



Diagnóstico temprano de enfermedades en cultivo de maíz mediante Redes Neuronales Convolucionales (RNC)

Early Diagnosis of Diseases in Corn Crops Using Convolutional Neural Networks (CNN)

Marcelo Antonio Callao-Pimentel^{1,2*}; Lilian Roxana Paredes-López^{1,2};
Luis Enrique Ricardo Burgos-Saavedra^{1,2}

1 Facultad de Ciencias Físicas y Matemáticas, Universidad Nacional Pedro Ruiz Gallo (UNPRG), Lambayeque, Perú.

2 Escuela profesional de estadística, Universidad Nacional Pedro Ruiz Gallo (UNPRG), Lambayeque, Perú.

* Autor correspondiente: mcallaop@unprg.edu.pe (M. A. Callao-Pimentel).

ORCID de los autores:

M. A. Callao-Pimentel: <http://orcid.org/0009-0007-2243-8985>

L. R. Paredes-López: <http://orcid.org/0000-0002-4290-1216>

L. E. R. Burgos-Saavedra: <http://orcid.org/0009-0008-8290-4228>

RESUMEN

El presente estudio desarrolla un modelo de clasificación automatizada basado en redes neuronales convolucionales (CNN) para analizar imágenes de plantas de maíz. El objetivo principal fue construir un sistema capaz de identificar de manera precisa la condición de las hojas de maíz, clasificándolas como saludables o afectadas por enfermedades comunes como la roya común y la mancha foliar por *Cercospora*. Se utilizó el dataset "Corn Disease Dataset" de Kaggle, dividiendo las imágenes en conjuntos de entrenamiento, validación y prueba. El modelo, construido en TensorFlow y Keras, alcanzó una precisión del 97.22 % en la fase de evaluación, demostrando su alta efectividad. Se aplicaron técnicas de aumento de datos y preprocesamiento de imágenes para mejorar el desempeño y la capacidad de generalización del modelo. Los resultados evidencian que las CNN son una herramienta poderosa para el diagnóstico temprano de enfermedades en cultivos de maíz, lo cual contribuye a mejorar la productividad agrícola y promover prácticas agrícolas sostenibles.

Palabras clave: Redes neuronales convolucionales; clasificación automatizada; maíz; procesamiento de imágenes; enfermedades de plantas.

ABSTRACT

This study develops an automated classification model based on Convolutional Neural Networks (CNN) to analyze images of maize plants. The main objective was to build a system capable of accurately identifying the condition of maize leaves, classifying them as healthy or affected by common diseases such as common rust and *Cercospora* leaf spot. The "Corn Disease Dataset" from Kaggle was used, dividing the images into training, validation, and testing sets. The model, built using TensorFlow and Keras, achieved an evaluation accuracy of 97.22%, demonstrating high effectiveness. Data augmentation techniques and image preprocessing were applied to enhance the model's performance and generalization capability. The results show that CNNs are a powerful tool for the early diagnosis of crop diseases, contributing to improved agricultural productivity and promoting sustainable farming practices.

Keywords: Convolutional Neural Networks; automated classification; maize; image processing; plant diseases.

Recibido: 13-04-2026.

Aceptado: 25-06-2026.



Esta obra está publicada bajo la licencia [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)

INTRODUCCIÓN

El reconocimiento automatizado de enfermedades en hojas de maíz mediante Redes Neuronales Convolucionales (CNN) representa un avance crucial para optimizar la detección temprana y mejorar la productividad agrícola de forma eficiente.

El campo del diagnóstico fitosanitario mediante inteligencia artificial ha experimentado avances significativos. Shandilya et al. (2025) desarrollaron un modelo híbrido CNN-ViT para la clasificación de enfermedades foliares en maíz, logrando una precisión del 98,75% al combinar la extracción de características locales de las CNN con la captura de dependencias globales de los Vision Transformers. Por su parte, Xu (2026) propusieron G-ResNet, una red híbrida CNN-Vision Mamba con módulos de atención jerárquica que mejora la discriminación de lesiones en imágenes con fondos complejos, alcanzando 99,10% de exactitud en datasets de maíz. Asimismo, Mehdipour et al. (2026) presentaron un modelo CNN-ViT ligero inspirado en arquitecturas mixture-of-experts, que logró 99,00% de precisión evaluado en condiciones de campo real, superando significativamente a modelos CNN convencionales. La integración de mecanismos de atención con arquitecturas convolucionales representa la tendencia más prometedora en el diagnóstico automatizado de enfermedades en cultivos de cereales.

