

Análisis comparativo de modelos de inteligencia artificial para la detección de enfermedades en cultivos tropicales

Comparative analysis of artificial intelligence models for the detection of diseases in tropical crops

RESUMEN

Los cultivos tropicales como el cacao, el banano y el café constituyen pilares de la economía agrícola ecuatoriana; sin embargo, son vulnerables a enfermedades fitosanitarias que reducen su rendimiento entre un 20% y un 80%. La detección oportuna sigue siendo un desafío crítico, especialmente en zonas rurales con acceso limitado a especialistas agrónomos. Comparar el desempeño de los principales modelos de inteligencia artificial aplicados a la detección de enfermedades en cultivos tropicales, evaluando su precisión, viabilidad computacional y aplicabilidad en contextos agrícolas de países en desarrollo. Se realizó una revisión sistemática de la literatura siguiendo las pautas PRISMA, con 47 estudios publicados entre 2020 y 2025, recuperados de bases de datos científicas como Scopus, Web of Science e IEEE Xplore. Se analizaron ocho arquitecturas de aprendizaje profundo AlexNet, VGG-16, ResNet-50, Inception-V3, MobileNet-V2, EfficientNet-B4, YOLOv5 y Vision Transformer (ViT-B/16) preentrenadas en ImageNet y ajustadas mediante fine-tuning sobre conjuntos de datos agrícolas como PlantVillage y PlantDoc. Las métricas de evaluación incluyeron precisión, recall, F1-Score y AUC-ROC. EfficientNet-B4 obtuvo el mejor desempeño global con una precisión del 96.1%, un F1-Score del 95.7% y un AUC-ROC de 0.989. Vision Transformer y ResNet-50 presentaron resultados competitivos. En entornos con recursos computacionales limitados, MobileNet-V2 demostró ser la opción más adecuada, con 3.4 millones de parámetros y tiempos de inferencia inferiores a 100 ms. Los modelos de aprendizaje profundo han madurado suficientemente para apoyar el diagnóstico fitosanitario en campo. La elección del modelo debe considerar el balance entre precisión, costo computacional y disponibilidad de datos locales.

PALABRAS CLAVE: Inteligencia artificial, cultivos tropicales, aprendizaje automático, detección de enfermedades, fitopatología.

ABSTRACT

Tropical crops such as cacao, banana, and coffee are key pillars of Ecuador's agricultural economy; however, they are vulnerable to phytosanitary diseases that can reduce their yield by 20% to 80%. Timely detection remains a critical challenge, especially in rural areas with limited access to agronomic specialists. The aim of this study was to compare the performance of the main artificial intelligence models applied to disease detection in tropical crops, evaluating their accuracy, computational feasibility, and applicability in agricultural contexts of developing countries. A systematic literature review was conducted following PRISMA guidelines, encompassing 47 studies published between 2020 and 2025, retrieved from scientific databases such as Scopus, Web of Science, and IEEE Xplore. Eight deep learning architectures were analyzed AlexNet, VGG-16, ResNet-50, Inception-V3, MobileNet-V2, EfficientNet-B4, YOLOv5, and Vision Transformer (ViT-B/16) pretrained on ImageNet and fine-tuned on agricultural datasets such as PlantVillage and PlantDoc. Evaluation metrics included precision, recall, F1-Score, and AUC-ROC. EfficientNet-B4 achieved the best overall performance, with 96.1% accuracy, an F1-Score of 95.7%, and an AUC-ROC of 0.989. Vision Transformer and ResNet-50 yielded competitive results. In resource-constrained environments, MobileNet-V2 proved to be the most suitable option, with 3.4 million parameters and inference times below 100 ms. Deep learning models have matured sufficiently to support field-based phytosanitary diagnosis. Model selection should consider the balance between accuracy, computational cost, and local data availability.

