

Artículo Científico

Sistema inteligente de detección de enfermedades en cultivos hidropónicos mediante visión artificial

Intelligent detection system of diseases in hydroponic crops using artificial vision

Diego Fernando Pichoasamin Morales¹ , Patricio Javier Cruz Dávalos² 

¹ Universidad Estatal Península de Santa Elena, diego.pichoasaminmorales8771@upse.edu.ec, Santa Elena - Ecuador

² Universidad Estatal Península de Santa Elena, pcruz.davalos@upse.edu.ec, Santa Elena - Ecuador

Autor para correspondencia: diego.pichoasaminmorales8771@upse.edu.ec

RESUMEN

Este estudio presenta el desarrollo de un sistema para la detección temprana de enfermedades en cultivos hidropónicos de lechuga, empleando visión artificial e inteligencia artificial (IA). Se implementa un modelo basado en la arquitectura MobileNetV2, entrenado mediante aprendizaje por transferencia y ejecutado en una Raspberry Pi 4, con el objetivo de garantizar portabilidad y bajo consumo de recursos. El entrenamiento del sistema se realizó empleando un conjunto de 2190 imágenes clasificadas en cuatro clases: sana, mildiu, oídio y mancha (bacteriana y foliar). Se utilizaron técnicas de aumento de datos y preprocesamiento adaptado al modelo. Se alcanzó una exactitud del 96.34% en el conjunto de validación y 94% en pruebas, evidenciando una alta capacidad de generalización. El modelo fue integrado a un prototipo físico que captura imágenes en línea, realiza inferencias locales y proporciona retroalimentación visual inmediata sobre la enfermedad detectada. Esta investigación demuestra la viabilidad técnica de aplicar IA en agricultura de precisión para entornos hidropónicos, reduciendo la intervención manual y mejorando la eficiencia productiva, con potencial para ser escalada en soluciones agrícolas inteligentes.

Palabras clave: Visión artificial; MobileNetV2; Aprendizaje por transferencia; Detección de enfermedades; Cultivos hidropónicos.

ABSTRACT

This work proposes the development of a system for the early detection of diseases in hydroponic lettuce crops, employing computer vision and artificial intelligence (AI). A model based on the MobileNetV2 architecture was implemented, trained using transfer learning and executed on a Raspberry Pi 4, with the aim of ensuring portability and low resource consumption. The system was trained using a dataset of 2190 images classified into four classes: healthy, downy mildew, powdery mildew, and spot (bacterial and leaf spot). For this, data augmentation techniques and model-adapted preprocessing were utilized. An accuracy of 96.34% was achieved on the validation set and 94% on tests, demonstrating a high generalization capacity. The model was integrated into a physical prototype that captures images online, performs local inferences, and provides immediate visual feedback on the detected disease. This research demonstrates the technical feasibility of applying AI in precision agriculture for hydroponic environments, reducing manual intervention and improving productive efficiency, with the potential for scalability into intelligent agricultural solutions.

Keywords: Computer vision; MobileNetV2; Transfer learning; Disease detection; Hydroponic crops.

Derechos de Autor

Los originales publicados en las ediciones electrónicas bajo derechos de primera publicación de la revista son del Instituto Superior Tecnológico Universitario Rumiñahui, por ello, es necesario citar la procedencia en cualquier reproducción parcial o total. Todos los contenidos de la revista electrónica se distribuyen bajo una [licencia de Creative Commons Reconocimiento-NoComercial-4.0 Internacional](#).



Citas

Pichoasamín Morales, D. F., & Cruz Dávalos, P. J. (2026). Sistema inteligente para la detección de enfermedades en cultivos hidropónicos mediante visión artificial. *CONECTIVIDAD*, 7(1), 37–54. <https://doi.org/10.37431/conectividad.v7i1.339>

1. INTRODUCCIÓN

En el sector alimentario, la hidroponía emerge como una alternativa innovadora, caracterizada por la sustitución del suelo tradicional por una solución nutritiva que combina agua, nutrientes y fertilizantes; esta técnica agrícola promueve un crecimiento más eficiente y acelerado de los cultivos, al mismo tiempo que reduce el esfuerzo necesario para los horticultores, además de maximizar el uso de recursos, la hidroponía se adapta perfectamente a espacios limitados, convirtiéndose en una opción sostenible para satisfacer la creciente demanda de alimentos en entornos urbanos (Swarup Sahoo et al., 2022).

Las enfermedades en cultivos hidropónicos provocadas por patógenos como bacterias, virus y hongos, afectan gravemente la productividad y calidad de las plantas, se manifiestan con síntomas visibles en las hojas, provocando una reducción del rendimiento y deterioro en la cosecha. Un manejo ineficiente de estas afecciones puede generar pérdidas sustanciales en la cosecha y económicas (Gowtham et al., 2024).

La propagación de enfermedades en plantas es un reto en entornos controlados y no controlados, siendo el monitoreo de enfermedades y la detección temprana fundamentales para prevenir la pérdida de cultivos, garantizar la cantidad y calidad de la producción agrícola, es ahí que la implementación de sistemas automatizados basados en el Internet de las Cosas (IoT), redes neuronales convolucionales profundas (DCNN) ofrece una solución prometedora, estos sistemas pueden identificar de manera precisa y oportuna las deficiencias de nutrientes, enfermedades de las plantas y problemas de suministro de agua, minimizando la intervención manual y mejorando la eficiencia operativa de los sistemas hidropónicos (Musa et al., 2021).

Rahman et al. (2024) manifiesta que el monitoreo constante de los parámetros y la necesidad de energía eléctrica confiable limitan la implementación efectiva de cultivos hidropónicos inteligentes y considera que al integrar tecnologías como la inteligencia artificial y el Internet de las Cosas puede revolucionar la hidroponía al automatizar procesos y optimizar los recursos. La detección oportuna de enfermedades, el uso eficiente de recursos, la integración de tecnologías como la inteligencia artificial (IA) y el Internet de las Cosas (IoT) ha transformado el monitoreo agrícola permitiendo detectar factores críticos como humedad, pH y temperatura, así como identificar enfermedades a partir del análisis de imágenes con redes neuronales profundas

(Bhandari et al., 2024), la IA se manifiesta como una herramienta para enfrentar las limitaciones en sistemas hidropónicos mediante soluciones automatizadas para la detección temprana de enfermedades en plantas (Akkem et al., 2023).