La producción de maíz es un pilar fundamental en la seguridad alimentaria mundial, debido a su elevada capacidad fotosintética y a su aporte como cultivo estratégico en múltiples regiones del planeta. Estudios como los de Bansal & Kumar (2021) evidencian que deficiencias nutricionales pueden reducir significativamente la productividad, mientras que Rachmad & Rochman (2023) destacan la vulnerabilidad del maíz frente a enfermedades que afectan su crecimiento. En el contexto global, la necesidad de asegurar un suministro continuo y eficiente de este cereal es imperativa, dado su impacto directo en el bienestar social y económico. Nayak & Tinababu (2024) menciona que la gestión agrícola adecuada, apoyada en tecnologías innovadoras, resulta esencial para garantizar tanto la productividad como la sostenibilidad de los cultivos. Dentro de este panorama, las enfermedades del maíz se constituyen en una de las principales amenazas, ya que reducen la capacidad fotosintética y comprometen el rendimiento final de las cosechas. Tal como señalan Abas et al. (2024), patologías como la roya común, el tizón foliar y la mancha gris requieren detección oportuna y manejo eficaz para evitar pérdidas masivas. Rodríguez & Cipra (2022) y Huaytan & Punzel (2023) ponen de manifiesto que el Perú enfrenta limitaciones relacionadas con la falta de capacitación técnica y recursos tecnológicos, lo que dificulta la detección temprana de plagas y enfermedades. Estas brechas generan la necesidad urgente de soluciones accesibles y adaptadas a los contextos locales, especialmente en la agricultura familiar, que constituye el núcleo productivo del país.

El avance de las ciencias computacionales ha abierto nuevas posibilidades para la agricultura de

precisión, particularmente mediante la aplicación de algoritmos de aprendizaje automático (Machine Learning, ML) y redes neuronales convolucionales (CNN). La eficacia de estas arquitecturas para identificar patrones complejos en imágenes médicas y agrícolas, alcanzando niveles de precisión superiores al 85% (De la Vega, 2022; Sorogastua, 2022). Géron (2023), quien subraya la capacidad de las CNN para procesar datos espaciales y reconocer estructuras de manera jerárquica. Estas innovaciones resultan claves para automatizar procesos que antes dependían de evaluaciones humanas, reduciendo costos y mejorando la eficiencia en la toma de decisiones.

La visión artificial y el procesamiento digital de imágenes constituyen la base tecnológica que permite implementar estas soluciones. Según González & Woods (2008), la segmentación y el reconocimiento son procesos centrales para dividir imágenes en regiones homogéneas y clasificar objetos de interés, facilitando el análisis computacional. Además, Domínguez (1996) destaca que el procesamiento de imágenes digitales ofrece herramientas para mejorar la calidad visual y automatizar el análisis, lo cual es esencial en entornos agrícolas con grandes volúmenes de datos visuales. La etapa de adquisición, descrita por Kashyapa (2022), resalta la importancia de capturar imágenes con buena nitidez y contraste, pues la calidad de los datos iniciales condiciona la efectividad de los algoritmos aplicados posteriormente.

El desarrollo de plataformas abiertas y lenguajes de programación especializados ha facilitado aún más la aplicación de estas metodologías en la práctica agrícola. Herramientas como OpenCV, documentada por Bradski (2000), permiten realizar segmentación, transformación y seguimiento de imágenes en tiempo real, mientras que lenguajes como Python y librerías como TensorFlow y Keras (Géron, 2023) simplifican la construcción y validación de modelos de aprendizaje profundo. Esta integración de software accesible y hardware cada vez más económico ha democratizado el uso de la inteligencia artificial en contextos rurales, permitiendo que incluso agricultores con recursos limitados puedan acceder a soluciones tecnológicas que mejoren su productividad.

