

Implementación de deep learning y redes neuronales convolucionales para la identificación de plagas en cultivo de ...

 My Files My Files Universidad Peruana Union

Detalles del documento

Identificador de la entrega

trn:oid:::29566:542927426

Fecha de entrega

23 dic 2025, 12:42 p.m. GMT-5

Fecha de descarga

23 dic 2025, 12:46 p.m. GMT-5

Nombre del archivo

Implementación de deep learning y redes neuronales convolucionales para la identificación dedocx

Tamaño del archivo

4.2 MB

29 páginas

7023 palabras

41.745 caracteres

6% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Texto citado
- Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 4%  Fuentes de Internet
- 1%  Publicaciones
- 3%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Fuentes principales

- 4% Fuentes de Internet
- 1% Publicaciones
- 3% Trabajos entregados (trabajos del estudiante)

Fuentes principales

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	Internet	revistaingenieria.org	<1%
2	Trabajos entregados	Universidad Rey Juan Carlos on 2024-10-02	<1%
3	Trabajos entregados	Universidad Peruana Union on 2023-09-13	<1%
4	Trabajos entregados	UNIBA on 2024-04-13	<1%
5	Internet	revistasinvestigacion.lasalle.mx	<1%
6	Internet	www.researchgate.net	<1%
7	Publicación	Helena Oliveres, David Pesántez, Joan Maurel. "Lessons to Learn for Adequate Tar...	<1%
8	Publicación	Hernández Pelegrín, Luis. "Covert Infections with RNA Viruses in the Mediterrane...	<1%
9	Trabajos entregados	Universidad Europea de Madrid on 2025-10-11	<1%
10	Trabajos entregados	Universidad de Cundinamarca on 2025-10-25	<1%
11	Internet	dspace.unl.edu.ec	<1%

12	Internet	laccei.org	<1%
13	Internet	pmc.ncbi.nlm.nih.gov	<1%
14	Internet	repositorio.uss.edu.pe	<1%
15	Internet	uvadoc.uva.es	<1%
16	Internet	worldwidescience.org	<1%
17	Internet	www.coursehero.com	<1%
18	Internet	www.ect.juntaex.es	<1%
19	Internet	www.institutodeempresa.net	<1%
20	Internet	www.upeace.org	<1%
21	Internet	1library.co	<1%
22	Trabajos entregados	Escuela de Posgrado Newman on 2024-11-08	<1%
23	Trabajos entregados	Universidad Nacional de Loja on 2025-07-08	<1%
24	Trabajos entregados	Universidad Tecnologica del Peru on 2025-12-08	<1%
25	Internet	diposit.ub.edu	<1%

26	Internet	ftposso.univalle.edu.co	<1%
27	Internet	revistas.udca.edu.co	<1%
28	Trabajos entregados unibuc on 2023-09-04		<1%
29	Internet	www.observatoriolaboralnuble.cl	<1%

Implementación de deep learning y redes neuronales convolucionales para la identificación de plagas en cultivo de arroz de San Martín

Gerald Franco Sandy-Coral¹, Helen Oblitas-Díaz^{1*}, Katerin Estrellita Mas-Mendoza¹, Yngue Elizabeth Ramirez-Pezo¹, and Nancy Esther Casildo-Bedón^{2*}

¹Universidad Peruana Unión, Facultad de Ingeniería y Arquitectura, Tarapoto, Perú.

²Universidad Peruana Unión, Facultad de Ingeniería y Arquitectura, Juliaca, Perú.

*Corresponding author (nancy.casildo@upeu.edu.pe, helenoblitas@upeu.edu.pe).

RESUMEN

El arroz es uno de los cultivos con mayor porcentaje de producción tanto internacional como nacional; ahora bien, en Perú la producción se ve afectada por plagas que comprometen la seguridad alimentaria y generan pérdidas económicas. La detección de plagas en el arroz utilizando tecnologías avanzadas es fundamental para optimizar el desarrollo eficaz de los cultivos. En este estudio, se propone un modelo de red neuronal convolucional (CNN), desarrollado sobre la arquitectura ResNet-50 con el propósito de identificar plagas las cuales serán captadas en campo y por drones. El entrenamiento se llevó a cabo con el uso del dataset IP102, aplicando preprocesamiento y balanceo de clases; asimismo, se obtuvo imágenes propias de agricultores locales. Es así que, se logró alcanzar una precisión de 92 % al 95 % con tendencia positiva. Además, se observa la integración del modelo de predicción en una plataforma web, proporcionando a los agricultores herramientas para un monitoreo automatizado y en tiempo real desde ambas interfaces. Esto, facilita una respuesta más rápida y eficiente ante la presencia de plagas. Este trabajo constituye a una de las primeras propuestas en el Perú que integra inteligencia artificial y agricultura, con impacto directo en la reducción de pesticidas, ahorro de costos de inspección y mejora en la productividad agrícola.

Palabras clave: Arroz, CRISP-DM, plagas, red neuronal convolucional, resnet-50

ABSTRACT

Rice is among the most widely produced crops globally and nationally; however, in Peru, yields are severely affected by pests that threaten food security and cause major economic losses. Early detection of pests using advanced technologies is crucial for optimizing crop development. In this study, we propose a convolutional neural network (CNN) based on the ResNet-50 architecture to identify pests captured in the field and via drones. The model was trained on the IP102 dataset with preprocessing and class balancing, supplemented by original images collected from local farmers. Our approach achieved 92–95% accuracy, showing an upward trend. The prediction model is integrated into a web platform that enables automated, real-time monitoring from both field and drone interfaces, allowing faster and more efficient responses to pest outbreaks. This work is among the first in Peru to integrate artificial intelligence into agriculture, offering tangible benefits such as reduced pesticide use, lower inspection costs, and improved productivity.

