

INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN CIENTÍFICA



ALEXANDRO ESCUDERO-NAHÓN
EDITOR

Transdigital[®]
editorial

INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN CIENTÍFICA

ALEXANDRO ESCUDERO-NAHÓN

EDITOR

ALEJANDRO GUADALUPE RINCÓN CASTILLO, ALEXANDRO ESCUDERO-NAHÓN, ALMA DELIA OTERO ESCOBAR, ANDREA SÁNCHEZ-RUIZ, ANDRÉS VALENCIA SÁNCHEZ, ANTONIO FRANCO VADILLO, ANTONIO JUAN CAPISTRAN ABUNDEZ, ARTURO GONZÁLEZ TORRES, AURA PATRICIA HERNÁNDEZ OLICÓN, BLANCA CECILIA LÓPEZ RAMÍREZ, CÁNDIDA MARCELA RODRÍGUEZ CHÁVEZ, CARLOS ENRIQUE LEVET RIVERA, CARLOS ZEPEDA-LUGO, CAROLINA MEDINA GARCÍA, CECILIA ESPERANZA OSTOS CRUZ, CESAIRE CHIATCHOUA, CHRISTIAN PAULINA MENDOZA TORRES, CLARA ROSALVA MERCADO-LÓPEZ, CLAUDIA MARGARITA GARCÍA PAULIN, DANIEL ALBERTO MEJÍA HERRERA, DIEGO ESCUDERO-SÁNCHEZ, ELENA ELSA BRICIO-BARRIOS, ELIZABETH VANESSA TENIENTE GASCA, ELSA SUÁREZ JASSO, EMMA PATRICIA MERCADO-LÓPEZ, ERIK CARBAJAL-DEGANTE, FABIÁN GÓMEZ SANTIAGO, FRANCISCO ANTONIO TORRES-ESPRIÚ, FRANCISCO DE JESÚS MATA GÓMEZ, FRANCISCO GUADALUPE AVENDAÑO ESPARZA, GEORGINA DEL CARMEN MOTA VALTIERRA, GERARDO QUIROZ BOJORGES, GUILLERMO VARGAS RODRÍGUEZ, HÉCTOR ALFREDO BAPTISTA GONZALES, HUMBERTO AGUIRRE BECERRA, INÉS GUADALUPE GERMÁN AGUILAR, ITZIA NALLELY GUZMÁN MEJÍA, , IVETTE SELENE MARAÑÓN LIZÁRRAGA, JOSÉ ANTONIO CISNEROS JIMÉNEZ, JOSÉ CRISTÓBAL SOLÍS POLLORENA, JOSÉ LUIS BAUTISTA LÓPEZ, JUAN CARLOS LOBATO-VALDESPINO, JULIA DOLORES TOSCANO GARIBAY, KARINA GUADALUPE CORTINA CALDERÓN, LEONARDO ELIPHAS DAZA RAMÍREZ, LEONARDO LEDESMA DOMÍNGUEZ, LUCIA MORALES-MORALES, LUIS ALONSO CASTAÑEDA NEGRETE, LUIS JAVIER RAÚL OBREGÓN HERRIN, LUIS RAMÓN CARREÑO DURÁN, LUZ ANGÉLICA MONDRAGÓN DEL ANGEL, MA. CRISTINA VÁZQUEZ HERNÁNDEZ, MANUEL RAMÓN GONZÁLEZ HERRERA, MARCOS SANCHEZ-LIZARRAGA, MARIAJOSÉ LÓPEZ LAIZA, MARIO ALBERTO DOMÍNGUEZ-ROVIRA, MARYSOL ESTRELLA HERNÁNDEZ GARCÍA, MIGUEL ÁNGEL MEDINA ROMERO, MIREILLE TOLEDO BLAS, MODESTA LORENA HERNÁNDEZ SÁNCHEZ, MÓNICA LORENA SÁNCHEZ LIMÓN, NALLELY GUADALUPE HERNÁNDEZ HERNÁNDEZ, OCTAVIO REYES LÓPEZ, PAVEL DAVID ULISES AVENDAÑO LÓPEZ, RAMAR MENDOZA DÍAZ, RITA ÁVILA ROMERO, RODRIGO OCHOA FIGUEROA, SALVADOR ORTIZ SANTOS, SANTIAGO ARCEO-DIAZ, TANIA HAIDÉE TORRES CHÁVEZ, TOMÁS PERALTA PALAZÓN, VITERVO LÓPEZ-CABALLERO Y XÓCHITL TRUJILLO-TRUJILLO.

AUTORES Y AUTORAS

Título original: Inteligencia artificial: experiencias y reflexiones sobre la investigación científica / Alexandro Escudero-Nahón (Editor) — Ciudad de Querétaro, México: Editorial Transdigital, 2026 — 457 páginas.

International Standard Book Number (ISBN): 978-968-9724-25-4.

Digital Object Identifier (DOI) del libro: <https://doi.org/10.56162/transdigitalbc12>

Clasificación DEWEY. Materia: 370.7—Estudio y enseñanza de la educación. Tipo de Contenido: Libros universitarios.
Clasificación thema: JN—Educación. Tipo de soporte: libro digital gratuito descargable. Formato: PDF. Tamaño: 8.3 Mb.



Este libro es una publicación de acceso abierto con los principios de Creative Commons Attribution 4.0 International License (CC BY-NC-SA). Esta licencia permite a los reutilizadores distribuir, remezclar, adaptar y desarrollar el material en cualquier medio o formato únicamente con fines no comerciales y siempre que se otorgue la atribución al creador. Si remezcla, adapta o construye sobre el material, debe licenciar el material modificado bajo términos idénticos.

Esta obra ha sido dictaminada por pares académicos expertos con el método de doble ciego. Los dictámenes están resguardados en los archivos de la Editorial *Transdigital*.

D.R. 2026 Alexandro Escudero-Nahón (Editor).

D.R. 2026 Autores y autoras.

D.R. 2026 Sello Editorial *Transdigital*.



Sociedad de Investigación sobre Estudios Digitales, S. C. Nombre de marca: *Transdigital*. Dirección: Circuito Altos Juriquilla 1132. Colonia Altos Juriquilla. C. P. 76230, Juriquilla, Querétaro, México.
+52 (442)301 32 38. editorial@transdigital.mx www.editorial.transdigital.mx



Registro en el Padrón Nacional de Editores como agente editor Sociedad de Investigación sobre Estudios Digitales, S. C., con el Dígito Identificador 978-607-99594.



Afiliación a la Cámara Nacional de la Industria Editorial Mexicana (CANIEM) con el número 4069, de conformidad con el artículo 17 de la Ley de Cámaras Empresariales y sus Confederaciones en vigor.

Registro Nacional de Instituciones y Empresas Científicas y Tecnológicas de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) de México con el folio: RENIECYT 2400068.



