

## Identificación de plagas y enfermedades en cultivos de citrus latifolia usando aprendizaje profundo

Alonso Hernández-Mora<sup>1</sup>, Roberto Ángel Meléndez-Armenta<sup>1</sup>,  
Carlos Alberto Ochoa-Ortiz<sup>2</sup>, Irahan Otoniel José-Guzmán<sup>1</sup>

<sup>1</sup> Tecnológico Nacional de México,  
Instituto Tecnológico Superior de Misantla,  
División de Estudios de Posgrado e Investigación,  
México

<sup>2</sup> Universidad Autónoma de Ciudad Juárez,  
México

{222t0539, ramelendeza, iojoseg}@itsm.edu.mx,  
alberto.ochoa@uacj.mx

**Resumen.** México es el segundo mayor productor de limón en el mundo; sin embargo, la mayoría de los agricultores no tienen el conocimiento suficiente para poder realizar la correcta identificación de plagas y enfermedades en este tipo de cultivos, por lo que son propensos a cometer errores y realizar acciones equivocadas que resulten en posibles daños en sus cultivos y con esto pérdidas económicas. Es por esto por lo que el objetivo del presente estudio es generar un modelo de aprendizaje profundo que sea capaz de identificar plagas y enfermedades en los cultivos de citrus latifolia. Para lograr este objetivo se utilizaron dos modelos de aprendizaje profundo preentrenados, se compararon y se eligió el que demostrara mejor rendimiento en cuanto a clasificación. Los resultados obtenidos por ambos modelos fueron satisfactorios, sin embargo, se eligió el modelo MobilNet ya que obtuvo una precisión del 99% en la clasificación de las distintas plagas y enfermedades tratadas en el estudio.

**Palabras clave:** Aprendizaje profundo, citrus latifolia, aprendizaje por transferencia, detección de enfermedades.

### Using Deep Learning to Identify Pest and Disease Detection in Citrus Latifolia Crops

**Abstract.** México is the second largest producer of lemons in the world; however, most farmers do not have enough knowledge to be able to correctly identify pests and diseases in this type of crops, so they are prone to make mistakes and perform wrong actions that result in possible damage to their crops and thus economic losses. For this reason, the objective of the study is to generate a deep learning model capable of identifying pests and diseases in citrus latifolia crops. To achieve this, two pre-trained deep learning models were used, compared and the one with the best classification performance was chosen. The results obtained by both models were satisfactory; however, the MobilNet model

was chosen since it obtained an accuracy of 99% in the classification of the different pests and diseases treated in the study.

**Keywords:** Deep learning, citrus latifolia, transfer learning, disease detection.

## 1. Introducción

México ocupa el segundo lugar a nivel mundial en la producción de limón, con una producción cercana a 2.9 millones de toneladas en 2021 de acuerdo con el Servicio de Información Agroalimentaria y Pesquera (SIAP).

La producción de limón en México se divide principalmente en tres variedades: el limón agrio (*citrus aurantifolia*), el limón italiano (*citrus lemon*) y el limón persa (*citrus latifolia*). El limón persa es la variedad más cultivada y la que genera la mayor cantidad de ingresos económicos, con una producción de poco más de 1.5 millones de toneladas en 2021 [1].

No obstante, su producción está expuesta a diversas plagas y enfermedades, como la fumagina, huanglongbing, wood pocket, araña roja, ácaros [2], entre otras, lo que representa un desafío significativo para los agricultores. Por lo tanto, es importante detectar estas plagas y enfermedades en etapas tempranas para minimizar las pérdidas y mejorar la calidad de los frutos.

Sin embargo, la detección suele depender de la experiencia de los agricultores y puede ser propensa a errores, ya que algunas plagas o enfermedades no presentan síntomas visibles en las primeras etapas. Por esta razón, es crucial desarrollar herramientas confiables para detectar plagas y enfermedades, con el fin de tomar medidas efectivas para prevenir y controlar su propagación.

En la detección de plagas y enfermedades en cítricos, como el limón persa, es común utilizar lesiones visibles para poder identificarlas correctamente, dichas lesiones pueden presentarse como manchas oscuras, decoloraciones o moteados [2]. Para apoyar a los agricultores en esta tarea, se han utilizado diferentes enfoques de inteligencia artificial, como Máquinas de Vectores de Soporte (SVMs), Redes Neuronales Convolucionales (CNNs) y K-Nearest-Neighbor KNN, entre otros.

