar las limitaciones asociadas al monitoreo manual y permitir una intervención temprana que reduzca las pérdidas productivas (X. Wang et al., 2021) (Vilar-Andreu et al., 2024).

De igual forma, estudios recientes incorporan imágenes capturadas mediante drones, sensores remotos y dispositivos móviles (Bijlwan et al., 2025). La integración de estas tecnologías ha impulsado el desarrollo de la agricultura de precisión capaces de monitorear grandes extensiones agrícolas de manera más eficiente y continua (Akhil et al., 2025) (Bharadwaja et al., 2025).

Además, la introducción de modelos de atención y mecanismos avanzados en aprendizaje profundo. Diversos estudios han explorado estrategias que permiten mejorar la extracción de características relevantes y la representación de patrones visuales complejos en imágenes agrícolas (Arun & Umamaheswari, 2022) (Kumar et al., 2025) (Mallick et al., 2025). Estas propuestas representan una nueva generación de sistemas que buscan incrementar la precisión y robustez de los procesos de detección y clasificación frente a las limitaciones observadas en arquitecturas convencionales (Ganesh et al., 2026) (S & Sharmila, 2026).

Dentro de este mismo enfoque, trabajos recientes exploran enfoques multitarea que permiten no solo detectar enfermedades o plagas, sino que estiman niveles de severidad, cuantificar infestaciones e incluso predecir el impacto de pérdida en la producción (Zhang et al., 2023) (Sun et al., 2026). Este tipo de soluciones refleja un avance progresivo de sistemas de clasificación simples hacia plataformas integrales de apoyo a la toma de decisiones agrícolas (Divyanth et al., 2023) (Singh Negi et al., 2026).

3.6 Enfoque C. Modelos Híbridos

Los modelos híbridos surgen como otra alternativa para aprovechar simultáneamente las fortalezas de Machine Learning y Deep Learning. En estos enfoques, las redes neuronales profundas suelen emplearse como extractores automáticos de características, mientras que algoritmos tradicionales son utilizados en las etapas finales de clasificación (Kirongo et al., 2024).

Los estudios analizados muestran que esta estrategia puede mejorar el rendimiento en escenarios donde existen limitaciones de datos o alta variabilidad en las imágenes. Como en el trabajo de Dash et al. (2023) corresponde a la combinación de DenseNet con máquinas de soporte vectorial, donde las características extraídas

por la red neuronal son utilizadas posteriormente por clasificadores tradicionales para distinguir entre tres enfermedades.

Algunos trabajos desarrollan arquitecturas híbridas específicas para la detección del gusano cogollero en maíz, combinando diferentes estructuras convolucionales para optimizar al mismo tiempo velocidad y precisión (Ishengoma et al., 2022). Estos sistemas han obtenido resultados competitivos en comparación con modelos de aprendizaje convencionales.

El estudio de Sujatha et al. (2021) compara algoritmos de aprendizaje automático y aprendizaje profundo con el propósito de identificar las configuraciones más adecuadas para diferentes contextos agrícolas. Los resultados indican que los modelos híbridos pueden ofrecer ventajas cuando los conjuntos de datos son limitados o cuando se requiere reducir costos computacionales.

3.7 Discusión de la revisión de la literatura

El análisis comparativo de la literatura permite identificar diferencias significativas entre los tres enfoques de investigación. Los métodos basados en Machine Learning presentan ventajas asociadas a su simplicidad, interpretabilidad y menor demanda computacional. Sin embargo, dependen fuertemente de la calidad de las características extraídas manualmente. Además, presentan limitaciones para adaptarse a escenarios agrícolas complejos cuando las condiciones de iluminación, fondo o variabilidad difieren de aquellas utilizadas durante el entrenamiento. La escalabilidad de estos métodos suele verse limitada al incrementar el número de clases o la complejidad visual de los síntomas y plagas analizadas.

A pesar de estas restricciones, los estudios desarrollados bajo el enfoque A representan la base metodológica de lo que posteriormente permitió el desarrollo de modelos más sofisticados basados en Deep Learning. Los modelos de aprendizaje profundo ofrecen mejores resultados reportados en términos de exactitud, eficiencia computacional y capacidad de generalización. Su habilidad para aprender características complejas y patrones distintivos de manera automática, les permite adaptarse a una amplia variedad de problemas agrícolas.

Además, facilitan la integración con tecnologías emergentes como drones, dispositivos móviles, sensores inteligentes y plataformas del internet de las cosas.

Si bien, los avances reportados comprueban un alto potencial para automatizar el diagnóstico fitosanitario, aún existen limitaciones relevantes que dificultan su implementación efectiva en entornos reales. Diversos modelos continúan siendo entrenados utilizando bases de datos controladas como PlantVillage, lo que limita su capacidad de generalización en condiciones reales de campo.

Por otro lado, el enfoque híbrido representa una opción complementaria que busca equilibrar precisión y eficiencia computacional. Sin embargo, la literatura indica que su adopción sigue siendo limitada en comparación con el crecimiento acelerado de las arquitecturas profundas. Este avance significativo ha orientado el interés hacia modelos basados en aprendizaje profundo, especialmente en aplicaciones que requieren detección en tiempo real y procesamiento de grandes volúmenes de datos visuales.

Actualmente, el aprendizaje profundo se ha posicionado como el enfoque predominante y más ampliamente adoptado en la detección automática de plagas y enfermedades agrícolas. La mayoría de las investigaciones se centra en la optimización de estas arquitecturas mediante mecanismos de atención, aprendizaje por transferencia y modelos multimodales.

La información completa de los estudios relacionados analizados se encuentra en el Anexo B, en el cual se presenta con mayor detalle la información recopilada durante la revisión de la literatura, incluyendo las aportaciones de cada uno de los trabajos analizados.

Capítulo 4. Metodología de solución

Este capítulo describe la metodología de solución al problema descrito en la sección 1.2 del presente trabajo de investigación.

Esta metodología propone combinar el análisis de imágenes capturadas por dron y celulares con técnicas avanzadas de aprendizaje profundo para enfrentar el desafío que representan las plagas en los cultivos de maíz y su impacto en la productividad y sostenibilidad agrícola. Este enfoque tiene como objetivo automatizar la detección de plagas, permitiendo una toma de decisiones oportuna y efectiva que contribuya a mitigar los daños en los cultivos reduciendo el uso de pesticidas.

A continuación, se describe la metodología propuesta, la cual está planteada en seis etapas para asegurar el funcionamiento y precisión del modelo a desarrollar, como se muestra en la Figura 5.




Figura 5. Metodología de solución.

4.1 Selección de un modelo de Aprendizaje Profundo

La primera etapa consistió en el análisis comparativo de tres arquitecturas de la familia ResNet empleadas para tareas de clasificación y reconocimiento de imágenes. Por esto, se consideraron criterios como el desempeño reportado en la literatura, la profundidad de la red, la capacidad de generalización y la eficiencia computacional. La Tabla 3 presenta una comparación de las principales características entre las arquitecturas ResNet evaluadas. A partir de este análisis, se seleccionó la arquitectura ResNet-50 debido a su equilibrio entre complejidad y rendimiento, así como por su capacidad para extraer características relevantes en problemas de visión por computadora relacionados con el ámbito agrícola. Posteriormente se realizó la comparación experimental con EfficientNetB0 y MobileNetV2.

Tabla 3. Comparación de las arquitecturas ResNet evaluadas con base a la literatura.

Criterio	ResNet34	ResNet50	ResNet101
Profundidad de la red	34 capas	50 capas	101 capas
Complejidad computacional	Menor	Intermedia	Mayor
Capacidad de generalización	Moderada	Alta	Muy alta, riesgo de sobreajuste con pocos datos

4.2 Recolección de datos

La recolección de datos se realizó mediante la captura de imágenes de cultivos de maíz en campo abierto durante la temporada de cosecha utilizando dispositivos móviles y un dron DJI M3 mini proporcionado por el Centro Nacional de Investigación y Desarrollo Tecnológico (TecNM/Cenidet). Esto permitió que las imágenes se obtuvieran bajo diferentes condiciones reales de iluminación, ángulos de captura y el ambiente del entorno, proporcionando un conjunto de datos representativo de las condiciones existentes en el escenario agrícola real. Estas imágenes recopiladas, se organizaron y etiquetaron para posteriormente utilizarlas en la etapa de preprocesamiento, entrenamiento y validación del modelo.

4.3 Preprocesamiento de imágenes

Una vez recolectado el conjunto de datos, las imágenes se sometieron a un proceso de preprocesamiento con el propósito de estandarizar su formato y asegurar su compatibilidad con el modelo de Aprendizaje Profundo. Las técnicas de preprocesamiento que se aplicaron son el redimensionamiento de las imágenes, la normalización de los valores del píxel, la aplicación de técnicas de aumentación de datos y la preparación del formato adecuado para la entrada de las imágenes

requerida por la arquitectura ResNet50. Estas técnicas permitieron mejorar la calidad del conjunto de datos, incrementar su diversidad y favorecer la capacidad de generalización del modelo. La Tabla 4 presenta las principales técnicas de preprocesamiento consideradas para esta investigación.

Tabla 4. Técnicas de preprocesamiento y aumentación de datos principales.

Técnica	Descripción
Normalización	Escala el valor de cada píxel de 0 a 255 a un rango de 0 a 1 (Géron, 2022).
Redimensionamiento (Resizing)	Ajuste del tamaño de la imagen al tamaño esperado para el modelo (Géron, 2022).
Rotación	Presenta variaciones de rotación en el sentido de las agujas del reloj, oscila entre 0 y 360 grados (Alshardan et al., 2025).
Recorte (Cropping)	Elimina partes innecesarias de la imagen para quedarse con el objeto de estudio (Dewi et al., 2023).
Brillo	Ajuste el brillo de la imagen a diferentes condiciones de iluminación (Alshardan et al., 2025).
Contraste / Contrast Limited Adaptive Histogram Equalization (CLAHE)	Aumento de contraste para resaltar detalles finos en regiones negras (Alshardan et al., 2025).
Volteo horizontal	Invierte la imagen en píxeles de columna y fila completos de izquierda a derecha (Alshardan et al., 2025).
Ruido Gaussiano / Distribución Gaussiana	Reduce ruido sin perder información relevante, suaviza la imagen (Sann, 2021).
Realce de bordes (Sharpening)	Hace que los bordes sean más pronunciados (Sann, 2021).
Conversión y compresión de formato	Normaliza imágenes a un mismo formato (PNG, JPG) (Géron, 2022).
Tileado de imágenes grandes	Divide imágenes muy grandes en mosaicos pequeños, reduciendo el uso de memoria y acelera el cálculo (Narayanaswamy et al., 2011).
Filtrado espectral o uso de índices vegetativos (si hay multiespectral)	Utiliza bandas adicionales para resaltar la salud vegetal (Gallinucci et al., 2020).