Sugerencia de referencia para el libro en APA 7a. edición:

Escudero-Nahón, A. (2026) (Editor). *Inteligencia artificial: experiencias y reflexiones sobre la investigación científica*. Editorial Transdigital. <https://doi.org/10.56162/transdigitalbc12>

CONTENIDO

00.	ANÁLISIS DE LAS EXPERIENCIAS Y REFLEXIONES SOBRE LA INTELIGENCIA ARTIFICIAL EN LA INVESTIGACIÓN CIENTÍFICA.....	9
	Alexandro Escudero-Nahón y Diego Escudero-Sánchez	
01.	CONDICIONES SOCIALES EN LA PLANEACIÓN ESTRATÉGICA PARA LA ADQUISICIÓN DE INTELIGENCIA ARTIFICIAL EN LAS ORGANIZACIONES	29
	José Antonio Cisneros Jiménez	
02.	EMPLOYMENT SITUATION FOR RECENT UNIVERSITY GRADUATES IN MEXICO CITY (2020-2024).....	43
	Mariajosé López Laiza, Rita Ávila Romero y Cesaire Chiatouchoua	
03.	INTELIGENCIA ARTIFICIAL Y PALEOGENÓMICA PREDICTIVA: INCOMPATIBILIDAD RH Y KELL EN EL COLAPSO DEMOGRÁFICO NEANDERTAL.....	58
	Luis Ramón Carreño Durán, Aura Patricia Hernández Olicón, Antonio Franco Vadillo, Mireille Toledo Blas, Fabián Gómez Santiago y Héctor Alfredo Baptista Gonzales	
04.	JUSTICIA ALGORÍTMICA Y GOBERNANZA ÉTICA ANTE LOS SESGOS DE LA INTELIGENCIA ARTIFICIAL	77
	Alma Delia Otero Escobar, Cecilia Esperanza Ostos Cruz y Elsa Suárez Jasso	
05.	INTELIGENCIA ARTIFICIAL GENERATIVA Y ÉTICA PROFESIONAL EN LA CONTADURÍA PÚBLICA.....	96
	Leonardo Eliphas Daza Ramírez y Francisco de Jesús Mata Gómez	
06.	INTEGRACIÓN DE LA INTELIGENCIA ARTIFICIAL EN PROCESOS DE INVESTIGACIÓN EN INSTITUCIONES EDUCATIVAS EN ZACATECAS, MÉXICO.....	123
	Alejandro Guadalupe Rincón Castillo, Cándida Marcela Rodríguez Chávez, Luis Alonso Castañeda Negrete y Daniel Alberto Mejía Herrera	
07.	¿PUEDEN LAS MÁQUINAS SALVAR AL MAÍZ? APRENDIZAJE PROFUNDO PARA LA DETECCIÓN DE PLAGAS	142
	Antonio Juan Capistran-Abundez, Vitervo López-Caballero, Lucía Morales-Morales y Andrea Sánchez-Ruiz	

08.	
TRIPLE CONVERGENCIA EN LA ERA DE LA TRANSFORMACIÓN DIGITAL DEL TURISMO: CIENCIA DE DATOS, INTELIGENCIA ANALÍTICA Y GESTIÓN DE DESTINOS	159
Manuel Ramón González Herrera y Carolina Medina García	
09.	
USO DE LA INTELIGENCIA ARTIFICIAL EN EL COACHING EMPRESARIAL (2024): REVISIÓN DE LITERATURA	175
Arturo González Torres, Gerardo Quiroz Bojorges y Pavel David Ulises Avendaño López	
10.	
EL USO DE LA INTELIGENCIA ARTIFICIAL EN LOS PROCESOS DE INVESTIGACIÓN CIENTÍFICA	193
Marysol Estrella Hernández García	
11.	
HACIA UNA NUEVA PRAXIS DE CIENCIA ABIERTA DOMINADA POR DATOS MASIVOS E INTELIGENCIA ARTIFICIAL GENERATIVA	208
Erik Carbajal-Degante y Leonardo Ledesma-Domínguez	
12.	
LA INTELIGENCIA ARTIFICIAL EN EL DERECHO: USO PRÁCTICO Y TRANSICIÓN REGULATORIA	224
Carlos Enrique Levet Rivera, Modesta Lorena Hernández Sánchez y Ramar Mendoza Díaz	
13.	
ENVEJECIMIENTO DIGNO EN MÉXICO: DETECCIÓN EN TIEMPO REAL DEL NIVEL DE RIESGO DE SARCOPENIA MEDIANTE INTELIGENCIA ARTIFICIAL	238
Santiago Arceo-Díaz, Xóchitl Trujillo-Trujillo y Elena Elsa Bricio-Barrios	
14.	
EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL GENERATIVA EN LA ARQUITECTURA EDITORIAL Y EL CRECIMIENTO EXPONENCIAL DE LA PRODUCCIÓN CIENTÍFICA EN SALUD.....	251
Salvador Ortiz Santos, Georgina del Carmen Mota Valtierra, Humberto Aguirre Becerra, Blanca Cecilia López Ramírez y Ma. Cristina Vázquez Hernández	
15.	
FACTORES CRÍTICOS DE ÉXITO PARA IMPLEMENTAR LA INTELIGENCIA ARTIFICIAL EN LAS UNIDADES DE CUIDADOS INTENSIVOS.....	265
Carlos Zepeda-Lugo, Marcos Sanchez-Lizarraga e Ivette Selene Marañón Lizárraga	

16.	ESCUCHA HUMANA E INTELIGENCIA ARTIFICIAL: LÍMITES Y ALCANCES EN LA INVESTIGACIÓN MUSICAL	280
	José Luis Bautista López, Guillermo Vargas Rodríguez y Luis Javier Raúl Obregón Herrin	
17.	EVOLUCIÓN DE LA REPRESENTACIÓN GRÁFICA: DEL TRAZO HUMANO AL ALGORITMO.....	295
	Luz Angélica Mondragón del Angel e Inés Guadalupe Germán Aguilar	
18.	CONOCIMIENTO O APARIENCIA: EL ESTATUTO EPISTÉMICO DE LA INTELIGENCIA ARTIFICIAL GENERATIVA.....	312
	Tomás Peralta Palazón	
19.	ENTRE EL PROMPT Y EL DISEÑO: EXPERIENCIAS DE CO-CREACIÓN CRÍTICA HUMANO-INTELIGENCIA ARTIFICIAL EN EDUCACIÓN SUPERIOR.....	325
	Juan Carlos Lobato-Valdespino y Claudia Margarita García Paulín	
20.	APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN LA GESTIÓN ADMINISTRATIVA DE LAS MICRO, PEQUEÑAS Y MEDIANAS EMPRESAS DEL SECTOR DE LA CONSTRUCCIÓN	343
	Elizabeth Vanessa Teniente Gasca, Octavio Reyes López y Christian Paulina Mendoza Torres	
21.	MODELOS Y APLICACIONES DE MACHINE LEARNING EN LA ESTRATIFICACIÓN DE RIESGO CLÍNICO.....	359
	Julia Dolores Toscano Garibay	
22.	ENTRE PRINCIPIOS Y PRÁCTICA: REVISIÓN DE MARCOS REGULATORIOS Y ÉTICOS SOBRE INTELIGENCIA ARTIFICIAL EN LA INVESTIGACIÓN CIENTÍFICA	374
	Miguel Ángel Medina Romero, Tania Haidée Torres Chávez y Rodrigo Ochoa Figueroa	
23.	INTELIGENCIA ARTIFICIAL EN EL PROCESO DE INVESTIGACIÓN CIENTÍFICA: USOS, EXPERIENCIAS Y LIMITACIONES.....	389
	Emma Patricia Mercado-López y Clara Rosalva Mercado-López	