Key words: Rice, CRISP-DM, pests, Convolutional Neural Network (CNN), Resnet-50

INTRODUCTION

El arroz es uno de los carbohidratos principales en la alimentación humana (Ríos-Ruiz et al., 2020) (Shah et al., 2022). Proporciona un 30% de calorías que se consumen durante el día en Latinoamérica, y hasta un 76% en el sudeste asiático (Venu Vasantha et al., 2022). En el Perú, una de sus principales regiones productoras es San Martín, la cual representa la base económica de aproximadamente 50,000 agricultores y produce el 35% del arroz nacional (INEI, 2023). Sin embargo, su rendimiento se ve comprometido por plagas como el gorgojo (*Stiophilus oryzae*), el minador (*Scirpophaga incertulas*), entre otros.

A nivel mundial, el 40 % de la producción agrícola se pierde debido a las plagas (Shenoy, 2024). Esto resalta la urgencia de implementar un sistema de detección temprana para mitigar el impacto negativo que causa. Si bien es cierto, existe un mecanismo de detección, el manejo tradicional (basado en inspecciones manuales); pero, resulta más costoso, se necesita mucho tiempo y es poco eficiente en plantaciones grandes, lo cual genera una reducción de la producción agrícola (Shafik et al., 2023).

Frente a esto, la inteligencia artificial (IA) se presenta como una herramienta tecnológica avanzada que permite el análisis automatizado de imágenes en tiempo real. Sumado a ello, las redes neuronales

convolucionales (CNN), han demostrado altos niveles de precisión en distintos estudios, alcanzando más del 90% en condiciones controladas (Rahman et al., 2020). Reduce costos en el uso de pesticidas (Peng&Wang, 2022) y reduce las pérdidas en la producción (Dey et al., 2022).

Por otro lado, la creciente disponibilidad de imágenes agrícolas obtenidas con drones, sensores multiespectrales y cámaras de alta resolución han transformado el monitoreo de cultivos (Sepúlveda, 2020). Esta evolución facilita la aplicación de visión por computadora, generando señales tempranas para mejorar la respuesta y la toma de decisiones agrícolas (Sharma&Shivandu, 2024).

En estos últimos años, modelos basados en redes neuronales convolucionales han logrado resultados de precisión superiores a 93% (Rahman et al., 2020). Estudios como el de Peng&Wang (2022) muestran que el modelo YOLOv8 mejorado alcanzó puntuaciones de [mAP@0.5](#) cercanas al 98%, lo que demuestra que es aplicable en el sector agrícola.

1

Por su parte Cayllante Capia (2024), implementó la metodología SEMMA (Sample, Explore, Modify, Model, Assess), el aprendizaje profundo, la transferencia de aprendizaje, y arquitecturas de redes neuronales VGG19 y ResNet-50 de aprendizaje diseñado, adaptándolo para su utilización en dispositivos móviles, lo que promete ser una herramienta valiosa en la detección de plagas.

1

5

Otro proyecto lo aborda Black Unda&Hernández Clemente (2024), quien desarrollo un sistema de visión artificial basado en OpenCV y mediante pruebas experimentales demostró la eficacia del sistema para identificar plagas.

23

Por ello, este estudio presenta el desarrollo de un modelo de redes neuronales convolucionales basado en la arquitectura ResNet-50, con el objetivo de identificar de manera automática las plagas que afectan los cultivos de arroz, contribuyendo a un manejo más eficiente y preciso. En las siguientes secciones, se detallan la metodología aplicada, los resultados experimentales y las implicancias del sistema propuesto.

MATERIALS AND METHODS

Diseño del estudio

6

El proceso estándar intersectorial para la minería de datos resultó fundamental para estructurar el desarrollo de esta investigación. Su marco metodológico compuesto por seis fases definidas como la comprensión del negocio, comprensión de los datos, preparación, modelado, evaluación e implementación, la convierte extremadamente compatible con investigaciones que involucren la inteligencia artificial.

Como se muestra en la Figura 1, el estudio se amoldó a mencionada metodología; permitiendo así, abordar el problema de manera metódica, facilitando la toma de decisiones informadas en cada fase y asegurando el cumplimiento del proceso.

Ver **Figura 1**.

El marco metodológico culmina en una solución de ingeniería totalmente integrada. La integración técnica completa del modelo predictivo, la lógica de backend y las interfaces de cliente se detalla en el plan arquitectónico del sistema, tal como se presenta en la Figura 2. Este diseño ilustra el flujo técnico, moviendo el modelo de Inteligencia Artificial entrenado a un servicio de predicción estructurado y en tiempo real para los usuarios finales, asegurando el control automatizado de plagas en los cultivos de arroz.

Ver **Figura 2**.

En coherencia a la Figura 2, la arquitectura de ingeniería utiliza un enfoque de microservicios centrado en una API RESTful construida con Django. El flujo de trabajo de predicción central involucra el modelo entrenado ResNet-50, que se exporta como un archivo .h5, y cuyas predicciones se sirven a través de una API de Django. Las solicitudes de predicción en tiempo real son procesadas por un motor de predicción, con resultados almacenados persistentemente en la Base de Datos y orquestados por una API REST dedicada y Django Workers para un monitoreo continuo y automatizado. El acceso del cliente se proporciona a través de un Cliente Web (React.js) y un Cliente Móvil (React Native), facilitando el acceso a las predicciones y a un historial completo. Finalmente, el sistema está diseñado para alta disponibilidad y escalabilidad, con recursos planificados para ser desplegados en un entorno de producción a través de AWS S3 y Railway, y con distribución a través de la Google Play Console.

A lo largo del desarrollo de la investigación, la conexión del flujo propuesto será analizada parte por parte y en detalle, asegurando una comprensión exhaustiva de la contribución de cada componente al sistema operativo final.