Este estudio tiene como objetivo desarrollar un sistema inteligente que permita la detección temprana de enfermedades en cultivos hidropónicos de lechuga empleando visión artificial e inteligencia artificial. El sistema facilitará una intervención preventiva oportuna para mitigar la propagación de enfermedades y mejorar la productividad, superando las limitaciones de los métodos manuales que son lentos y propensos a errores. La visión es una solución eficiente para automatizar el análisis de imágenes y obtener un diagnóstico fiable de enfermedades, lo que contribuye a una agricultura más eficiente, económica y sostenible.

El artículo se estructura en varias secciones que abordan los aspectos para el desarrollo del sistema inteligente propuesto, en la Sección 2, Materiales y Métodos, se describe la metodología empleada que consta de tres partes, la recolección y preprocesamiento de imágenes, el entrenamiento del modelo de visión artificial y la evaluación del rendimiento del sistema en condiciones reales de cultivo; en la Sección 3, Resultados y Discusión, se analizan e interpretan las métricas de evaluación, como exactitud y efectividad en la detección de enfermedades; finalmente, en la Sección 4, Conclusiones, se describen las principales contribuciones del estudio y las direcciones futuras para la investigación.

2. MATERIALES Y MÉTODOS

La metodología empleada es un enfoque experimental, orientado al desarrollo de un prototipo de sistema inteligente para la detección temprana de enfermedades en cultivos hidropónicos de lechuga, el prototipo integra visión artificial y algoritmos de inteligencia artificial (IA) para el procesamiento de imágenes, empleando una plataforma de hardware accesible como la Raspberry Pi 4, la investigación busca evaluar la viabilidad y efectividad del sistema en un entorno controlado, asegurando que pueda ofrecer una solución práctica para mejorar la gestión de enfermedades en la agricultura hidropónica.

2.1. Arquitectura del sistema

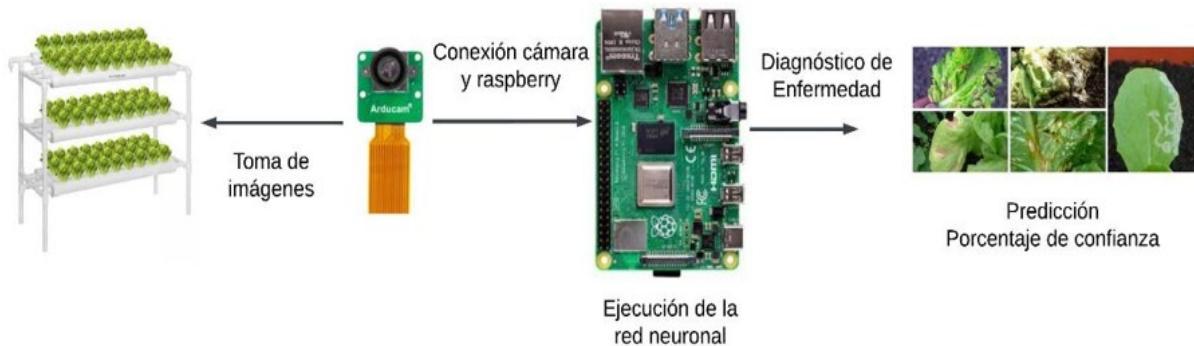
El sistema inteligente propuesto fue implementado en la plataforma Raspberry Pi 4, debido a su

costo accesible y su capacidad de procesamiento adecuada para aplicaciones de visión artificial en tiempo real. La elección de MobileNetV2 se fundamenta en su arquitectura optimizada para dispositivos con recursos limitados, como la Raspberry Pi 4, debido a su bajo número de parámetros y alta eficiencia computacional (Sandler et al., 2018), MobileNetV2 presenta un equilibrio entre precisión y velocidad de inferencia, siendo especialmente adecuado para aplicaciones en tiempo real sobre plataformas embebidas, su diseño basado en convoluciones separables en profundidad permite mantener una alta capacidad de extracción de características con un bajo costo computacional.

Se empleó TensorFlow en conjunto con MobileNetV2 debido a la alta compatibilidad entre ambos. MobileNetV2 es una arquitectura ligera y eficiente que ha demostrado un rendimiento notable en tareas de clasificación de imágenes en dispositivos de bajo consumo, su integración con TensorFlow permite una implementación fluida, estable y escalable para sistemas inteligentes de monitoreo agrícola, facilitando el diagnóstico automatizado de enfermedades en cultivos hidropónicos (Bhandari et al., 2024). Se consideró la versión TensorFlow Lite que permite implementar modelos optimizados en dispositivos como la Raspberry Pi 4 y por su integración con arquitecturas ligeras como MobileNetV2, esta versión ha demostrado ser eficaz para tareas de clasificación en agricultura de precisión, logrando alta precisión con baja latencia y un reducido consumo de energía (Duhan et al., 2025; Lu et al., 2023).

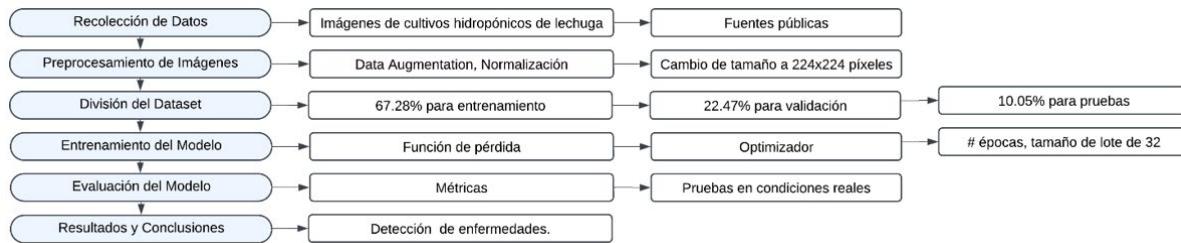
La Figura 1., presenta la arquitectura del sistema implementada mediante un módulo de cámara Arducam con sensor IMX477 y la plataforma Raspberry Pi 4 para la captura y procesamiento de imágenes. Esta configuración permite una adquisición precisa y un análisis en tiempo real, adecuados para aplicaciones de visión artificial y control embebido.