4.4 Diseño del modelo

En esta etapa se diseñó la arquitectura de clasificación basada en la red neuronal ResNet50 preentrenada. La red base fue empleada como extractor de características, manteniendo congelados los parámetros de las capas convolucionales durante el proceso de entrenamiento. Sobre esta arquitectura se añadieron capas finales para adaptar el modelo al problema de clasificación binaria de imágenes de cultivos de maíz con y sin presencia de plagas. La configuración propuesta incluyó una capa Global Average Pooling para reducir la dimensionalidad de las características extraídas, una capa Dropout como mecanismo de regularización y una capa densa de salida, encargada de realizar la clasificación de las imágenes.

4.5 Entrenamiento del modelo

El entrenamiento del modelo se realizó utilizando el 80% del conjunto total de imágenes de las imágenes obtenidas en las etapas anteriores. Durante este proceso, el modelo se entrenó para identificar patrones asociados a la presencia y ausencia de plagas en cultivos de maíz mediante un enfoque de clasificación binaria basado en aprendizaje profundo. Se ajustaron únicamente los parámetros de las capas finales integradas de la arquitectura ResNet50, sin realizar ninguna modificación a los parámetros entrenados previamente de la red base, para aprovechar las características anteriormente aprendidas.

4.6 Validación del modelo

La etapa final consistió en la evaluación del desempeño del modelo utilizando el subconjunto de datos independiente al empleado durante el entrenamiento. Para esto, se emplearon métricas de evaluación ampliamente utilizadas en problemas de clasificación, incluyendo exactitud, precisión, sensibilidad y puntaje F1. Estas métricas permitieron analizar la capacidad del modelo para distinguir correctamente

entre imágenes de cultivos de maíz con y sin presencia de plagas, proporcionando una evaluación general de su desempeño y capacidad de generalización.

Además, se realizó un análisis del comportamiento del modelo mediante gráficos de evaluación. Es por esto que se empleó la curva de Precisión-Sensibilidad (PR, Precision-Recall), la cual permite visualizar el equilibrio entre la precisión y la sensibilidad del clasificador. Asimismo, se utilizó la curva de Características Operativa del Receptor (ROC), representa la sensibilidad en relación con la tasa de falsos positivos, con el fin de evaluar la capacidad del modelo entre las clases de ausencia o presencia de plagas. Los resultados obtenidos a partir de estas gráficas, fortalecieron la interpretación de desempeño del modelo para su validación.

Capítulo 5. Implementación de la solución

Este capítulo presenta la preparación del conjunto de datos, el entrenamiento y la evaluación del desempeño de tres arquitecturas de Aprendizaje Profundo. Destacando la comparación de los resultados para identificar la arquitectura con mejor desempeño en la detección de plagas en cultivos de maíz.

5.1 Creación del dataset

Con el propósito de evaluar el desempeño del modelo en condiciones reales de cultivo, se emplearon imágenes capturadas directamente en campo. La recolección de datos se llevó a cabo en cultivos de maíz ubicados en cinco zonas de tres municipios del estado de Morelos (Emiliano Zapata, Jojutla y Tlaltizapán), ver Anexo B para mayor referencia de los cultivos, utilizando diversos dispositivos de adquisición, entre ellos teléfonos celulares y un dron DJI M3 mini proporcionado por el departamento de Comunicación y Eventos del Centro Nacional de Investigación y Desarrollo Tecnológico (TecNM/Cenidet).

Como resultado, se conformó un conjunto de datos integrado por 2,500 imágenes, clasificadas equitativamente en dos clases correspondientes a hojas sanas y hojas afectadas por plagas, 1,250 imágenes para cada categoría. El uso de imágenes a campo abierto permite evaluar la capacidad de generalización del modelo ante escenarios no controlados, caracterizados por variaciones en iluminación, perspectiva, resolución y condiciones ambientales propias del entorno agrícola.

La Figura 6 presenta el dron utilizado para la adquisición de imágenes, mientras que las Tablas 3 y 4 describen las principales especificaciones técnicas del equipo para comprender la capacidad de captura utilizada durante el desarrollo de la investigación (*DJI Mini 3 - Especificaciones - DJI*, s. f.).



Figura 6. Dron DJI M3 mini.

Tabla 5. Características de la aeronave.

Aeronave	
Peso	284 g
Altitud máxima	4000 m
Tiempo máximo de vuelo	38 min
Distancia máxima de vuelo	18 km

Tabla 6. Características de la cámara.

Cámara	
Píxeles	48 MP
Rango de ISO	100 - 3200
Tamaño máximo de imagen	8064 x 6048
Resolución de video	4K, FHD, HDR

La captura de imágenes utilizando el dron se realizó considerando distintos ángulos de adquisición, con el objetivo de obtener mayor diversidad visual del cultivo, como se muestra en la Figura 7. Se siguieron tres técnicas de captura: cenital (90° desde la perspectiva superior), inclinada a 45° y lateral (orientada de forma horizontal hacia el follaje). Esta diversidad de ángulos permitió ampliar la información visual del cultivo, aportando mayor diversidad al conjunto de datos para el análisis posterior




Figura 7. Ángulos de captura de imágenes por dron.

La Figura 8 presenta una imagen de un cultivo de maíz sano capturada por medio de un teléfono celular, se observan hojas con coloración verde uniforme, sin evidencia visible de daños, deformaciones o presencia de plagas. Por su parte, la Figura 9 muestra una imagen de un cultivo sano obtenida mediante dron, donde se aprecia una distribución homogénea de la vegetación uniforme de las plantas, características asociadas a un cultivo en condiciones saludables.



Figura 8. Imagen de cultivo de maíz sana capturada por celular.



Figura 9. Imagen de cultivo de maíz sana capturada por dron.

La Figura 10 muestra una imagen de un cultivo de maíz afectado por plagas capturada mediante un teléfono celular. En la imagen se identifican daños visibles en las hojas, tales como perforaciones, áreas de tejido consumido y bordes irregulares, síntomas comúnmente asociados a las afectaciones de plagas. Al igual, la Figura 11 presenta una imagen adquirida mediante dron, en la cual se observa la presencia de insectos sobre las plantas de maíz. Aunque el cultivo conserva una apariencia general saludable, la detección de estos organismos evidencia la existencia de una infestación que podría comprometer el desarrollo del cultivo si no se implementan medidas de control oportunas.



Figura 11. Imagen de cultivo de maíz con plaga capturada por celular.



Figura 10. Imagen de cultivo de maíz con plaga capturada por dron.

5.2 Preprocesamiento de imágenes

Una vez capturadas las imágenes, se aplicaron diversas técnicas de preprocesamiento con el objetivo de estandarizar el formato de los datos antes de utilizarse en el entrenamiento del modelo. Estas técnicas permitieron reducir variaciones de iluminación, el formato de almacenamiento y la presencia de ruido, para obtener un conjunto de datos más consistente. La Figura 12 presenta el flujo de preprocesamiento y preparación de datos aplicado a las imágenes utilizadas para el análisis de este estudio.




Figura 12. Flujo de preprocesamiento y preparación de imágenes.

Primeramente, se realizó la verificación de los archivos para asegurar que únicamente se incluyeran imágenes en formatos compatible (.jpg, .jpeg y .png). Posteriormente, las imágenes se etiquetaron dependiendo de la clase asignada entre cultivos de maíz sanos y cultivos de maíz con presencia de plaga. Después, las imágenes se redimensionaron a una resolución de 224x224 píxeles para adecuar el tamaño de entrada requerido por las arquitecturas ResNet. Una vez estandarizadas, el conjunto se dividió en dos subconjuntos: entrenamiento (80%) y validación (20%), lo que permite evaluar la capacidad de generalización del modelo con datos no utilizados durante el entrenamiento.

Posteriormente, las imágenes se normalizaron para ajustarlas al formato esperado por ResNet. Finalmente, en el entrenamiento se aplicó aumentación de datos con la finalidad de incrementar la variabilidad de las muestras. Las técnicas aplicadas se presentan en la Tabla 7.

Tabla 7. Técnicas de aumentación de datos aplicadas.

Técnica de preprocesamiento	Imagen
Original	
Volteo horizontal	
Rotación	
Zoom	
Contraste	

5.3 Entrenamiento y validación del modelo

Posteriormente, el conjunto de imágenes se dividió en dos subconjuntos destinados al entrenamiento y validación del modelo, utilizando una proporción de 80% y 20% respectivamente. Esta distribución facilita el entrenamiento del modelo con un conjunto de datos específico y evaluar posteriormente su desempeño sobre imágenes no utilizadas durante el aprendizaje. Lo cual es fundamental para medir la capacidad de generalización del modelo y reducir el riesgo de sobreajuste.

La Figura 13 muestra la distribución del conjunto de datos empleada para el entrenamiento y validación del modelo. El total de 2,500 imágenes de cultivos de maíz, se realizó una división en una proporción 80:20, designando 2,000 imágenes al conjunto de entrenamiento y 500 imágenes para el de validación. Esto permite al modelo identificar patrones asociados a las clases de cultivos de maíz sanas y con presencia de plaga, mientras que el conjunto de validación se utiliza para evaluar su desempeño y capacidad de generalización sobre muestras no vistas durante el entrenamiento.




Figura 13. Subconjuntos de entrenamiento y validación.

La Figura 14 ilustra el proceso de entrenamiento y clasificación empleado en este estudio. A partir del conjunto de entrenamiento conformado por 2,000 imágenes de

cultivos de maíz, la arquitectura ResNet se entrenó para reconocer patrones relacionados con la presencia y ausencia de plaga. Como resultado de este proceso se obtuvo la función hipótesis $h(x) = y$, la cual representa el modelo entrenado, generado por el algoritmo de aprendizaje profundo. Posteriormente, este modelo recibe como entrada una nueva imagen de un cultivo de maíz (x) y produce como salida una predicción (y), clasificándola como cultivo sano (0) o cultivo con presencia de plaga (1). Este proceso facilita automatizar la identificación de plagas a partir de imágenes no utilizadas durante el entrenamiento.




Figura 14. Proceso de entrenamiento y clasificación.

Una vez definido el proceso general de entrenamiento y clasificación del modelo, se realizó un diseño experimental que permitió comparar en mismas condiciones de entrenamiento y validación el desempeño de las arquitecturas de aprendizaje profundo para la detección de plagas en cultivos de maíz. En esta investigación se evaluaron tres redes neuronales convolucionales preentrenadas mediante aprendizaje por transferencia ResNet50, MobileNetV2 y EfficientNetB0, las cuales

se entrenaron con el mismo conjunto de datos, la misma división 80:20, mismas técnicas de aumento de datos, mismos parámetros y procedimiento de entrenamiento. La arquitectura fue la única variable experimental para realizar una comparación objetiva de su desempeño.