Comprensión del negocio

Esta etapa es el punto de partida del proceso CRISP-DM y tiene como finalidad comprender el contexto agrícola; así como también, definir los objetivos desde una perspectiva funcional. Para ello, se realizó una revisión de literatura técnica y entrevistas enriquecedoras con especialistas del sector arrocero, lo cual permitió identificar las principales dificultades en la detección oportuna de plagas.

Es así que, se evidenció que los métodos tradicionales, como la inspección manual presentan limitaciones significativas en términos de eficiencia, costos y precisión; lo que repercute directamente en el rendimiento de los cultivos. Por lo cual, se establecieron los requerimientos claves, los cuales se enfocan en mejorar el tiempo de respuesta ante infestaciones, reducir la dependencia de personal especializado y optimizar el manejo fitosanitario mediante el uso de herramientas tecnológicas accesibles y eficientes.

Comprensión de los datos

Para dar inicio a esta fase se realizó una exploración completa del conjunto de datos IP102 para entender su estructura, origen y características generales. Es así que, se identificó que el conjunto de datos contiene imágenes etiquetadas de plagas agrícolas, están organizadas por clase, y almacenadas en formatos estándar. Por lo cual, esta comprensión básica permitió confirmar que los datos eran adecuados para abordar el problema planteado y orientó las siguientes fases del proceso (Peng&Wang, 2022).

Por otro lado, esta fase también permitió identificar el tipo de información contenida en las etiquetas, su relación con el contexto agrícola, y el nivel de detalle disponible para cada instancia. Además, se validó que el volumen y formato de los datos fueran compatibles con el enfoque de aprendizaje profundo propuesto en el estudio.

Recolección de datos

El conjunto de datos IP102 está conformado por 75,222 imágenes con un promedio de 737 muestras por clase (Mahjabin, 2022). Este repositorio incluye imágenes de cultivos de arroz, maíz, trigo, remolacha y

2

alfalfa, así como de otras plantas, entre ellas itis, cítricos y mango. No obstante, como se muestra en la Figura 3, para el análisis, solo se ha seleccionado las imágenes correspondientes al cultivo de arroz.

158

Ver Figura 3.

160

Es relevante señalar que, el conjunto de datos presenta una distribución no uniforme en la cantidad de imágenes, debido a que, algunas clases contienen un número significativamente mayor que otras. Esta falta de equilibrio podría afectar el rendimiento del modelo CNN, ya que las clases menos representadas podrían generar sesgo en las predicciones.

165

En el caso específico del arroz, de las 102 clases originales del conjunto de datos IP102, solo 24 clases de plagas fueron relevantes para este cultivo. Tras el filtrado, de las 75,222 imágenes totales, se utilizaron aproximadamente 28,232 imágenes correspondientes a plagas que afectan al arroz

169

Preparación de datos

Como parte del preprocesamiento de datos, se aplicaron técnicas como el redimensionamiento de imágenes, normalización y limpieza de datos. Además, para aumentar la cantidad y variedad del conjunto de entrenamiento, se llevaron a cabo operaciones de aumentación, tales como rotaciones, ajustes de contraste y recortes. Con ello, se busca aumentar la diversidad del conjunto de entrenamiento y reducir el riesgo de sobreajuste (López Saca et al., 2018). Las transformaciones incluyen:

176

- Redimensionado a 224x224 píxeles.
- Escalado de los valores de píxel al rango [0, 1].
- Volteo horizontal aleatorio para simular diferentes orientaciones de las imágenes.
- Rotación, zoom y contraste aleatorios para crear más diversidad en el conjunto de datos.

181

9

Estas transformaciones contribuyen a mejorar la capacidad de generalización del modelo al exponerlo a múltiples versiones de las mismas imágenes. Además, los datos se dividieron en tres subconjuntos: entrenamiento (60%), validación (10%) y prueba (30%), como se muestra en la Figura 4.

27

185

Ver Figura 4.

187

Construcción del modelo

Durante el desarrollo del modelo, se hizo uso de una red neuronal convolucional (CNN) para la clasificación de imágenes. Puesto que, es un tipo de arquitectura de red neuronal artificial diseñada en específico para el procesamiento de imágenes y datos visuales; asimismo, tiene una estructura que se inspira en el córtex visual del cerebro humano, permitiéndole detectar patrones y características en imágenes (Ruiz-Tamayo et al., 2024).

Las CNN han demostrado un rendimiento sobresaliente en actividades como clasificación de imágenes, segmentación de imágenes y detección de objetos (Fang et al., 2025); convirtiéndolo así, en la opción ideal para diversas aplicaciones con inteligencia artificial basadas en el procesamiento de imágenes (Morales et al., 2024).

En la detección de plagas en cultivos de arroz, la elección de una arquitectura de red neuronal es un factor clave para lograr un procesamiento eficiente y una clasificación precisa de las imágenes. Entre las diversas redes convoluciones, ResNet-50 (Residual Network con 50 capas) se está consolidando como una buena opción, esto debido al uso de conexiones residuales, que permiten entrenar redes profundas sin tener los problemas típicos del gradiente desaparecido (Al-Gaashani et al., 2023; Paneru et al., 2021).

ResNet-50 a diferencia de modelos más antiguos, ResNet-50 introduce conexiones residuales, esto le permite aprender de representaciones aún más complejas sin tener que comprometer la velocidad del entrenamiento (Enciso et al., 2023).

Debido a estas razones, ResNet-50 reemplaza a otras arquitecturas como AlexNet, VGG-16, InceptionV3 y EfficientNet-B0 en esta investigación, haciendo que se consolide la mejor opción en el desarrollo para la detección de plagas en cultivos de arroz (Cayllante Capia, 2024).

Con el siguiente grafico podemos determinar que el uso de esta arquitectura genera alto impacto en la precisión, como lo podemos observar en la Figura 5.

Ver Figura 5.