Figura 1. Diseño del sistema



La Figura 2., presenta el diagrama de flujo de la metodología central empleada para el desarrollo y entrenamiento del modelo de inteligencia artificial de detección de enfermedades, este proceso abarca desde la recolección y preprocesamiento de los datos hasta la evaluación de su rendimiento. La implementación y configuración del sistema físico que integra este modelo entrenado para la detección en tiempo real se detalla posteriormente en la sección de Detección de enfermedades.

Figura 2. Metodología de Desarrollo y Entrenamiento del Modelo de IA



2.2. Recolección de datos

Tabla 1. Características visuales de las clases a entrenar en hojas de lechuga

Condición	Cantidad Imágenes	Características	Imagen	Condición	Cantidad Imágenes	Características	Imagen
Clase 1 Hoja sana	Train: 359 Validate: 119 Test: 55 Total: 533	Verde uniforme, brillante Sin manchas, sin polvo ni vellosidad				Bacteriana: Manchas marrones a negras, con bordes difusos y aspecto acuoso.	
Clase 2 Mildiu	Train: 377 Validate: 125 Test: 55 Total: 557	Zonas amarillas o pálidas en la parte superior; moho blanco en el envés		Clase 4 Mancha	Train: 374 Validate: 125 Test: 55 Total: 554		
Clase 3 Oídio	Train: 368 Validate: 123 Test: 55 Total: 546	Polvo blanco en la superficie superior; capa polvorienta que se desprende al frotar				Foliar: Manchas circulares, de color amarillo a marrón claro, con halo de decoloración.	

Se recopiló un dataset de imágenes de lechugas en condiciones hidropónicas, incluyendo ejemplos de plantas sanas y de enfermedades: mildiu, oídio y mancha bacteriana o foliar. Estas imágenes fueron obtenidas de bases de datos públicas reconocidas en visión artificial aplicada a la agricultura, como el conjunto de datos PlantVillage (Jeyabose et al., 2022), utilizado para la detección y clasificación de enfermedades vegetales, y los datos de Agriculture-Vision Dataset (Chiu et al., 2020), empleado para el análisis de patrones agrícolas. Además, se recopiló información técnica de fuentes especializadas, como la proporcionada por NE-VAL. La construcción del dataset se basó en la disponibilidad de imágenes de alta calidad de plantas

de lechuga, abarcando tanto estados sanos como las principales enfermedades identificadas en cultivos hidropónicos, el tamaño total de 2190 imágenes se determinó para asegurar una representación suficiente de la variabilidad morfológica de cada clase, a fin de obtener un entrenamiento robusto de modelos de aprendizaje profundo y mitigar el riesgo de sobreajuste. Respecto a la división del dataset, Ye et al. (2025) realizan una revisión exhaustiva en esta área y reportan que los estudios dividieron sus conjuntos de datos entre entrenamiento 80% y prueba/verificación 20%. Asimismo, estudios como el de Carvalho et al. (2025) aplican diversas distribuciones, incluyendo ejemplos como 60/20/20, 70/15/15 y 80/10/10, lo que demuestra la flexibilidad en las proporciones. Finalmente, el dataset empleado para este estudio comprende un total de 2190 imágenes distribuidas en el 67.49 % (1478 imágenes) para el conjunto de entrenamiento, 22.47% (492 imágenes) para el conjunto de validación y 10.05% (220 imágenes) para el conjunto de pruebas, conforme las clases de la Tabla 1.

Para garantizar que el modelo aprenda las características de interés y precise la ubicación de las enfermedades, la determinación de las clases se complementó mediante la anotación de imágenes, se empleó la herramienta LabelImg, permitiendo la creación manual de bounding boxes alrededor de las áreas afectadas y la asignación detallada de las etiquetas correspondientes a cada clase, la utilización de LabelImg facilita la categorización precisa de cada muestra, mejorando la capacidad de generalización del modelo siendo su uso extendido en necesidades de anotación directa para visión artificial (Khan & Singh, 2024).

2.3. Preprocesamiento de Imágenes

Para optimizar la entrada del modelo de red neuronal convolucional y garantizar la compatibilidad con la arquitectura MobileNetV2, todas las imágenes del dataset fueron redimensionadas a un tamaño uniforme de 224x224 píxeles previo al entrenamiento. Esta resolución es la entrada estándar y optimizada para MobileNetV2, lo cual es fundamental para aprovechar sus pesos pre-entrenados en un esquema de aprendizaje por transferencia (Sandler et al., 2018). Además, la elección de 224x224 píxeles es una práctica común y ampliamente adoptada en el campo de la visión artificial con aprendizaje profundo, especialmente en tareas de clasificación que utilizan modelos pre-entrenados (Kamilaris & Prenafeta-Boldú, 2018). La estandarización a esta resolución no solo asegura la compatibilidad con un modelo ya optimizado para procesar

características visuales a esta escala, sino que también contribuye significativamente a la eficiencia computacional durante el entrenamiento y la inferencia, un aspecto particularmente relevante para la implementación en el prototipo físico basado en Raspberry Pi 4.

2.4. Entrenamiento del Modelo

El proceso de entrenamiento del modelo se basó en una estrategia de aprendizaje por transferencia (Transfer Learning), aprovechando la arquitectura pre-entrenada de MobileNetV2 sobre el conjunto de datos ImageNet, la técnica fue seleccionada para beneficiarse de la capacidad de MobileNetV2 de extraer características visuales complejas, considerando que esta técnica reducía tiempo de entrenamiento y la necesidad de un dataset extremadamente voluminoso, la capa convolucional base de MobileNetV2 se mantuvo congelada para preservar los pesos pre-entrenados y se adjuntó una nueva capa de clasificación totalmente conectada adaptada para la tarea de cuatro clases de salida.