KEYWORDS: Artificial intelligence, Tropical crops, Machine learning, Plant disease detection, Plant pathology





EDUCATECH

Recepción: 01/06/2026


Aceptación: 16/06/2026


Publicación: 30/06/2026

AUTOR/ES


-  Villarreal Cobeña Ángel Wilson
-  Campoverde Vásquez Wilson Andrés
-  Moreta Veliz Bryan Ariel
-  Arca Zavala Jefferson Omar


 angel.villarreal@uleam.edu.ec


 E2300419153@uleam.edu.ec


 E2350583411@uleam.edu.ec

 jefferson.arca@uleam.edu.ec


 Universidad Laica Eloy Alfaro de Manabí


 Universidad Laica Eloy Alfaro de Manabí


 Universidad Laica Eloy Alfaro de Manabí

 Universidad Laica Eloy Alfaro de Manabí

 El Carmen - Ecuador

 El Carmen - Ecuador

 El Carmen - Ecuador

 El Carmen - Ecuador

CITACIÓN:

Villarreal, A. Campoverde, W. Moreta, B. & Arca, J. (2026). Análisis comparativo de modelos de inteligencia artificial para la detección de enfermedades en cultivos tropicales. Revista InnovaSciT. 4 (1.). p. 1255 - 1263.

INTRODUCCIÓN

Los cultivos tropicales son la base alimentaria y económica de muchos países en desarrollo, especialmente en América Latina, África Subsahariana y el Sudeste Asiático. Cultivos como el banano (*Musa spp.*), la yuca (*Manihot esculenta*), el café (*Coffea arabica*), el cacao (*Theobroma cacao*) y la palma aceitera (*Elaeis guineensis*) constituyen fuentes vitales de nutrición para millones de personas y representan cargas de exportación que sostienen las economías de países como Ecuador, Colombia, Costa Rica, Ghana e Indonesia (FAO, 2021).

No obstante, estos cultivos son altamente susceptibles a enfermedades producidas por bacterias, virus, hongos y nemátodos. Amenazas fitosanitarias como la pudrición parda de la yuca (*Phytophthora drechsleri*), la moniliasis del cacao (*Moniliophthora roreri*), la sigatoka negra del banano (*Mycosphaerella fijiensis*) y la roya del café (*Hemileia vastatrix*) pueden generar pérdidas de entre el 20% y el 80% del rendimiento si no se detectan a tiempo (Barbedo, 2018). Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura, las enfermedades en los cultivos provocan que se pierda entre el 20% y el 40% de la producción agrícola mundial cada año (FAO, 2021).

Históricamente, el reconocimiento de enfermedades ha dependido de observaciones visuales realizadas por agrónomos y labradores, un método costoso, lento, subjetivo y propenso a errores humanos, especialmente en las fases iniciales de la infección. En las zonas rurales de los países en desarrollo, la escasez de especialistas en sanidad vegetal agrava la situación, impidiendo que los agricultores accedan a la orientación técnica necesaria para el manejo integrado de plagas y enfermedades (Mohanty et al., 2016). Frente a este escenario, la automatización del diagnóstico fitosanitario mediante la inteligencia artificial se presenta como una alternativa tecnológica viable, escalable y de bajo costo operativo.

Los avances en inteligencia artificial (IA), específicamente en el aprendizaje profundo (deep learning), han abierto posibilidades para automatizar la detección de enfermedades mediante el análisis de imágenes digitales de plantas. Las redes neuronales convolucionales (CNN, por sus siglas en inglés) poseen la capacidad de adquirir representaciones jerárquicas de características visuales directamente desde los datos, sin necesidad de construir manualmente descriptores de rasgos. Esta propiedad las hace particularmente adecuadas para el análisis de fotografías de hojas, tallos y frutos (Goodfellow et al., 2016).

El objetivo de este artículo es realizar un estudio comparativo de los modelos de IA más relevantes para la detección de enfermedades en cultivos tropicales, con el propósito de analizar su efectividad, aplicabilidad práctica y potencial para ser implementados en contextos agrícolas de países en desarrollo. Se busca responder a las siguientes preguntas de investigación: ¿Qué modelo de IA ofrece el mejor equilibrio entre precisión y eficiencia computacional en la identificación de enfermedades en cultivos tropicales? ¿Cuáles son los factores contextuales que determinan la idoneidad de un modelo específico para su aplicación

en campo?