220

221 En la Figura 5 se observa que ResNet-50 logra un equilibrio entre precisión y tiempo de inferencia. Aunque

222 modelos como VGG-16 tienen más parámetros y un mayor tiempo de inferencia, ResNet-50 ofrece una

223 precisión comparable a InceptionV3 y EfficientNet-B0 con una cantidad moderada de parámetros, lo que la

224 hace una opción eficiente para tareas de visión por computadora.

225

226 ResNet-50 (Residual Network con 50 capas) es una arquitectura de red neuronal convolucional (CNN), que

227 fue desarrollada por Microsoft Research, esta introduce el concepto variado de las conexiones residuales.

228 Este diseño de arquitectura hace posible el entrenamiento de redes neuronales profundas sin tener que

229 sufrir en degradación en el rendimiento (Analuisa-Aroca et al., 2023).

230

231 El modelo ResNet-50 tiene una estructura diseñada para procesar imágenes de manera profunda. Comienza

232 con la entrada de la imagen y esta pasa por una primera capa de convolución, esta detecta patrones básicos

233 como los bordes y texturas. Después, la imagen se reduce en tamaño mediante la capa MaxPooling, esto

234 ayuda a que la red tenga enfoque en las características más relevantes e importantes.

235

236 Luego de esta etapa inicial, la imagen atraviesa cuatro bloques principales, cada uno más profundo que el

237 anterior y capaz de identificar detalles más complejos. Cada bloque está compuesto por varias capas que

238 trabajan en conjunto para analizar desde las formas más simples hasta las estructuras más detalladas.

239

240 El punto fuerte en innovación de ResNet-50 es que hace uso de conexiones residuales, significa que, en

241 lugar de hacer la transformación completamente en cada paso, esta mantiene una referencia de lo

242 aprendido en las etapas anteriores, permitiendo que el modelo se entrene mucho mejor sin tener que

243 perder información que resulta valiosa (De la Cruz-Rocca et al., 2024).

244

245 Una vez que la imagen hasta este punto ha sido analizada a profundidad máxima, se pasa por una capa de

246 Global Average Pooling, que resume toda la información a nivel de un conjunto de valores clave. Esta

247 información es enviada a una capa completamente conectada, haciendo posible que la organice y la prepara

248 para la decisión final. Finalmente, la capa Softmax funciona generando la probabilidad para cada categoría,

249 determinando qué tipo de plaga aparece en la imagen. Como se ilustra en la Figura 6, este diagrama

250 esquemático destaca la estructura y componentes de la red ResNet-50.

251

Ver **Figura 6**.

Es gracias a esta estructura, que podemos lograr identificar plagas en gran precisión, asegurando que el análisis sea ligero, eficiente y seguro, ideal para la detección de plagas en cultivos de arroz (Reddy et al., 2023).

Entrenamiento y evaluación

En la actualidad, se ha resaltado la importancia de entrenar estos modelos con grandes volúmenes de datos para lograr una clasificación precisa y eficiente de las plagas en distintos cultivos (Lubinus et al., 2021). Asimismo, la capacidad de estas redes para aprender patrones visuales complejos ha permitido optimizar su desempeño en entornos reales; por lo cual, facilita su integración en sistemas de monitoreo agrícola automatizados (Huerta-Mora et al., 2020).

Por otro lado, el proceso de entrenamiento del modelo consiste en alimentar la red neuronal con imágenes de plagas, haciendo ajustes en sus parámetros a lo largo de las múltiples épocas; para así, mejorar su capacidad de clasificación. Durante el entrenamiento, el modelo predictivo fue optimizando su rendimiento al aprender los patrones visuales en los datos de entrada. Para ello, en la Figura 6 se muestra la evolución de la precisión del modelo durante el entrenamiento y la validación, reflejando el aprendizaje progresivo de la red neuronal.

Se entrenó durante 50 épocas con AdamW (LR 0.001, batch 32) usando ResNet-50 preentrenada en ImageNet; primero se congelaron conv1 y layers 1–3 por 5 épocas para ajustar la capa clasificadora y luego se descongeló todo el modelo para el ajuste fino.

Como función de pérdida se empleó entropía cruzada con ponderación por clase (pesos inversamente proporcionales a la frecuencia) y label smoothing = 0.1, con el propósito de mitigar el desbalance del conjunto y mejorar la calibración de las probabilidades predichas.

Para incrementar la capacidad de generalización del modelo frente a variaciones de campo, se aplicaron técnicas de data augmentation, incluyendo rotaciones aleatorias de hasta $\pm 20^\circ$, volteos horizontales, escalado dinámico y *color jitter* (ajustes de brillo, contraste y saturación). Estas transformaciones permitieron ampliar artificialmente la diversidad del dataset, mitigando en parte el desbalance entre clases.

284

285 Ver **Figura 7**.

286

287 En la Figura 7, se observa el gráfico de precisión del modelo. Para ello, la línea de color azul muestra la
288 precisión sobre los datos de entrenamiento y la línea roja representa la precisión en los datos que existen
289 para la validación. De esta manera, conforme avance las épocas la precisión del modelo aumenta de manera
290 progresiva, indicando que la red está mejorando la capacidad que tiene para distinguir entre diferentes
291 tipos de plagas. Sin embargo, la variabilidad de precisión de validación sugiere posibles fluctuaciones en el
292 aprendizaje del modelo.

293

294 Ver **Figura 8**.

295

296 La figura 8, presenta un gráfico de pérdida del modelo (loss vs epochs), donde se visualiza la reducción de
297 la función de pérdida a lo largo del entrenamiento. En este caso, la línea azul representa la pérdida en los
298 datos de entrenamiento, y la línea roja muestra la pérdida en validación. Se observa una disminución de
299 gran significancia en las primeras épocas, lo que claramente indica que el momento está ajustándose de
300 manera correcta a los datos. No obstante, la variabilidad en la pérdida de validación sugiere que pueden
301 existir momentos de sobreajuste del modelo predictivo. Por lo tanto, para tener seguro un aprendizaje
302 efectivo, es muy importante no solo aumentar en gran parte la precisión, sino también minimizar el error.