24.	
LA MEDIACIÓN EPISTÉMICA DE LA INTELIGENCIA ARTIFICIAL GENERATIVA EN LA CIENCIA CONTEMPORÁNEA.....	406
Andrés Valencia Sánchez y José Cristóbal Solís Pollorena	
25.	
ANÁLISIS DOCUMENTAL DE LA ADOPCIÓN Y HUMANIZACIÓN DE ASISTENTES DIGITALES BASADOS EN INTELIGENCIA ARTIFICIAL	422
Karina Guadalupe Cortina Calderón, Nallely Guadalupe Hernández Hernández y Mónica Lorena Sánchez Limón	
26.	
DEL ANDAMIAJE CON INTELIGENCIA ARTIFICIAL A LA AUTONOMÍA: EVALUACIÓN DE CÓDIGO ESTADÍSTICO EN INGENIERÍA	442
Francisco Antonio Torres-Espriú, Itzia Nallely Guzmán Mejía, Francisco Guadalupe Avenidaño Esparza y Mario Alberto Domínguez-Rovira	



07.

**¿PUEDEN LAS MÁQUINAS SALVAR AL MAÍZ?
APRENDIZAJE PROFUNDO PARA LA DETECCIÓN DE
PLAGAS**

ANTONIO JUAN CAPISTRAN-ABUNDEZ

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO, MÉXICO
ORCID: 0000-0001-8110-989X

VITERVO LÓPEZ-CABALLERO

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO, MÉXICO
ORCID: 0000-0002-1942-9558

LUCIA MORALES-MORALES

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO, MÉXICO
ORCID: 0009-0006-6593-4762

ANDREA SÁNCHEZ-RUIZ

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO, MÉXICO
ORCID: 0009-0005-7773-0575

DOI del capítulo del libro: <https://doi.org/10.56162/transdigitalbc12.07>

07.

¿PUEDEN LAS MÁQUINAS SALVAR AL MAÍZ? APRENDIZAJE PROFUNDO EN LA DETECCIÓN DE PLAGAS

INTRODUCCIÓN

Según la Organización de las Naciones Unidas (ONU), la Agenda 2030 para el Desarrollo Sostenible, es un plan de colaboración entre países interesados por garantizar la paz universal, la prosperidad, la libertad y los derechos humanos para guiar al planeta Tierra hacia la sostenibilidad. Con una visión integral del futuro de la humanidad, la propuesta tiene 17 Objetivos para el Desarrollo Sostenible (ODS), los cuales proporcionan una hoja de ruta para impulsar el crecimiento económico, social, cultural y la protección del medio ambiente.

La presente investigación se alinea con el ODS 2 que, de acuerdo con Huck (2023), promueve el incremento de la productividad agrícola y la sostenibilidad de los sistemas alimentarios. También se adscribe con el ODS 12, el cual fomenta el uso eficiente de los recursos naturales y la reducción del impacto ambiental. Además, Mejía (2003) menciona que la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), considera al maíz como una fuente de vida para quienes lo cultivan y por su adaptabilidad a diferentes climas, es uno de los granos alimenticios de mayor producción y consumo en el mundo.

De igual forma, la Secretaría de Agricultura y Desarrollo Rural de México (SADER), informa que el maíz es un alimento básico cultivable en los 32 estados del país, siendo así un componente fundamental del patrimonio gastronómico y cultural de la sociedad mexicana. Sin embargo, Santhi et al. (2024) reportan que el daño de plagas en diversas secciones del maíz, disminuye la producción. Por lo cual, Liakos et al. (2018) consideran adecuado vigilar la salud de los plantíos durante el crecimiento para que el rendimiento agrícola aumente. Mientras que, Barbedo (2018) menciona que la inspección visual de plagas en los cultivos puede originar sesgos. Por lo tanto, se considera a la agricultura inteligente como un recurso

recomendable para abordar este desafío. Es decir, según Kamilaris et al. (2017) la agricultura asociada con la tecnología, mejora los recursos obtenidos de la actividad agraria.

Finalmente, Yu et al. (2021) mencionan que a partir de la integración de la inteligencia artificial en actividades agrícolas, diversos estudios abordan la clasificación de plagas en plantas de arroz, mango, manzana, pepino, té y otros cultivos. También, Xu et al. (2023) considera que, la clasificación de imágenes tiene diversas aplicaciones en la agricultura. Por lo tanto, el objetivo de este trabajo es reportar un conjunto de artículos en los cuales se investigan algoritmos de automatización para detectar plagas en imágenes de hojas de maíz capturadas con dron y celular.

DESCRIPCIÓN DEL PROBLEMA DE INVESTIGACIÓN

Según, Brewbaker & Hawaii (2003) el maíz es fundamental para las finanzas del mundo debido a que la solicitud del cultivo aumenta conforme crece la población mundial. Sin embargo, Liakos et al. (2018) consideran que las plagas son un desafío constante para los agricultores debido a las complicaciones para controlarlas tanto en condiciones de cultivo al aire libre como en invernadero y según, L. Paliwal (2001), destacan por ser las más visibles, las enfermedades foliares tales como: los tizones, las manchas y las royas, ya que a primera vista son alarmantes.

Con base en lo anterior, Qian et al. (2022) recomiendan identificar las plagas en etapas iniciales para evitar la propagación al resto del cultivo, reducir el uso de pesticidas y mejorar la cantidad de producción. Sin embargo, Wahyuningrum et al. (2023) mencionan que la detección manual es difícil y propensa a errores en entornos de campo. Por tal razón, Yu et al (2021) lo consideran un desafío constante para los agricultores detectar plagas durante la etapa de crecimiento del maíz.