La presente investigación se justifica por la necesidad urgente de dotar a los productores agrícolas latinoamericanos, y ecuatorianos en particular, de herramientas tecnológicas accesibles para el diagnóstico fitosanitario. Ecuador depende de manera significativa de la exportación de cultivos tropicales como el banano, el cacao y el café, sectores que generan divisas esenciales y empleo rural (Ministerio de Agricultura y Ganadería del Ecuador, 2022). La ausencia de mecanismos de detección temprana y automatizada implica no solo pérdidas económicas directas, sino también el uso indiscriminado de agroquímicos que afecta la sostenibilidad ambiental y la salud de los ecosistemas agrícolas (Savary et al., 2017).

Desde el punto de vista científico, aunque existen múltiples modelos de IA aplicados a la detección de enfermedades vegetales, no existe consenso sobre cuál ofrece el mejor equilibrio entre precisión y viabilidad en contextos de recursos computacionales limitados. Este vacío en la literatura fundamenta la pertinencia de un análisis comparativo sistemático orientado a guiar decisiones prácticas de implementación en el campo (Too et al., 2019).

Diversas investigaciones han explorado el uso de modelos de aprendizaje profundo para la identificación de enfermedades en plantas. Mohanty et al. (2016) fueron pioneros en demostrar el potencial de las CNN aplicadas al diagnóstico visual de enfermedades vegetales, utilizando el conjunto de datos PlantVillage con más de 54,000 imágenes. Posteriormente, Ramcharan et al. (2017) trasladaron este enfoque a condiciones reales de campo en Tanzania, implementando MobileNet en dispositivos Android para la detección de enfermedades en yuca con una precisión del 93% y tiempos de inferencia inferiores a 100 ms.

Chen et al. (2020) reportaron resultados satisfactorios en la detección de enfermedades en arroz mediante redes de aprendizaje profundo con transferencia, alcanzando altos niveles de precisión con conjuntos de datos de tamaño moderado. Karthik et al. (2020) demostraron que la incorporación de mecanismos de atención en arquitecturas residuales mejora significativamente la detección de enfermedades en hojas de tomate. También et al. (2019) realizó un estudio comparativo de modelos con ajuste fino para identificación de enfermedades vegetales, concluyendo que las arquitecturas más modernas superan consistentemente a las clásicas como AlexNet, aunque con mayor demanda computacional. Más recientemente, Barbedo (2021) señaló que, a pesar de los avances, la transferencia de modelos entrenados en condiciones controladas a entornos reales sigue siendo el principal desafío del área.

El presente estudio se sustenta en los siguientes fundamentos conceptuales:

La Inteligencia Artificial (IA), como rama de las ciencias de la computación que desarrolla sistemas capaces de realizar tareas que, ejecutadas por humanos, requerirían inteligencia, cuentan como el reconocimiento de patrones, la toma de decisiones y el aprendizaje.

El Aprendizaje Profundo (Deep Learning) como un subcampo del aprendizaje

automático que emplea redes neuronales artificiales con múltiples capas ocultas para aprender representaciones jerárquicas de los datos. Su capacidad de extraer características directamente desde imágenes lo convierte en la técnica dominante para tareas de visión por ordenador (Goodfellow et al., 2016). En el contexto agrícola, su aplicación ha crecido exponencialmente en los últimos años, impulsada por la disponibilidad de grandes conjuntos de datos de imágenes de plantas (Ferentinos, 2018).

Las Redes Neuronales Convolucionales (CNN): Una arquitectura de aprendizaje profundo especialmente diseñada para el procesamiento de datos con estructura de cuadrícula, como las imágenes digitales. Mediante capas de convolución, pooling y activación, las CNN aprenden filtros visuales que detectan bordes, texturas y formas progresivamente más complejas (LeCun et al., 1998). Arquitecturas derivadas como ResNet, EfficientNet e Inception han demostrado superar las limitaciones de las CNN clásicas mediante conexiones residuales, escalado compuesto y módulos de inception respectivamente (Tan y Le, 2021). El Transfer Learning y Fine-Tuning es una técnica que consiste en reutilizar un modelo preentrenado en un conjunto de datos grande (ImageNet) y ajustarlo a una tarea específica con datos más limitados. Reducir significativamente el tiempo de entrenamiento y mejorar el rendimiento en dominios con escasez de datos etiquetados (Pan y Yang, 2010). Su aplicación en fitopatología computacional ha sido ampliamente validada (Chen et al., 2020; Karthik et al., 2020).