Finalmente, es importante resaltar que, aunque la producción de maíz en el Perú ha experimentado un crecimiento sostenido en las últimas décadas (Huamanchumo, 2013), persisten brechas significativas en productividad y en adopción tecnológica. Estas limitaciones pueden ser abordadas mediante la incorporación de sistemas inteligentes que permitan la detección temprana de enfermedades, contribuyendo no solo a la seguridad alimentaria, sino también a la sostenibilidad económica de los agricultores. En este sentido, el objetivo de este estudio es construir un modelo que permita clasificar con precisión si las hojas de maíz presentan alguna enfermedad o se encuentran sanas, con el fin de una intervención apropiada, rápida y efectiva.

METODOLOGÍA

El presente estudio se desarrolló bajo un enfoque cuantitativo y de carácter no experimental, enfocado en la evaluación del desempeño de modelos de redes neuronales convolucionales (CNN) aplicados a la detección automática de enfermedades en hojas de maíz. Se optó por la metodología SEMMA (Sample, Explore, Modify, Model, Assess), reconocida en minería de datos por estructurar el flujo de trabajo desde la recolección de información hasta la evaluación final.

La adopción de SEMMA responde a la necesidad de garantizar un proceso ordenado y reproducible. Según González y Woods (2008), el análisis de datos en visión artificial requiere fases bien definidas para minimizar errores y obtener resultados confiables, mientras que Géron (2023) enfatiza que la preparación y exploración de los datos impacta directamente en la calidad de los modelos de aprendizaje profundo.

Algoritmo 1. Modelo de clasificación automatizada de enfermedades foliares en maíz mediante RNC

ENTRADA: Imágenes de hojas de maíz (I) con etiquetas de clase (y)

SALIDA: Modelo de clasificación M, métricas de evaluación.

PASO 1 – MUESTREO (Sample)

1.1 Cargar datasets: PlantDoc (Singh et al., 2020) y Pandian & Geetharamani (2019) 1.2 Aplicar criterios de inclusión: resolución $\geq 224 \times 224$ px, etiqueta verificada 1.3 Excluir imágenes duplicadas, dañadas o con etiquetas dudosas 1.4 Particionar (estratificado): 70% entrenamiento / 15% validación / 15% prueba

PASO 2 – ANÁLISIS EXPLORATORIO (Explore)

2.1 Calcular distribución de clases y detectar desbalances 2.2 Revisar calidad de imágenes (ruido, sombras, sobreexposición) 2.3 Planificar uso de Grad-CAM para validación de interpretabilidad

PASO 3 – PREPROCESAMIENTO (Modify)

3.1 Redimensionar imágenes: 224×224 píxeles 3.2 Normalizar: $I_{norm} = I / 255.0$ 3.3 Aplicar Data Augmentation: rotación ($\pm 30^\circ$), volteo H/V, zoom ($0.8-1.2 \times$), brillo 3.4 Codificar etiquetas: one-hot encoding (n_clases = 3)

PASO 4 – CONSTRUCCIÓN DEL MODELO (Model)

4.1 Seleccionar arquitectura base: ResNet-50 o EfficientNet-B0 (pesos ImageNet) 4.2 Congelar capas base; añadir capas de clasificación: GlobalAveragePooling2D \rightarrow Dense(256, ReLU) \rightarrow Dropout(0.5) \rightarrow Dense(3, Softmax) 4.3 Compilar: Adam (lr=1e-4), pérdida=categorical_crossentropy, métrica=accuracy 4.4 Entrenar: batch_size=32, epochs=100 Callbacks: EarlyStopping(patience=10), ModelCheckpoint 4.5 Fine-tuning: descongelar últimas capas, lr=1e-5, re-entrenar SI Accuracy_val mejora: guardar modelo M SI NO: ajustar hiperparámetros \rightarrow repetir desde 4.3

PASO 5 – EVALUACIÓN (Assess)

5.1 Calcular: Accuracy, Precision, Recall, F1-score por clase 5.2 Generar matriz de confusión sobre conjunto de prueba 5.3 Aplicar Grad-CAM para mapas de activación e interpretabilidad 5.4 Registrar tiempo de inferencia por imagen RETORNAR: M, métricas, mapas Grad-CAM