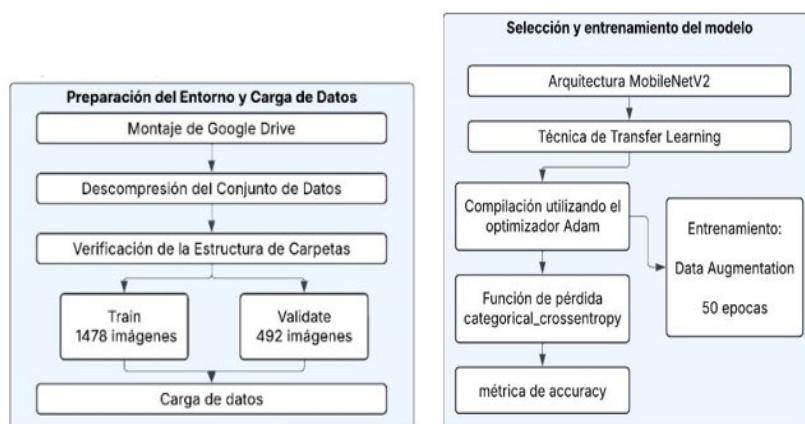
La implementación de MobileNetV2 ha demostrado resultados sobresalientes en tareas de clasificación de imágenes en el dominio agrícola. Lu et al. (2023) propusieron una versión mejorada de MobileNetV2 para la identificación de enfermedades en cultivos, logrando una precisión del 99.53% en el conjunto de datos PlantVillage. Asimismo, Ahmed et al. (2021) desarrollaron una arquitectura ligera basada en MobileNetV2 para la clasificación de enfermedades en hojas de tomate, alcanzando una precisión del 99.30% con un tamaño de modelo de 9.60 MB y 4.87 millones de operaciones de punto flotante, lo que la hace adecuada para dispositivos de bajos recursos.

Se implementó una normalización de píxeles escalando los valores de intensidad de las imágenes a un rango flotante de [0,1], preparando los datos de entrada para una convergencia del modelo, para mitigar el riesgo de sobreajuste y mejorar la capacidad de generalización del modelo, se aplicaron técnicas de aumento de datos (Data Augmentation) exclusivamente al conjunto de entrenamiento. Estas transformaciones se implementaron en tiempo real durante el proceso de entrenamiento, generando nuevas variaciones sintéticas de las imágenes existentes sin incrementar físicamente el tamaño del conjunto de datos base, ampliando artificialmente la diversidad y la cantidad efectiva de ejemplos que el modelo observó, mejorando su robustez frente a variaciones en el entorno real.

Las operaciones incluyeron rotaciones aleatorias hasta 45°, traslaciones horizontales y verticales hasta 20% del ancho o alto de la imagen, cambios de brillo con un factor de hasta 0.2, cizallamiento y zooms aleatorios con un factor de hasta 0.2, la exposición del modelo a esta mayor variabilidad de características contribuyó a un entrenamiento más robusto.

La preparación inicial del entorno consistió en el montaje de Google Drive para acceder al conjunto de datos comprimido tras la descompresión, se verificó la estructura de carpetas que organizaba las imágenes por clase: mancha, mildiu, oidio, sana, dentro de los directorios train y validate respectivamente. La carga de las imágenes y la generación automática de etiquetas se realizó mediante la herramienta de TensorFlow/Keras que facilitó la creación de objetos tf.data. dataset directamente desde la estructura de directorios, asignando etiquetas basadas en los nombres de las carpetas, resultando en un conjunto de entrenamiento y conjunto de validación, el flujo de información se visualiza en la Figura 3.

Figura 3. Etapas de entrenamiento del modelo



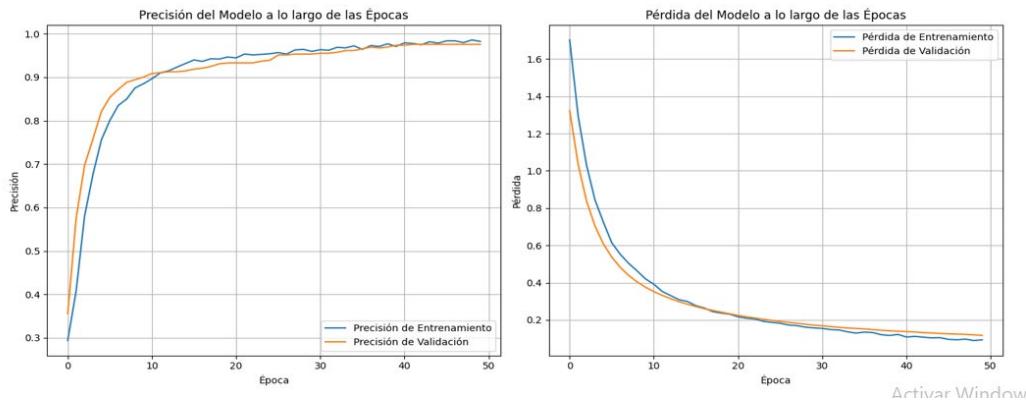
3. RESULTADOS Y DISCUSIÓN

3.1. Modelo de clasificación

El modelo fue compilado empleando el optimizador Adam, mismo que fue configurado con una tasa de aprendizaje adaptativa, y, la función de pérdida seleccionada fue la entropía cruzada categórica. El entrenamiento se diseñó para un máximo de 50 épocas con un tamaño de lote de 32 imágenes, para prevenir el sobreajuste y optimizar el rendimiento del modelo, se implementó una estrategia de parada temprana (early stopping), esta estrategia monitoreó la precisión en el conjunto de validación deteniendo el entrenamiento cuando no se evidenciaron mejoras en esta métrica, el criterio se cumplió en la época 42.