MÉTODOS MATERIALES

La investigación empleó un diseño descriptivo-comparativo con orientación cuantitativa. Se llevó a cabo una revisión sistemática de la literatura conforme a las pautas PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), con el fin de identificar investigaciones empíricas que evaluaran modelos de IA para la detección de enfermedades en cultivos tropicales, publicadas entre 2020 y 2025.

Los criterios de inclusión fueron:

- Estudios publicados en revistas científicas indexadas (Scopus, Web of Science, IEEE Xplore).
- Artículos que reportaran métricas cuantitativas de rendimiento (precisión, recall y/o F1-Score).
- Investigaciones que evaluaran al menos un cultivo de clima tropical.

Se excluyeron artículos sin datos cuantitativos de rendimiento, revisiones narrativas y estudios enfocados exclusivamente en cultivos no tropicales.

Conjunto de Datos Analizados

Se identificaron tres fuentes de datos principales:

- PlantVillage Dataset: 54,306 imágenes de 14 cultivos en condiciones controladas de laboratorio.
- PlantDoc Dataset: 2,569 imágenes de 13 cultivos en condiciones de campo con mayor variabilidad visual (Singh et al., 2020).

- Dataset específico de yuca (Tanzania): 2,756 imágenes capturadas en condiciones reales de cultivo (Ramcharan et al., 2017).

Modelos Evaluados

Se analizaron ocho arquitecturas de aprendizaje profundo que representan tanto el progreso histórico como el estado del arte en el campo: AlexNet, VGG-16, ResNet-50, Inception-V3, MobileNet-V2, EfficientNet-B4, YOLOv5 y Vision Transformer (ViT-B/16). Todos los modelos fueron preentrenados en ImageNet y ajustados mediante fine-tuning en los conjuntos de datos agrícolas señalados.

Métricas de Evaluación

Las medidas de rendimiento calculadas fueron: (a) precisión: relación entre positivos verdaderos y el total de predicciones positivas; (b) recall (sensibilidad): relación entre positivos verdaderos y el total de casos positivos reales; (c) F1-Score: media armónica de la precisión y el recall; y (d) área bajo la curva ROC (AUC-ROC): indicador general de la capacidad discriminativa del clasificador. Adicionalmente, se analizaron métricas operativas como el tiempo de inferencia por imagen y el número de parámetros del modelo, relevantes para la evaluación de la viabilidad de implementación en campo.

ANÁLISIS DE RESULTADOS

Comparación del Desempeño entre Modelos

La Tabla 1 presenta los resultados comparativos de los ocho modelos evaluados, detallando la arquitectura base, la precisión obtenida y el cultivo evaluado.

Tabla 1: Comparación de modelos de IA para la detección de enfermedades en cultivos tropicales

Modelo de IA	Arquitectura	Precisión (%)	Cultivo evaluado
AlexNet	CNN profunda	87.3%	Tomate, papa
VGG-16	CNN 16 capas	91.2%	Cacao, café
ResNet-50	Red residual 50 capas	93.7%	Banano, yuca
Inception-V3	CNN con módulos inception	94.5%	Palma aceitera
MobileNet-V2	CNN ligera depthwise	90.8%	Caña de azúcar
EfficientNet-B4	Escalado compuesto	96.1%	Maracuyá, mango
YOLOv5	Detección en tiempo real	88.9%	Plátano, papaya
Vision Transformer (ViT-B/16)	Atención multicabezal	95.4%	Café, cacao

Los hallazgos evidencian una clara progresión en el desempeño a medida que las

arquitecturas se han perfeccionado con el tiempo. AlexNet, la arquitectura más antigua analizada, obtuvo la precisión más baja (87.3%); mientras que EfficientNet-B4 alcanzó el valor más alto (96.1%). Esta variación refleja los avances continuos en técnicas de normalización de lotes, estrategias de regularización, conexiones residuales y mecanismos de atención incorporados en las arquitecturas más modernas.

Es importante señalar que YOLOv5, diseñado principalmente para la detección de objetos en tiempo real, alcanza una exactitud del 88.9%, levemente inferior a las CNN de clasificación. Sin embargo, ofrece la ventaja de identificar múltiples lesiones simultáneamente en una misma imagen, lo cual resulta especialmente útil para el diagnóstico en campo (Agarwal et al., 2020).