Sample (Muestreo)

La fase Sample se centró en la recopilación y organización de imágenes de hojas de maíz. Se empleó como fuente principal el Corn Disease. Se emplearon los datasets PlantDoc (Singh et al., 2020) y el de Pandian & Geetharamani (2019), el dataset incluyó cuatro categorías de interés: hojas sanas, roya común, mancha gris foliar y tizón. Estas enfermedades son relevantes por su impacto en la productividad del maíz, tal como señalan Bansal y Kumar (2021) y Abas et al. (2024), quienes destacan que la detección temprana resulta fundamental para evitar pérdidas significativas.

Para garantizar la calidad del muestreo, se aplicaron criterios de inclusión y exclusión. Se conservaron únicamente las imágenes con buena resolución, enfoque nítido y etiquetas verificables. En contraste, se descartaron imágenes duplicadas, con etiquetas dudosas o dañadas. Estas prácticas coinciden con lo expuesto por Rachmad y Rochman (2023), quienes resaltan la importancia de conjuntos de datos limpios en la clasificación de enfermedades vegetales.

Con el objetivo de estructurar el dataset, se elaboró un resumen (Tabla 1) que muestra la distribución de imágenes por clase y por partición (entrenamiento, validación y prueba).

Tabla 1

Distribución de imágenes por clase y partición

Clase	Frecuencia	Porcentaje
Common Rust	1306	42,93%
Gray Leaf Spot	574	18,87%
Healthy	1162	38,20%
Total	4188	100,00%

Nota: Frecuencia y proporción de las hojas de maíz de acuerdo a la clase de enfermedad.

Además, se documentaron metadatos de cada archivo (ruta, tamaño, fecha de adquisición y etiqueta) con el fin de asegurar trazabilidad. Tal como recomiendan Huaytan & Punzel (2023), este registro facilita la auditoría y la replicación de experimentos en diferentes contextos agrícolas.

Explore (Análisis exploratorio de datos)

Este análisis permitió detectar ligeros desbalances de clases, particularmente en la categoría tizón, lo cual puede afectar la precisión del modelo. Según Abas et al. (2024), los desbalances en datasets agrícolas generan modelos menos robustos, lo que refuerza la necesidad de aplicar técnicas de augmentación y balanceo.

La exploración incluyó también la revisión de calidad de imágenes: se identificaron fotografías con fondos ruidosos, sombras excesivas y sobreexposición. Como señalan Domínguez (1996) y Kashyapa (2022), la calidad de los datos de entrada condiciona directamente la efectividad del procesamiento de imágenes digitales y de la visión artificial.

Asimismo, se planificó el uso de herramientas de interpretabilidad como Grad-CAM, que permiten verificar si las CNN concentran su atención en las áreas foliares enfermas. Esto coincide con lo

indicado por Fiestas (2022), quien resalta la importancia de validar que los modelos analicen características relevantes y no artefactos externos.

Modify (Preprocesamiento y enriquecimiento)

La fase Modify consistió en transformar y preparar los datos para el modelado. Se aplicaron procesos de redimensionamiento a 224x224 píxeles, normalización de escala (1./255) y codificación categórica de etiquetas.

Se aplicaron también técnicas de data augmentation, como rotaciones aleatorias, giros horizontales, zooms y ajustes de contraste. Estas transformaciones enriquecen el dataset y reducen el riesgo de sobreajuste. De acuerdo con Bansal & Kumar (2021), estas técnicas permiten que los modelos aprendan a generalizar mejor en condiciones de campo real.

Además, se implementaron procesos de limpieza, eliminando duplicados y revisando inconsistencias de etiquetas. Este paso sigue lo planteado por Rachmad & Rochman (2023), quienes señalan que la confiabilidad de las etiquetas es crítica en la clasificación automática de enfermedades agrícolas.

Para asegurar consistencia, se construyó un pipeline automatizado de preprocesamiento en Python con librerías como OpenCV, TensorFlow y Keras. Como destaca Bradski (2000), el uso de OpenCV resulta clave en visión artificial por su capacidad para procesar imágenes en tiempo real.