En particular, las CNNs son ampliamente utilizadas en tareas de visión artificial que implican imágenes [3], lo que las convierte en una herramienta común en la detección de plagas y enfermedades en cítricos. Por ejemplo, en [4, 5] se utilizaron modelos de CNN para detectar enfermedades en las hojas y frutos de los cítricos, obteniendo resultados superiores en rendimiento en comparación con otros modelos estudiados.

Además, en [6], se utilizó la arquitectura del modelo ResNet50 junto con el algoritmo AMSR para mejorar la calidad de las imágenes y desarrollar un nuevo modelo de aprendizaje profundo, que demostró una precisión de hasta el 97.95% en pruebas.

Por lo tanto, en este estudio se propone el desarrollo de una aplicación móvil que realice la identificación de plagas y enfermedades en los frutos de *citrus latifolia* con ayuda de modelos de aprendizaje profundo, con el fin de poder tomar las medidas necesarias de control sobre la plaga o enfermedad identificada y coadyuvar en la toma de decisiones para combatirlas y así reducir las pérdidas económicas en los agricultores.

**Tabla 1.** Resumen de los algoritmos.

Referencia	Algoritmo	Resultados
[4]	CNN	El modelo propuesto realiza la detección de enfermedades en hojas y frutos de los cítricos, con una precisión del 94,55%.
[5]	CNN	El modelo propuesto demuestra ser mejor que otros modelos como DenseNet y MobileNet, alcanzando una precisión de hasta el 95%.
[6]	CNN	Se entrenó un modelo para clasificar enfermedades en hojas de los cítricos, obteniendo una precisión de hasta el 95,6%.
[7]	MF-RANet	El modelo propuesto obtiene una precisión del 96% en la identificación de enfermedades de los cítricos, esto gracias al uso de un algoritmo de mejora de imágenes.
[8]	MIB	El modelo propuesto identifica distintas enfermedades en frutos y hojas de los cítricos con una precisión de hasta el 98%.
[9]	CNN	Se compararon dos modelos preentrenados y demuestra que los modelos de aprendizaje profundo tienen una sensibilidad mayor al 95% en la identificación de HLB.
[10]	CNN	Se utilizaron modelos preentrenados como AlexNet y VGG junto al optimizador SGDM para la detección de enfermedades en cítricos. La precisión obtenida fue del 94,3%.
[11]	MobileNet	Se utilizó el modelo preentrenado MobileNet junto con el algoritmo IWOA, logrando obtener una precisión de hasta el 99,7% en la identificación de enfermedades de los cítricos.

## 2. Trabajos relacionados

En la tabla 1 se muestra un resumen de los sistemas de identificación de enfermedades en cítricos basados en técnicas de aprendizaje profundo. Como se puede observar la mayor parte de los algoritmos revisados en la literatura hacen uso de redes neuronales convolucionales.

Los métodos de aprendizaje profundo han sido utilizados por distintos autores en el reconocimiento de enfermedades en las hojas y frutos de los cítricos tal como se puede observar en la tabla anterior. La identificación de plagas y enfermedades en hojas y frutos en cultivos es un tema que ha sido estudiado durante mucho tiempo.

Para esto se han utilizado una amplia variedad de métodos de aprendizaje automático y algoritmos de preprocesamiento de imágenes que pueden aumentar la precisión con la que se identifican estas enfermedades.

En estudios como [3], se menciona que los métodos de aprendizaje profundo brindan soluciones innovadoras a problemas relacionados con la agricultura y que, para este

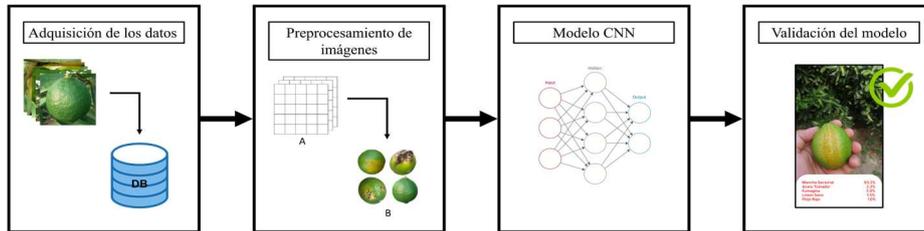


Fig. 1. Metodología propuesta (Fuente: Elaboración propia).

tipo de tareas, las redes neuronales convolucionales son la piedra angular (CNN). En [4, 5, 6] se muestran modelos de CNNs propuestos para la clasificación de enfermedades en hojas y frutos de los cítricos.