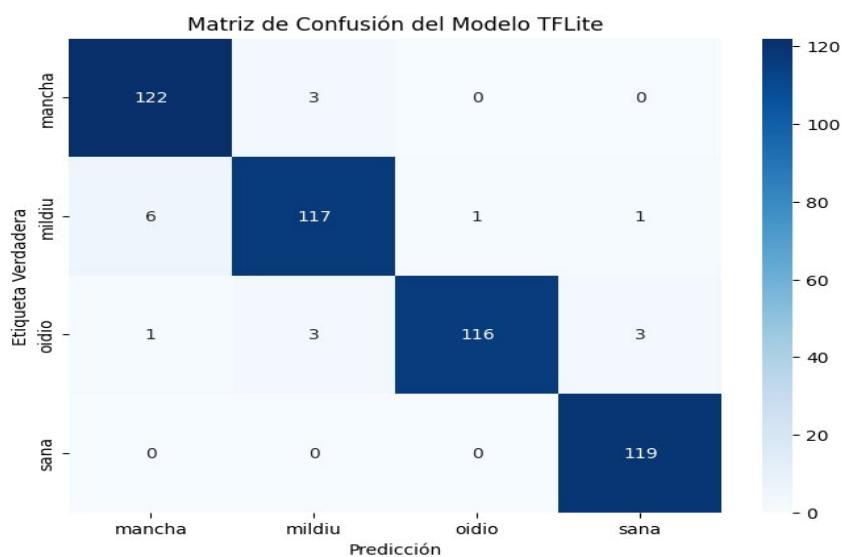
La aplicación de la parada temprana actuó como una medida de regularización, ya que al continuar el entrenamiento más allá de la época 42 el riesgo de sobreajuste se habría incrementado, deteriorando la capacidad de generalización del modelo a datos no vistos, al detener el proceso en el punto óptimo de precisión de validación, se garantiza que el modelo aprenda patrones significativos de los datos sin memorizar el ruido específico del conjunto de entrenamiento.

Figura 4. Precisión del modelo de entrenamiento



La matriz de confusión del conjunto de validación refleja que el modelo de clasificación de enfermedades en hojas de lechuga tiene un rendimiento muy sólido en la identificación de las cuatro clases (mancha, mildiu, oido, sana), ver Figura 5, los errores de clasificación son mínimos y no hay una confusión sistemática importante entre ninguna de las clases.

Figura 5. Matriz de confusión en el conjunto de validación



En la Tabla 2., se visualiza la precisión que indica la exactitud de las predicciones positivas para cada clase, la exhaustividad (Recall) mide la capacidad del modelo para identificar todas las instancias reales, la puntuación F1 representa la media armónica la exactitud y exhaustividad,

ofreciendo un balance, finalmente las imágenes de soporte muestra la distribución de muestras por clase, evidenciando un rendimiento robusto en todas las categorías, con una Exactitud (Accuracy) global del 96.34%, la clase ‘sana’ alcanza una exhaustividad del 100%, lo que es crucial para evitar diagnósticos erróneos en cultivos saludables.

Tabla 2. Métricas de rendimiento del modelo en el conjunto de validación

Clases	Precisión	Exhaustividad (Recall)	Puntuación F1	Soporte (Imágenes)
Mancha	0.95	0.98	0.96	125
Mildiu	0.95	0.94	0.94	125
Oídio	0.99	0.94	0.97	123
Sana	0.97	1.00	0.98	119
Exactitud (Accuracy)	0.9634			492

3.2. Evaluación del modelo

Para evaluar la capacidad de generalización del modelo entrenamos a datos no vistos, se realizó pruebas sobre el conjunto de imágenes de test, obteniendo una precisión 94% en la clasificación de las cuatro categorías de enfermedades como se visualiza en la Tabla 3. y en la Figura 6 correspondiente a la matriz de confusión del conjunto de pruebas de 220 imágenes, porcentaje inferior a la obtenida en el conjunto de validación.

Figura 6. Matriz de confusión del modelo MobileNetV2 en el conjunto de pruebas

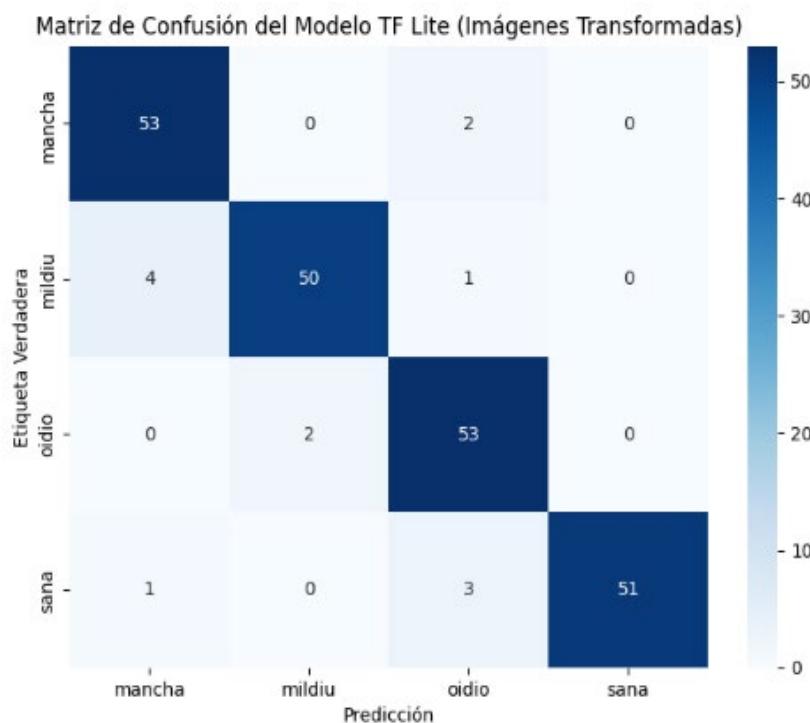
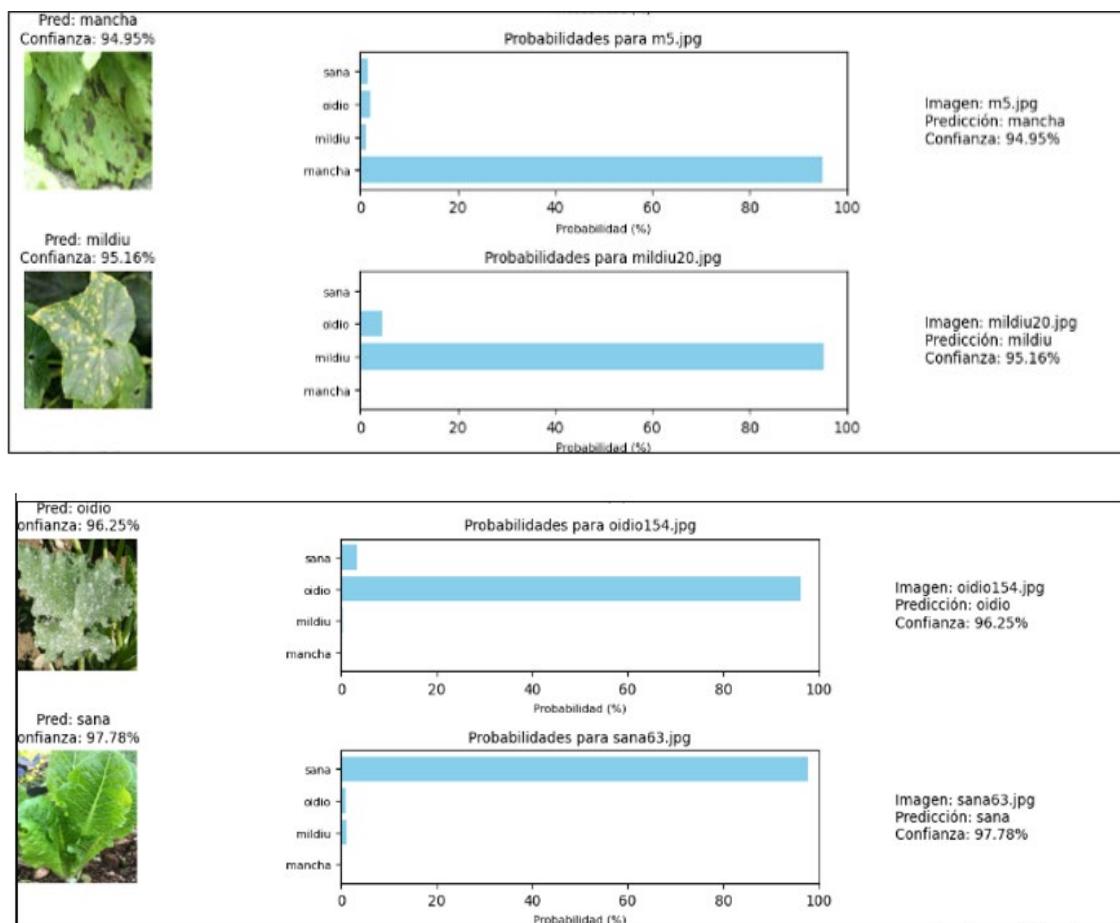