5.3.1 Planeación del experimento

La planeación del experimento tiene como propósito establecer una estructura de pasos a seguir para que los resultados sean válidos y reproducibles. Esta etapa se compone de cuatro partes: el objetivo experimental, la formulación de la pregunta de investigación experimental, la descripción del ambiente de prueba y el diseño experimental.

5.3.1.1 *Objetivo del experimento*

Comparar el desempeño de clasificación de las tres arquitecturas de redes neuronales convolucionales evaluadas (ResNet50, MobileNetV2 y EfficientNetB0), entrenadas basadas en aprendizaje por transferencia con el mismo conjunto de datos y las mismas condiciones de entrenamiento, para la tarea de detección de plagas en cultivos de maíz.

5.3.1.2 *Formulación de la pregunta*

¿Cuál de las arquitecturas ResNet50, MobileNetV2 y EfficientNetB0 alcanza el mejor desempeño en la clasificación de imágenes de cultivos de maíz sanos y con presencia de plagas, de acuerdo con las métricas de exactitud y F1-score obtenidas por el conjunto de validación?

5.3.1.3 *Ambiente de la prueba*

El experimento se ejecutó en un entorno de cómputo en la nube mediante la plataforma Google Colaboratory, la cual proporciona acceso a recursos de cómputo acelerado por GPU sin requerir infraestructura local dedicada. En la Tabla 8 se describen las principales características del entorno de hardware y software utilizado durante la ejecución de las pruebas.

Tabla 8. Características del ambiente de prueba.

Componente	Especificación
Plataforma	Google Colaboratory
Tipo de entorno de ejecución	GPU T4
GPU	NVIDIA GeForce RTX 2060 Mobile
RAM	32 GB
Sistema operativo	Ubuntu
Lenguaje de programación	Python (Python 3.10.12)
Framework de Deep Learning	TensorFlow / Keras
Bibliotecas adicionales	NumPy, Pandas, Matplotlib, Seaborn, OpenCv, scikit-learn
Conjunto de dato	2,500 imágenes (1,250 sanas / 1,250 con plaga)
Tamaño de entrada de las imágenes	224 x 224 píxeles, 3 canales (RGB)

5.3.1.4 Diseño del experimento

El experimento se diseñó como una comparación controlada de tres tratamientos (las tres arquitecturas), donde la variable independiente es la arquitectura de red neuronal convolucional utilizada como extractor de características. Para que la comparación sea válida, se mantuvieron fijas todas las demás condiciones del experimento, de manera que la única variable modificada fue la arquitectura empleada como modelo base.

a. Variables del experimento

Las variables consideradas en el diseño del experimento se describen en la Tabla 9.

Tabla 9. Variables consideradas en el diseño del experimento.

Tipo de variable	Descripción
Variable independiente	Arquitectura de red neuronal convolucional: ResNet50, MobileNetV2 y EfficientNetB0.
Variables dependientes (desempeño)	Exactitud, precisión, cobertura, F1-score, curva ROC (AUC-ROC) y curva PR.
Variables controladas	Conjunto de datos, división entrenamiento/validación (80:20), técnica de aumentación de datos, tamaño de entrada (224x224), optimizador (Adam), función de pérdida (entropía cruzada binaria), número máximo de épocas, criterios de paro temprano, semilla aleatoria.

b. Tratamientos evaluados

Con base en las variables definidas, se evaluaron tres tratamientos correspondientes a las tres arquitecturas comparadas, cada una utilizada como extractor de características preentrenado, con sus pesos congelados y el mismo esquema de clasificación binaria:

- Tratamiento 1: ResNet50 + GlobalAveragePooling2D + Dropout (0.3) + Dense (1, sigmoide)
- Tratamiento 2: MobileNetV2 + GlobalAveragePooling2D + Dropout (0.3) + Dense (1, sigmoide)
- Tratamiento 3: EfficientNetB0 + GlobalAveragePooling2D + Dropout (0.3) + Dense (1, sigmoide)

c. Procedimiento experimental

El procedimiento que se siguió para cada uno de los tres tratamientos es el siguiente:

1. Carga y verificación del conjunto de datos completo (2,500 imágenes), validando el formato de archivo y que cada imagen correctamente etiquetada como sana o con presencia de plaga.
2. División del conjunto de datos en entrenamiento (80%, 2,000 imágenes) y validación (20%, 500 imágenes), mediante muestreo aleatorio por clase, utilizando una semilla fija para garantizar que la misma repartición se reutilice en los tres tratamientos.
3. Construcción del modelo correspondiente a cada arquitectura, aplicando el preprocesamiento específico de cada una (normalización propia de ResNet50, de MobileNetV2 y EfficientNetB0).
4. Aplicación de aumentación de datos (volteo horizontal, rotación, zoom y ajuste de contraste) únicamente al conjunto de entrenamiento.
5. Entrenamiento del modelo durante un máximo de 30 épocas, con paro temprano basado en la pérdida de validación y reducción de la tasa de estancamiento en el aprendizaje.
6. Cálculo de las métricas de desempeño de clasificación y construcción de la matriz de confusión, curva ROC y PR, correspondientes a cada arquitectura.

5.3.2 Ejecución y resultados del experimento

En este apartado se documentan los resultados obtenidos al ejecutar el procedimiento experimental descrito en la sección 5.3.1.4, así como el análisis correspondiente en función a la pregunta de investigación experimental planteada en la sección 5.3.1.2.

5.3.2.1 *Correr las pruebas y recolectar los datos*

Las tres arquitecturas se entrenaron de manera consecutiva, siguiendo las condiciones descritas anteriormente. La Tabla 10 muestra un resumen del número de épocas efectivamente ejecutada por cada arquitectura antes de que el criterio de paro temprano detuviera el entrenamiento, y el tiempo total de entrenamiento.

Tabla 10. Resumen del entrenamiento por arquitectura.

Arquitectura	Épocas ejecutadas	Pérdida final (validación)
ResNet50	30	0.2868
MobileNetV2	30	0.4593
EfficientNetB0	30	0.4225

Una vez que el entrenamiento de cada arquitectura finalizó, se recolectaron las predicciones del conjunto de validación (500 imágenes), de las cuales se obtuvieron las métricas de desempeño de clasificación presentadas en la Tabla 11.

Tabla 11. Métricas de desempeño de clasificación por arquitectura.

Arquitectura	Accuracy	Precision	Recall	F1-score
ResNet50	89.4%	91.9%	86.4%	89.1%
MobileNetV2	78.2%	77.9%	78.8%	78.3%
EfficientNetB0	80.6%	81.0%	80.0%	80.5%

Con el propósito de complementar el análisis cuantitativo presentado en las tablas anteriores, se generaron las matrices de confusión, las curvas ROC y las curvas PR de las tres arquitecturas, las cuales se presentan en las Figuras 15, 16 y 17 lo que permiten visualizar de manera gráfica el desempeño de cada modelo durante el proceso de clasificación.




Figura 15. Matriz de confusión por arquitectura.




Figura 16. Curva ROC por arquitectura.




Figura 17. Curva PR por arquitectura.

5.3.2.2 *Análisis de los datos*

A partir de los datos recolectados en la sección 5.3.2.1 se procede a responder la pregunta de investigación experimental planteada en la sección 5.3.1.2.

a. Desempeño de clasificación

De acuerdo con los resultados de la Tabla 11, la arquitectura ResNet50 obtuvo el mayor desempeño general, alcanzando el valor más alto de accuracy (89.4%) y F1-score (89.1%), seguido por EfficientNetB0 con un F1-score de 80.5% y MobileNetV2 con 78.3%. En términos de diferencia, ResNet50 supera a EfficientNetB0 en 8.6 puntos porcentuales en F1-score y a MobileNetV2 en 10.8 puntos porcentuales, lo cual evidencia una diferencia significativa en el desempeño entre la arquitectura de mayor capacidad de representación y las arquitecturas ligeras evaluadas. Asimismo, aunque EfficientNetB0 presenta un comportamiento intermedio y más equilibrado entre precisión y recall, no logra alcanzar el nivel de desempeño de ResNet50 en ninguna de las métricas principales evaluadas.

Estos resultados indican que, para la tarea de detección de plagas en cultivos de maíz en entornos agrícolas reales, la mayor capacidad representacional de ResNet50 se refleja como un mejor rendimiento predictivo en comparación con las arquitecturas más ligeras. El análisis presentado en esta sección responde a la pregunta de investigación experimental planteada en la sección 5.3.1.2, aportando evidencia empírica, y no únicamente argumentos basados en la literatura revisada en el Capítulo 3) sobre lo conveniente de emplear una arquitectura más profunda frente a alternativas ligeras en el contexto de este estudio.

Capítulo 6. Conclusiones y trabajos futuros

Este capítulo presenta las conclusiones de la investigación, destacando sus principales resultados y aportaciones. Asimismo, se plantean los trabajos futuros y las publicaciones científicas derivadas del proyecto.

6.1 Conclusiones

Como resultado del desarrollo de la metodología propuesta, la implementación del modelo de aprendizaje profundo y la evaluación experimental descrita en el Capítulo 5, se puede concluir que se logra el objetivo general de esta investigación, el cual consistió en implementar una red neuronal convolucional para la detección de plagas en cultivos de maíz mediante imágenes capturadas con dron y dispositivos móviles en condiciones reales de campo.

La comparación experimental realizada entre las arquitecturas ResNet50, EfficientNetB0 y MobileNetV2 permitió identificar el comportamiento de cada modelo bajo las mismas condiciones de preprocesamiento, entrenamiento y validación. Los resultados obtenidos demostraron que ResNet50 presentó el mejor desempeño en la tarea de clasificación binaria entre cultivos sanos y cultivos con presencia de plagas, lo que pudo demostrar una mayor capacidad para extraer características diferenciadoras y generalizar sobre imágenes no utilizadas durante el entrenamiento.

La construcción de un conjunto de datos propio obtenido mediante dron y dispositivos móviles en parcelas agrícolas del estado de Morelos, forma un elemento relevante de la investigación. La utilización de este material capturado en condiciones reales de campo (en lugar de bases de datos limitadas a ambientes controlados), permitió evaluar el comportamiento de las arquitecturas de aprendizaje profundo en escenarios de aplicación agrícola real. Sin embargo, estas condiciones contienen variaciones de iluminación, perspectiva y fondo complejo, lo que incrementa el problema de clasificación.

El aprendizaje por transferencia permitió entrenar modelos de clasificación utilizando un conjunto de datos de tamaño pequeño, aprovechando el conocimiento previamente adquirido por arquitecturas entrenadas sobre grandes bases de datos de imágenes. De igual manera, la aplicación de técnicas de preprocesamiento y aumentación de datos contribuyó a mejorar la capacidad de generalización del

modelo, al incrementar la diversidad de las imágenes utilizadas durante el entrenamiento, reduciendo el riesgo de sobreajuste.

