

Artículo de Investigación

Redes Neuronales Convolucionales para la Clasificación de la Mancha Negra en los cítricos

Convolutional Neural Networks for Citrus Black Spot Classification

Autores:

Andrés Alfonso Huanca Namuche¹, Bruno Sebastian Terry Alvarado², Cristian García Estrella³

¹Universidad Peruana Unión, Tarapoto, Perú, andreshuanca@upeu.edu.pe,
<https://orcid.org/0000-0002-3102-0245>

²Universidad Peruana Unión, Tarapoto, Perú, brunoterry@upeu.edu.pe, <https://orcid.org/0000-0002-4075-5593>

³Universidad Nacional de San Martín, Tarapoto, Perú, _.@gmail.com, <https://orcid.org/0000-0002-5687-8694>

Autor de Correspondencia: *Andrés Alfonso Huanca Namuche*, andreshuanca@upeu.edu.pe

Reception: 19-January-2025 **Acceptance:** 18-February-2025 **Published:** 16-March-2025

Como citar este artículo:

Huanca Namuche, A. A., Terry Alvarado, B. S., & García-Estrella, C. (2025). Redes Neuronales Convolucionales para la Clasificación de la Mancha Negra en los Cítricos. *Sapiens International Multidisciplinary Journal*, 2(2), 1-20. <https://doi.org/10.71068/4x9sw526>

Resumen

Se presenta un innovador modelo de visión artificial basado en redes neuronales convolucionales (CNN) para la clasificación de la mancha negra en los cítricos. Este estudio adopta una metodología que fusiona Investigación y Desarrollo con principios ágiles de Scrum. La evaluación comparativa con los modelos existentes de clasificación de cítricos en diferentes contextos demuestra que nuestro modelo muestra diferencias significativas en la precisión de clasificación respecto a los modelos B y C. El análisis estadístico, incluyendo la prueba de McNemar, confirma la eficacia del modelo, resaltando su fiabilidad y competitividad en la detección de enfermedades en cítricos. Los resultados obtenidos no solo proporcionan un modelo eficiente para la clasificación de la mancha negra en los cítricos, sino que también promueven el avance en la aplicación de la inteligencia artificial en la agricultura. Este enfoque sugiere nuevas direcciones de investigación y subraya la importancia de la visión artificial en la mejora de la salud de los cultivos. La implementación de este modelo puede reducir pérdidas económicas y optimizar la productividad, aportando beneficios significativos tanto para los agricultores como para la industria agrícola.

Palabras clave: Visión artificial, redes neuronales convolucionales, mancha negra, inteligencia artificial.

Abstract

An innovative computer vision model based on convolutional neural networks (CNN) is presented for the classification of black spot in citrus fruits. This study adopts a methodology that combines Research and Development with agile Scrum principles. Comparative evaluation with existing citrus classification models in different contexts demonstrates that our model shows significant differences in classification accuracy compared to models B and C. Statistical analysis, including the McNemar test, confirms the model's effectiveness, highlighting its reliability and competitiveness in the detection of diseases in citrus fruits. The results obtained not only provide an efficient model for the classification of black spot in citrus fruits but also promote advances in the application of artificial intelligence in agriculture. This approach suggests new directions for research and emphasizes the importance of computer vision in improving crop health. The implementation of this model can reduce economic losses and optimize productivity, providing significant benefits for both farmers and the agricultural industry.

Keywords: Computer vision, convolutional neural networks, black spot, artificial intelligence.

1. INTRODUCCIÓN

Los cítricos representan una de las frutas más consumidas a nivel mundial, y su producción se concentra principalmente en países con climas cálidos y subtropicales. Según la FAO, estos se cultivan en más de 140 países de todo el mundo, siendo Brasil, China y Estados Unidos los líderes de la producción global. Sin embargo, esta industria enfrenta desafíos significativos, como la enfermedad de la mancha negra, causada por el hongo "*Phyllosticta citricarpa*". Esta patología, común en la mayoría de los principales países productores, afecta la calidad visual de los frutos, reduciendo su valor comercial y generando importantes pérdidas económicas. Por ello, se han realizado estudios detallados sobre la epidemiología y manejo de esta enfermedad (Carstens et al., 2017; Hincapie et al., 2014), destacando la importancia de implementar estrategias de control integradas para mitigar sus impactos.

La detección precisa de enfermedades de las plantas es de gran importancia en la agricultura porque tiene un rol crucial en el resguardo de la expansión de la patología de la mancha negra (John et al., 2023). Sin embargo, la detección manual de enfermedades foliares es un proceso laborioso y propenso a errores (Chowdhury et al., 2021). Por lo tanto, existe la necesidad de desarrollar un enfoque automatizado y eficiente para la detección y clasificación de enfermedades foliares de plantas. Estudios anteriores han presentado un modelo para detectar y clasificar automáticamente las enfermedades de las hojas de las plantas mediante la combinación de métodos de segmentación de imágenes y algoritmos genéticos (Almeyda & Ipanaqué, 2022).

A través de la investigación científica, se ha identificado la existencia de estrategias deficientes para la clasificación de la patología de la mancha negra (Zacarias et al., 2022), lo cual representa un problema significativo en la industria de los cítricos. La mancha negra, como enfermedad fúngica, afecta la calidad y comercialización de los cítricos, generando pérdidas económicas (Eh Teet & Hashim, 2023) y reduciendo la productividad de los cultivos (Strano et al., 2022).