Tabla 3. Métricas de rendimiento del modelo en el conjunto de pruebas

Clases	Precisión	Exhaustividad (Recall)	Puntuación F1	Soporte (Imágenes)
Mancha	0.91	0.96	0.94	55
Mildiu	0.96	0.91	0.93	55
Oídio	0.90	0.96	0.93	55
Sana	1.00	0.93	0.96	55
Exactitud		0.94		220

En comparación con los métodos tradicionales de monitoreo manual, el sistema propuesto ofrece ventajas sustanciales en precisión, consistencia y tiempo de respuesta, estudios como el de Da Silva Ferreira et al. (2018) señalan que la precisión de las evaluaciones visuales humanas para determinar el estado sanitario de lechugas puede alcanzar hasta un 91% cuando son realizadas por evaluadores expertos, pero se reduce al 87% en evaluadores sin experiencia, adicional, se determina que existe un considerable variabilidad entre evaluadores, especialmente en fases tempranas o intermedias de enfermedad, lo cual puede afectar la confiabilidad del diagnóstico. En la Figura 7 se visualiza ejemplos de las pruebas realizadas a cada clase.

Figura 7. Ejemplos de aplicación del modelo entrenado



La Tabla 4., detalla los porcentajes de Falsos Positivos (FP) y Falsos Negativos (FN) por clase, no se registraron casos sin resultado, la clase ‘Sana’ exhibe un rendimiento excepcional con 0.00% de FP en ambos conjuntos, minimizando diagnósticos erróneos de enfermedad, sin embargo, Oidio muestra el FP más alto en pruebas 10.17%, mientras que Mildiu 9.09% y Sana 7.27% presentan los FN más elevados en pruebas. Estos FN son particularmente críticos, ya que representan fallos en la detección de patologías existentes o clasificaciones incorrectas de plantas sanas como enfermas, siendo los porcentajes de error son globalmente bajos, evidenciando la robustez y capacidad de generalización del modelo en la detección temprana de las clases, enfermedades o sanas.

Tabla 4. Detección de la enfermedad

Clase	Conjunto de Validación		Conjunto de Pruebas	
	FP (%)	FN (%)	FP (%)	FN (%)
Mancha	5.43%	2.40%	8.62%	3.64%
Mildiu	4.88%	6.40%	3.85%	9.09%
Oidio	3.42%	5.69%	10.17%	3.64%
Sana		0.00% 0.00% 0.00%		7.27%

Según López y Martínez (2020) los métodos tradicionales de monitoreo manual en cultivos presentan limitaciones importantes, como la subjetividad en la interpretación de síntomas y la fatiga del evaluador, que pueden conducir a errores y retrasos en la toma de decisiones, métodos tradicionales aunque ampliamente usados, no garantizan una evaluación uniforme ni replicable, especialmente cuando el personal carece de la formación técnica adecuada o cuando se manejan grandes extensiones de cultivo.

El modelo MobileNetV2 desarrollado en este estudio demostró un rendimiento sobresaliente en la tarea de clasificación de enfermedades en hojas de lechuga. La estrategia de Transfer Learning con MobileNetV2, la congelación de sus capas base, la adición de una capa de clasificación y el uso de Dropout, demostraron ser eficientes para el entrenamiento del modelo, logrando una exactitud de validación del 96.34%, con una pérdida final de validación de 0.1178 en su punto óptimo, el modelo alcanzó una exactitud del 94% en el conjunto de pruebas, manteniendo en ambos casos un rendimiento homogéneo entre las clases evaluadas, dicha capacidad del sistema facilita una detección más temprana de las enfermedades.