Model (Construcción y entrenamiento)

La fase Model correspondió a la construcción de los clasificadores. Se aplicó la estrategia de transfer learning, empleando arquitecturas como ResNet-50 y EfficientNet, preentrenadas en grandes bases de datos y ajustadas al problema específico. Este enfoque permite mejorar la precisión incluso con un número limitado de imágenes.

El modelo fue compilado con el optimizador Adam, tasa de aprendizaje inicial de $1e-4$, función de pérdida `categorical_crossentropy` y métrica de accuracy. Se entrenó con un máximo de 100 épocas y batch size de 32, aplicando `early stopping` y `checkpointing` para guardar los mejores pesos (Tabla 2).

Tabla 2
Hiperparámetros principales utilizados en el modelado

Parámetro	Valor
Entrada	224x224
Batch	32
Epoch	100
Optimizador	Adam

Nota: Parámetros de modelo de machine learning para Redes neuronales convolucionales.

Además, se aplicaron técnicas de regularización como dropout y validación cruzada en algunos experimentos piloto. Como subraya Nayak & Tinababu (2024), estas estrategias son necesarias para prevenir el sobreentrenamiento y garantizar que los modelos se adapten a datos no vistos.

Assess (Evaluación y validación)

En la fase Assess, el modelo fue evaluado con métricas tradicionales: accuracy, precision, recall, F1-score y matriz de confusión. Estas métricas permiten analizar tanto el rendimiento global como el específico de cada clase.

Finalmente, se aplicaron pruebas de interpretabilidad con Grad-CAM y se verificó el tiempo de inferencia por imagen para evaluar la viabilidad del modelo en aplicaciones de campo. Tal como indican Rodríguez & Cipra (2022) y Huaytan & Punzel (2023), la aplicabilidad práctica en contextos rurales depende no solo de la precisión, sino también de la facilidad de uso y rapidez de respuesta.

RESULTADOS Y DISCUSIÓN

Los resultados obtenidos evidenciaron un rendimiento sobresaliente del modelo de red neuronal convolucional aplicado a la clasificación de enfermedades foliares en maíz. La exactitud alcanzada en el conjunto de prueba fue de 97,22%, con una pérdida de 0,28809, lo cual refleja una adecuada capacidad de generalización sobre las muestras no utilizadas durante el entrenamiento. Estos valores son consistentes con los hallazgos de Bansal & Kumar (2021), quienes reportaron precisiones superiores al 95% en CNN entrenadas con datasets balanceados.

El análisis por clase mostró que la categoría "Saludable" obtuvo precisión y exhaustividad perfectas (1.00) (Tabla 3), lo que implica que el modelo identificó correctamente todas las instancias sin generar falsos positivos. En contraste, "Roya común" alcanzó recall perfecto (1,00) pero una precisión menor (0,93), lo que sugiere la existencia de predicciones erróneas hacia esa clase. La etiqueta "Mancha foliar (Cercospora)" registró precisión de 1,00 y recall de 0,92, revelando la omisión de un caso. Estos

patrones se asemejan a los descritos por Rachmad & Rochman (2023), quienes observaron que ciertas enfermedades presentan síntomas visualmente solapados, dificultando su discriminación. Asimismo, se ratifica a la necesidad de conjuntos de datos amplios y balanceados para mejorar la sensibilidad de los modelos.

Tabla 3
Métricas por clase

Clase	Precisión	Recall	F1
Common Rust	1,00	0,92	0,96
Gray Leaf Spot	0,93	1,00	0,97
Healthy	1,00	1,00	1,00

Esto confirma que los síntomas de ambas enfermedades pueden compartir patrones morfológicos similares en determinadas fases, dificultando la clasificación automática. De acuerdo con Domínguez (1996), las variaciones de contraste y textura en imágenes pueden inducir errores de reconocimiento si no se aplican procesos de segmentación adecuados, mientras

que Huaytan & Punzel (2023) enfatizan la importancia de técnicas de preprocesamiento para minimizar la influencia de condiciones externas en la detección.