Ante esta problemática, resulta fundamental desarrollar soluciones efectivas y precisas que permitan una clasificación confiable de la mancha negra en los cítricos. La situación planteada tiene como propósito fundamental proponer y desarrollar un modelo de visión artificial basado en redes neuronales convolucionales (CNN) como una solución adecuada para abordar la clasificación de la mancha negra en los cítricos. Se ha evidenciado el logro de las redes neuronales convolucionales en el análisis visual de estructuras y clasificación de imágenes (Patil & Rane, 2021), lo cual las convierte en una herramienta idónea para enfrentar este desafío específico.

Se espera que, mediante la implementación de este modelo, se logre una clasificación más precisa y confiable, lo cual contribuirá a reducir las pérdidas económicas y será un apoyo para el desarrollo de la productividad de las plantaciones citrícolas. Además, la implementación exitosa de este modelo puede llevar a mejoras significativas en la calidad

del producto final, así como a la optimización de los procesos agrícolas relacionados con el manejo de la mancha negra en los cítricos.

Los progresos más recientes en el ámbito del análisis de imágenes y el Deep Learning, específicamente en redes neuronales convolucionales, han evidenciado ser sumamente eficaces en la identificación y localización de objetos en imágenes. (Bai et al., 2021). Sin embargo, hasta la fecha, existe una brecha significativa en la literatura científica en cuanto a la aplicación específica de estas técnicas para la clasificación de la mancha negra en los cítricos.

La pretensión principal de este trabajo es elaborar un modelo de visión artificial utilizando redes neuronales convolucionales que aborde esta problemática de manera innovadora y efectiva. Por lo tanto, el desarrollo de métodos de diagnóstico rápidos y precisos para distinguir la manifestación de esta patología en los cítricos permitirá una respuesta más efectiva y oportuna, al comparar el modelo propuesto con otros dos modelos ya existentes en el campo, se espera identificar y demostrar de manera concluyente la superioridad del nuevo enfoque en cuanto a precisión y eficiencia.

La distinción notoria entre el modelo de visión computarizada que se fundamenta en redes neuronales convolucionales y los modelos existentes radica en su capacidad para analizar características específicas de la mancha negra en los cítricos, tales como su forma, tamaño, textura y distribución espacial. Además, el uso de CNN permite una representación jerárquica de las características (Zheng et al., 2020), lo cual puede mejorar la capacidad del modelo para discriminar entre la mancha negra y otras imperfecciones o características similares en los cítricos.

Este estudio no solo aportará al campo visual computarizado y el Deep Learning, sino que también ofrecerá beneficios a la industria agrícola una herramienta precisa y confiable para la clasificación automatizada de la mancha negra. La implementación exitosa de este modelo podría resultar en beneficios significativos, como el incremento de la fiabilidad del producto, el decremento de los costos en procedimientos de la categorización manual y la maximización de la productividad.

La literatura científica revela que se ha dedicado atención significativa al estudio de la detección de la mancha negra en los cítricos en años recientes (Palei et al., 2023) y se han producido diferentes perspectivas y técnicas para la categorización y diagnóstico de manera precisa de la enfermedad en los cultivos (Vaidya et al., 2023). La pretensión principal de este trabajo es elaborar un modelo de visión artificial utilizando redes neuronales convolucionales que aborde esta problemática de manera innovadora y efectiva. Por lo tanto, el desarrollo de métodos de diagnóstico rápidos y precisos para distinguir la manifestación de esta patología en los cítricos permitirá una respuesta más efectiva y oportuna, al comparar el modelo propuesto con otros dos modelos ya existentes en el campo, se espera identificar y demostrar de manera concluyente la superioridad del nuevo enfoque en cuanto a precisión y eficiencia.

Los estudios existentes han explorado el uso de métodos tradicionales, como la inspección visual y la evaluación de síntomas visibles en la fruta (Tran et al., 2020), así como técnicas más avanzadas basadas en tecnologías de imagen y procesamiento digital. Todas estas tecnologías mencionadas anteriormente abarcan el uso de cámaras de alta calidad, exploración mediante luz ultravioleta, métodos de análisis de imágenes y algoritmos de machine learning (Ghanei Ghooshkhaneh & Mollazade, 2023).

En este contexto, el uso de redes neuronales convolucionales (CNN) se ha destacado como un enfoque prometedor para la detección y clasificación precisa de la mancha negra en los cítricos. Estos modelos de inteligencia artificial son capaces de aprender patrones complejos en las imágenes y ofrecer resultados con alta precisión (Saedi & Khosravi, 2020).

Además, se ha explorado el uso de técnicas espectroscópicas, como la espectroscopía infrarroja cercana (NIRS) y la espectroscopía de reflectancia difusa (DRS), que se basan en la medición de las propiedades ópticas de la fruta para obtener información rápida y no destructiva sobre su estado de salud (Cheng et al., 2019).

A medida que avanza la investigación, se observa un creciente interés en la integración de sistemas de detección de enfermedades basados en imágenes con la incorporación de tecnologías de internet de los artefactos, virtualización de recursos y análisis de datos. Estas soluciones permiten la monitorización continua de los cultivos y la detección temprana de la enfermedad, facilitando la toma de decisiones y el manejo oportuno de la mancha negra (Taha et al., 2022).