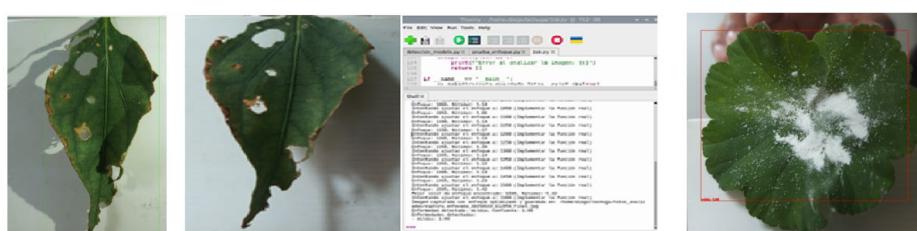
La exactitud del 94% obtenida en este estudio valida la capacidad del modelo MobileNetV2 para clasificar eficientemente las enfermedades de la lechuga, siendo un resultado altamente adecuado para un sistema de detección temprana en entornos hidropónicos, esta robusta capacidad de generalización sobre datos no vistos se alinea con investigaciones previas en el campo, por ejemplo, Jeyabose et al. (2022) reportaron un diseño basado en MobileNet que alcanzó una exactitud del 96% para la detección de enfermedades en hojas de cultivos, demostrando el potencial de esta arquitectura; estudios más específicos en cultivos hidropónicos de lechuga han logrado exactitudes comparables como Li et al. (2023) identificaron hojas defectuosas con una tasa de exactitud promedio del 94.3% utilizando una arquitectura optimizada, estos antecedentes respaldan la competitividad y la idoneidad del rendimiento alcanzado en nuestra investigación, superando la consistencia y fiabilidad de los métodos de inspección manual.

3.3. Detección de enfermedades

Para la implementación práctica y validación del sistema de detección en un entorno de cultivo, se desarrolló un prototipo que integra el modelo de clasificación previamente entrenado con componentes de hardware, siendo el objetivo de evaluar la capacidad del modelo para operar sobre imágenes capturadas en tiempo real y proporcionar inferencias directamente en el punto de aplicación.

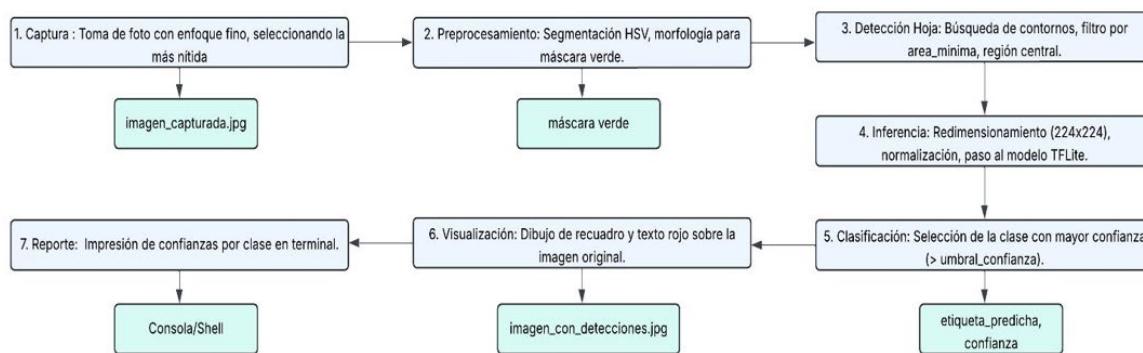
El prototipo se construyó empleando una tarjeta Raspberry Pi 4 modelo B como plataforma de procesamiento embebido, la cual se conectó a una cámara Arducam Raspberry Pi HQ con lente de enfoque motorizado y módulo IMX477 que permitió tener una captura de imágenes de alta resolución. Se utilizó la herramienta de línea de comandos libcamera-still, parte del ecosistema de la cámara de Raspberry Pi, esta herramienta permite capturar imágenes directamente desde la cámara y guardarlas en el sistema de archivos, para optimizar la calidad de la imagen, se implementó un control de enfoque motorizado mediante la función setfocus, en la Figura 8 se visualiza la captura fotográfica con el prototipo.

Figura 8. Capturas en tiempo real con el prototipo



La detección de enfermedades se realizó mediante un proceso que combina técnicas de visión por computador con un modelo de aprendizaje automático, una vez capturada la imagen, el sistema primero busca la lechuga, identifica las zonas verdes y las depura para aislar la hoja, pero solo si es lo suficientemente grande y está cerca del centro, esto evita que clasifique errores como un fondo vacío, al encontrarla, dibuja un recuadro rojo para señalarla, posterior la imagen se prepara para el modelo de inteligencia artificial, redimensionándola y ajustando sus colores, el modelo la examina e indica qué enfermedad predice con un porcentaje de confianza, esta predicción se muestra directamente sobre la imagen y en la consola, para visualizar los posibles resultados.

Figura 9. Flujo de funcionamiento del prototipo.



El modelo genera un array de confianzas para cada clase de enfermedad, siendo la clase con mayor confianza se selecciona como predicción, los resultados obtenidos demuestran la funcionalidad básica del sistema para la captura de imágenes y la ejecución de un modelo de inferencia en la Raspberry.

Tabla 5. Detección de la enfermedad

Pruebas	Detección del sistema	Pruebas	Detección del sistema
sistema detectó una hoja sana		sistema detectó una enfermedad de tipo oídio	
sistema no pudo clasificarla como sana o enferma		sistema detectó una enfermedad de tipo mancha	

A pesar de la robustez demostrada por el sistema de detección de enfermedades, se reconoce ciertas limitaciones, el prototipo podría verse afectado por variaciones extremas en las condiciones de iluminación o por la diversidad de especies de lechuga más allá de las evaluadas, siendo una trabajo futuro el expandir el conjunto de datos de entrenamiento para incluir una gama más amplia de escenarios ambientales y variedades de cultivos, así como optimizar el modelo para mantener su alta precisión bajo estas condiciones fluctuantes, esta mejora no solo fortalecerá la fiabilidad del sistema a nivel técnico y asegurará una herramienta más adaptable y útil para los agricultores, permitiéndoles tomar decisiones más informadas y proactivas para el cuidado de sus cultivos hidropónicos.

4. CONCLUSIONES

El sistema inteligente desarrollado demostró una alta eficacia en la detección temprana de enfermedades en cultivos hidropónicos de lechuga, utilizando técnicas de visión artificial e inteligencia artificial. La implementación de MobileNetV2 mediante aprendizaje por transferencia permitió alcanzar una exactitud del 96.34% en el conjunto de validación y 94% en el conjunto de pruebas, lo que evidencia su capacidad para operar con precisión en condiciones reales.