Por su parte, Rouhiainen (2020) menciona que la integración de la inteligencia artificial a la agricultura, permite a los productores tomar mejores decisiones para incrementar la producción. Por lo tanto, el objetivo general de la presente investigación es desarrollar e implementar un sistema basado en aprendizaje profundo mediante el análisis de imágenes capturadas con dron y celular para la detección de plagas en cultivos de maíz. Para ello, se proponen los siguientes objetivos específicos:

1. Diseñar un conjunto de imágenes capturadas con dron y celular.

2. Entrenar un modelo de aprendizaje profundo con técnicas de procesamiento de imágenes.
3. Validar el modelo de aprendizaje profundo realizando pruebas con el conjunto de imágenes.
4. Desarrollar una plataforma web para identificar plagas en imágenes de cultivos de maíz.

JUSTIFICACIÓN DE LA INVESTIGACIÓN

Según la FAO, se reconoce al maíz a nivel mundial por su adaptabilidad a diferentes condiciones climáticas y en México es pilar de la agricultura debido a que se cultiva en los 32 estados del país siendo así un grano estratégico por su valor económico y pertinente para la seguridad alimentaria. Sin embargo, según Wahyuningrum et al. (2023), la presencia de enfermedades en las hojas de maíz son un riesgo constante para la producción, lo cual disminuye la disponibilidad del cereal.

Por su parte, Xu et al. (2023) mencionan que tradicionalmente, la detección de plagas es una actividad realizada mediante inspección visual, lo cual consume tiempo, es propensa a errores y difícil de realizar en campos agrícolas grandes, lo cual puede llevar a daños irreparables en los cultivos, menor producción y afectación negativa económica de los agricultores.

Con base en lo anterior, es recomendable implementar sistemas automáticos que ayuden a los productores de maíz a detectar las plagas en etapas iniciales de infestación para que les sea posible tomar medidas preventivas. En este sentido el uso de redes neuronales convolucionales se plantea como una solución innovadora ya que estas herramientas de aprendizaje profundo tienen el potencial de analizar grandes conjuntos de imágenes y detectar patrones de interés. Además, estas técnicas permiten automatizar la detección de plagas, lo cual puede reducir tiempos, costos operativos y minimizar el uso de insumos agrícolas como pesticidas, contribuyendo así a la sostenibilidad ambiental. En este sentido, para abordar uno de los desafíos permanentes de la agricultura, la presente investigación tiene el propósito de detectar plagas en cultivos de maíz utilizando técnicas de aprendizaje profundo con redes neuronales convolucionales, las cuales tienen buenos resultados para el reconocimiento de imágenes.

MARCO CONCEPTUAL

INTELIGENCIA ARTIFICIAL


Según Russell y Norvig (2021), es el estudio de agentes que reciben percepciones del entorno y realizan acciones. Esta perspectiva se centra en el concepto de agente inteligente, que asigna secuencias de percepción a acciones específicas. Esta definición se alinea con el enfoque de “sistemas que actúan racionalmente”, enfatizando la creación de sistemas que aprenden qué maximizar y funcionan bajo la incertidumbre de los objetivos humanos.

APRENDIZAJE PROFUNDO

Según Hendrycks (2024), son un conjunto de técnicas que utiliza redes neuronales con múltiples capas para crear modelos que pueden aprender de grandes conjuntos de datos. Las redes neuronales utilizan capas de nodos interconectados para transformar las entradas en salidas. Por ejemplo, una red neuronal profunda entrenada para el reconocimiento de objetos en imágenes puede aprender a identificar patrones en los datos de píxeles sin procesar, tal como se observa, de forma general el funcionamiento del aprendizaje profundo en la Figura 1.

Figura 1

Funcionamiento general del aprendizaje profundo



Nota. Tomada de Krishna y Kalluri (2019).

RED NEURONAL CONVOLUCIONAL

Según Courville (2016), es una red que emplea una operación matemática llamada convolución, la cual es un tipo especializado de operación lineal. Se especializa en procesar

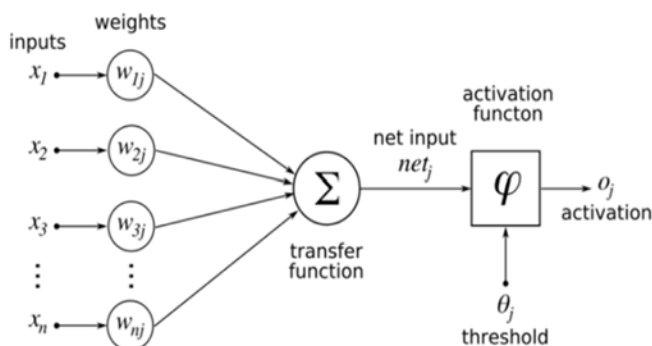
datos que tienen una topología conocida similar a una cuadrícula. Es decir, mediante la aplicación de múltiples capas de convolución, seguidas de capas de activación, agrupamiento y normalización, pueden modelar relaciones complejas entre los elementos de una imagen, permitiendo aplicaciones avanzadas como la detección de objetos y la segmentación semántica.

FUNCIONES DE LAS REDES NEURONALES CONVOLUCIONALES

Se estructuran en capas sucesivas que permiten la extracción automática de características de las imágenes. El proceso inicia con las capas convolucionales, aplicando filtros para detectar patrones como bordes, texturas y formas. Estas capas permiten a la red identificar características locales en las imágenes, que luego se combinan a medida que avanzan a través de las capas. Después, las capas de agrupamiento reducen la resolución de las imágenes para mantener las características más importantes y disminuir la complejidad computacional. Finalmente, las capas totalmente conectadas integran la información extraída por las capas anteriores y realizan la clasificación. En la Figura 2, se observa de forma general el funcionamiento de una red neuronal.

Figura 2

Representación esquemática de una neurona artificial



Nota. Tomada de UNAL (2020).

REDES NEURONALES RESIDUALES (ResNet)

Según, He et al. (2016) son arquitecturas de aprendizaje profundo que utilizan conexiones de atajo basadas en la identidad dentro de los bloques de la red. A diferencia de las redes de propagación hacia adelante simples, las ResNet incorporan estas conexiones para facilitar el entrenamiento de modelos muy profundos, mejorar el flujo de información y

proporcionar un mejor espacio de funciones. Es decir, la entrada de la capa anterior se suma a la salida de la capa actual por lo cual, esta conexión residual facilita el aprendizaje de la red y mejora su rendimiento en actividades de clasificación de imágenes, detección de objetos, segmentación semántica, extracción de características y transferencia de aprendizaje.

Como ejemplo, la ResNet-50 destaca por ser una arquitectura de gran profundidad cuya principal innovación es el uso de bloques residuales tipo “cuello de botella”. Su estructura interna se organiza en una secuencia de 16 bloques residuales distribuidos en grupos de 3, 4, 6 y 3, donde cada bloque integra tres capas convolucionales con dimensiones de 1x1, 3x3 y 1x1 píxeles.