A pesar de los avances realizados, aún existen limitaciones en los estudios existentes. La falta de estandarización en los procedimientos de análisis y la relevancia de contar con muestras de datos más extensos y representativos son desafíos que deben abordarse (Booij et al., 2022). Además, se reconoce la oportunidad de explorar nuevas técnicas de detección y análisis de imágenes, así como la integración de múltiples fuentes de información, como datos espectrales e información climática, con el fin de fortalecer mucho más la exactitud de la percepción de la mancha negra en los cítricos (Chaniago & Rahma, 2021).

La visión artificial, que busca dotar a los sistemas informáticos de la capacidad de interpretar y comprender imágenes y videos (Ibrahim et al., 2020) de manera similar a los seres humanos, encuentra aplicaciones en diversos campos, como la medicina, seguridad, conducción autónoma, procesamiento de imágenes y reconocimiento de objetos. En particular, el aprendizaje profundo ha evidenciado una alta competencia en el reconocimiento de artefactos (Ouchra & Belangour, 2021).

Históricamente, el desarrollo de las CNN ha alcanzado hitos significativos. Desde las arquitecturas pioneras como LeNet-5 y AlexNet, hasta las redes más profundas como VGGNet y las redes residuales (ResNet), se ha obtenido una mejora sustancial en el rendimiento (Feng et al., 2019; Wang & Yang, 2019) y la precisión en tareas de

clasificación e identificación de objetos (Benallal & Tayeb, 2023; Rasheed et al., 2021; Tripathi, 2021; Yang et al., 2023; Zhu et al., 2023).

Estos avances en visión artificial y redes neuronales convolucionales han sido exitosamente implementados en el ámbito agrícola (Ito et al., 2023). En estudios recientes, se han propuesto enfoques basados en CNN para la detección de enfermedades en plantas utilizando imágenes de hojas, logrando altos niveles de precisión en la clasificación de enfermedades (Shrivastava et al., 2022). Estos enfoques se caracterizan por su menor carga computacional y abordan los desafíos relacionados con la disponibilidad de conjuntos de datos grandes y la complejidad computacional.

2. METODOLOGÍA

En el presente estudio se utilizó una población de 1.725 imágenes de frutos de limón y naranja con y sin tizón. Para el entrenamiento del modelo, se utilizó una muestra de 1.315 imágenes, de las cuales 505 tenían manchas negras y 810 eran de frutos sanos. Para la prueba del modelo, se seleccionaron 410 imágenes adicionales, de las cuales 107 tenían manchas negras y 303 eran de fruta sana. Las imágenes se organizaron en dos categorías: `citrus_healthy` y `citrus_black_spot`. Estas imágenes se almacenaron en un directorio base y se cargaron utilizando la biblioteca OpenCV. Se estableció que el tamaño de la muestra sería uniforme al tamaño de la población para garantizar una representación completa de las frutas de limón. Esta decisión se tomó teniendo en cuenta el enfoque basado en técnicas de Deep Learning, que permite una manipulación flexible de los datos en términos de aumentar o reducir el número de imágenes utilizadas. El uso de la muestra completa permitirá obtener una representación amplia y precisa de la población objetivo, proporcionando la posibilidad de entrenar y evaluar modelos de Deep Learning de forma fiable y precisa.

Se llevó a cabo la obtención de datos mediante diversos instrumentos que nos permitieron capturar imágenes de alta calidad de cítricos afectados por la enfermedad de la mancha negra. Para ello, se empleó un celular con una cámara de 12 megapíxeles. Además, se utilizará el almacenamiento en la nube de Google Drive para garantizar el respaldo y acceso seguro a las imágenes desde diferentes dispositivos.

Adicionalmente, se utilizará un dataset de Kaggle, que contiene una amplia colección de imágenes de naranjas afectadas por la mancha negra. La incorporación de este dataset permitirá aumentar la diversidad y cantidad de datos disponibles para el entrenamiento y prueba de los modelos de Deep Learning, mejorando así la generalización y precisión de los resultados.

Para preparar los datos de entrada del modelo, se utilizó ImageDataGenerator de Keras. Esta herramienta no solo permitió normalizar las imágenes (escalando los valores de los píxeles), sino que también aplicó diversas técnicas de aumento de datos, tales como rotación, desplazamiento horizontal y vertical, zoom y volteo horizontal. Estas técnicas ayudaron a incrementar la diversidad de las imágenes de entrenamiento, mejorando la capacidad del modelo para generalizar.

Se emplearon enfoques estadísticos cruciales para respaldar la evaluación y comparación de los modelos propuestos en la detección de la enfermedad de la mancha negra en los limones. Estos métodos han sido escogidos minuciosamente para garantizar una evaluación robusta y precisa, en

línea con los rigurosos estándares de la investigación de alta calidad en el campo de la visión artificial y la detección de enfermedades en cultivos.

En primer lugar, se utilizarán curvas de precisión y pérdida para evaluar el desempeño del modelo. Estas curvas mostrarán cómo la precisión y la pérdida del modelo evolucionaron durante el entrenamiento y la validación, permitiendo identificar posibles problemas de sobreajuste (Montesinos López et al., 2022).

Además, se procederá a la construcción de las curvas ROC, que ofrecerán una comprensión visual profunda de cómo el modelo distingue entre limones con mancha negra y limones sanos. Además de la curva ROC en sí misma, se mostrará la matriz de confusión, esta métrica descriptiva proporcionará insights detallados sobre cómo el modelo se desempeña en términos de la detección de verdaderos positivos, la minimización de falsos positivos y una mirada general del comportamiento del modelo (Maxwell et al., 2021).