El comportamiento del entrenamiento evidenció un aumento progresivo de la exactitud y una disminución de la pérdida, lo que demuestra aprendizaje efectivo (Figura 1). Sin embargo, se observó que la pérdida de validación se mantuvo por debajo de la de entrenamiento, lo cual es inusual y sugiere la posible existencia de data leakage o diferencias en la complejidad de los subconjuntos (Figura 2). Géron (2023) advierte que la fuga de información entre particiones puede inflar artificialmente las métricas de validación, mientras que se recomienda la implementación de validación cruzada estratificada para evitar sobreestimaciones del rendimiento.

Las visualizaciones mediante Grad-CAM mostraron que las activaciones de la red se concentraron en las regiones foliares afectadas (Figura 3), confirmando que las decisiones del modelo se sustentan en características sintomáticas y no en artefactos del fondo. Este hallazgo se alinea con lo

planteado por Fiestas Sorogastua (2022), quien enfatizó la relevancia de la interpretabilidad en modelos de aprendizaje profundo para fortalecer la confianza en sus predicciones, y con lo descrito en IntroC.docx, donde se resalta que la segmentación y focalización son esenciales para una clasificación fiable. En consecuencia, la interpretabilidad respalda la validez biológica de los resultados.




Figura 1. Curvas de entrenamiento.




Figura 2. Matriz de confusión.




Figura 3. Mapas Grad-CAM.

Si bien las métricas globales fueron destacadas, es necesario reconocer limitaciones que condicionan la generalización de los resultados. El reducido tamaño del conjunto de prueba (36 imágenes) y el bajo soporte por clase (9 - 14 instancias) incrementan la varianza de las estimaciones. Abas et al. (2024) advierten que la falta de muestras diversas limita la capacidad de extrapolación de los modelos de visión artificial, mientras que Nayak & Tinababu (2024) destacan la importancia de validaciones externas en dominios distintos. Así, los resultados deben considerarse preliminares y sujetos a confirmación en pruebas con mayor heterogeneidad de datos.

En comparación con la literatura internacional, los resultados se encuentran dentro del rango superior reportado para sistemas basados en CNN en agricultura. Estudios como los de Bansal & Kumar (2021) y Nayak & Tinababu (2024) registraron niveles de precisión entre 95% y 98%, cifras semejantes a las alcanzadas en el presente estudio.

No obstante, estos mismos autores señalan caídas de rendimiento cuando los modelos son expuestos a dominios externos, lo que refuerza la recomendación de ampliar el muestreo geográfico y de dispositivos de captura.

Si bien presentan implicaciones para la adopción local. Según Rodríguez & Cipra (2022), la integración de herramientas tecnológicas en agricultura requiere acompañamiento en capacitación y adaptación al contexto productivo, mientras que Huaytan & Punzel (2023) resaltan que la heterogeneidad de condiciones en campo puede afectar la efectividad de modelos entrenados en entornos controlados. De esta manera, la transición del prototipo a una herramienta práctica debe contemplar pruebas piloto regionales y el desarrollo de interfaces accesibles para agricultores.

Asimismo, las mejoras técnicas sugeridas a partir de los resultados incluyen la incorporación de segmentación previa y anotaciones expertas, lo

cual coincide con lo planteado por Domínguez (1996) respecto al valor de la segmentación para la detección de patrones en imágenes. A esto se suma la necesidad de explorar estrategias avanzadas de ajuste de hiperparámetros y ensamblajes de modelos, recomendadas como mecanismos para mejorar la robustez en casos límite.

En la Tabla 4 se compara el desempeño del modelo propuesto con otros modelos publicados en maíz y cultivos similares, incluyendo estudios recientes de 2025 y 2026. Estos resultados confirman la factibilidad técnica de aplicar CNN a la clasificación de enfermedades foliares en maíz, mostrando

desempeños comparables o superiores a los de estudios previos en condiciones similares. Sin embargo, las limitaciones de la muestra y las anomalías detectadas durante el entrenamiento obligan a considerar estos hallazgos como un primer paso hacia el desarrollo de sistemas robustos para su aplicación en campo. La literatura revisada respalda la necesidad de ampliar datasets, diversificar escenarios de validación y fortalecer los procesos de interpretabilidad, condiciones indispensables para transformar estos prototipos en soluciones aplicables en la agricultura de precisión.