303

304 Por lo que se refiere a, la evaluación del desempeño de un modelo de aprendizaje profundo es un paso
305 fundamental para garantizar su eficacia en tareas de clasificación; en especial en el ámbito agrícola, donde
306 la identificación de plagas es crucial para la toma de decisiones (Yan et al., 2015).

307

308 Con respecto a, las métricas como precisión, recall y F1-score permiten medir la calidad de las predicciones
309 del modelo, lo cual proporciona una visión más detallada de la capacidad que tiene el modelo para
310 diferenciar entre distintas clases y minimizar errores (Arunabha et al., 2021). Además, el uso de estas
311 métricas facilita la comparación entre diferentes arquitecturas y ajustes del modelo, asegurando que la
312 solución sea la más adecuada para el problema presentado (Valle-Medina et al., 2025).

313

314 Para determinar el desempeño en la clasificación de plagas, se usaron métricas clave como precisión, recall
315 y F1-score; puesto que, estas permiten medir la calidad de las predicciones y evaluar qué tan bien está

funcionando el modelo en cada una de las clases a predecir, identificando fortalezas y áreas de mejora (Zapeta et al., 2022). Análogamente, el empleo de estas métricas también ayuda a minimizar sesgos en la clasificación y a optimizar el rendimiento del modelo en entornos reales (Ferrer, 2023).

En la Figura 9, se representan valores obtenidos en cada clase durante la evaluación del modelo.

Ver **Figura 9**.

La figura 9 muestra una tabla en la que se pueden analizar los valores de precisión, recall y F1-score, los cuales permiten evaluar el desempeño en cada una de las categorías. Por lo que, los identificadores 101 y 15 correspondientes a plagas específicas del dataset, presentan altos valores en todas las métricas evaluadas; lo que indica, una clasificación casi precisa. Por otro lado, categorías como 50 y 39 presentan un menor rendimiento en términos de precisión, lo cual indica dificultades en sus funciones de reconocimiento, pese al balanceo y aumentación aplicado, clases minoritarias mantuvieron menor precisión; conviene recolectar más muestras de estas plagas y evaluar ponderación de clases en futuras versiones.

Pues bien, el modelo refleja una precisión global del 92%, lo que indica un alto nivel de precisión en la clasificación de plagas. Además, el promedio simple entre todas las clases (macro avg) que es de 69.29 % y el promedio ponderado según el tamaño de cada clase (weighted avg) que es de 73.28 % revela un desempeño sólido en la mayoría de las clases; permitiendo así, una identificación confiable en los diferentes tipos de plagas.

Por consiguiente, los resultados obtenidos demuestran la efectividad y la capacidad que tiene el modelo para clasificar correctamente las distintas categorías. Incluso, con ajustes en los hiper parámetros y una ampliación del conjunto de datos, el modelo puede seguir optimizando su rendimiento para así alcanzar mayores niveles de precisión.

Además, para tener una evaluación más detallada del desempeño del modelo en la clasificación de plagas, se realizó una matriz de confusión, en la cual se muestra la relación entre las predicciones del modelo y las etiquetas reales; permitiéndonos así, identificar que categorías son clasificadas con mayor precisión y en cuáles se presentan confusiones con otras clases, como se muestra en la Figura 9.

348 Ver **Figura 10**.

349
350 En esta **Figura 10** se ejemplifica la matriz de confusión; para ello, los valores más oscuros hacen referencia
351 a las predicciones más precisas, demostrando que el modelo ha identificado correctamente una gran
352 cantidad de instancias dentro de cada clase. Asimismo, se observa un excelente desempeño en clases como
353 101, 15 y 67, donde el modelo ha logrado una identificación precisa. Dentro de lo que respecta, la matriz
354 de confusión es herramienta es fundamental para mejorar la eficiencia del sistema y fortalecer la capacidad
355 que tiene para reconocer todas las plagas presentadas (Riehl et al., 2023; Tötsch&Hoffmann, 2020).

357 **Despliegue del modelo**

358
359 Al integrar el modelo en una plataforma accesible para los agricultores, se da acceso al uso de una aplicación
360 web o móvil con la posibilidad de registrar datos de ubicación geográfica, cargar imágenes y obtener
361 diagnósticos más precisos sobre sus cultivos. Por lo que el despliegue incluirá una interfaz de usuario
362 intuitiva y un sistema completo de control de plagas y enfermedades. Además, este sistema contará con
363 métodos de control, noticias reales y actualizadas; asimismo, contará con un catálogo general de plagas y
364 enfermedades, facilitando información detallada y acciones recomendadas para cada situación.

29

366 Por consiguiente, la Figura 11 muestra el sistema **de monitoreo de plagas y enfermedades en cultivos de**
367 **arroz en** tiempo real en vista web. Para ello, en la parte superior se encuentra una barra de navegación con
368 enlaces a secciones clave como Home, Predictions, Catalog, Resources, Crops, y Support, facilitando el
369 acceso a diferentes secciones del sistema.

371 Ver **Figura 11**.

372
373 Por tanto, la página principal (home) muestra las predicciones en tiempo real de plagas y enfermedades;
374 indicando el nombre de cada plaga y su nivel de confianza. Por otro lado, cuenta con una sección de historial,
375 donde se registran eventos anteriores, proporcionando la fecha, el tipo de plaga o enfermedad, y una breve
376 descripción del impacto que tuvieron en los cultivos.

Por añadidura, una aplicación móvil se encuentra actualmente en desarrollo, esto con el objetivo de ampliar la accesibilidad y las funcionalidades para aquellos usuarios que necesiten monitorear sus cultivos desde dispositivos móviles.