En el contexto de la Evaluación del Área bajo la Curva (AUC), se calculará este indicador fundamental que brinda una medida cuantitativa del rendimiento global de cada modelo en la detección de la enfermedad. Las métricas de Sensibilidad, Especificidad y AUC son particularmente efectivas para resaltar la capacidad de los modelos en diversas configuraciones de umbral de decisión (Muschelli, 2020). Adicionalmente, la prueba de McNemar será implementada para contrastar los resultados entre los modelos, permitiendo una evaluación detallada de las Diferencias Significativas en términos de la clasificación binaria. Esta prueba estadística proveerá información esencial sobre si las diferencias observadas en las tasas de detección son estadísticamente significativas (Wu, 2023).

Con el fin de brindar resultados confiables y medir la incertidumbre asociada a las estimaciones, se calcularon Intervalos de Confianza del AUC. Este enfoque añadirá una capa adicional de confiabilidad a los resultados obtenidos. Cabe destacar que, para la ejecución de estos análisis, se hará uso de los siguientes softwares, Jupyter Notebook y Microsoft Excel conocido por su capacidad para manejar eficientemente datos y aprovechar herramientas estadísticas avanzadas.

La metodología utilizada en este estudio se basa en una adaptación de dos enfoques metodológicos: la Metodología de Investigación y Desarrollo (I+D) y la Metodología Agile Scrum. Durante la primera fase se aplicó la Metodología de Investigación y Desarrollo, mientras que la segunda y la tercera se desarrollarán bajo los principios de la metodología Agile Scrum.

Figura 1.

Proceso de la metodología implementada



Nota: El diagrama ilustra las fases de la metodología implementada.

Fuente: Elaboración propia

1. Fase inicial: "Análisis preliminar"

En esta fase inicial, se ejecutaron las siguientes actividades:

1. Búsqueda bibliográfica rigurosa: Se llevó a cabo una búsqueda exhaustiva en fuentes científicas y literatura especializada. Se recopiló información detallada sobre la enfermedad de la mancha negra en los cítricos, lo que permitió construir una sólida base de conocimientos.
2. Análisis profundo: Los estudios seleccionados fueron sometidos a un análisis detallado. Se comprendieron a fondo los síntomas característicos de la enfermedad, identificando las características clave esenciales para la comprensión de la patología.
3. Síntesis metódica: Basándose en la estructura metodológica, se realizó una síntesis organizada de los síntomas identificados, estableciendo las bases para la siguiente etapa del estudio según la Metodología de Investigación y Desarrollo.


2. Fase intermedia: "Procesamiento de imágenes"


En esta fase intermedia, se llevaron a cabo las siguientes actividades:

1. Planificación adaptativa: Se planificó un protocolo detallado para recolectar muestras de cítricos, incluyendo métodos de selección y condiciones de recolección, asegurando datos representativos.
2. Iteraciones de captura de imágenes: Se capturaron imágenes de alta calidad en ciclos iterativos, recopilando datos de manera gradual y adaptándose a los avances del equipo.
3. Gestión dinámica de imágenes: Las imágenes capturadas fueron organizadas y etiquetadas, con reuniones de revisión para asegurar una gestión ágil y adaptable.
4. Mejora constante del procesamiento: Se realizaron ajustes iterativos en las actividades de limpieza y pre procesamiento, manteniendo un enfoque continuo en mejorar la calidad y coherencia de los datos.

Figura 2.

Clasificación de imágenes de cítricos.





Nota: Las figuras muestran cítricos con la mancha negra y cítricos sanos.

Fuente: Elaboración propia


3. Fase final: "Evaluación comparativa y resultados"

La última fase se compone de las siguientes actividades:

1. Diseño de arquitectura avanzada: Se diseñó meticulosamente la arquitectura de las redes neuronales convolucionales, definiendo capas, conexiones y optimizaciones para abordar los requerimientos específicos de la detección de la mancha negra en los cítricos.

Figura 3.

Diseño de la red neuronal convolucional.



Nota: Diagrama del diseño de la red neuronal convolucional para la clasificación de la mancha negra en los cítricos.


Fuente: Elaboración propia

2. División estratégica de datos: El conjunto de datos fue dividido en grupos de entrenamiento y prueba, permitiendo una validación sólida y evaluación efectiva de los modelos desarrollados.
3. Entrenamiento iterativo y validación continua: Los modelos fueron entrenados en iteraciones, evaluando continuamente su rendimiento en el conjunto de validación para garantizar la adaptabilidad y evitar el sobreajuste.

4. Ajuste y optimización constante: Se optimizaron los modelos mediante técnicas de ajuste de hiperparámetros, ajustando parámetros y modificando arquitecturas para lograr un rendimiento óptimo.

Figura 4.

Proceso del modelo para la clasificación de la mancha negra en los cítricos



Nota: El diagrama muestra el proceso de desarrollo del modelo.

Fuente: Elaboración propia

5. Evaluación rigurosa y comparativa: Se evaluaron y compararon los modelos optimizados utilizando métricas como exactitud, precisión y recall. Además, se comparó el modelo desarrollado con dos modelos existentes en la clasificación de cítricos en diferentes contextos en la literatura científica, demostrando su innovación.
6. Iteración y mejora continua: Se realizaron iteraciones en el proceso cuando los resultados no fueron satisfactorios, logrando un modelo altamente efectivo.

Figura 5.