Por otro lado, en [7] se hace uso de algoritmos de mejora de imágenes como AMSR, que está basado en el algoritmo retinex multiescala, este fue utilizado para extraer la mayor cantidad de características de las imágenes. El modelo CNN utilizado en este estudio utiliza el modelo ResNet50 para la extracción de características del conjunto de imágenes de enfermedades de cítricos.

Así mismo en [8], se propone un modelo de aprendizaje profundo que hace uso de extracción de características gaussianas para la extracción de capas de varias imágenes, este modelo obtuvo excelentes resultados en la tarea de clasificación de enfermedades en imágenes de cítricos.

Por otro lado, a pesar de que los modelos de CNN representan herramientas que pueden ofrecer buenas soluciones a problemas de clasificación de imágenes, estos requieren de grandes cantidades de datos y consumen demasiados recursos computacionales.

Para situaciones en donde los datos son pocos se suelen utilizar modelos preentrenados [9, 10, 11, 12]. Este tipo de modelos se emplea para evitar que el modelo obtenga un bajo rendimiento al no contar con los datos necesarios para el entrenamiento.

Es importante mencionar que las CNN son muy utilizadas en la identificación de enfermedades en distintos cultivos como arroz [13], tomate [14] y maíz [15]. Además, que se suelen utilizar modelos preentrenados, ya que muchas veces obtener imágenes de enfermedades específicas, en este tipo de cultivos, se vuelve una tarea complicada.

### 3. Materiales y métodos

#### 3.1. Herramienta Tensorflow

Tensorflow es una biblioteca de código abierto que permite construir y entrenar modelos de aprendizaje automático para distintas tareas, como clasificación de imágenes, procesamiento de lenguaje natural, reconocimiento de voz y detección de objetos [16].

También proporciona acceso a modelos de aprendizaje automático preentrenados, permitiendo la reutilización de modelos entrenados en grandes cantidades de datos y

Tabla 2. Distribución del número de imágenes por clase.

Enfermedad / plaga	Fumagina	Acaro Tostador	Mancha Sectorial	Piojo rojo	Limón sano
Ejemplo					

así reducir el tiempo y recursos necesarios que toma desarrollar nuevas soluciones de aprendizaje automático [17].

Para desarrollar herramientas orientadas a dispositivos móviles, tensorflow ofrece la biblioteca tensorflow lite. Esta biblioteca permite desarrollar modelos de aprendizaje automático que pueden ser utilizados en dispositivos con recursos limitados, como teléfonos inteligentes, tablets, dispositivos IoT (internet de las cosas) y otros sistemas integrados [18].

### 3.2. Android Studio

Android Studio es un entorno de desarrollo integrado (IDE) utilizado en la creación de aplicaciones móviles para el sistema operativo Android. Este IDE proporciona distintas características y herramientas que facilitan el proceso de desarrollo de aplicaciones. Algunas de las herramientas que ofrecen son el editor de código, depurador, emulador de dispositivos, diseñador de interfaces, plantillas, entre otras [19]. Esto lo convierte en una herramienta indispensable para los desarrolladores, ya que permite crear aplicaciones de manera efectiva y eficiente.

### 3.3. Procedimiento

En la figura 1, se observan los pasos de la metodología propuesta para el desarrollo de la aplicación móvil y el modelo de aprendizaje profundo. Obtención de los datos: En la primera etapa se realizó la recolección de las imágenes necesarias para poder llevar a cabo los experimentos.

El conjunto de imágenes utilizado en el estudio fue recolectado manualmente de distintas huertas de la región de Martínez de la Torre, Veracruz. Este conjunto estaba compuesto por un total de 5000 imágenes, de 5 categorías distintas (1000 imágenes por cada una), a color con un tamaño de 1280x1280 píxeles y en formato JPEG.