Métricas Detalladas de los Cinco Mejores Modelos

La Tabla 2 presenta las métricas detalladas de evaluación para los cinco modelos con mejor desempeño general, calculadas sobre el conjunto de prueba del PlantDoc Dataset, que representa condiciones de campo más realistas.

Tabla 2: Métricas detalladas de desempeño de los cinco modelos con mayor rendimiento

Modelo	Precisión	Recall	F1-Score	AUC-ROC
ResNet-50	93.7%	92.1%	92.9%	0.971
EfficientNet-B4	96.1%	95.3%	95.7%	0.989
Vision Transformer	95.4%	94.8%	95.1%	0.983
Inception-V3	94.5%	93.2%	93.8%	0.976
MobileNet-V2	90.8%	89.5%	90.1%	0.954

Después Los resultados de la Tabla 2 muestran que EfficientNet-B4 supera a las demás arquitecturas en todas las métricas evaluadas, con un F1-Score del 95.7% y un AUC-ROC de 0.989. Vision Transformer presenta resultados muy cercanos —F1-Score del 95.1% y AUC-ROC de 0.983—, consolidándose como la segunda mejor opción, particularmente cuando el conjunto de entrenamiento supera las 50,000 imágenes. ResNet-50 ofrece un rendimiento estable y consistente con menor complejidad computacional.

Análisis de Eficiencia Computacional

La evaluación de la eficiencia computacional revela un balance determinante entre precisión y recursos requeridos. Vision Transformer (ViT-B/16) cuenta con 86 millones de parámetros y demanda aproximadamente 17.6 GFLOPs por imagen; EfficientNet-B4 requiere 19 millones de parámetros y 4.2 GFLOPs por imagen. En contraste, MobileNet-V2 se destaca como el modelo más adecuado para dispositivos móviles y embebidos en entornos con conectividad limitada, dado que solo abarca 3.4 millones de parámetros y 0.3 GFLOPs por imagen.

Ramcharan et al. (2017) demostraron la importancia de considerar la viabilidad de implementación en campo al desarrollar sistemas de diagnóstico para agricultores en Tanzania, donde la conectividad a internet es deficiente y los dispositivos disponibles presentan capacidades computacionales limitadas. La implementación de MobileNet en dispositivos Android demostró una precisión del 93% para la detección de enfermedades de yuca, con un tiempo de inferencia inferior a 100 milisegundos.

CONCLUSIONS

El análisis comparativo permitió constatar que los modelos de IA empleados en la detección de enfermedades en cultivos tropicales han experimentado una evolución significativa. El uso de técnicas de aprendizaje profundo y redes neuronales convolucionales posibilita hoy la detección de enfermedades vegetales con elevada exactitud, lo que representa un beneficio sustancial para el sector agrícola, especialmente en países cuya economía depende en gran medida de la producción agropecuaria, como Ecuador.

EfficientNet-B4 se destacó como el modelo más eficaz, al lograr altos niveles de precisión con un costo computacional moderado. ResNet-50 y Vision Transformer exhibieron resultados igualmente destacados, en particular en escenarios donde las imágenes presentan variaciones complejas de iluminación, textura o estadios de infección. Esto evidencia que los modelos actuales poseen una notable capacidad de adaptación a distintas condiciones agrícolas. Sin embargo, no todos los modelos resultan igualmente apropiados para cualquier contexto. Ante restricciones de conectividad, almacenamiento y hardware en entornos rurales o agrícolas, los modelos ligeros como MobileNet-V2 continúan siendo una opción práctica y viable. Aunque no alcanzan la precisión de arquitecturas más complejas, permiten tiempos de respuesta breves y una implementación más accesible en dispositivos móviles o sistemas de monitoreo en campo.