Modelo de red neuronal convolucional

```

model_citrus_black_spot = tf.keras.models.Sequential([
    tf.keras.layers.Conv2D(64, (3, 3), activation='relu', kernel_regularizer=l2(0.001), input_shape=(150, 150, 3)),
    tf.keras.layers.MaxPooling2D(2, 2),
    tf.keras.layers.Dropout(0.25), # Dropout en la capa convolucional

    tf.keras.layers.Conv2D(64, (3, 3), activation='relu', kernel_regularizer=l2(0.001)),
    tf.keras.layers.MaxPooling2D(2, 2),
    tf.keras.layers.Dropout(0.25), # Dropout en la capa convolucional

    tf.keras.layers.Conv2D(128, (3, 3), activation='relu', kernel_regularizer=l2(0.001)),
    tf.keras.layers.MaxPooling2D(2, 2),
    tf.keras.layers.Dropout(0.25), # Dropout en la capa convolucional

    tf.keras.layers.Conv2D(256, (3, 3), activation='relu', kernel_regularizer=l2(0.001)),
    tf.keras.layers.MaxPooling2D(2, 2),
    tf.keras.layers.Dropout(0.25), # Dropout en la capa convolucional

    tf.keras.layers.Flatten(),

    tf.keras.layers.Dense(512, activation='relu', kernel_regularizer=l2(0.001)),
    tf.keras.layers.Dropout(0.5), # Dropout en la capa densa

    tf.keras.layers.Dense(1, activation='sigmoid')
])

model_citrus_black_spot.summary()
  
```

Nota: La figura muestra el modelo de red neuronal convolucional implementado en código con Python en Jupyter Noteboot.

Fuente: Elaboración propia

Algoritmo 1 Pseudocódigo del algoritmo de detección de la enfermedad de la mancha negra de los cítricos. Los datos y los resultados se almacenan en una serie de estructuras, como se puede ver en las figuras 6,7 y 8.

Tabla 1.

Modelo de red neuronal convolucional

```

1.   model_citrus_black_spot = tf.keras.models.Sequential([
2.   tf.keras.layers.Conv2D(64, (3, 3), activation='relu', kernel_regularizer=l2(0.001),
input_shape=(150, 150, 3)),
3.   tf.keras.layers.MaxPooling2D(2, 2),
4.   tf.keras.layers.Dropout(0.25),
5.   tf.keras.layers.Conv2D(64,          (3,          3),          activation='relu',
kernel_regularizer=l2(0.001)),
6.   tf.keras.layers.MaxPooling2D(2, 2),
7.   tf.keras.layers.Dropout(0.25),
8.   tf.keras.layers.Conv2D(128,        (3,          3),          activation='relu',
kernel_regularizer=l2(0.001)),
9.   tf.keras.layers.MaxPooling2D(2, 2),
10.  tf.keras.layers.Dropout(0.25),
11.  tf.keras.layers.Conv2D(256, (3, 3), activation='relu',
12.  tf.keras.layers.MaxPooling2D(2, 2),
13.  tf.keras.layers.Dropout(0.25),
14.  tf.keras.layers.Flatten(),
15.  tf.keras.layers.Dense(512, activation='relu', kernel_regularizer=l2(0.001)),
16.  tf.keras.layers.Dropout(0.5),
17.  tf.keras.layers.Dense(1, activation='sigmoid')
18.  ])
19.  model_citrus_black_spot.summary()
```

Nota: La tabla muestra el código exacto solo del modelo de red neuronal convolucional para la detección de la enfermedad de la mancha negra en Python.


Fuente: Elaboración propia

7. Documentación integral: Los resultados y comparaciones fueron documentados minuciosamente, contribuyendo a la conclusión del estudio y futuras investigaciones. Este enfoque ágil aseguró una iteración constante y mejora continua.

3. RESULTADOS

Figura 6.

Resultados de la curva de precisión y pérdida




Nota: La figura muestra los resultados de la curva de precisión y pérdida obtenidos del modelo durante su entrenamiento y validación.

Fuente: Elaboración propia

La Figura 6 presenta la evolución de la precisión y la pérdida del modelo a lo largo de 81 épocas de entrenamiento. Se puede observar que la precisión en los conjuntos de entrenamiento y validación se estabiliza rápidamente cerca de un valor de 1.0, lo que indica un excelente ajuste del modelo. Por otro lado, la pérdida se reduce de manera constante, alcanzando valores mínimos cercanos a cero. Estos resultados sugieren que el modelo no presenta problemas de sobreajuste y es capaz de generalizar bien a nuevos datos.

Figura 7.

Resultados de la curva de la curva ROC




Nota: La figura ilustra el desempeño de clasificación de la mancha negra en cítricos.

Fuente: Elaboración propia

La Figura 7 muestra la curva ROC, con un área bajo la curva (AUC) de 1.0, lo que indica un rendimiento perfecto del modelo. Un AUC de 1.0 significa que el modelo clasifica correctamente todos los casos positivos y negativos sin ninguna ambigüedad. Este resultado refuerza la capacidad del modelo para distinguir de manera efectiva entre cítricos saludables y aquellos con mancha negra.

Figura 8.

Resultados de la matriz de confusión



***Nota:** La figura muestra el desempeño del modelo en la clasificación de la mancha negra en cítricos.*

***Fuente:** Elaboración propia*

La Figura 8 muestra la matriz de confusión, indicando que el modelo tiene una precisión del 100% en la clasificación de cítricos saludables y enfermos. Los 107 cítricos saludables fueron clasificados correctamente sin errores, al igual que los 303 cítricos con mancha negra. Este resultado demuestra que el modelo CNN logra una separación clara entre las dos clases, evidenciando un excelente rendimiento en la clasificación.