La comparación experimental realizada sobre las mismas condiciones de entrenamiento hizo posible determinar objetivamente que ResNet50 obtuvo el mejor desempeño entre las arquitecturas evaluadas, EfficientNetB0 y MobileNetV2 también mostraron resultados competitivos, aunque inferiores en las métricas de evaluación. Los resultados obtenidos evidencian que el aprendizaje profundo representa una alternativa viable para apoyar procesos de monitoreo fitosanitario dentro de la agricultura de precisión, favoreciendo la detección temprana de plagas y proporcionando información útil para la toma de decisiones.

6.2 Aportaciones

Esta investigación presenta las siguientes aportaciones:

- Se desarrolló un conjunto de datos propio conformado por 2,500 imágenes de cultivos de maíz capturadas en condiciones reales de campo mediante dron y dispositivos móviles, organizado para la clasificación binaria entre cultivos sanos y con presencia de plaga.
- Se implementó una metodología de preprocesamiento y aumentación de datos que facilitó preparar el conjunto para el entrenamiento de modelos de aprendizaje profundo mediante aprendizaje por transferencia.
- Se realizó una comparación experimental objetiva, entre las arquitecturas ResNet50, EfficientNetB0 y MobileNetV2, utilizando las mismas condiciones de entrenamiento, validación y evaluación, logrando identificar la arquitectura con mejor desempeño para el problema planteado.
- Se desarrolló un sistema basado en ResNet50 capaz de clasificar imágenes de cultivos de maíz con y sin presencia de plaga, demostrando la viabilidad del uso de redes neuronales convolucionales para aplicaciones en la agricultura de precisión.

- Los resultados obtenidos proporcionan evidencia experimental que puede ser de utilidad como referencia para futuras investigaciones relacionadas con la detección de plagas en campo abierto, mediante visión por computadora ya aprendizaje profundo.

6.3 Trabajos futuros

Como trabajo futuro se propone ampliar el conjunto de datos incorporando imágenes provenientes de diferentes estados de la República Mexicana, distintas variedades de maíz y diversas etapas de crecimiento del cultivo, con el propósito de incrementar la capacidad de generalización del modelo. Asimismo, es conveniente extender el problema de clasificación binaria a un sistema de multiclase que permita identificar diferentes especies de plagas presentes en el cultivo para proporcionar información más específica de apoyo a la toma de decisiones durante el manejo fitosanitario.

Se propone evaluar arquitecturas de aprendizaje profundo más recientes, incluyendo modelos basados en mecanismos de atención y modelos de lenguaje visual (VLM) o enfoques multimodales que permitan integrar información espacial y espectral, con el objetivo de comparar su desempeño de las redes neuronales convolucionales tradicionales. Al igual que incorporar técnicas de detección y segmentación de objetos que permita localizar de manera precisa las regiones afectadas dentro de la imagen, proporcionando información de mayor utilidad.

Por último, se plantea desarrollar una plataforma de monitoreo que integre el modelo entrenado con dron y dispositivos móviles para realizar inferencias en tiempo real durante los recorridos de inspección agrícola. Esta integración facilitaría la adopción de la solución propuesta por productores y agricultores, fortaleciendo los procesos de vigilancia fitosanitaria y contribuyendo al desarrollo de herramientas tecnológicas de apoyo para la producción de maíz.

6.4 Publicaciones

- Capistran-Abundez, A. J., López-Caballero, & Sánchez-Ruiz, A. (2024). Systematic literature review: Artificial Intelligence algorithms for pest detection in maize crops.
- Se publicó un póster en la cuarta edición del Congreso Internacional de Tecnología y Ciencia Aplicada (CITCA)
- Capistran-Abundez, A. J., López-Caballero, V., Sánchez-Ruiz, A. & Morales-Morales, L. (2026). Algoritmos de Inteligencia Artificial en la Agricultura de Precisión: Una Revisión Sistemática de la Literatura sobre la Detección de Plagas y Enfermedades en Maíz. En A. L. Ramos-Soto, D. Vázquez-Guzmán, J. Tarango & E. Cruz-Domínguez (Eds.), Investigación estratégica para el desarrollo sostenible y la agenda 2030 de las Naciones Unidas (pp. 30-50). Sello Editorial Americana / Knowledge & Science. Colombia.
- Capistran-Abundez, A. J., López-Caballero, V., Morales-Morales, L., & Sánchez-Ruiz, A. (2026). ¿Pueden las máquinas salvar al maíz? Aprendizaje profundo para la detección de plagas. En A. Escudero-Nahón (Ed.), Inteligencia artificial: experiencias y reflexiones sobre la investigación científica (pp. 142-158). Editorial Transdigital.
<https://doi.org/10.56162/transdigitalbc12.07>

Referencias

- Ahmad, A., Gamal, A. E., & Saraswat, D. (2023). Toward Generalization of Deep Learning-Based Plant Disease Identification Under Controlled and Field Conditions. *IEEE Access*, 11, 9042-9057. <https://doi.org/10.1109/ACCESS.2023.3240100>
- Akhil, P., Kumar, P. D., & S, L. P. (2025). Automated Pest Classification of Paddy Field using Drone Imagery. 2025 8th International Conference on Trends in Electronics and Informatics (ICOEI), 756-761. <https://doi.org/10.1109/ICOEI65986.2025.11013354>
- Albahli, S., & Masood, M. (2022). Efficient attention-based CNN network (EANet) for multi-class maize crop disease classification. *Frontiers in Plant Science*, 13, 1003152. <https://doi.org/10.3389/fpls.2022.1003152>
- Ali, F., Qayyum, H., & Iqbal, M. J. (2023). Faster-PestNet: A Lightweight Deep Learning Framework for Crop Pest Detection and Classification. *IEEE Access*, 11, 104016-104027. <https://doi.org/10.1109/ACCESS.2023.3317506>
- Al-Shahari, E. A., Aldehim, G., Sharaf Almalki, N., Assiri, M., Sayed, A., & Alnfai, M. M. (2024). Innovative Insect Detection and Classification for the Agricultural Sector Using Gannet Optimization Algorithm With Deep Learning. *IEEE Access*, 12, 108041-108051. <https://doi.org/10.1109/ACCESS.2024.3438308>
- Arun, R. A., & Umamaheswari, S. (2022). Effective and efficient multi-crop pest detection based on deep learning object detection models. *Journal of Intelligent & Fuzzy Systems*, 43(4), 5185-5203. <https://doi.org/10.3233/JIFS-220595>
- Bagheri, N. (2020). Application of aerial remote sensing technology for detection of fire blight infected pear trees. *Computers and Electronics in Agriculture*, 168, 105147. <https://doi.org/10.1016/j.compag.2019.105147>
- Bharadwaja, V., Bn, S., Mt, P., Tarafdar, R., Santiago, S., & Jegajothi, B. (2025). Deep Learning-Powered UAV Surveillance for Automated Pest Control in Smart Farms. 2025 8th International Conference on Computing Methodologies and Communication (ICCMC), 37-43. <https://doi.org/10.1109/ICCMC65190.2025.11140868>
- Bijlwan, A., Ranjan, R., Pokhariyal, S., Govind, A., Singh, M., Singh, K. P., Singh, R. K., Rajput, R. K. S., & Srivastava, R. K. (2025). Enhancing rice disease and insect-pest detection through augmented deep learning with transfer learning techniques. *Smart Agricultural Technology*, 11, 100954. <https://doi.org/10.1016/j.atech.2025.100954>
- Bonilla, Ó. S. O., & Duke, A. M. R. (2024). Convolutional Neural Network Modeling for Pest Detection in Corn Crops: Optimization for Monitoring Efficiency. 2024 9th International Conference on Control and Robotics Engineering (ICCRE), 334-338. <https://doi.org/10.1109/ICCRE61448.2024.10589895>
- Bouguettaya, A., Zarzour, H., Kechida, A., & Taberkit, A. M. (2022). Deep learning techniques to classify agricultural crops through UAV imagery: A review. *Neural Computing and Applications*, 34(12), 9511-9536. <https://doi.org/10.1007/s00521-022-07104-9>
- Brereton, P., Kitchenham, B. A., Budgen, D., Turner, M., & Khalil, M. (2007). Lessons from applying the systematic literature review process within the software

- engineering domain. *Journal of Systems and Software*, 80(4), 571-583. <https://doi.org/10.1016/j.jss.2006.07.009>
- Carrillo, C. (2009). El origen del maíz. *Naturaleza y cultura en Mesoamérica. Ciencias*, 92-93(092), 9-11.
- Chen, J., Wang, W., Zhang, D., Zeb, A., & Nanekharan, Y. A. (2021). Attention embedded lightweight network for maize disease recognition. *Plant Pathology*, 70(3), 630-642. <https://doi.org/10.1111/ppa.13322>
- Chulu, F., Phiri, J., O.Y., P., Nyirenda, M., M.Kabemba, M., & H.Sohati, P. (2019). A Convolutional Neural Network for Automatic Identification and Classification of Fall Army Worm Moth. *International Journal of Advanced Computer Science and Applications*, 10(7). <https://doi.org/10.14569/IJACSA.2019.0100717>
- Dash, A., Sethy, P. K., & Behera, S. K. (2023). Maize disease identification based on optimized support vector machine using deep feature of DenseNet201. *Journal of Agriculture and Food Research*, 14, 100824. <https://doi.org/10.1016/j.jafr.2023.100824>
- Deb, N., & Rahman, T. (2025). An efficient VGG16-based deep learning model for automated potato pest detection.
- Divyanth, L. G., Ahmad, A., & Saraswat, D. (2023). A two-stage deep-learning based segmentation model for crop disease quantification based on corn field imagery. *Smart Agricultural Technology*, 3, 100108. <https://doi.org/10.1016/j.atech.2022.100108>
- Ganesh, D., Kumar, M. S., Tejaswi, M. L., Vanaja, P., Kumar, R. B., & Kumar, S. A. (2026). PEST-AWARE: A Physics-Enhanced Spatio-Temporal Attention Framework for Robust Crop Pest Detection in Precision Agriculture. 2026 4th International Conference on Artificial Intelligence and Machine Learning Applications Theme: Healthcare and Internet of Things (AIMLA), 1-7. <https://doi.org/10.1109/AIMLA67915.2026.11522283>
- Géron, A. (2022). Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, Inc.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gupta, G., & Kumar Pal, S. (2025). Applications of AI in precision agriculture. *Discover Agriculture*, 3(1), 61. <https://doi.org/10.1007/s44279-025-00220-9>
- Gurr, G. M., Wratten, S. D., & Luna, J. M. (2003). Multi-function agricultural biodiversity: Pest management and other benefits. *Basic and Applied Ecology*, 4(2), 107-116. <https://doi.org/10.1078/1439-1791-00122>
- Ha, T. M. (2014). A Review on the Development of Integrated Pest Management and Its Integration in Modern Agriculture.
- Haque, Md. A., Marwaha, S., Deb, C. K., Nigam, S., Arora, A., Hooda, K. S., Soujanya, P. L., Aggarwal, S. K., Lall, B., Kumar, M., Islam, S., Panwar, M., Kumar, P., & Agrawal, R. C. (2022). Deep learning-based approach for identification of diseases of maize crop. *Scientific Reports*, 12(1), 6334. <https://doi.org/10.1038/s41598-022-10140-z>
- He, J., Liu, T., Li, L., Hu, Y., & Zhou, G. (2023). MFaster R-CNN for Maize Leaf Diseases Detection Based on Machine Vision. *Arabian Journal for Science and Engineering*, 48(2), 1437-1449. <https://doi.org/10.1007/s13369-022-06851-0>

- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition (arXiv:1512.03385). arXiv. <https://doi.org/10.48550/arXiv.1512.03385>
- Hernández Solano, A., Dyer, G. A., Camacho Villa, T. C., Sulser, T., Becerril García, J., Burrola Méndez, S. I., Sonder, K., Meza Pale, P., Zepeda Villareal, A., Ancira Moreno, M. M., Ramírez Silva, C. I., Rendón Medel, R., & Serratos Hernández, J. A. (2021). Reporte Técnico Final del Proyecto TEEB AgriFood Maíz-Milpa. Tomo I. Proyección business-as-usual (BAU) del sector maíz y milpa en México en el contexto del cambio climático (p. 269).
- IBM. (2024). Deep Learning: Qué es y cómo funciona. <https://www.ibm.com/mx-es/topics/deep-learning>
- Ishengoma, F. S., Rai, I. A., & Said, R. N. (2021). Identification of maize leaves infected by fall armyworms using UAV-based imagery and convolutional neural networks. *Computers and Electronics in Agriculture*, 184, 106124. <https://doi.org/10.1016/j.compag.2021.106124>
- Jara Calvo, T. W. (2014). Manejo integrado del cultivo y las plagas del maíz.
- Jasrotia, S., Yadav, J., Rajpal, N., Arora, M., & Chaudhary, J. (2023). Convolutional Neural Network Based Maize Plant Disease Identification. *Procedia Computer Science*, 218, 1712-1721. <https://doi.org/10.1016/j.procs.2023.01.149>
- Ji, Z., Bao, S., Chen, M., & Wei, L. (2024). ICS-ResNet: A Lightweight Network for Maize Leaf Disease Classification. *Agronomy*, 14(7), 1587. <https://doi.org/10.3390/agronomy14071587>
- Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, 8(3), 446-457. <https://doi.org/10.1016/j.inpa.2020.09.006>
- Khan, F., Zafar, N., Tahir, M. N., Aqib, M., Waheed, H., & Haroon, Z. (2023). A mobile-based system for maize plant leaf disease detection and classification using deep learning. *Frontiers in Plant Science*, 14, 1079366. <https://doi.org/10.3389/fpls.2023.1079366>
- Khan, I., Sohail, S. S., Madsen, D. Ø., & Khare, B. K. (2024). Deep transfer learning for fine-grained maize leaf disease classification. *Journal of Agriculture and Food Research*, 16, 101148. <https://doi.org/10.1016/j.jafr.2024.101148>
- Kilaru, R., & Raju, K. M. (2022). Prediction of Maize Leaf Disease Detection to improve Crop Yield using Machine Learning based Models. 2021 4th International Conference on Recent Trends in Computer Science and Technology (ICRTCST), 212-217. <https://doi.org/10.1109/ICRTCST54752.2022.9782023>
- Kirongo, A. C., Muketha, G. M., Mworio, E., & Maitethia, D. (2024). Application of Real-Time Deep Learning in integrated Surveillance of Maize and Tomato Pests and Bacterial Diseases. *Journal of the Kenya National Commission for UNESCO*. <https://doi.org/10.62049/jkncu.v4i1.46>
- Koresh, H. J. D. (2024). Impact of the Preprocessing Steps in Deep Learning-Based Image Classifications. *National Academy Science Letters*, 47(6), 645-647. <https://doi.org/10.1007/s40009-023-01372-2>
- Kumar, M. S., Usha, R., Reddy, B. R. K., Ramachandra, S., Prakash, P. J., & Swetha, B. (2025). Deep Learning Driven—Pest Classification and Sustainable

- Agriculture. 2025 International Conference on Electronics and Renewable Systems (ICEARS), 1759-1762. <https://doi.org/10.1109/ICEARS64219.2025.10940311>
- Kundu, N., Rani, G., Dhaka, V. S., Gupta, K., Nayaka, S. C., Vocaturo, E., & Zumpano, E. (2022). Disease detection, severity prediction, and crop loss estimation in MaizeCrop using deep learning. *Artificial Intelligence in Agriculture*, 6, 276-291. <https://doi.org/10.1016/j.aiaa.2022.11.002>
- Li, H., Wang, Z., Yue, X., Wang, W., Tomiyama, H., & Meng, L. (2023). An architecture-level analysis on deep learning models for low-impact computations. *Artificial Intelligence Review*, 56(3), 1971-2010. <https://doi.org/10.1007/s10462-022-10221-5>
- M, T., Trivedi, S., Gupta, D., & Bagaria, P. K. (2025). UAV Based Maize Crop Images Classification as Leaf and Soil Using Color Space and Machine Learning Models. 2025 11th International Conference on Communication and Signal Processing (ICCSP), 229-233. <https://doi.org/10.1109/ICCSP64183.2025.11088677>
- Mallick, M. T., Murty, D. O., Pal, R., Mandal, S., Saha, H. N., & Chakrabarti, A. (2025). High-speed system-on-chip-based platform for real-time crop disease and pest detection using deep learning techniques. *Computers and Electrical Engineering*, 123, 110182. <https://doi.org/10.1016/j.compeleceng.2025.110182>
- Manai, E., Mejri, M., & Fattahi, J. (2024). Confusion Matrix Explainability to Improve Model Performance: Application to Network Intrusion Detection. 2024 10th International Conference on Control, Decision and Information Technologies (CoDIT), 1-5. <https://doi.org/10.1109/CoDIT62066.2024.10708595>
- Masood, M., Nawaz, M., Nazir, T., Javed, A., Alkanhel, R., Elmannai, H., Dhahbi, S., & Bourouis, S. (2023). MaizeNet: A Deep Learning Approach for Effective Recognition of Maize Plant Leaf Diseases. *IEEE Access*, 11, 52862-52876. <https://doi.org/10.1109/ACCESS.2023.3280260>
- McCarthy, J., Minsky, M., Shannon, C. E., & Rochester, N. (1955). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. Dartmouth College.
- Miao, J., & Zhu, W. (2022). Precision–recall curve (PRC) classification trees. *Evolutionary Intelligence*, 15(3), 1545-1569. <https://doi.org/10.1007/s12065-021-00565-2>
- Nakalembe, C., Becker-Reshef, I., Bonifacio, R., Hu, G., Humber, M. L., Justice, C. J., Keniston, J., Mwangi, K., Rembold, F., Shukla, S., Urbano, F., Whitcraft, A. K., Li, Y., Zappacosta, M., Jarvis, I., & Sanchez, A. (2021). A review of satellite-based global agricultural monitoring systems available for Africa. *Global Food Security*, 29, 100543. <https://doi.org/10.1016/j.gfs.2021.100543>
- O'Halloran, T., Obaido, G., Otegbade, B., & Mienye, I. D. (2024). A deep learning approach for Maize Lethal Necrosis and Maize Streak Virus disease detection. *Machine Learning with Applications*, 16, 100556. <https://doi.org/10.1016/j.mlwa.2024.100556>
- Pacal, I., Kunduracioglu, I., Alma, M. H., Deveci, M., Kadry, S., Nedoma, J., Slany, V., & Martinek, R. (2024). A systematic review of deep learning techniques for plant diseases. *Artificial Intelligence Review*, 57(11), 304. <https://doi.org/10.1007/s10462-024-10944-7>

- Paliwal, R. L. (2001). EL MAÍZ. El Maiz en Los Tropicos: Mejoramiento Y Produccion (Coleccion FAO: Produccion Y Proteccion Vegetal), (28).
- Pan, S., Qiao, J., Wang, R., Yu, H., Wang, C., Taylor, K., & Pan, H. (2022). Intelligent diagnosis of northern corn leaf blight with deep learning model. *Journal of Integrative Agriculture*, 21(4), 1094-1105. [https://doi.org/10.1016/S2095-3119\(21\)63707-3](https://doi.org/10.1016/S2095-3119(21)63707-3)
- Phan, H., Ahmad, A., & Saraswat, D. (2022). Identification of Foliar Disease Regions on Corn Leaves Using SLIC Segmentation and Deep Learning Under Uniform Background and Field Conditions. *IEEE Access*, 10, 111985-111995. <https://doi.org/10.1109/ACCESS.2022.3215497>
- Qian, X., Zhang, C., Chen, L., & Li, K. (2022). Deep Learning-Based Identification of Maize Leaf Diseases Is Improved by an Attention Mechanism: Self-Attention. *Frontiers in Plant Science*, 13, 864486. <https://doi.org/10.3389/fpls.2022.864486>
- SADER. (s. f.). Maíz, cultivo de México. gob.mx. Recuperado 8 de diciembre de 2024, de <http://www.gob.mx/agricultura/articulos/maiz-cultivo-de-mexico>
- Russell, S. J., & Norvig, P. (with Chang, M., Devlin, J., Dragan, A., Forsyth, D., Goodfellow, I., Malik, J., Mansinghka, V., Pearl, J., & Wooldridge, M. J.). (2022). *Artificial intelligence: A modern approach* (Fourth edition, global edition). Pearson.
- S, S. C. C., & Sharmila, K. (2026). An Intelligent Deep Learning Framework for Automated Pest Detection in Coconut Trees. 2026 7th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI), 738-743. <https://doi.org/10.1109/ICMCSI67283.2026.11412952>
- SADER. (s. f.). MANUAL DE PLAGAS Y ENFERMEDADES EN MAIZ (Campaña Manejo Fitosanitario de Cultivos Básicos, p. 20). Secretaría de Desarrollo Agroalimentario y Grandeza de México Rural.
- Sánchez-del Cid, E. L., Rendón-von Osten, J., González-Chávez, M. D. C. Á., Torres-Dosal, A., & Huerta-Lwanga, E. (2025). Pesticide residues in tropical agricultural soils: Distribution, seasonality, and earthworm ecological risk. *Emerging Contaminants*, 11(1), 100436. <https://doi.org/10.1016/j.emcon.2024.100436>
- Santhi, S., Murugan, M., Srinivasan, T., & Kg, S. (2024). Corn Leaf Disease Detection using Deep Learning Techniques. 2024 2nd International Conference on Sustainable Computing and Smart Systems (ICSCSS), 1536-1540. <https://doi.org/10.1109/ICSCSS60660.2024.10625229>
- Singh, N. T., Kaur, C., Chaudhary, A., & Goyal, S. (2023). Preprocessing of Medical Images using Deep Learning: A Comprehensive Review. 2023 Second International Conference on Augmented Intelligence and Sustainable Systems (ICAISS), 521-527. <https://doi.org/10.1109/ICAISS58487.2023.10250462>
- Singh Negi, A., Rawat, A., Rawat, B., Bhardwaj, R., Khwairakpam, R., & Agarwal, V. (2026). An Efficient ConvNeXt-Based Transfer Learning Approach for Agricultural Pest Classification. 2026 4th International Conference on Knowledge Engineering and Communication Systems (ICKECS), 1-6. <https://doi.org/10.1109/ICKECS70176.2026.11528046>
- Sujatha, R., Chatterjee, J. M., Jhanjhi, N., & Brohi, S. N. (2021). Performance of deep learning vs machine learning in plant leaf disease detection.