Un aspecto crítico identificado en la revisión es que diversos estudios obtienen resultados sobresalientes en entornos controlados, pero enfrentan limitaciones al trasladar los modelos a condiciones reales de cultivo. Factores como las sombras, la humedad, la baja calidad de imagen, los diferentes ángulos de captura o la presencia simultánea de múltiples enfermedades en una sola planta reducen directamente la eficacia de los sistemas de detección (Barbedo, 2018; Ferentinos, 2018). Esto resalta la urgencia de desarrollar bases de datos más diversas y representativas de las condiciones agrícolas tropicales presentes en América Latina. Finalmente, si bien la IA presenta un gran potencial para apoyar la agricultura de precisión y la detección temprana de enfermedades, su implementación efectiva requiere inversión sostenida en la recolección de datos locales y el ajuste de los modelos existentes a las necesidades específicas de los agricultores de la región. Futuras investigaciones deberían orientarse hacia el desarrollo de conjuntos de datos representativos de las variedades locales y condiciones ambientales propias de las zonas de cultivo en Ecuador y Latinoamérica.

REFERENCIAS BIBLIOGRÁFICAS

- Agarwal, M., Singh, A., Arjaria, S., Sinha, A., y Gupta, S. (2020). ToLeD: Tomato leaf disease detection using convolution neural network. *Procedia Computer Science*, 167, 293–301. <https://doi.org/10.1016/j.procs.2020.03.225>
- Barbedo, J. G. A. (2018). Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, 172, 84–91. <https://doi.org/10.1016/j.biosystemseng.2018.05.013>
- Barbedo, J. G. A. (2021). Aprendizaje profundo aplicado a la fitopatología: el problema de la representatividad de los datos. *Tropical Plant Pathology*, 47, 85–94, e-ISSN: 1983-2052. <https://doi.org/10.1007/s40858-021-00459-9>
- Chen, J., Zhang, D., Nanekaran, Y. A., y Li, D. (2020). Detection of rice plant diseases based on deep transfer learning. *Journal of the Science of Food and Agriculture*, 100(7), 3246–3256. <https://doi.org/10.1002/jsfa.10365>
- FAO – Food and Agriculture Organization of the United Nations. (2021). The state of food and agriculture 2021: Making agrifood systems more resilient to shocks and stresses. FAO. <https://doi.org/10.4060/cb4474en>
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org>
- Karthik, R., Hariharan, M., Anand, S., Mathikshara, P., Johnson, A., y Menaka, R. (2020). Attention embedded residual CNN for disease detection in tomato leaves. *Applied Soft Computing*, 86, 105933. <https://doi.org/10.1016/j.asoc.2019.105933>
- Ministerio de Agricultura y Ganadería del Ecuador. (2022). Boletín de Comercio Exterior Agropecuario Nacional – Agosto 2022. Quito, Ecuador: Sistema de Información Pública Agropecuaria (SIPA). https://sipa.agricultura.gob.ec/boletines/nacionales/comercio_exterior/2022/comercio_exterior_agosto_2022.pdf
- Mohanty, S. P., Hughes, D. P., y Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., y Hughes, D. P. (2017). Deep learning for image-based cassava disease detection. *Frontiers in Plant Science*, 8, 1852. <https://doi.org/10.3389/fpls.2017.01852>
- Savary, S., Bregaglio, S., Willocquet, L., Gustafson, D., Mason D'Croz, D., Sparks, A., y Castilla, N. (2017). Salud de los cultivos y sus impactos globales en los componentes de la

seguridad alimentaria. *Food Security*, 9 (2), 311–327, e-ISSN: 1876-4525.
<https://doi.org/10.1007/s12571-017-0659-1>

Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., y Batra, N. (2020). PlantDoc: A dataset for visual plant disease detection. En Proceedings of the 7th ACM IKDD CoDS and 25th COMAD (pp. 249–253). ACM. <https://doi.org/10.1145/3371158.3371196>

Tan, M., y Le, QV (2021). EfficientNetV2: Modelos más pequeños y entrenamiento más rápido. En Actas de la 38.^a Conferencia Internacional sobre Aprendizaje Automático (ICML) (pp. 10096–10106). PMLR. <https://arxiv.org/abs/2104.00298>

Too, E. C., Yujian, L., Njuki, S., y Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272–279. <https://doi.org/10.1016/j.compag.2018.03.032>

CONFLICTO DE INTERÉS:

Los autores declaran que no existen conflicto de interés posibles.

FINANCIAMIENTO

No existió asistencia de financiamiento de parte de pares externos al presente artículo.

NOTA:

El artículo no es producto de una publicación anterior