4. DISCUSIÓN

Comparación entre nuestro modelo (modelo A) y otro modelo de detección de enfermedades (modelo B).

Modelo A: Modelo de visión artificial basado en redes neuronales convolucionales para la clasificación de la mancha negra en los cítricos.

Modelo B: A precise fruit disease identification model based on context data fusion with faster-CNN in edge computing environment (Dhiman et al., 2023).

Figura 9.

Resultados de los modelos A y B basados en la clasificación

<i>Modelo</i>	<i>Exactitud</i>	<i>Precisión</i>	<i>Recuperación</i>
A	100%	100%	100%
B	96.07%	86.41%	69.45%

***Nota:** La figura muestra el desempeño de los modelos en la clasificación de la mancha negra en cítricos.*

***Fuente:** Elaboración propia*

Planteamiento de la hipótesis:

Ho: No hay diferencia significativa entre las proporciones de cítricos correctamente clasificados por el modelo A y B.

Ha: Existe una diferencia significativa entre las proporciones de cítricos correctamente clasificados por el modelo A y B.

Nivel de significancia: 5%

Prueba estadística: McNemar

Tabla 2.

Resultados de la prueba estadística del modelo A y B

Comparación de Modelos de CNN para la clasificación de la Mancha Negra en Cítricos

Modelo A y B	X	4
	P	0,045

Nota: La tabla muestra el resultado de la comparación estadística mediante McNemar.

Fuente: Elaboración propia

Como $P < 0.05$ aceptamos la H_a , esto significa que el modelo A es significativamente mejor que el modelo B al clasificar la enfermedad de la mancha negra en los cítricos.

Comparación entre nuestro modelo (modelo A) y otro modelo de detección de enfermedades (modelo C).

Modelo A: Modelo de visión artificial basado en redes neuronales convolucionales para la clasificación de la mancha negra en los limones.

Modelo C: Citrus Diseases Recognition by Using CNN Model (Jasim et al., 2022).

Figura 10.

Resultados de los modelos A y C basados en la clasificación

Modelo	Exactitud	Precisión	Recuperación
A	100%	100%	100%
C	87.62%	-	-

Nota: La figura muestra el desempeño de los modelos en la clasificación de la mancha negra en cítricos.

Fuente: Elaboración propia

Planteamiento de la hipótesis:

H_0 : No hay diferencia significativa entre las proporciones de cítricos correctamente clasificados por el modelo A y C.

H_a : Existe una diferencia significativa entre las proporciones de cítricos correctamente clasificados por el modelo A y C.

Nivel de significancia: 5%

Prueba estadística: McNemar

Tabla 3.

Resultados de la prueba estadística del modelo A y C

Comparación de Modelos de CNN para la clasificación de la Mancha Negra en Cítricos

Modelo A y C	X	13
	P	0,0003

Nota: La tabla muestra el resultado de la comparación estadística mediante McNemar.

Fuente: Elaboración propia

Como $P < 0.05$ aceptamos la H_a , esto significa que el modelo A es significativamente mejor que el modelo C al clasificar la enfermedad de la mancha negra en los cítricos.

5. CONCLUSIÓN

Esta investigación ha arrojado resultados significativos que contribuyen a avanzar en la detección precisa de enfermedades en frutos de limón y naranja. Mediante la aplicación de técnicas de Deep Learning y la implementación de la Metodología de Investigación y Desarrollo en conjunto con la Metodología Agile Scrum, fue posible abordar de manera eficiente y sistemática el desafío de identificar la mancha negra en cítricos.

Los resultados obtenidos, apoyados en la comparación exhaustiva con modelos existentes en la literatura científica, demuestran la efectividad del modelo propuesto en la clasificación de la enfermedad. La evaluación comparativa con el Modelo B y el Modelo C revela que existen diferencias significativas en las proporciones de cítricos correctamente clasificados, destacando el Modelo A como una herramienta superior y altamente fiable en el campo de la detección de enfermedades en cítricos. Estas diferencias consolidan la posición del Modelo A como la opción más competitiva y eficaz disponible.

La adaptación de enfoques metodológicos innovadores, como la combinación de la Metodología de Investigación y Desarrollo con la Metodología Agile Scrum, ha demostrado ser crucial para el éxito del proyecto, permitiendo la iteración constante y la mejora continua en el desarrollo y evaluación del modelo. Representa un paso significativo en la aplicación de la inteligencia artificial a la agricultura, proporcionando no sólo un modelo eficaz para la detección de la mancha negra de los cítricos, sino también valiosos conocimientos para futuras investigaciones en el campo de la visión artificial aplicada a la sanidad de los cultivos.