Tabla 4

Comparación del modelo propuesto con estudios previos en diagnóstico de enfermedades foliares

Estudio	Cultivo	Arquitectura	Dataset	Acc. (%)	Año
Presente estudio	Maíz	ResNet-50 / EfficientNet	PlantDoc + Kaggle	97,22	
Mehdipour et al.	Maíz	CNN-ViT ligero	Campo real	99,90	2026
Xu	Maíz	G-ResNet (CNN-Mamba)	Kaggle	99,10	2026
Shandilya et al.	Maíz	CNN-ViT híbrido	PlantVillage + CD&S	98,75	2025
Nayak et al.	Múltiples cultivos	CNN (Transfer Learning)	PlantVillage	97,80	2024
Rachmad & Rochman	Maíz	CNN personalizada	PlantVillage	95,40	2023
Mishra et al.	Papa / Mango	EfficientNet-B4	PlantVillage + Kaggle	98,10	2025
Bansal & Kumar	Maíz	CNN profunda	Kaggle	96,30	2021

Nota: Acc. = Accuracy en conjunto de prueba. Los valores corresponden a los reportados originalmente por cada estudio.

CONCLUSIONES

Los resultados obtenidos en la investigación permiten concluir que el modelo de redes neuronales convolucionales implementado demostró un desempeño sobresaliente en la clasificación de enfermedades foliares de maíz bajo condiciones controladas de entrenamiento y validación. La exactitud alcanzada, cercana al 97,2%, así como las métricas de precisión, exhaustividad y F1-score, evidencian la viabilidad técnica de esta metodología como herramienta de apoyo para la agricultura de precisión. La capacidad del modelo para identificar de manera correcta hojas sanas y distinguirlas de las afectadas resulta especialmente relevante, ya que contribuye a la detección temprana de enfermedades que pueden comprometer la productividad del cultivo. Asimismo, los mapas de activación Grad-CAM confirmaron que las predicciones se basan en características sintomáticas plausibles desde el

punto de vista biológico, lo cual fortalece la validez de las decisiones automatizadas y respalda su aplicabilidad práctica.

No obstante, también se evidenciaron limitaciones que deben ser atendidas antes de un despliegue operativo. Entre ellas destacan el tamaño reducido de la muestra de prueba, el soporte limitado por clase y la anomalía observada en las curvas de entrenamiento, factores que condicionan la generalización de los resultados. En este sentido, se recomienda ampliar la base de datos con imágenes provenientes de diversas regiones y dispositivos, implementar validaciones externas más rigurosas y explorar técnicas de segmentación foliar y ajuste avanzado de hiperparámetros. Con estas mejoras, el modelo no solo podrá consolidar su precisión en entornos reales, sino también transformarse en una herramienta robusta y confiable para la toma de decisiones en la gestión sanitaria del maíz.

AGRADECIMIENTOS

Se expresa un reconocimiento especial a la Universidad Nacional Pedro Ruiz Gallo, institución que brindó el respaldo académico y logístico necesario para la realización del presente trabajo de investigación. Asimismo, se agradece a la Facultad de Ciencias Físicas y Matemáticas por proporcionar el espacio académico y científico en el

cual se desarrollaron los análisis y discusiones que sustentan este estudio. Finalmente, se manifiesta un agradecimiento sincero a la Escuela Profesional de Estadística, cuya formación académica y apoyo permanente hicieron posible la culminación de esta investigación.