Maíz

Según, L. Paliwal (2001) es de los granos alimenticios más antiguos con origen en México de la familia Poáceas o Gramíneas, tribu *Maydeas*, *Zea mays*. El maíz no crece en forma silvestre y no puede sobrevivir en la naturaleza, por lo cual es una planta completamente domesticada. Además, es uno de los cereales de mayor consumo y una de las especies vegetales más productiva.

PLAGAS DEL MAÍZ

Según, Savary et al. (2019), son organismos bióticos principalmente insectos, hongos, bacterias y virus que interactúan negativamente con el cultivo, provocando daños fisiológicos, estructurales o funcionales causantes de pérdidas de rendimiento, calidad del grano y rentabilidad económica, siendo ejemplo, las plagas del cogollo que dañan los extremos de los brotes de tallos y raíces afectando el crecimiento vertical de la planta.

TRABAJOS RELACIONADOS

Con base en la descripción del problema, la búsqueda de investigaciones afines se realiza en idioma inglés durante el periodo de años 2018-2025 en los buscadores académicos, *Google Scholar*, *IEEE Xplore*, *Multidisciplinary Digital Publishing Institute (MDPI)* y *Science-Direct* a partir de cadenas de búsqueda formadas por las siguientes palabras: “deep learning algorithms”, “pest detection in corn crops” y “drone and cell phone images”. Se observa que, en los artículos revisados, se abordan tres enfoques de algoritmos de inteligencia artificial: aprendizaje automático, aprendizaje profundo y aprendizaje híbrido, los cuales se describen a continuación.

ENFOQUE CON APRENDIZAJE AUTOMÁTICO

El propósito de este enfoque es abordar investigaciones que han implementado algoritmos de aprendizaje automático, tales como: *Support Vector Machine* (SVM), *Multinomial Naïve Bayes* (MNB), *K-Nearest Neighbor* (KNN) y *Decision Trees* (DT), orientados a la identificación de plagas y enfermedades foliares en imágenes de hojas de maíz. La eficacia de estos modelos se evalúa mediante métricas de desempeño como la precisión, la matriz de confusión y la sensibilidad.

En este sentido, Barbedo (2018) implementó un modelo de aprendizaje por transferencia utilizando la red neuronal GoogLeNet con la Neural Network Toolbox de MATLAB 2017b. Se entrenó y validó con un conjunto de 50,000 imágenes, orientadas a la detección de las principales enfermedades del maíz. Por otra parte, Aravind et al. (2018) proponen un enfoque basado en el procesamiento de imágenes, empleando un modelo de máquina de vectores de soporte multiclase para analizar 2,000 imágenes de PlantVillage, las cuales fueron clasificadas en mancha de cercospora, óxido, pudrición de hojas y hojas sanas alcanzando un 83.7% de precisión.

De forma parecida, en el estudio de Resti et al. (2022) se analizaron 761 imágenes proporcionadas por la Universidad de Sriwijaya para identificar las enfermedades óxido, mildiu y mancha foliar así como las plagas *spodoptera frugiperda* y *heliiothis armigera* en plantas de maíz. En este caso, se aplicaron los algoritmos *Multinomial Naïve Bayes* y *K-Nearest Neighbor*, con resultados de precisión del 92.72% y 99.54%, respectivamente.

Finalmente, en la investigación de Idress et al. (2024) se analizaron 600 imágenes de *PlantVillage*, previamente segmentadas mediante el método *K-means clustering* y caracterizadas a través de medidas estadísticas como la media y la desviación estándar. Posteriormente, se aplicaron técnicas de clasificación como árboles de decisión, *K-Nearest Neighbor*, *Support Vector Machine* (SVM) y Redes Neuronales Artificiales (ANN), logrando un 92.7% de precisión con ANN y un 91.3% con SVM en la clasificación de mancha foliar, roya común y hojas sanas.

ENFOQUE CON APRENDIZAJE PROFUNDO

Debido a los buenos resultados de las técnicas de aprendizaje profundo, diversas investigaciones recientes coinciden en la aplicación de redes neuronales convolucionales para identificar plagas en imágenes de hojas de maíz. De forma general, se han utilizado

conjuntos de imágenes públicas como *PlantVillage*, repositorios académicos de libre acceso, colecciones locales obtenidas en campo e incluso imágenes sintéticas generadas mediante técnicas de aumento de datos, las cuales se validan con métricas ampliamente aceptadas en la literatura tales como precisión, sensibilidad, exactitud y puntaje F1, lo que ha permitido observar la eficacia de estos modelos.

En una primera línea de investigación, varios estudios prefieren las redes clásicas de transferencia de aprendizaje como VGG, *ResNet*, *GoogLeNet* o *Inception*. Por ejemplo, en el estudio de Islam et al. (2023) se utilizaron los modelos VGG-16, VGG-19 y *ResNet-50* previamente entrenados con transferencia de aprendizaje para identificar y clasificar enfermedades en 10,000 imágenes de hojas infectadas y sanas de cultivos como tomates, papas y pimientos provenientes de *PlantVillage* obteniendo 98.98% de precisión con el modelo *ResNet-50*. De forma similar, en la investigación de Agarwal et al. (2019) se propone la arquitectura de VGG16 e *Inception V3* para identificar hojas sanas, roya común, tizón y mancha gris en 3,852 imágenes de hojas de maíz del conjunto de datos de *PlantVillage*, obteniendo un 94% de precisión.

Por otra parte, Waheed et al. (2020) propone la red neuronal convolucional optimizada, *DenseNet*, para detectar la roya común, mancha gris y tizón en 12,332 imágenes de hojas de maíz con un 98.06% de resultado de precisión global. De forma complementaria, en la investigación de Amin et al. (2022) se propone *EfficientNetB0* y *DenseNet121* para identificar mancha gris foliar, roya común, tizón y hojas sanas del maíz en imágenes del conjunto de datos de *PlantVillage* obteniendo 98.56% como resultado de precisión.

En el estudio realizado por Yin et al. (2022) se propone el modelo *DISE-Net* para detectar en 1268 imágenes la enfermedad de la hoja pequeña de maíz, causada por el hongo *Bipolaris maydis* con un resultado de 97.12% de precisión. Mientras que, en la investigación de Zhu & Gao (2024) se utiliza *MC-ShuffleNetV2* como variante optimizada de *ShuffleNetV2* con el módulo de atención *Convolutional Block Attention Module* (CBAM) para detectar tizón y roya común en 2,725 imágenes obtenidas en el norte de Anhui, China con 99.86% de precisión. También, en la investigación de Zhou et al. (2024) se utiliza el modelo *ShuffleNetV2*, optimizado con técnicas como *Max Pooling* y el mecanismo de atención *SimAM* para identificar tizón y mancha en 1,902 imágenes de hojas de maíz capturadas en el campo, las cuales fueron aumentadas a 4,000 mediante técnicas de procesamiento de imágenes obteniendo un 98.40% como resultado de precisión. Además, en el estudio de Chen et al. (2021) se utiliza *Mobile-DANet* para detectar la mancha por *phaeosphaeria*, podredumbre

de la mazorca, mancha gris, roya y mancha ocular del maíz en imágenes de *PlantVillage* y del Instituto de Botánica Subtropical de Xiamen, China con resultados de precisión del 98.50% y de 95.86%, respectivamente.