REFERENCIAS BIBLIOGRÁFICAS

- Almeyda, E., & Ipanaqué, W. (2022). Recent Developments of Artificial Intelligence for Banana: Application Areas, Learning Algorithms, and Future Challenges. *Engenharia Agricola*, 42(SpecialIssue). <https://doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210144/2022>
- Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B. (2021). Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. *Pattern Recognition*, 120, 108102. <https://doi.org/10.1016/j.patcog.2021.108102>
- Benallal, M. A., & Tayeb, M. S. (2023). An image-based convolutional neural network system for road defects detection. *IAES International Journal of Artificial Intelligence*, 12(2). <https://doi.org/10.11591/ijai.v12.i2.pp577-584>
- Booij, T. M., Chiscop, I., Meeuwissen, E., Moustafa, N., & Hartog, F. T. H. den. (2022). ToN_IoT: The Role of Heterogeneity and the Need for Standardization of Features and Attack Types in IoT Network Intrusion Data Sets. *IEEE Internet of Things Journal*, 9(1), 485–496. <https://doi.org/10.1109/JIOT.2021.3085194>
- Carstens, E., Linde, C. C., Slabbert, R., Miles, A. K., Donovan, N. J., Li, H., Zhang, K., Dewdney, M. M., Rollins, J. A., Glienke, C., Schutte, G. C., Fourie, P. H., & McLeod, A. (2017). A Global Perspective on the Population Structure and Reproductive System of *Phyllosticta citricarpa*. *Phytopathology®*, 107(6), 758–768. <https://doi.org/10.1094/PHYTO-08-16-0292-R>
- Chaniago, M. B., & Rahma, Y. D. (2021). Implementation of Pest Detection Based on International Technological Education in Orange Plants Using Neural Network and Svm Methods. *Review of International Geographical Education Online*, 11(3), 33–42. <https://doi.org/10.33403/rigeo.800466>
- Cheng, N.-Y., Chen, C.-C., Liang, B.-J., & Tseng, S.-H. (2019). Nondestructive Evaluation of Apple Fruit Quality by Frequency-Domain Diffuse Reflectance Spectroscopy: Variations in Apple Skin and Flesh. *Applied Sciences*, 9(11), 2355. <https://doi.org/10.3390/app9112355>
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Ayari, M. A., Khan, A. U., Khan, M. S., Al-Emadi, N., Reaz, M. B. I., Islam, M. T., & Ali, S. H. M. (2021). Automatic and Reliable Leaf Disease Detection Using Deep Learning Techniques. *AgriEngineering*, 3(2), 294–312. <https://doi.org/10.3390/agriengineering3020020>
- Dhiman, P., Manoharan, P., Lilhore, U. K., Alroobaea, R., Kaur, A., Iwendi, C., Alsafyani, M., Baqasah, A. M., & Raahemifar, K. (2023). PFDI: a precise fruit disease identification model based on context data fusion with faster-CNN in edge computing environment. *Eurasip Journal on Advances in Signal Processing*, 2023(1). <https://doi.org/10.1186/s13634-023-01025-y>
- Eh Teet, S., & Hashim, N. (2023). Recent advances of application of optical imaging techniques for disease detection in fruits and vegetables: A review. *Food Control*, 152, 109849. <https://doi.org/10.1016/j.foodcont.2023.109849>
- Feng, S., Wu, J., Zhou, S., & Li, R. (2019). The Implementation of LeNet-5 with NVDLA on RISC-V SoC. 2019 IEEE 10th International Conference on Software Engineering and Service Science (ICSESS), 39–42. <https://doi.org/10.1109/ICSESS47205.2019.9040769>

- Ghanei Ghoshkhaneh, N., & Mollazade, K. (2023). Optical Techniques for Fungal Disease Detection in Citrus Fruit: A Review. *Food and Bioprocess Technology*. <https://doi.org/10.1007/s11947-023-03005-4>
- Hincapie, M., Wang, N.-Y., Peres, N. A., & Dewdney, M. M. (2014). Baseline Sensitivity of *Guignardia citricarpa* Isolates from Florida to Azoxystrobin and Pyraclostrobin. *Plant Disease*, 98(6), 780–789. <https://doi.org/10.1094/PDIS-03-13-0335-RE>
- Ibrahim, M. R., Haworth, J., & Cheng, T. (2020). Understanding cities with machine eyes: A review of deep computer vision in urban analytics. *Cities*, 96, 102481. <https://doi.org/10.1016/j.cities.2019.102481>
- Ito, K., Higashi, H., Hietanen, A., Fält, P., Hine, K., Hauta-Kasari, M., & Nakauchi, S. (2023). The Optimization of the Light-Source Spectrum Utilizing Neural Networks for Detecting Oral Lesions. *Journal of Imaging*, 9(1). <https://doi.org/10.3390/jimaging9010007>
- Jasim, W. N., Almola, S. A. S., Alabiech, M. H., & Harfash, E. J. (2022). Citrus Diseases Recognition by Using CNN Model. *Informatica (Slovenia)*, 46(7), 85–94. <https://doi.org/10.31449/inf.v46i7.4284>
- John, M. A., Bankole, I., Ajayi-Moses, O., Ijila, T., Jeje, T., & Lalit, P. (2023). Relevance of Advanced Plant Disease Detection Techniques in Disease and Pest Management for Ensuring Food Security and Their Implication: A Review. *American Journal of Plant Sciences*, 14(11), 1260–1295. <https://doi.org/10.4236/ajps.2023.1411086>
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—part 1: Literature review. In *Remote Sensing* (Vol. 13, Issue 13). <https://doi.org/10.3390/rs13132450>
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Overfitting, Model Tuning, and Evaluation of Prediction Performance. In *Multivariate Statistical Machine Learning Methods for Genomic Prediction* (pp. 109–139). Springer International Publishing. https://doi.org/10.1007/978-3-030-89010-0_4
- Muschelli, J. (2020). ROC and AUC with a Binary Predictor: a Potentially Misleading Metric. *Journal of Classification*, 37(3). <https://doi.org/10.1007/s00357-019-09345-1>
- Ouchra, H., & Belangour, A. (2021). Object detection approaches in images: a survey. In X. Jiang & H. Fujita (Eds.), *Thirteenth International Conference on Digital Image Processing (ICDIP 2021)* (p. 85). SPIE. <https://doi.org/10.1117/12.2601452>
- Palei, S., Behera, S. K., & Sethy, P. K. (2023). A Systematic Review of Citrus Disease Perceptions and Fruit Grading Using Machine Vision. *Procedia Computer Science*, 218, 2504–2519. <https://doi.org/10.1016/j.procs.2023.01.225>
- Patil, A., & Rane, M. (2021). Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition (pp. 21–30). https://doi.org/10.1007/978-981-15-7078-0_3
- Rasheed, A., Younis, M. S., Qadir, J., & Bilal, M. (2021). Use of Transfer Learning and Wavelet Transform for Breast Cancer Detection.