RESULTS AND DISCUSSION

RESULTADOS

Rendimiento del modelo propuesto

El sistema desarrollado está basado en la arquitectura ResNet-50, alcanzó una precisión promedio de 92% y logrando hasta un 95% de exactitud en clases específicas de plagas en cultivos de arroz. Por lo que este desempeño notable posiciona al modelo entre uno de los más robustos dentro del campo de la visión artificial aplicada a la agricultura.

Es así como, este rendimiento se logró con la aplicación de un conjunto de técnicas durante la fase de entrenamiento, incluyendo: preprocesamiento, aumento de datos por clase, balanceo del Dataset IP102 y ajuste de hiperparámetros. Las curvas de precisión y pérdida (Figuras 6 y 7) evidencian un aprendizaje estable. Además, mientras que la matriz de confusión (Figura 9) demuestra una notable disminución en los errores de clasificación entre clases.

En contrastación, con estudios en los que se validan únicamente en contextos simulados, el modelo propuesto fue evaluado con imágenes reales capturadas en campo mediante drones; fortaleciendo así la confiabilidad de los resultados.

Integración funcional del sistema

La solución propuesta no es simplemente un modelo predictivo, sino un ecosistema tecnológico completo, funcional y automatizado. Por ello, el modelo una vez entrenado, fue exportado en formato .h5 e integrado en un backend construido con Python y Django, usando WebSockets para ejecutar inferencias en tiempo real. Además, el frontend, desarrollado en React, proporciona una interfaz clara, moderna y accesible para mostrar los resultados al usuario final.

Asimismo, contamos con un worker automatizado (programado con schedule) ejecuta el proceso de predicción cada 10 segundos, inspeccionando una carpeta de entrada donde se colocan nuevas imágenes para ser clasificadas. Estas imágenes, son procesadas y organizadas automáticamente en carpetas según su resultado.

A su vez, se diseñó un ejecutable (.exe) con:

- Botón de Play/Pausa para controlar el análisis,
- Contador de tiempo visible,
- Operación completamente autónoma, sin necesidad de terminales o intervención técnica.

Este sistema fue probado por un especialista en drones, quien ejecutó el .exe tras un sobrevuelo real en campo. Las imágenes captadas por el dron eran enviadas automáticamente a la carpeta monitoreada por el sistema, y la predicción se realizaba sin intervención humana adicional. Este proceso fue validado con éxito en escenarios reales de cultivo, demostrando la solidez del sistema.

La operación integrada y autónoma se gestiona y monitoriza de forma intuitiva. La Figura 12 a continuación muestra la interfaz del ejecutable (.exe) completamente operativa, destacando los controles de análisis (Reproducir/Pausar) y la información del contador de tiempo que asiste al especialista en el campo.

Ver **Figura 12**.

DISCUSION

Comparación crítica de investigaciones previas

Últimamente, la detección de plagas mediante redes neuronales convolucionales (CNN) ha ido ganándose un lugar importante dentro de soluciones eficaces aplicada a la agricultura. Sin embargo, la mayoría de los estudios revisados se mantienen dentro de un enfoque experimental; es decir, no presentan soluciones prácticas, operativas o validadas en campo.

Tal como indican (Dey et al., 2022), evaluaron cuatro variantes de CNN, incluyendo MobileNetV2, para detectar la plaga Hispa, enfermedades fúngicas y deficiencias nutricionales en arroz. Es así que, lograron

una precisión general del 71.5%, trabajando con imágenes controladas. Sin embargo, el sistema no fue desplegado en una plataforma operativa ni validado en campo, y no se incluyó interacción con hardware o interfaces de usuario.

En el caso de (Hu et al., 2023), propusieron un modelo basado en VGG16 y EfficientNetB0 para detectar plagas utilizando visión por computadora. Aunque se logró una precisión superior al 85% y entrenaron modelos robustos, tampoco diseñaron una arquitectura funcional ni aplicaron su solución en ambientes reales.

Según (Madhavi et al., 2021), con el uso de un enfoque basado en DenseNet201 y mecanismos de atención para detección de múltiples plagas en campo abierto, lograron una precisión destacada (>90%). No obstante, su sistema permaneció en pruebas offline y no se acompañó de ninguna herramienta automatizada o interfaz gráfica.

En cambio, (Rahman et al., 2020) propuso una CNN personalizada con reconocimiento de plagas y enfermedades en arroz y maíz. Aunque el enfoque técnico fue acertado y se evaluó en condiciones reales no lo desarrollaron en una plataforma interactiva ni continua para los agricultores.

Por otro lado, (Hassan et al., 2023) combinó CNNs con mecanismos de atención paralela, logrando precisiones superiores al 90% y utilizando imágenes obtenidas en ambientes agrícolas reales. Sin embargo, su propuesta tampoco fue integrada en una herramienta funcional de uso continuo, quedando como prueba de concepto investigativa.

Finalmente, (Peng&Wang, 2022) aplicaron aprendizaje por transferencia en imágenes de insectos. Se lograron buenos resultados de precisión superiores al 80%; sin embargo, no se implementó en ningún entorno de producción ni se validó el sistema con actores del agro.

Tras el análisis de la literatura disponible, y a partir de la revisión detallada de los documentos proporcionados, se puede afirmar con evidencia de que en Perú no se han desarrollado investigaciones aplicadas en este campo hasta la actualidad. Las pocas publicaciones nacionales existentes son revisiones sistemáticas sin propuestas tecnológicas implementadas, sin entrenamiento de modelos propios, y sin validación en campo con datos reales.

474

475 Por ende, la presente investigación es la primera en el país en integrar un modelo CNN entrenado
476 específicamente para plagas en arroz, desplegarlo en un entorno automatizado y validar su funcionamiento
477 con datos captados por drones en condiciones reales.