REFERENCIAS BIBLIOGRÁFICAS

- Abas, M. I., Syarif, S., Nurtanio, I., & Tahir, Z. (2024). Detection of corn plant diseases using convolutional neural network: A review. *AIP Conference Proceedings*, 3145, 040001. <https://doi.org/10.1063/5.0211960>
- Bansal, S., & Kumar, A. (2021). Deep Learning for Maize Crop Deficiency Detection. In: Das, B., Patgiri, R., Bandyopadhyay, S., Balas, V.E. (eds) *Modeling, Simulation and Optimization. Smart Innovation, Systems and Technologies*, vol 206. Springer, Singapore. https://doi.org/10.1007/978-981-15-9829-6_37
- Bradski, G. (2000). The OpenCV Library. Dr. Dobb's Journal of Software Tools.
- De la Vega Jiménez, F. (2022). Classification of medical images for Alzheimer's diagnosis using convolutional neural networks. arXiv. <https://arxiv.org/abs/2210.08330>
- Dominguez Torres, A. (1996). Procesamiento digital de imágenes. *Perfiles Educativos*, (72).
- Fiestas Sorogastua, A. (2022). Evaluación del crecimiento de plantines de alcachofa mediante redes neuronales convolucionales. Universidad Privada Antenor Orrego. <https://hdl.handle.net/20.500.12759/8841>
- Géron, A. (2023). *Aprendizaje automático práctico con Scikit-Learn, Keras y TensorFlow* (3ª ed.). O'Reilly Media.
- González, R. C., & Woods, R. E. (2008). *Digital Image Processing* (3rd ed.). Prentice Hall.
- Huamanchumo, C. (2013). La cadena de valor de maíz en el Perú: diagnóstico del estado actual, tendencias y perspectivas. Instituto Interamericano de Cooperación para la Agricultura (IICA). <https://hdl.handle.net/11324/2654>
- Huaytan, C. & Punzel, R. (2023) AGROMEDIC - Detección y tratamiento de enfermedades en la planta del maíz. Universidad de Lima. <https://hdl.handle.net/20.500.12724/17727>
- Pandian, J. A., & Geetharamani, G. (2019). Data for: Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network", *Mendeley Data*, V1. <https://doi.org/10.17632/tywbtsjrjv.1>
- Kashyapa, R., & Kashyapa, R. (2022). *What is image acquisition in machine vision? - Trigger mechanism*. Qualitas Technologies. <https://qualitastech.com/image-acquisition/image-acquisition-in-machine-vision-trigger-mechanism/>
- Nayak, D., Nair, R. R., TinaBabu, N., & Kishore, S. (2024). CNN-based Plant Leaf Disease Detection: A Key Solution for Enhancing Agricultural Productivity. 3rd International Conference For Advancement In Technology (ICONAT), GOA, 1-6. <https://doi.org/10.1109/iconat61936.2024.10774756>
- Rachmad, A., Fuad, M., & Rochman, E. M. S. (2023). Convolutional neural network-based classification model of corn leaf disease. *Mathematical Modelling of Engineering Problems*, 10(2), 530-536. <https://doi.org/10.18280/mmep.100220>
- Rodríguez Alva, C. J., & Cipra Salinas, E. P. (2022). Detección de plagas y enfermedades en los cultivos de maíz utilizando procesamiento de imágenes con redes neuronales, en el distrito de Cascas - La Libertad, año 2022 [Tesis de licenciatura, Universidad Privada Antenor Orrego]. <https://hdl.handle.net/20.500.12759/14671>
- Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., Batra, N. (2020). PlantDoc: a dataset for visual plant disease detection. In *Proceedings of the 7th ACM IKDD CoDS and 25th COMAD 2020 Jan 5* (pp. 249-253).
- Shandilya, G., Gupta, S., Mohamed, H. G., Bharany, S., Rehman, A. U., & Hussen, S. (2025). Enhanced Maize Leaf Disease Detection and Classification Using an Integrated CNN-ViT Model. *Food Science & Nutrition*, 13(7), e70513. <https://doi.org/10.1002/fsn3.70513>
- Mishra, U., Pandey, A., Logeswari, G., & Tamarasi, K. (2025). Deep learning-based disease detection in potato and mango leaves: a comparative study of CNN, AlexNet, ResNet, and EfficientNet. *Scientific Reports*, 16, 2788. <https://doi.org/10.1038/s41598-025-32607-5>
- Xu, H. (2026). Corn or maize leaf disease classification based on CNN and vision mamba model. *Scientific Reports*, 16, 18783. <https://doi.org/10.1038/s41598-026-50033-z>
- Mehdipour, S., Mirroshandel, S. A. & Tabatabaei, S. A. (2026). A novel lightweight hybrid CNN-ViT for maize leaf disease classification. *Scientific Reports*, 16, 10468. <https://doi.org/10.1038/s41598-026-41190-2>