- Microprocessors and Microsystems, 80, 103615.
<https://doi.org/10.1016/j.micpro.2020.103615>
- Sun, F., Guan, Z., Lyu, Z., Zhen, T., Liu, S., & Li, X. (2026). Efficient and lightweight deep learning model for small-object detection in stored grain pest management. *Journal of Stored Products Research*, 115, 102890.
<https://doi.org/10.1016/j.jspr.2025.102890>
- Timilsina, S., Sharma, S., & Kondo, S. (2025). Advancements in maize leaf disease detection, segmentation and classification: A review. *Biosystems Engineering*, 255, 104162. <https://doi.org/10.1016/j.biosystemseng.2025.104162>
- Tiwari, V., & Prakash, S. (2024). Enhancement of Farming Using IoT Based Unmanned Aerial Vehicles. 2024 2nd International Conference on Disruptive Technologies (ICDT), 941-948.
<https://doi.org/10.1109/ICDT61202.2024.10489272>
- Vijaykanth Reddy, T., & Sashi Rekha, K. (2021). Deep Leaf Disease Prediction Framework (DLDPF) with Transfer Learning for Automatic Leaf Disease Detection. 2021 5th International Conference on Computing Methodologies and Communication (ICCMC), 1408-1415.
<https://doi.org/10.1109/ICCMC51019.2021.9418245>
- Vilar-Andreu, M., García, L., Garcia-Sanchez, A.-J., Asorey-Cacheda, R., & Garcia-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>
- Wahyuningrum, R. T., Kusumaningsih, A., & Yousi, D. M. (2023). Classification of Corn Leaf Diseases using Loss-Fused Convolutional Neural Network. 2023 International Conference on Information Management and Technology (ICIMTech), 696-701. <https://doi.org/10.1109/ICIMTech59029.2023.10277763>
- Wang, B. (2022). Identification of Crop Diseases and Insect Pests Based on Deep Learning. *Scientific Programming*, 2022, 1-10.
<https://doi.org/10.1155/2022/9179998>
- Wang, X., Liu, J., & Zhu, X. (2021). Early real-time detection algorithm of tomato diseases and pests in the natural environment. *Plant Methods*, 17(1), 43.
<https://doi.org/10.1186/s13007-021-00745-2>
- Xu, W., Li, W., Wang, L., & Pompelli, M. F. (2023). Enhancing Corn Pest and Disease Recognition through Deep Learning: A Comprehensive Analysis. *Agronomy*, 13(9), 2242. <https://doi.org/10.3390/agronomy13092242>
- Yu, H., Liu, J., Chen, C., Heidari, A. A., Zhang, Q., Chen, H., Mafarja, M., & Turabieh, H. (2021). Corn Leaf Diseases Diagnosis Based on K-Means Clustering and Deep Learning. *IEEE Access*, 9, 143824-143835.
<https://doi.org/10.1109/ACCESS.2021.3120379>
- Zarboubi, M., Chabaa, S., & Dliou, A. (2023). Advancing Precision Agriculture with Deep Learning and IoT Integration for Effective Tomato Pest Management. 2023 IEEE International Conference on Advances in Data-Driven Analytics And Intelligent Systems (ADACIS), 1-6.
<https://doi.org/10.1109/ADACIS59737.2023.10424149>
- Zhang, C., Hu, Z., Xu, L., & Zhao, Y. (2023). A YOLOv7 incorporating the Adan optimizer based corn pests identification method. *Frontiers in Plant Science*, 14, 1174556. <https://doi.org/10.3389/fpls.2023.1174556>

- Zhang, H., Zhao, S., Song, Y., Ge, S., Liu, D., Yang, X., & Wu, K. (2022). A deep learning and Grad-Cam-based approach for accurate identification of the fall armyworm (*Spodoptera frugiperda*) in maize fields. *Computers and Electronics in Agriculture*, 202, 107440. <https://doi.org/10.1016/j.compag.2022.107440>
- Zhang, J., Dong, N., Ma, J., Cai, H., & Shi, P. (2026). A temporally transferrable approach for quantifying crop residue cover: Linking deep learning of UAV images with satellite-based spectral modelling. *Biosystems Engineering*, 264, 104418. <https://doi.org/10.1016/j.biosystemseng.2026.104418>
- Zhang, S., Wang, H., Zhang, C., Liu, Z., Jiang, Y., & Yu, L. (2024). JutePest-YOLO: A Deep Learning Network for Jute Pest Identification and Detection. *IEEE Access*, 12, 72938-72956. <https://doi.org/10.1109/ACCESS.2024.3403491>

ANEXOS

Anexo A. Formulario de extracción de información.

Tabla A1. Formulario de extracción respondido por artículo.

INFORMACIÓN GENERAL	
Información a extraer	Anotaciones del revisor
Identificador del artículo:	ART_039A
Nombre de la persona que revisó el artículo:	Andrea Sánchez Ruiz
Título del artículo:	An efficient VGG16-based deep learning model for automated potato pest detection
Autores del artículo:	Nibedita Deb, TawfikurRahman
Año de publicación del artículo:	2025
Base de datos donde se encontró el artículo:	Science Direct
Palabras clave del artículo:	Deep learning, VGG16, Potato pest detection, Image classification, Precision agriculture
RESULTADOS OBJETIVOS	
¿El objetivo del artículo está claramente establecido (especifíquelo)?	Desarrollar un modelo de Deep Learning preciso y eficiente basado en la arquitectura VGG16 para automatizar la detección y selección en plagas de papas
Problema que aborda el artículo:	Las técnicas tradicionales de detección de plagas implican la inspección manual del terreno por expertos, requiere mucha mano de obra, implica mucho tiempo y suele ser subjetivo. Estos métodos no son escalables para zonas agrícolas a gran escala, especialmente en entornos con escasos recursos
¿El artículo plantea alguna pregunta de investigación?	No
Resumen del artículo:	La detección oportuna y precisa de las plagas de la patata es fundamental para mitigar las pérdidas de cosechas y fomentar la agricultura sostenible. Este estudio presenta un modelo eficiente de aprendizaje profundo basado en la arquitectura VGG16 para la clasificación automatizada de las plagas comunes de las

INFORMACIÓN GENERAL	
Información a extraer	Anotaciones del revisor
	hojas de la patata, entre las que se incluyen los pulgones, el escarabajo de la patata de Colorado, los minadores de hojas y las mariquitas. Se recopiló un conjunto de datos seleccionado de 3.000 imágenes anotadas, que incluía tanto hojas infectadas por plagas como hojas sanas, a partir de imágenes reales de campo tomadas directamente en zonas agrícolas rurales. Para mejorar la generalización, el modelo se ajustó mediante aprendizaje por transferencia y se optimizó con técnicas de aumento de datos, como la rotación, el volteo, el zoom y el ajuste del contraste. Los resultados experimentales demuestran que el modelo propuesto, basado en VGG16, alcanza un rendimiento superior en las métricas de exactitud (96,3 %), precisión (95,8 %), recuperación (96,1 %) y puntuación F1 (95,9 %), superando a arquitecturas de referencia como ResNet50, InceptionV3, MobileNetV2 y EfficientNetB0. Análisis adicionales, como matrices de confusión, curvas ROC-AUC y evaluaciones por clases, confirman la robustez del modelo en escenarios del mundo real. Con un tiempo medio de inferencia de 45 ms por imagen en un entorno Kaggle (por ejemplo, una GPU Tesla P100 o T4) y un potencial de implementación satisfactorio en dispositivos periféricos, el modelo propuesto ofrece una solución escalable, ligera y práctica para la monitorización en tiempo real de plagas en la agricultura de precisión. Los trabajos futuros se centrarán en ampliar la diversidad de plagas, mejorar la interpretabilidad del modelo e integrar el sistema en marcos de agricultura inteligente basados en el Internet de las cosas (IoT).
Metodología de estudio del artículo (si es que aplica):	• Recolección de imágenes • Procesamiento de imágenes • Aumentación de datos • Transferencia de conocimiento • Diseño de la arquitectura • Entrenamiento • Experimentación y validación • Configuración de hardware • Evaluación

INFORMACIÓN GENERAL	
Información a extraer	Anotaciones del revisor
¿Cómo validan su propuesta de solución los autores?	• Comparación con otros modelos • Métricas de evaluación • Tamaño del modelo y velocidad de detección • Matriz de confusión
RESULTADOS SUBJETIVOS	
¿Qué entendió el revisor del artículo? (descripción de lo que se entendió del artículo) La detección manual de plagas presenta limitaciones relacionadas con el tiempo, el costo y la dependencia del conocimiento especializado, especialmente en áreas agrícolas extensas. Los autores demuestran que el uso de modelos de Deep Learning basado en transferencia de aprendizaje, forma una alternativa viable para automatizar la identificación de enfermedades en cultivos de papa. El estudio muestra la importancia de contar con un conjunto de datos variado y aplicar técnicas de preprocesamiento y aumento de datos para mejorar el desempeño del modelo. Los resultados reportan un recall del 96.1%, lo cual sugiere que este tipo de enfoque puede contribuir significativamente a la agricultura de precisión mejorando la precisión de monitoreo de problemas fitosanitarios.	
EN EL CONTEXTO DE LA INVESTIGACIÓN	
Q1. ¿Qué enfoque metodológico utilizan los autores del artículo para la detección de plagas y/o enfermedades en cultivos de maíz mediante imágenes?	Deep Learning
Q2. ¿Qué tipos específicos de plagas y/o enfermedades son abordados en el estudio del artículo?	1. Pulgones 2. Escarabajos de la papa de Colorado 3. Minadores de hojas
Q3. ¿Qué conjunto de datos o dataset utilizan los autores para validar la solución propuesta en su investigación?	Se utilizó un conjunto de datos público y fotografías propias dando un total de 3,000 imágenes de cultivos de papa
Q4. ¿Qué arquitectura de red neuronal o modelo de Deep Learning emplean los autores para la detección de plagas y/o enfermedades?	VGG16
Q5. Para la detección de plagas, ¿Qué métricas son abordadas en el artículo?	• Accuracy • Precision • Recall • F1-score • Curva ROC • Tiempo de inferencia • mAP (%) • Model Size (MB) • Parámetros (M)

INFORMACIÓN GENERAL	
Información a extraer	Anotaciones del revisor
Anotaciones del revisor (opcional).	