478

479 A diferencia de los trabajos analizados, esta investigación no se limita a métricas de laboratorio ni al
480 entrenamiento del modelo. Se diseñó e implementó una solución completa que incluye:

481

- 482 • Modelo ResNet-50 con precisión entre 92% y 95%
- 483 • Backend en Django con WebSockets para ejecución en tiempo real
- 484 • Frontend en React con interfaz moderna e intuitiva
- 485 • Worker automatizado que analiza imágenes cada 10 segundos
- 486 • Ejecutable (.exe) para usuarios sin conocimientos técnicos
- 487 • Validación en campo con imágenes reales capturadas por drones.

488

489 Ver **Tabla 1**.

490

491 De acuerdo con la información recopilada en la Tabla 1, ninguna investigación ha logrado implementar una
492 solución funcional de punta a punta como la desarrollada en este trabajo. A pesar de la calidad técnica de
493 los estudios mencionados, todos permanecen en fase de laboratorio, sin conexión con herramientas de uso
494 real, sin despliegue operativo y sin contacto con usuarios finales del sector agrícola.

495

20

496 Esta investigación, por tanto, no solo contribuye desde el punto de vista académico, sino que rompe el
497 paradigma existente. Es la primera propuesta integral validada en campo y operativa en Perú, lista para ser
498 usada en proyectos reales de transformación digital del agro.

499

500 **Discusión crítica: aportes, innovación y contexto científico**

501 La principal diferencia entre esta investigación y los estudios revisados radica en su enfoque de ingeniería
502 aplicada. Mientras la mayoría de los trabajos se quedan en métricas de precisión y pruebas en Jupyter
503 Notebook, la propuesta presentada entrega un sistema funcional, completo y validado en la práctica.

504

505 La innovación de esta investigación se resume en los siguientes pilares:

- Automatización completa del monitoreo fitosanitario.
- Interacción directa con hardware agrícola (drones).
- Visualización de resultados en una plataforma web (React).
- Control del sistema mediante ejecutable (.exe), sin necesidad de código.
- Validación en condiciones reales de campo con imágenes reales.

Este enfoque multidisciplinario (IA + Web + IoT + agricultura) no solo resuelve el problema de clasificación, sino que lo lleva a una solución usable por técnicos, agricultores o cualquier actor del sector agrario. Se opto por clasificación con ResNet-50; puesto que, se presenta el uso imágenes centradas en la plaga, donde la localización ya está resuelta. Así logrando maximizar la precisión por clase y simplificamos el entrenamiento.

Limitaciones actuales y líneas futuras

Aunque el sistema ha demostrado gran efectividad, se identifican algunas oportunidades de mejora:

- El desbalance en algunas clases del dataset IP102 aún afecta ciertas categorías de plagas. Se propone aplicar técnicas como sobremuestreo, pérdida focal o generación sintética (GANs) para mejorar la representación de clases minoritarias.
- Actualmente, el sistema opera en local. Se sugiere su migración a la nube (AWS, GCP) para permitir monitoreo 24/7 y acceso desde dispositivos móviles o estaciones remotas.
- La arquitectura ResNet-50 es potente, pero en próximas versiones podría integrarse con Vision Transformers (ViT) o modelos híbridos CNN+Transformer para abordar patrones visuales más complejos o plagas poco diferenciables.
- Aunque el modelo alcanzó alta precisión en las condiciones evaluadas, su desempeño podría verse afectado ante plagas no representadas o variaciones ambientales tales como iluminación, fondo, estado fenológico.

Relevancia y potencial de impacto

El sistema presentado integra visión por computadora, automatización, desarrollo web, electrónica agrícola (drones) y experiencia de usuario, todo en una solución funcional y real.

Este enfoque permite reducir:

- El tiempo de detección de plagas.
- El uso innecesario de pesticidas.
- Costos de inspección manual.

Al estar validado con imágenes reales de campo y funcionar sin conexión a internet, se convierte en una herramienta ideal para zonas rurales o regiones con limitada conectividad, como muchas áreas agrícolas del Perú. Su capacidad de escalabilidad, accesibilidad y bajo costo operativo le otorgan un alto potencial de impacto social, económico y ambiental.

CONCLUSIONS

Esta investigación cumplió con éxito el objetivo principal: desarrollar un sistema predictivo basado en redes neuronales convolucionales capaz de identificar plagas en cultivos de arroz con una **precisión superior a 92% y aplicabilidad práctica**. Es decir, el modelo entrenado con la arquitectura ResNet-50 alcanzó un rendimiento sobresaliente, validado con imágenes reales y contextualizado dentro de una solución funcional.

En contraste con estudios previos, tanto locales como internacionales, este trabajo avanzó hacia la **construcción y validación de un sistema operativo real**; siendo capaz de procesar imágenes en tiempo real y generar diagnósticos automáticos sin requerir intervención técnica constante. Esto constituye un primer paso seguro hacia la transformación digital en el monitoreo fitosanitario en arroz; además, con potencial de impacto en la productividad, la seguridad alimentaria y el uso racional de insumos agrícolas.

En futuras investigaciones es recomendable la integración de nuevos conjuntos de datos provenientes de diversas zonas productoras y el despliegue piloto del sistema en asociaciones o comunidades agrícolas para mayor validación.

Author contribution

Conceptualization: H.O-D. Methodology: K.E.M-M. Software: G.F.S-C. Validation: N.E.C-B, Y.E.R-P. Formal analysis: H.O-D, K.E.M-M, G.F.S-C. Investigation: H.O-D, K.E.M-M, G.F.S-C. Resources: H.O-D, K.E.M-M, G.F.S-C. Data curation: Y.E.R-P. Writing-original draft: H.O-D, K.E.M-M, G.F.S-C. Writing-review&editing: H.O-D, K.E.M-M, G.F.S-C. Visualization: Y.E.R-P. Supervision: N.E.C-B. **Project administration: H.O-D, K.E.M-**

570 M. Funding acquisition: H.O-D, K.E.M-M, G.F.S-C. All co-authors reviewed the final version and approved
571 the manuscript before submission.