Preprocesamiento de los datos: Para el preprocesamiento de las imágenes, se retiró el fondo de cada una de ellas para evitar que afectara la extracción de características y se redimensionaron en dos tamaños distintos.

Durante el preprocesamiento, el conjunto de datos resultante se dividió en dos partes: la primera parte contenía el 80% de las imágenes totales del conjunto original para el entrenamiento del modelo, y la segunda parte contenía el 20% restante para realizar pruebas. Modelo CNN: Para el modelo de CNN se tomaron en cuenta dos modelos preentrenados proporcionados Tensorflow Hub que son MobileNet e Inception [17].

acaro_tostador	199	0	0	0	1	acaro_tostador	198	1	0	0	1
fumagina	0	199	0	0	1	fumagina	0	198	0	0	2
limon_sano	0	0	200	0	0	limon_sano	0	0	199	0	1
mancha_sectorial	0	0	0	200	0	mancha_sectorial	0	0	1	199	0
piojo_rojo	0	0	1	0	199	piojo_rojo	1	0	0	2	197

**Fig. 2.** Matriz de confusión de MobileNet e Inception.

Estos han sido utilizados en otros estudios para la identificación de enfermedades en cultivos como cítricos [12], arroz [13], tomate [14], entre otros [15]. Los resultados que estos modelos obtuvieron en la clasificación de enfermedades en estudios anteriores demostraron que pueden ser de gran utilidad y proporcionar herramientas que ayuden a los agricultores a realizar este tipo de tareas.

Para desarrollar el modelo de CNN se utilizó el lenguaje de programación Python, debido a que es un lenguaje que ofrece muchas herramientas para este tipo de problemas y además es compatible con la librería de tensorflow.

En esta etapa se realizaron ajustes a los modelos, esto para poder identificar las clases dentro de nuestro conjunto de imágenes. Dentro de los ajustes realizados se redimensionaron las imágenes a un tamaño específico para cada uno de los dos modelos, por ejemplo, para MobileNet las imágenes se redimensionaron a un tamaño de 224x224 píxeles, mientras que para Inception 299x299 píxeles.

Validación: En la última etapa de la metodología se realizan pruebas de los modelos utilizando una aplicación Android, que realiza la identificación de plagas y enfermedades en tiempo real. Esta muestra en pantalla la clase a la que pertenece la imagen capturada y muestra el porcentaje de precisión.

## 4. Resultados

Como se mencionó anteriormente en este estudio se utilizaron MobileNet e Inception. Ambas arquitecturas deberían ser capaces de identificar las plagas y enfermedades en los frutos de citrus latifolia con una precisión aceptable. Es importante mencionar que los resultados obtenidos por estos modelos se compararon, esto con el fin de poder elegir el que demuestre una mejor precisión en la clasificación.

Los datos de entrenamiento fueron los mismos para ambos algoritmos (tabla 2), aunque durante la etapa de preprocesamiento, el redimensionamiento de las imágenes fue distinto en cada modelo, ya que cada uno recibe como entrada imágenes en tamaños distintos por ejemplo MobileNet recibe imágenes de 224 x 224 píxeles e Inception imágenes de 299 x 299 píxeles. Esto es importante, pues de no hacer una correcta redimensión, se pueden generar errores a la hora de entrenar los modelos.

Con los ajustes necesarios, se procedió a realizar el entrenamiento de los modelos durante 25 épocas. Tras el entrenamiento, ambos modelos obtuvieron resultados satisfactorios, los modelos fueron evaluados con ayuda de una matriz de confusión, en la figura 2 se pueden observar las matrices resultantes de cada modelo. A partir de esta

**Tabla 3.** Métricas de evaluación.

Modelo	Exactitud	Precisión	Especificidad
MobileNet	0.9975	0.997	0.998
Inception	0.9945	0.991	0.992

se obtuvo la precisión de los modelos tal como se observa en la tabla 3. Se puede observar que el modelo MobileNet obtuvo una precisión superior al modelo Inception.

A partir de la matriz de confusión se obtuvieron las métricas para evaluar a cada uno de los modelos están son exactitud, precisión y especificidad.