Anexo B. Resumen de trabajos relacionados.

Tabla B1. Resumen de estudios seleccionados.

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Bagheri, 2020)	A	1. Enfermedad de fuego 2. Deficiencia de nutrientes	Evaluar la capacidad de teledetección multiespectral para el diagnóstico de la enfermedad de tizón de fuego en huertos de peras a niveles de hoja y de copa del árbol	Máquina de soporte vectorial (SVM)	11,280 imágenes capturadas por drones
(Kilaru & Raju, 2022)	A	1. Mancha gris o Cercospora 2. Roya común 3. Mancha foliar norteña	Diseñar un sistema automatizado para la detección temprana de enfermedades en hojas de maíz	SVM	3,823 imágenes de PlantVillage
(Kasinathan et al., 2021)	B	1. Locusta migratoria 2. Parasa lepida 3. Gypsy moth larva 4. Empoasca flavescens 5. Spodoptera exigua 6. Chrysocus chinensis 7. Laspeyresia pomonella larva 8. Atractomorpha sinensis 9. Laspeyresia pomonella 10. Rice leaf roller 11. Rice leaf caterpillar 12. Paddy stem maggot 13. Asiatic rice borer 14. Yellow rice borer 15. Rice gall midge 16. Rice Stemfly	Clasificar y detectar los insectos en el maíz, la soja y el trigo, etc. mediante el aprendizaje automático y el algoritmo de detección de plagas de insectos en la fase inicial de crecimiento de los cultivos.	Red Neuronal propuesta por los autores	1,922 imágenes de IP102 y de otros estudios

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
		17. Brown plant hopper 18. White backed plant hopper 19. Small brown plant hopper 20. Rice water weevil 21. Rice leafhopper			
(Zarboubi et al., 2023)	B	1. Helicoverpa Armigera 2. Fruit Fly 3. Whiteflies	Aprovechar los avances tecnológicos mediante la introducción de un dispositivo portátil diseñado para el recuento de plagas en trampas de feromonas	YOLO-v8	2,108 imágenes aumentadas
(Kundu et al., 2022)	B	1. Tizón de la hoja del Turcicum (TLB) 2. Óxido (Rust) 3. Multienfermedades (combinación de TLB y Rust)	Desarrollar un marco basado en aprendizaje profundo para la detección automática de enfermedades en el maíz, la predicción de la gravedad de estas enfermedades y la estimación de la pérdida de cultivos.	MaizeNet	2,996 imágenes
(B. Wang, 2022)	B	1. Escarabajos 2. Insectos de agallas de peras Psílidos de peras	Desarrollar un modelo de reconocimiento de enfermedades y plagas en cultivos de peras basados en aprendizaje profundo.	AlexNet	1,200 imágenes capturadas de campo experimental
(Bonilla & Duke, 2024)	B	1. Gusano cogollero 2. Taladradores del tallo del maíz 3. Gusanos cortadores 4. Escarabajos pulga del maíz	Desarrollar un modelo basado en redes neuronales convolucionales (CNN) para la detección automática y temprana de plagas en cultivos de maíz	YOLOv8	1,227 imágenes de "pest detection V2"

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Yu et al., 2021)	B	1. Mancha gris 2. Roya (moho) Mancha foliar	Combinar el algoritmo de K-means clustering y un modelo de deep learning mejorado	VGG-19	300 imágenes por enfermedad capturadas de campo experimental
(Arun & Umamaheswari, 2022)	B	1. Molecricket 2. Redspider 3. Wireworm 4. Armyworm 5. Grub 6. Ampelophaga 7. Lytta Polita 8. Meadow Moth 9. Pieris Canidia 10. Wheat Sawfly 11. Xylotrechus 12. Cicadellidae 13. Cicadella Viridis 14. Miridae 15. Papilio Xuthus 16. Prodenia Litura 17. Lawana Imitata 18. Salurnis Marginella 19. Apolygus Lucorum 20. Locustoidea	Desarrollar un método automatizado basado en técnicas de Deep Learning y CNN para detectar múltiples clases de plagas, automáticamente extraen características complejas de diversas plagas en imágenes de cultivos	Faster R-CNN-ResNet101	11,234 Imágenes de IP102
(Deb & Rahman, 2025)	B	1. Aphids 2. Colorado potato beetles 3. Leafminers	Desarrollar un modelo de Deep Learning preciso y eficiente basado en la arquitectura VGG16 para automatizar la detección y selección en plagas de papas	VGG16	3,000 imágenes de datos públicos y propias por los autores

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Santhi et al., 2024)	B	1. Tizón 2. Roya común Manchez gris en la hoja	Localizar y clasificar enfermedades de hojas de maíz utilizando arquitectura basadas en aprendizaje profundo para mejorar la precisión en la detección de enfermedades.	VGG 16	Imágenes obtenidas de Kaggle
(I. Khan et al., 2024)	B	1. Tizón bacteriano de la hoja y la vaina del maíz 2. Mancha parda del maíz 3. Mildiú vellosa de rayas marrones del maíz 4. Roya común del maíz 5. Mancha de hoja del maíz por Curvularia 6. Tizón de la hoja del maíz Maydis 7. Raíces de maíz de cepa postfloración 8. Maíz Rajastán Mildiú vellosa 9. Tizón de la hoja del maíz Turcicum	Desarrollar un enfoque de aprendizaje profundo basado en transferencia de aprendizaje para la clasificación de enfermedades en hojas de maíz. Se busca mejorar la precisión y generalización.	ResNet50	8,750 imágenes obtenidas de Plant Village
(Phan et al., 2022),	B	1. Mancha gris de la hoja 2. Roya común 3. Tizón del norte de la hoja	Proponen un marco que permite la detección y diagnóstico de múltiples enfermedades en condiciones de campo y con fondos variados	DenseNet-121	4,455 imágenes de CD&S y Plant Village

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Haque et al., 2022a)	B	1. Tizón de la hoja de Maydis 2. Tizón de la hoja de Turcicum 1. Tizón de la hoja y la vaina en bandas	Desarrollar un enfoque automatizado y eficiente para la identificación de estas enfermedades utilizando redes neuronales convolucionales	Inception-V3	5,939 imágenes capturadas con teléfonos inteligentes y cámaras digitales
(Pan et al., 2022)	B	2. Tizón de la hoja de maíz 3. Mancha de la hoja 4. Mancha de la hoja del maíz 5. Mancha gris de la hoja 6. Roya del maíz 7. Hongo curvulario de la hoja de maíz	Mejorar la capacidad de los agricultores y los investigadores para diagnosticar la enfermedad del tizón de la hoja de maíz basado en modelos de redes neuronales convolucionales profundas	GoogleNet	985 imágenes
(O'Halloran et al., 2024)	B	1. Necrosis Letal del Maíz 2. Virus de la Raya del Maíz	Mejorar la precisión y eficiencia en la identificación de las enfermedades de Necrosis Letal del Maíz y el Virus de la Raya del Maíz a través de arquitecturas de redes neuronales convolucionales	EfficientNet V2 B0	15,344 imágenes capturadas por dispositivos móviles
(Wahyuningrum et al., 2023)	B	1. Roya común 2. Hoja del Norte Mancha gris de la hoja	Mejorar la precisión en la clasificación de enfermedades en hojas de maíz utilizando una red neuronal convolucional fusionada por pérdidas para reducir	Red neuronal convolucional fusionada por pérdidas (LF-CNN)	3,852 imágenes obtenidas de Mendeley

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
			la variabilidad intra-clase.		
(Xu et al., 2023)	B	1. El tizón de la hoja del maíz 2. Helminthosporium maydis 3. Mancha gris de la hoja 4. Enfermedad de la roya 5. Barrenador del tallo - Gusano cogollero del maíz	Mejorar una identificación eficiente y precisa de las plagas y enfermedades del maíz.	ResNet50	2,150 imágenes obtenidas de bases de datos
(J. He et al., 2023)	B	1. Anthracnose leaf blight 2. Tropical rust 3. Southern maize rust 4. Common rust 5. Southern leaf blight 6. Phaeosphaeria leaf spot 7. Diplodia leaf streak 8. Physoderma brown spot 9. Northern leaf blight	Diseñar un modelo mejorado para la detección inteligente, rápida y precisa de enfermedades en hojas de maíz en condiciones reales de campo con fondo complejo	VGG16	2,139 imágenes de China Science Data Network y propias por los autores

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Albahli & Masood, 2022)	B	1. Mancha gris de la hoja 2. Roya común 3. Tizón del norte de la hoja 4. Tizón del sur de la hoja	Desarrollar un modelo de red neuronal convolucional denominado EANet, que utiliza un mecanismo de atención espacial y de canal para mejorar la clasificación de enfermedades en las hojas de maíz.	EfficientNet v2	7,500 imágenes de PlantVillage y propias por los autores
(Vijaykanth Reddy & Sashi Rekha, 2021)	B	1. Manchas en las hojas 2. Enfermedad del mosaico 3. Roya 4. Manchas marrones	Proponer un marco de trabajo automatizado para la detección de enfermedades en hojas de plantas de manzana, utilizando modelos de aprendizaje profundo con transferencia de aprendizaje.	DLDPF (integra AlexNet y GoogleNet)	13,689 imágenes de PlantVillage
(Masood et al., 2023)	B	1. Tizón de la hoja del norte 2. Mancha de la hoja del norte 3. Mancha gris en la hoja	Mejorar la detección y clasificación de cultivos afectados por enfermedades en las hojas de maíz, utilizando mecanismos de atención espacial y de canal para extraer características más detalladas de las muestras.	MaizeNet (ResNet50 como red base)	2,112 imágenes de PlantVillage
(Qian et al., 2022)	B	1. Tizón de hoja de maíz 2. Mancha gris de la hoja 3. Óxido de maíz	Desarrollar un modelo de Deep Learning para mejorar la identificación y clasificación de enfermedades en hojas de maíz en entornos de campo reales.	Transformador de vision (Vit)	7,701 imágenes de Plant Village