En la investigación de Wang et al. (2022) se desarrolló el modelo *AlexNet*, para detectar roya común, mancha curvularia lunata, tizón del norte y podredumbre del tallo en 2,725 imágenes de la Academia de Ciencias Agrícolas de Anhui, China, las cuales fueron aumentadas mediante técnicas de procesamiento de imágenes para alcanzar un total de 10,785 imágenes obteniendo una precisión promedio del 99.35%. Mientras que, en el estudio de Ishengoma et al. (2021) se identifican agujeros pequeños y manchas traslucidas provocadas por el gusano cogollero en 11,280 imágenes de campos de maíz de Tanzania, utilizando VGG16, VGG19, *InceptionV3* y *MobileNetV2*, con resultados de precisión del 99.92%, 99.67%, 100% y 100%, respectivamente.

De forma similar, Hu et al. (2020) se desarrolla un modelo que combina aprendizaje por transferencia y técnicas de aumento de datos para identificar mancha gris, roya común, tizón foliar y hojas sanas en 4,354 imágenes de hojas de maíz de *PlantVillage* con 98.02% de precisión. También, Çakmak (2024) se enfoca en la clasificación automática de roya común, mancha gris, tizón foliar y hojas sanas utilizando el modelo *EfficientNet B3*, obteniendo 99.66% de precisión. Por su parte, Leng et al. (2023) abordan la detección automatizada del tizón foliar con imágenes RGB capturadas con cámaras de mano y drones con una arquitectura basada en *YOLOv5*, denominada *CEMLB-YOLO*, la cual se validó con indicadores de eficiencia computacional como número de parámetros y *FLOPs* obteniendo como resultado un *mAP@0.5* del 87.5%.

La investigación de Pfordt y Paulus (2025) presenta una revisión sistemática, empleando arquitecturas como *AlexNet*, VGG16, *ResNet* y *GoogLeNet* para identificar la plaga del gusano cogollero en imágenes de *PlantVillage* las cuales se evaluaron con las métricas estándar de precisión, sensibilidad, especificidad y puntaje F1. Por su parte, Reddy et al. (2021) proponen un sistema automatizado para la detección de roya común, mancha foliar y tizón en 1,239 imágenes capturadas con cámaras de teléfonos móviles en entornos de campos agrícolas. Se utiliza el modelo *Faster R-CNN* con el extractor de características *ResNet-50*, el cual fue validado con las métricas *Intersection over Union (IoU)*, *Average Precision (AP)* y *mean Average Precision (mAP)*, alcanzando una precisión global del 94.06%.

En el estudio de Lv et al. (2020) se propone una red denominada *DMS-Robust AlexNet*, que integra convolución dilatada, convolución multi-escala, activación *PReLU* y el optimizador *AdaBound*, incluyendo la aplicación de la transformada *wavelet* y un algoritmo *Retinex* para identificar hoja sana, mancha por cercospora, roya común y tizón en 5,470 imágenes capturadas en campo y de *PlantVillage* obteniendo una precisión de 98.62%. Por su parte, Handrizal et al. (2024) proponen desarrollar una red neuronal convolucional personalizada y la arquitectura previamente entrenada VGG16, implementando el dropout para prevenir el sobreajuste y el optimizador Adam que mejora el rendimiento del sistema para identificar tizón, roya común y mancha foliar en 3,918 imágenes digitales con 95% de precisión. De forma similar, Craze et al. (2022) abordan la identificación automática de mancha gris, tizón foliar, roya común y mancha *phaeosphaeria* en imágenes capturadas en campos de maíz, utilizando una red VGG16 modificada, la cual obtuvo una precisión del 73.4% mientras que el modelo entrenado con imágenes de *PlantVillage* obtuvieron un 94.1 % de precisión. Finalmente, Zhang et al. (2018) proponen los modelos *GoogLeNet* y *Cifar10*, con las funciones de activación *ReLU*, capas de regularización *Dropout* y combinaciones específicas de pooling para identificar mancha curvularia, mosaico enano, mancha gris, tizón, mancha parda, mancha redonda, roya y tizón en 3,060 imágenes obtenidas de *PlantVillage* y *Google* con resultados del 98.90% y de 98.8% de precisión respectivamente

ENFOQUE HIBRIDO

En el trabajo de Qian et al. (2022) se propone un modelo de red neuronal convolucional con un mecanismo de atención y transformación basado en el modelo ViT (*Vision Transformer*) y CCT (*Cascaded Convolutional Transformer*) para eliminar ruido de fondo en las imágenes e identificar tizón foliar, roya común y mancha gris en 7,701 imágenes de *PlantVillage* y fotografías tomadas con teléfonos móviles en campos de maíz, obteniendo un 98.70% de precisión. Por otra parte, Yu et al. (2021) proponen utilizar técnicas de agrupamiento *K-Means* y el modelo VGG-19 para detectar roya y mancha foliar en 900 imágenes del *Crop Disease Recognition of the 2018 Artificial Intelligence Challenger Competition*, obteniendo 93% de precisión. En paralelo, Wahyuningrum et al. (2023) comparan la precisión de un modelo de red neuronal convolucional tradicional con el modelo mejorado *Loss-Fused Convolutional Neural Network* (LF-CNN) para la clasificación de hojas sanas, roya común, tizón y mancha gris con imágenes de *Mendeley Data*, con precisión de 94.15%. Finalmente, Masood et al. (2023) proponen el modelo *Faster-RCNN* llamado *MaizeNet* que emplea los módulos *ResNet-50* y *Convolutional Block Attention* (CBA) para detectar mancha gris y tizón foliar

en imágenes del *Corn Disease and Severity* del Centro de Agronomía para Investigación y Educación de la Universidad de Purdue con resultados de precisión del 97.91 %.

En la investigación de Santhi et al. (2024) se propone el modelo VGG 16 con clasificadores de *K-nearest neighbors* (KNN) y redes neuronales artificiales (ANN) para detectar las plagas tizón, roya común y mancha gris en imágenes de *PlantVillage* con resultados de precisión del 95.25 %. Por su parte, Xu et al. (2023) proponen un modelo que agrega el mecanismo de atención ECA (*Environment-Cognition-Action*) y el optimizador *Adam* a la red neuronal convolucional *ResNet50* para detectar tizón foliar, mancha gris, roya común, barrenador del tallo y gusano cogollero en 2,650 imágenes de la Universidad Agrícola del Noreste de China. Además, Ji et al. (2024) plantean el modelo *ICS-ResNet*, el cual incorpora los módulos de atención espacial (ISA) y atención de canal (ICA) a la *ResNet-50* para identificar mancha ceciliana, roya común, tizón foliar y virus de la línea en 8,280 imágenes de *PlantVillage*, obteniendo 98.87% de precisión. Finalmente, Kundu et al. (2022) utilizan el algoritmo de agrupamiento *K-Means* y un modelo personalizado llamado *MaizeNet* para detectar tizón foliar y roya común en 2,996 imágenes del *Indian Council of Agricultural Research* (ICAR) el cual, presentó una precisión de 98.50%.