- Saedi, S. I., & Khosravi, H. (2020). A deep neural network approach towards real-time on-branch fruit recognition for precision horticulture. *Expert Systems with Applications*, 159, 113594. <https://doi.org/10.1016/j.eswa.2020.113594>
- Shrivastava, A., Chakkaravathy, M., & Shah, M. A. (2022). A Comprehensive Analysis of Machine Learning Techniques in Biomedical Image Processing Using Convolutional Neural Network. *Proceedings of 5th International Conference on Contemporary Computing and Informatics, IC3I 2022*, 1363–1369. <https://doi.org/10.1109/IC3I56241.2022.10072911>
- Strano, M. C., Altieri, G., Allegra, M., Di Renzo, G. C., Paterna, G., Matera, A., & Genovese, F. (2022). Postharvest Technologies of Fresh Citrus Fruit: Advances and Recent Developments for the Loss Reduction during Handling and Storage. *Horticulturae*, 8(7), 612. <https://doi.org/10.3390/horticulturae8070612>
- Taha, M. F., ElMasry, G., Gouda, M., Zhou, L., Liang, N., Abdalla, A., Rousseau, D., & Qiu, Z. (2022). Recent Advances of Smart Systems and Internet of Things (IoT) for Aquaponics Automation: A Comprehensive Overview. *Chemosensors*, 10(8), 303. <https://doi.org/10.3390/chemosensors10080303>
- Tran, N. T., Miles, A. K., Dietzgen, R. G., Shuey, T. A., Mudge, S. R., Papacek, D., Chandra, K. A., & Drenth, A. (2020). Inoculum Dynamics and Infection of Citrus Fruit by *Phyllosticta citricarpa*. *Phytopathology®*, 110(10), 1680–1692. <https://doi.org/10.1094/PHYTO-02-20-0047-R>
- Tripathi, M. (2021). Analysis of Convolutional Neural Network based Image Classification Techniques. *Journal of Innovative Image Processing*, 3(2), 100–117. <https://doi.org/10.36548/jiip.2021.2.003>
- Vaidya, G., Chaudhary, N., Nasare, S., Warutkar, S., Kawathekar, S., & Dhengre, S. (2023). Disease Detection of Citrus Plants Using Image Processing Techniques. *2023 11th International Conference on Emerging Trends in Engineering & Technology - Signal and Information Processing (ICETET - SIP)*, 1–6. <https://doi.org/10.1109/ICETET-SIP58143.2023.10151494>
- Wang, W., & Yang, Y. (2019). Development of convolutional neural network and its application in image classification: a survey. *Optical Engineering*, 58(04), 1. <https://doi.org/10.1117/1.OE.58.4.040901>
- Wu, Y. (2023). Joint comparison of the predictive values of multiple binary diagnostic tests: an extension of McNemar's test. *Journal of Biopharmaceutical Statistics*, 33(1). <https://doi.org/10.1080/10543406.2022.2065500>
- Yang, L., Yu, X., Zhang, S., Long, H., Zhang, H., Xu, S., & Liao, Y. (2023). GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases. *Computers and Electronics in Agriculture*, 204, 107543. <https://doi.org/10.1016/j.compag.2022.107543>
- Zacarias, J. R. O., Sullca-Mendoza, Y. C., Valenzuela-Lino, Y. S., Del Carpio-Ramirez, S. I., Moggiano, N., & Coaquira-Rojo, C. (2022). Simulation of an Automated Tahitian lemon grading system based on computer vision. *2022 IEEE 13th Annual Ubiquitous Computing*,

Electronics and Mobile Communication Conference, UEMCON 2022.
<https://doi.org/10.1109/UEMCON54665.2022.9965667>

Zheng, H., Fu, J., Zha, Z.-J., Luo, J., & Mei, T. (2020). Learning Rich Part Hierarchies With Progressive Attention Networks for Fine-Grained Image Recognition. *IEEE Transactions on Image Processing*, 29, 476–488. <https://doi.org/10.1109/TIP.2019.2921876>

Zhu, J., Wang, A., Wu, W., Zhao, Z., Xu, Y., Lei, R., & Yue, K. (2023). Deep-Learning-Based Recovery of Frequency-Hopping Sequences for Anti-Jamming Applications. *Electronics*, 12(3), 496. <https://doi.org/10.3390/electronics12030496>

Conflicto de Intereses: Los autores afirman que no existen conflictos de intereses en este estudio y que se han seguido éticamente los procesos establecidos por esta revista. Además, aseguran que este trabajo no ha sido publicado parcial ni totalmente en ninguna otra revista.