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Chen et al., 2021b)	B	1. Mancha de phaeosphaeria 2. Pudrición de la espiga por gibberella (mancha blanca) 3. Cima loca 4. Mancha gris de la hoja 5. Tizón de la hoja del norte 6. Roya meridional 7. Marchitez bacteriana de Goss 8. Mancha ocular del maíz	Desarrollar una red neuronal convolucional mejorada, Mobile-DANet, la cual se basa en la arquitectura de DenseNet con mecanismos de atención (SCAM)	Mobile-DANet, basada en DenseNet	2,690 imágenes de Plant Village
(Ji et al., 2024)	B	1. Mancha caeciliana de la hoja 2. Roya común 3. Tizón del norte de la hoja 4. Virus de la línea del maíz	Desarrollar un modelo de sistema de red neuronal convolucional para mejorar la precisión y velocidad en la clasificación de enfermedades de las hojas de maíz.	ICS-ResNet50	8,280 imágenes de Plant Village y Kaggle
(Al-Shahari et al., 2024)	B	1. Rodillo de hoja de arroz 2. Barrenador asiático del arroz 3. Barrenador amarillo del arroz 4. Mosquito de la agalla del arroz 5. Mosca del tallo del arroz 6. Chicharrita del arroz	Desarrollar un enfoque innovador para la detección y clasificación de insectos en cultivos de arroz utilizando un algoritmo de optimización de gannet combinado con técnicas de aprendizaje profundo	DenseNet	300 imágenes de IP102

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Jasrotia et al., 2023)	B	1. Mancha gris de la hoja 2. Roya común 3. Tizón de la hoja	Desarrollar un modelo de redes neuronales convolucionales para eficientar el diagnóstico de enfermedades de plantas de maíz	MaxPooling CLAHE- HSV_CNN	3,080 imágenes de Plant Village
(S. Zhang et al., 2024)	B	1. Black hairy, 2. Field cricket, 3. Indigo caterpillar, 4. Jute semilooper, 5. Jute stem girdler, 6. Jute stem weevil, 7. Leaf beetle, 8. Pod borer, 9. Yellow mite	Superar de manera eficaz las limitaciones existentes en el ámbito de la identificación de plagas del yute y ofrecer a los productores de yute una solución de detección de plagas precisa, eficaz y práctica.	YOLO-v7	3,252 imágenes aumentadas
(F. Khan et al., 2023)	B	1. Mancha gris de la hoja 2. Virus del mosaico de la caña de azúcar 3. Tizón del norte de la hoja	Desarrollar e implementar un sistema basado en deep learning para la detección y clasificación en tiempo real de enfermedades foliares en el maíz mediante una aplicación móvil.	YOLO-v8	2,675 imágenes por un dispositivo móvil
(Ali et al., 2023)	B	1. Bug 2. Pupa Borer 3. Root Borer 4. Beetle 5. Fall Army Bug 6. Army Worm	Superar los problemas de las estructuras actuales	MobileNet	75,000 imágenes de IP102
(X. Wang et al., 2021b)	B	1. Tizón Temprano 2. Tizón Tardío 3. Mildiu Polvoriento 4. Tizón de Manchas 5. Moho Gris 6. Mildiu de las Hojas	Desarrollar un algoritmo de detección de objetos mejorada para la detección temprana y en tiempo real	YOLOv3	10,696 imágenes capturadas por cámara de vigilancia

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
		7. Mancha Gris de la hoja 8. Minador de Hojas 9. Mosca Blanca			
(Vilar-Andreu et al., 2024)	B	No se menciona el tipo específico plagas	Proponer una nueva forma de utilizar YOLO para la detección de plagas desde una perspectiva generalista, detectando en tiempo real la presencia de cualquier tipo de insecto en cualquier tipo de cultivo	YOLO-v8	Imágenes obtenidas de IP102
(Bijlwan et al., 2025)	B	1. BLB 2. Brown Spot 3. False Smut 4. Sheath Blight 5. Demsel Fly 6. Gundhi Bug 7. Hispa 8. Leaf Folder (Larva) 9. Pyrilla Perpusilla 10. Stem Borer 11. Stem Borer (eggs)	Ofrecer una evaluación exhaustiva de la eficacia de las metodologías de aprendizaje profundo a la hora de mejorar la precisión y la eficiencia en la detección, clasificación y evaluación de enfermedades y plagas en los cultivos de arroz.	EfficientNet B0	14,064 imágenes por celular
(Akhil et al., 2025)	B	1. Brown Planthopper 2. Rice Stem Borer 3. Leaf Folder 4. Rice Gall Midge 5. Paddy Bug	Ofrecer una solución escalable, precisa y eficiente para la clasificación de plagas en arrozales. Diseñando un sistema automática de clasificación de plagas para arrozales basado en algoritmos de aprendizaje profundo aplicados a imágenes captadas por drones	ResNet y EfficientNet	Imágenes propias por los autores obtenidas por dron

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Bharadwaja et al., 2025).	B	1. Aphids 2. Armyworm 3. Beetle 4. Bollworm 5. Grasshopper 6. Mites 7. Mosquito 8. Sawfly 9. Stem Borer	Desarrollar un sistema de seguimiento de plagas basado en drones (UAV) de gran precisión que mejore la detección temprana, optimice el control de plagas y favorezca las prácticas agrícolas sostenibles	YOLOv8-L	3,150 imágenes de diversas fuentes web
(Kumar et al., 2025)	B	104 plagas	Diseñar un sistema para identificar plagas en los cultivos y clasificarlas como beneficiosos o perjudiciales. Enfoque de categorización de CNN para desarrollar el modelo de identificación y clasificación de plagas	Un modelo CNN propuesto	IP102
(Mallick et al., 2025)	B	Mung bean: 1. Yellow mosaic 2. Cercospora leaf spots 3. Charcoal rot 4. Powdery mildew 5. Fusarium wilt 6. Halo blight 7. Aphid 8. Bruchids 9. Stem fly 10. White fly Mustard: 1. Alternaria Blight 2. Bacterial Blight 3. Downy Mildew 4. White Rust 5. Aphid 6. Leaf Miner 7. Saw Fly 8. Painted Bug	Facilitar la toma de decisiones y proporcionar a los agricultores información rápida y precisa para una gestión eficaz de los cultivos	MobileNet-V3	245 imágenes

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
(Ganesh et al., 2026)	B	No se menciona el tipo de plaga	Superar limitaciones de los actuales sistemas de detección de plagas, integrando una estructura aprendizaje espacio-temporal, las restricciones basadas en la física, la inferencia multitarea y la colaboración entre el borde y la nube	Solo se menciona que es una red ligera	Imágenes capturadas con cámaras de campo, dron y dispositivos IoT
(S & Sharmila, 2026)	B	1. Leaf blight 2. Bud rot 3. Rhinoceros beetle 4. Red palm weevil.	Proponer un marco inteligente de aprendizaje profundo para la detección automática de plagas en los cocoteros, que aprovecha una arquitectura híbrida de CNN-Transformer, optimizada para imágenes aéreas captadas mediante drones y dispositivos de captura de imágenes aéreas.	EfficientNet-V3	14,250 imágenes
(Zhang et al., 2023)	B	1. Locusta migratoria 2. Parasa lepida 3. Gypsy moth larva 4. Empoasca flavescens 5. Spodoptera exigua 6. Chrysocus chinensis 7. Laspeyresia pomonella larva 8. Atractomorph a sinensis 9. Laspeyresia pomonella	Desarrollar un método eficiente y preciso para la identificación de plagas en maíz para reducir tiempo y costo de entrenamiento, y mejorar la detección de plagas en entornos naturales.	YOLOv7	30,603 imágenes de diversos estudios y de IP102

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
		10. Rice leaf roller 11. Rice leaf caterpillar 12. Paddy stem maggot 13. Asiatic rice borer 14. Yellow rice borer 15. Rice gall midge 16. Rice Stemfly 17. Brown plant hopper 18. White backed plant hopper 19. Small brown plant hopper 20. Rice water weevil 21. Rice leafhopper			
(Sun et al., 2026)	B	1. Rhyzopertha dominica 2. Tribolium castaneum 3. Plodia interpunctella 4. Sitophilus zeamais 5. Sitotroga cerealella	Desarrollar un modelo de detección de plagas en granos, que sea preciso, eficiente y ligero que permita implementarse en plataformas con recursos limitados	YOLOv8n	2,000 imágenes por los autores
(Divyanth et al., 2023)	B	1. Mancha gris de la hoja 2. Tizón del norte 3. Mancha del norte	Desarrollar sistemas precisos de gestión de enfermedades para identificar y clasificar las lesiones causadas por enfermedades del maíz y estimar su gravedad en condiciones de campo complejas	DeepLabV3	1,050 imágenes por los autores
(Singh Negi et al., 2026)	B	1. Weevil 2. Moth 3. Caterpillar 4. Slug 5. Ants 6. Bees	Ofrecer una forma eficaz de detectar las plagas de forma temprana y de intervenir de	ConvNeXt-Tiny	5,494 imágenes de Kaggle – Agricultural Pest Image Dataset

Trabajo	Enfoque	Tipo de Plaga	Solución	Algoritmo utilizado	Dataset utilizado
		7. Wasp 8. Beetle 9. Earwig 10. Grasshoper 11. Earthworms 12. Snail	inmediato en el manejo de los cultivos		
(Ishengoma et al., 2021)	C	Gusano cogollero	Detectar de manera precisa las hojas de maíz infectadas utilizando algoritmos de reconocimiento automático basado en redes neuronales convolucionales	Inception-V3	11,280 imágenes capturadas por drones
(Kironko et al., 2024)	C	Maíz 1. Gusano cogollero Tomate: 1. Brillo temprano 2. Moho de la hoja 3. Lote de hojas 4. Mancha bacteriana 5. Tuta absoluta 6. Frutos de Tuta absoluta	Demostrar el potencial de las técnicas de aprendizaje automático y visión por computadora para ayudar a agricultores en Kenia a realizar diagnósticos en tiempo real de enfermedades y plagas en cultivos de tomate y maíz.	Faster R-CNN combinado con MobileNetV2	4,925 imágenes capturadas con cámaras digitales
(Dash et al., 2023)	C	1. Tizón 2. Roya común 3. Mancha gris de la hoja 4. Hojas sanas	Desarrollar un modelo de clasificación que extrae características profundas mediante DenseNet201 y máquina de soporte vectorial (VSM) para distinguir y clasificar cuatro enfermedades.	DenseNet-201	3,988 imágenes obtenidas de PlantVillage y Kaggle
(Sujatha et al., 2021)	C	1. Mancha negra 2. Cancro 3. Enverdecimiento 4. Melanosis	Comparar el rendimiento de diversos métodos de aprendizaje automático y aprendizaje profundo para la detección de enfermedades	VGG-16	609 imágenes obtenidas

Anexo C. Evidencia de imágenes de campo.



Figura C1. Cultivo de maíz del municipio de Emiliano Zapata, Morelos (sitio 1).



Figura C2. Cultivo de maíz del municipio de Emiliano Zapata, Morelos (sitio 2).



Figura C3. Evidencia de la recolección en Emiliano Zapata.



Figura C4. Cultivo de maíz del municipio de Jojutla, Morelos (sitio 1).



Figura C5. Cultivo de maíz del municipio de Jojutla, Morelos (sitio 2).



Figura C6. Evidencia de la recolección en Jojutla.



Figura C7. Cultivo del municipio de Taltizapán, Morelos.



Figura C8. Evidencia de la recolección en Taltizapán.