MÉTODO DE INVESTIGACIÓN

Debido a que el diagnóstico tradicional realizado por personas para identificar enfermedades y plagas en cultivos de maíz es subjetivo y complejo por las condiciones propias del entorno agrícola, se propone elaborar una plataforma web con un modelo de aprendizaje profundo para identificar plagas en imágenes de hojas de maíz mediante la siguiente metodología de solución:

ETAPA 1. REALIZAR LA CAPTURA DE IMÁGENES CON DRON Y CELULAR

En la primera fase, se realiza una colección de imágenes de hojas de maíz sanas y con plaga de diversos cultivos capturadas con dron y celular.

ETAPA 2. CREAR CONJUNTO DE IMÁGENES CAPTURADAS CON DRON Y CELULAR

En la segunda fase, se elabora una base de datos con las imágenes obtenidas en la etapa 1 para clasificar imágenes de hojas maíz sanas o con plaga.

ETAPA 3. ESTUDIAR Y ELABORAR UNA ARQUITECTURA DE APRENDIZAJE PROFUNDO

En la tercera fase, se estudian características y funcionamiento de diversos modelos de aprendizaje profundo para elaborar una con la cual identificar plagas en imágenes de hojas de maíz.

ETAPA 4. ENTRENAR EL MODELO DE APRENDIZAJE PROFUNDO

En la cuarta fase, se entrena el modelo de aprendizaje profundo elaborado con las imágenes recopiladas y clasificadas para que aprenda a reconocer patrones y realizar predicciones.

ETAPA 5. VALIDAR O EVALUAR EL MODELO DE APRENDIZAJE PROFUNDO

En la quinta fase, se divide el conjunto de imágenes en entrenamiento, validación y prueba para evaluar el modelo con métricas de clasificación.

ETAPA 6. VISUALIZAR Y ANALIZAR IMÁGENES EN UNA PLATAFORMA WEB.

En la sexta fase se desarrolla una plataforma web en la cual se adjuntan imágenes nuevas para que el modelo de aprendizaje profundo identifique si son de hojas de maíz sanas o con plaga.

CONCLUSIONES

En esta investigación se realiza una búsqueda de trabajos relacionados sobre el uso de algoritmos de inteligencia artificial para detectar enfermedades y plagas en imágenes de hojas de maíz capturadas con dron y celular con el objetivo de proporcionar a los agricultores un recurso informático que les facilite el monitoreo y toma de decisiones sin necesidad de desplazamientos físicos constantes al campo.

La implementación de modelos de aprendizaje profundo, además de apoyar a las medidas de control, promueve la transición hacia la agricultura orgánica al reducir la dependencia de químicos. Por lo tanto, si se mejora el rendimiento de los cultivos sin dañar el ambiente, esta tecnología emergente, contribuye directamente a los Objetivos de Desarrollo Sostenible 2 y 12.

REFERENCIAS

- Agarwal, M., Bohat, V. K., Ansari, M. D., Sinha, A., Gupta, S. K., & Garg, D. (2019). A Convolution Neural Network based approach to detect the disease in Corn Crop. *Proceedings of the 2019 IEEE 9th International Conference on Advanced Computing, IACC 2019*, 176–181. <https://doi.org/10.1109/IACC48062.2019.8971602>
- Amin, H., Darwish, A., Hassanien, A. E., & Soliman, M. (2022). End-to-End Deep Learning Model for Corn Leaf Disease Classification. *IEEE Access*, 10, 31103–31115. <https://doi.org/10.1109/ACCESS.2022.3159678>
- Aravind, K. R., Raja, P., Mukesh, K. V., Anirudh, R., Ashwin, R., & Szczepanski, C. (2018). Disease classification in maize crop using bag of features and multiclass support vector machine. *Proceedings of the 2nd International Conference on Inventive Systems and Control, ICISC 2018*, Icisc, 1191–1196. <https://doi.org/10.1109/ICISC.2018.8398993>
- Barbedo, J. G. A. (2018). Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, 172, 84–91. <https://doi.org/10.1016/j.biosystemseng.2018.05.013>
- Brewbaker, J. L., & Hawaii, T. (2003). *Corn Production in the Tropics*. www.ctahr.hawaii.edu
- Çakmak, M. (2024). Automatic Maize Leaf Disease Recognition Using Deep Learning. *Sakarya University Journal of Computer and Information Sciences*, 7(1), 61–76. <https://doi.org/10.35377/saucis...1418505>
- Chen, J., Wang, W., Zhang, D., Zeb, A., & Nanekaran, Y. A. (2021). Attention embedded lightweight network for maize disease recognition. *Plant Pathology*, 70(3), 630–642. <https://doi.org/10.1111/ppa.13322>
- Craze, H. A., Pillay, N., Joubert, F., & Berger, D. K. (2022). Deep Learning Diagnostics of Gray Leaf Spot in Maize under Mixed Disease Field Conditions. *Plants*, 11(15), 1–17. <https://doi.org/10.3390/plants11151942>
- Goodfellow, I., Bengio, Y., & Aaron Courville (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Handrizal, Manik, F. Y., & Sianturi, V. J. (2024). Classification of Corn Leaf Diseases Using Cnn: a Deep Learning Approach. *Journal of Theoretical and Applied Information Technology*, 102(24), 8937–8945.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Hendrycks, D. (2024). *Introduction to AI safety, ethics, and society*. CRC Press.
- Hu, R., Zhang, S., Wang, P., Xu, G., Wang, D., & Qian, Y. (2020). The identification of corn leaf diseases based on transfer learning and data augmentation. *ACM International Conference Proceeding Series*, 58–65. <https://doi.org/10.1145/3403746.3403905>