Los resultados demuestran que el modelo MobileNet es superior a Inception en todas las métricas, a pesar de que ambos modelos obtienen resultados similares se considera mejor utilizar MobileNet, ya que en tiempo de entrenamiento este utiliza aproximadamente 2 horas e Inception demora hasta 8 horas.

El modelo MobileNet se implementó en la aplicación móvil, ya que obtuvo mejores resultados en la tarea de clasificación. La figura 3 muestra los resultados obtenidos por el modelo al capturar imágenes en tiempo real desde un dispositivo Android. En la imagen se puede apreciar que el funcionamiento de la aplicación es bastante simple, pues solo consta de una pantalla en donde se realiza la captura de imágenes en tiempo real y se muestra la clase a la que se asocia dicha imagen junto al porcentaje de precisión.

La aplicación desarrollada en Android Studio en conjunto con el modelo seleccionado representa una herramienta muy útil para ayudar a los agricultores a identificar plagas y enfermedades en los cultivos de citrus latifolia con una precisión de hasta el 99.7%.

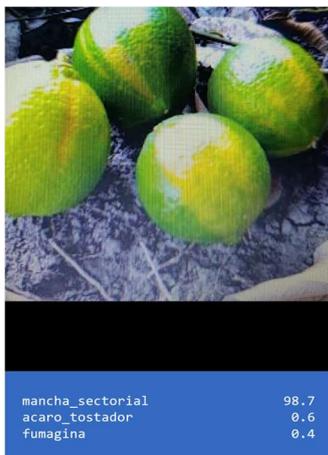
## 5. Conclusiones y trabajo a futuro

Los resultados de la investigación sobre la clasificación de imágenes de plagas y enfermedades en frutos de citrus latifolia son muy prometedores. Se ha demostrado que el uso combinado de una aplicación móvil y un modelo de aprendizaje profundo, en particular una red neuronal convolucional, permite identificar con gran precisión plagas y enfermedades que afectan a los frutos de citrus latifolia.

El modelo MobileNet ha alcanzado una precisión impresionante del 99.7% en esta tarea. Estos hallazgos pueden tener importantes implicaciones para la industria agrícola, ya que una herramienta eficaz para la identificación temprana y el control de plagas y enfermedades en los cultivos de citrus latifolia puede aumentar significativamente la producción y reducir los costos.

MobileNet e Inception son dos arquitecturas de redes neuronales convolucionales utilizadas para la clasificación de imágenes en aplicaciones de visión por computadora.

Si bien ambas arquitecturas han demostrado ser efectivas en la clasificación de imágenes, es notable que MobileNet es una mejor opción si se desea realizar una implementación en una aplicación móvil, pues esta se diseñó para ser más eficiente dentro de entornos en donde los recursos son limitados.



**Fig. 3.** Precisión de clasificación en la App.

Como trabajo futuro se pretende realizar una aplicación móvil más completa, que sea multiplataforma para poder llegar a más agricultores y que pueda ofrecer recomendaciones a los agricultores sobre qué acciones realizar para poder llevar un mejor control de las plagas y enfermedades identificadas en sus cultivos de citrus latifolia.

Otro punto importante que se desea tratar en un futuro es en relación con las plagas y enfermedades que puede identificar la aplicación móvil junto con el modelo, se podría expandir el conjunto de datos a otras plagas y enfermedades que afectan tanto los frutos de citrus latifolia, como sus hojas. Con esto se podría brindar una mejor herramienta a los agricultores.