La creación de un dataset robusto de 2190 imágenes que abarcó las clases de enfermedades propuestas: mildiu, oídio, mancha (bacteriana, foliar) y el estado sano de la hoja, fue primordial para el estudio. El dataset complementado con técnicas de aumento de datos, garantizó un entrenamiento altamente efectivo y concedió una gran robustez al modelo frente a diversas variaciones ambientales como la iluminación, el enfoque y la morfología de las hojas analizadas, lo que se reflejó en la alta precisión y capacidad de generalización demostrada por el sistema.

La integración del modelo basado en MobileNetV2 en una Raspberry Pi 4 Model B equipada con una cámara de alta resolución, estableció un sistema robusto para la detección temprana de enfermedades en lechugas. El estudio demostró la viabilidad de ejecutar inferencias en tiempo real con bajo consumo energético y sin requerir infraestructura computacional costosa, lo que la convierte en una alternativa eficiente y precisa al monitoreo manual, al reducir los tiempos de detección y eliminar la subjetividad en el diagnóstico, siendo una solución accesible para

pequeños y medianos productores agrícolas.

Como trabajo futuro se propone explorar el sistema a otros cultivos, así como la integración de sensores ambientales, además, se sugiere evaluar la implementación de modelos más avanzados como MobileNetV3 o EfficientNet para optimizar el rendimiento energético y la escalabilidad del sistema en entornos agrícolas reales.

Contribución de los Autores (CRediT): DFPM: Curación de datos, Análisis formal, Adquisición de fondos, Metodología, Recursos, Validación, Visualización, Redacción-borrador original. PJCD: Conceptualización, Investigación, Administración del proyecto, Software, Supervisión, Redacción-revisión y edición.

Conflicto de Intereses: Los autores declaran que no existen conflictos de intereses en esta publicación.

REFERENCIAS

- Ahmed, S., Hasan, M. M., Ahmed, T., Sony, M. R. K., & Kabir, M. H. (2022). Less is more: Lighter and faster deep neural architecture for tomato leaf disease classification. *IEEE Access*, 10, 68868–68884. <https://doi.org/10.1109/ACCESS.2022.3187203>
- Akkem, Y., Biswas, S. K., & Varanasi, A. (2023). Smart farming using artificial intelligence: A review. *Engineering Applications of Artificial Intelligence*, 120, 105899. <https://doi.org/10.1016/J.ENGAPPAI.2023.105899>
- Bhandari, N., Agarwal, R., & Bhandari, N. (2024). An insight on artificial intelligence (AI) and Internet of Things (IoT) driven hydroponics farming. *E3S Web of Conferences*, 556, 01036. <https://doi.org/10.1051/e3sconf/202455601036>
- Chiu, V., Ma, T., Jin, K., Li, Z., Sun, Y., Lee, J., Liu, D., Krouse, E., Chen, Y., & Li, B. (2020). Agriculture-Vision: A large aerial image database for agricultural pattern analysis. En *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 59-60). IEEE.
- Duhan, S., Gulia, P., Gill, N. S., & Narwal, E. (2025). RTR_Lite_MobileNetV2: A lightweight and efficient model for plant disease detection and classification. *Current Plant Biology*, 42(3), 100459. <https://doi.org/10.1016/j.cpb.2025.100459>
- Gowtham, V., Guhan, N. S., Balasubramanian, M., & Gangadurai, E. (2024). A smart hydroponic plant disease detection system using CNN. *International Journal of Electronics and Communication Engineering*, 7(2), 1–14.

- Jeyabose, A., Eunice, J., Popescu, D. E., Chowdary, M. K., & Hemanth, J. (2022). Deep learning-based leaf disease detection in crops using images for agricultural applications. *Agronomy*, 12(10), 2395. <https://doi.org/10.3390/agronomy12102395>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Khan, A., & Singh, A. (2024). Comparative analysis of image annotation tools: LabelImg, VGG Annotator, Label Studio, and Roboflow. *JETIR Research Journal*.
- Li, Y., Chen, J., Li, Z., Sun, Q., & Pan, M. (2023). Hydroponic lettuce defective leaves identification based on improved YOLOv5s. *Frontiers in Plant Science*, 14, 1242337. <https://doi.org/10.3389/fpls.2023.1242337>
- Lu, Y., Zhang, Y., Wang, Y., & Li, X. (2023). Improved MobileNetV2 crop disease identification model for intelligent agriculture. *PeerJ Computer Science*, 9, e1595. <https://doi.org/10.7717/peerj-cs.1595>
- Musa, A., Hamada, M., Aliyu, F. M., & Hassan, M. (2021). An intelligent plant disease detection system for smart hydroponic using convolutional neural network. En *Proceedings of the 2021 IEEE 14th International Symposium on Embedded Multicore/Many-core Systems-on-Chip (MCSoC)* (pp. 345–351). IEEE. <https://doi.org/10.1109/MCSoC51149.2021.00058>
- Rahman, M. A., Chakraborty, N. R., Sufiun, A., Banshal, S. K., & Tajnin, F. R. (2024). An AIoT-based hydroponic system for crop recommendation and nutrient parameter monitorization. *Smart Agricultural Technology*, 8, 100472. <https://doi.org/10.1016/j.atech.2024.100472>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. En *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). IEEE. <https://doi.org/10.1109/CVPR.2018.00474>
- Swarup Sahoo, R., Kumar Tripathy, C., Samantasinghar, U., & Biswal, P. (2022). Implementation of an indoor deep water culture farming system using IoT. En *2022 IEEE 2nd International*

Symposium on Sustainable Energy, Signal Processing and Cyber Security (iSSSC) (pp. 1–5). IEEE. <https://doi.org/10.1109/iSSSC56467.2022.10051358>

Ye, M., Ward, P. J., De Plaen, J. J-F. G., & Koks, E. E. (2025). A deep learning pipeline to power infrastructure detection in high-resolution satellite images. *Big Earth Data*. <https://doi.org/10.1080/20964471.2025.2490408>