- Huck, W. (2023). Transforming our world: the 2030 Agenda for Sustainable Development. *Sustainable Development Goals*. <https://doi.org/10.5040/9781509934058.0025>
- Idress, K. A. D., Gadalla, O. A. A., Öztekin, Y. B., & Baitu, G. P. (2024). Machine Learning-based for Automatic Detection of Corn-Plant Diseases Using Image Processing. *Tarim Bilimleri Dergisi*, 30(3), 464–476. <https://doi.org/10.15832/ankutbd.1288298>
- 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(October 2020), 106124. <https://doi.org/10.1016/j.compag.2021.106124>
- Islam, M. M., Adil, M. A. A., Talukder, M. A., Ahamed, M. K. U., Uddin, M. A., Hasan, M. K., Sharmin, S., Rahman, M. M., & Debnath, S. K. (2023). DeepCrop: Deep learning-based crop disease prediction with web application. *Journal of Agriculture and Food Research*, 14(July). <https://doi.org/10.1016/j.jafr.2023.100764>
- Ji, Z., Bao, S., Chen, M., & Wei, L. (2024). ICS-ResNet: A Lightweight Network for Maize Leaf Disease Classification. *Agronomy*, 14(7). <https://doi.org/10.3390/agronomy14071587>
- Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2017). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, 143(January), 23–37. <https://doi.org/10.1016/j.compag.2017.09.037>
- Krishna, S. T., & Kalluri, H. K. (2019). Deep learning and transfer learning approaches for image classification. *International Journal of Recent Technology and Engineering*, 7(5), 427–432.
- 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 Maize-Crop using deep learning. *Artificial Intelligence in Agriculture*, 6, 276–291. <https://doi.org/10.1016/j.aiia.2022.11.002>
- L. Paliwal, R. (2001a). El maíz en los trópicos: mejoramiento y producción. En *Food and Agriculture Organization of the United Nations*. <http://www.fao.org/docrep/003/x7650s/x7650s00.htm>
- L. Paliwal, R. (2001b). El Maíz en los trópicos: mejoramiento y producción. *Fao*, 392. <http://www.fao.org/docrep/003/x7650s/x7650s00.htm>
- Leng, S., Musha, Y., Yang, Y., & Feng, G. (2023). CEMLB-YOLO: Efficient Detection Model of Maize Leaf Blight in Complex Field Environments. *Applied Sciences (Switzerland)*, 13(16). <https://doi.org/10.3390/app13169285>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors (Switzerland)*, 18(8), 1–29. <https://doi.org/10.3390/s18082674>

- Lv, M., Zhou, G., He, M., Chen, A., Zhang, W., & Hu, Y. (2020). Maize Leaf Disease Identification Based on Feature Enhancement and DMS-Robust Alexnet. *IEEE Access*, 8, 57952–57966. <https://doi.org/10.1109/ACCESS.2020.2982443>
- 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(May), 52862–52876. <https://doi.org/10.1109/ACCESS.2023.3280260>
- Mejía, D. (2003). Maize: Post-Harvest Operation (F. (Technical) AGST/FAO: Danilo Mejía, PhD (ed.).
- Pfordt, A., & Paulus, S. (2025). A review on detection and differentiation of maize diseases and pests by imaging sensors. *Journal of Plant Diseases and Protection*, 132(1). <https://doi.org/10.1007/s41348-024-01019-4>
- 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(April), 1–15. <https://doi.org/10.3389/fpls.2022.864486>
- Reddy, D. B. R. S., Madhavi, D. G. B., Lakshmi, C. H. S., Nagendra, D. K. V., & Sridevi, D. R. (2021). Detection of Disease in Maize Plant Using Deep Learning. *Alinteri Journal of Agriculture Sciences*, 36(2), 82–88. <https://doi.org/10.47059/alinteri/v36i2/ajas21118>
- Resti, Y., Irsan, C., Putri, M. T., Yani, I., Anshori, & Suprihatin, B. (2022). Identification of Corn Plant Diseases and Pests Based on Digital Images using Multinomial Naïve Bayes and K-Nearest Neighbor. *Science and Technology Indonesia*, 7(1), 29–35. <https://doi.org/10.26554/sti.2022.7.1.29-35>
- Rouhiainen, L. (2020). Artificial Intelligence: 101 Things You Should Know Today About Our Future. <https://doi.org/10.1128/AAC.03728-14>
- Russell, S. J., & Norvig, P. (2021). *Artificial Intelligence A Modern Approach*. Pearson.
- Santhi, S., Murugan, M., Srinivasan, T., & Shanthi, K. G. (2024). Corn Leaf Disease Detection using Deep Learning Techniques. *2nd International Conference on Sustainable Computing and Smart Systems, ICSCSS 2024–Proceedings, ICSCSS*, 1536–1540. <https://doi.org/10.1109/ICSCSS60660.2024.10625229>
- Savary, S., Willocquet, L., Pethybridge, S. J., Esker, P., McRoberts, N., & Nelson, A. (2019). The global burden of pathogens and pests on major food crops. *Nature Ecology and Evolution*, 3(3), 430–439. <https://doi.org/10.1038/s41559-018-0793-y>
- Unal, Z. (2020). Smart Farming Becomes even Smarter with Deep Learning—A Bibliographical Analysis. *IEEE Access*, 8, 105587–105609. <https://doi.org/10.1109/ACCESS.2020.3000175>

- Waheed, A., Goyal, M., Gupta, D., Khanna, A., Hassanien, A. E., & Pandey, H. M. (2020). An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. *Computers and Electronics in Agriculture*, 175(January), 105456. <https://doi.org/10.1016/j.compag.2020.105456>
- Wahyuningrum, R. T., Kusumaningsih, A., & Yousi, D. M. (2023). Classification of Corn Leaf Diseases using Loss-Fused Convolutional Neural Network. *Proceedings of 2023 International Conference on Information Management and Technology, ICIM-Tech 2023*, 696–701. <https://doi.org/10.1109/ICIMTech59029.2023.10277763>
- Wang, Y., Jin Tao, & Gao, H. (2022). Corn Disease Recognition Based on Attention Mechanism Network. *Axioms*, 11(480).
- 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). <https://doi.org/10.3390/agronomy13092242>
- Yin, C., Zeng, T., Zhang, H., Fu, W., Wang, L., & Yao, S. (2022). Maize Small Leaf Spot Classification Based on Improved Deep Convolutional Neural Networks with a Multi-Scale Attention Mechanism. *Agronomy*, 12(4). <https://doi.org/10.3390/agronomy12040906>
- 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>
- Zhang, X., Qiao, Y., Meng, F., Fan, C., & Zhang, M. (2018). Identification of maize leaf diseases using improved deep convolutional neural networks. *IEEE Access*, 6, 30370–30377. <https://doi.org/10.1109/ACCESS.2018.2844405>
- Zhou, H., Su, Y., Chen, J., Li, J., Ma, L., Liu, X., Lu, S., & Wu, Q. (2024). Maize Leaf Disease Recognition Based on Improved Convolutional Neural Network ShuffleNetV2. *Plants*, 13(12), 1–18. <https://doi.org/10.3390/plants13121621>
- Zhu, S., & Gao, H. (2024). MC-ShuffleNetV2: A lightweight model for maize disease recognition. *Egyptian Informatics Journal*, 27(January), 100503. <https://doi.org/10.1016/j.eij.2024.100503>



INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN CIENTÍFICA

ISBN: 978-968-9724-25-4



9 789689 724254

Trans[®]
digital
editorial