## Referencias

1. Servicio de información agroalimentaria y pesquera (SIAP): Anuario estadístico de la producción agrícola 2021 (2022) <https://nube.siap.gob.mx/cierreagricola/>
2. Secretaria de agricultura y desarrollo rural (SADER): Plagas y enfermedades comunes del limón (2021) <https://www.gob.mx/agricultura/es/articulos/plagas-y-enfermedades-comunes-del-limon>
3. Dhanya, V. G., Subeesh, A., Kushwaha, N. L., Vishwakarma, D., Kumar, T. N., Ritika, G., Snigh, A. N.: Deep learning based computer vision approaches for smart agricultural applications. *Artificial Intelligence in Agriculture*, vol. 6, pp. 211–229 (2022) doi: 10.1016/j.aiia.2022.09.007
4. Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhmi, M., Gumaci, A.: Automatic detection of citrus fruit and leaves diseases using deep neural network model. *IEEE Access*, vol. 9, pp. 112942–112954 (2021) doi: 10.1109/ACCESS.2021.3096895
5. Janarthan, S., Thuseethan, S., Rajasegarar, S., Lyu, Q., Zheng, Y., Yearwood, J.: Deep metric learning based citrus disease classification with sparse data. *IEEE Access*, vol. 8, pp. 162588–162600 (2020) doi: 10.1109/ACCESS.2020.3021487
6. Ramadhan, M. I., Suyanto, S.: Detection of disease in citrus plants through leaf images using a convolutional neural network. In: 2021 3rd International Conference on Electronics

- Representation and Algorithm (ICERA), pp. 71–76 (2021) doi: 10.1109/ICERA53111.2021.9538757
7. Yang, R., Liao, T., Zhao, P., Zhou, W., He, M., Li, L.: Identification of citrus diseases based on AMSR and MF-RANet. *Plant Methods*, vol. 18, no. 113 (2022) doi: 10.1186/s13007-022-00945-4
  8. Brindha, G. M., Karishma, K. K., Nivetha, J., Vidhya, B.: Automatic detection of citrus fruit diseases using MIB classifier. In: 2022 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC), pp. 1111–1116 (2022) doi: 10.1109/ICESC54411.2022.9885702
  9. Gómez-Flores, W., Garza-Saldaña, J. J., Varela-Fuentes, S. E.: A Huanglongbing detection method for orange trees based on deep neural networks and transfer learning. In *IEEE Access*, vol. 10, pp. 116686–116696 (2022) doi: 10.1109/ACCESS.2022.3219481
  10. Elaraby, A., Hamdy, W., Alanazi, S.: Classification of citrus diseases using optimization deep learning approach. *Computational Intelligence and Neuroscience*, vol. 2022 (2022) doi: 10.1155/2022/9153207
  11. Hassam, M., Khan, M. A., Armghan, A., Althubiti, S. A., Alhaisoni, M., Alqahtani, A., Kadry, S., Kim, Y.: A single stream modified MobileNet V2 and whale controlled entropy based optimization framework for citrus fruit diseases recognition. *IEEE Access*, vol. 10, pp. 91828–91839 (2022) doi: 10.1109/ACCESS.2022.3201338
  12. Berger, J., Preussler, C., Agostini, J. P.: Identification of Huanglongbing symptoms in citrus leaves by deep learning techniques. *Electronic Journal of SADIO*, vol. 18, no. 2, pp. 2–20 (2019)
  13. Masykur, F., Adi, K., Nurhayati, O. D.: Classification of paddy leaf disease using MobileNet model. In: *IEEE 8th International Conference on Computing, Engineering and Design (ICCED)*, pp. 1–4 (2022) doi: 10.1109/ICCED56140.2022.10010535
  14. Baheti, H., Thakare, A., Bhople, Y., Darekar, S., Dodmani, O.: Tomato plant leaf disease detection using inception V3. *Intelligent Systems and Applications. Lecture Notes in Electrical Engineering*, vol. 959, pp. 49–60 (2023) doi: 10.1007/978-981-19-6581-4\_5
  15. Saeed, Z., Raza, A., Qureshi, A. H., Haroon-Yousaf, M.: A multi-crop disease detection and classification approach using CNN. In: *International Conference on Robotics and Automation in Industry (ICRAI)*, pp. 1–6 (2021) doi: 10.1109/ICRAI54018.2021.9651409
  16. Tensorflow: Crea modelos de aprendizaje automático de nivel de producción con TensorFlow (2023) <https://www.tensorflow.org/?hl=es-419>
  17. Tensorflow Hub (2023) <https://tfhub.dev/>
  18. TensorFlow: Implementa modelos de aprendizaje automático en dispositivos móviles y perimetrales TensorFlow Lite (2023) <https://www.tensorflow.org/lite?hl=es-419>
  19. Android Studio.: Conceptos básicos de la plataforma. Developers (2023) <https://developer.android.com/about?hl=es-419>