572

573 Acknowledgements

574 Esta investigación conto con el apoyo de subvenciones de la Universidad Peruana Unión.

575

576 References

577 Al-Gaashani, M., Abdel, N., Alnashwan, R., Khayyat, M., & Ali, M. (2023). Using a Resnet50 with a kernel attention
578 mechanism for rice disease diagnosis. *Life*, 13(6), 1277. <https://doi.org/10.3390/life13061277>

579 Analuisa-Aroca, I., Vergara-Romero, A., & Pérez Almeida, I. B. (2023). Convolutional neural networks ResNet-50
580 for weevil detection in corn kernels. *Scientia Agropecuaria*, 13(3), 385–394.
581 <https://doi.org/10.17268/sci.agropecu.2023.034>

582 Arunabha, R., Bose, R., & Bhaduri, J. (2021). A fast accurate fine-grain object detection model based on YOLOv4
583 deep neural network. <http://arxiv.org/abs/2111.00298>

584 Black Unda, W., & Hernández Clemente, E. I. (2024). Desarrollo de un sistema de visión artificial basado en
585 OpenCV para la detección de plagas en cultivos. *Memorias Del Concurso Lasallista de Investigación,*
586 *Desarrollo e Innovación*, 11(2), 79–84. <https://doi.org/10.26457/mclidi.v11i2.4257>

587 Zayllante Capia, J. A. (2024). Modelo de Aprendizaje Profundo para identificar plagas en la producción de quinua.
588 *Revista Ingeniería*, 8(20), 31–48. <https://doi.org/10.33996/revistaingenieria.v8i20.116>

589 De la Cruz-Rocca, M., Muñoz-Robles, W., & Trinidad-Malpartida, M. (2024). Análisis de la aplicación de redes
590 neuronales convolucionales en el área de la visión artificial. *Investigación Valdizana*, 18(1), e2105.
591 <https://doi.org/10.33554/riv.18.1.2105>

592 Dey, B., Masum Ul Haque, M., Khatun, R., & Ahmed, R. (2022). Comparative performance of four CNN-based deep
593 learning variants in detecting Hispa pest, two fungal diseases, and NPK deficiency symptoms of rice (*Oryza*
594 *sativa*). *Computers and Electronics in Agriculture*, 202, 107340.
595 <https://doi.org/10.1016/j.compag.2022.107340>

596 Enciso, S., Mamani, E., & Ordoñez, E. (2023). Determinación de la mejor Arquitectura de Redes Neuronales
597 Convolucionales: VGG16, ResNet50 ó MobileNet para detección de la Neumonía 2023. *C&T Riqchary Revista*
598 *de Investigación En Ciencias y Tecnología*, 5(1), 1–10. <https://doi.org/10.57166/riqchary/v5.n1.2023.104>

599 Bang, Q., Jiang, A., Liu, M., & Zhao, S. (2025). Faster R-CNN model for target recognition and diagnosis of scapular
600 fractures. *Journal of Bone Oncology*, 51, 100664. <https://doi.org/10.1016/j.jbo.2025.100664>

601 Ferrer, L. (2023). *Analysis and Comparison of Classification Metrics* (Vol. 4). <http://arxiv.org/abs/2209.05355>

- 602 Hassan, S., Alam, M., Illahi, U., & Mohd, M. (2023). A new deep learning-based technique for rice pest detection
603 using remote sensing. *PeerJ Computer Science*, 9, e1167. <https://doi.org/10.7717/peerj-cs.1167>
- 604 Hu, Y., Deng, X., Lan, Y., Chen, X., Long, Y., & Liu, C. (2023). Detection of Rice Pests Based on Self-Attention
605 Mechanism and Multi-Scale Feature Fusion. *Insects*, 14(3), 280. <https://doi.org/10.3390/insects14030280>
- 606 Huerta-Mora, E., González-Huitrón, V., Rodríguez-Rangel, H., & Amabilis-Sosa, L. (2020). Detección de
607 enfermedades foliares con arquitecturas de redes neuronales convolucionales. *Revista Internacional de*
608 *Desarrollo Regional Sustentable*, 5(1), 18–40.
609 <http://rinderesu.com/index.php/rinderesu/article/view/46/50>
- 610 INEI. (2023). *El departamento de San Martín lideró la producción de arroz paddy en octubre de 2023*.
611 [https://www.gob.pe/en/institucion/inei/noticias/887524-departamento-de-san-martin-lidero-la-](https://www.gob.pe/en/institucion/inei/noticias/887524-departamento-de-san-martin-lidero-la-produccion-de-arroz-cascara-en-octubre-de-2023)
612 [produccion-de-arroz-cascara-en-octubre-de-2023](https://www.gob.pe/en/institucion/inei/noticias/887524-departamento-de-san-martin-lidero-la-produccion-de-arroz-cascara-en-octubre-de-2023)
- 613 Bópez Saca, F., Ferreyra Ramírez, A., Avilés Cruz, C., Villegas Cortez, J., Zúñiga López, A., & Rodriguez Martinez, E.
614 (2018). Preprocesamiento de bases de datos de imágenes para mejorar el rendimiento de redes neuronales
615 convolucionales. *Research in Computing Science*, 147(7), 35–45. <https://doi.org/10.13053/rcs-147-7-3>
- 616 Eubinus, F., Rueda, C., Marconi, B., & Arias, Y. (2021). Redes neuronales convolucionales: un modelo de Deep
617 Learning en imágenes diagnósticas. Revisión de tema. *Revista Colombiana de Radiología*, 32(3), 5591–5599.
618 <https://doi.org/10.53903/01212095.161>
- 619 Madhavi, G., Rani, J., & Rao, S. (2021). Pest Detection for Rice Using Artificial Intelligence. *International Research*
620 *Journal on Advanced Science Hub (IRJASH) Special*.
621 <https://rspsciencehub.com/index.php/journal/article/view/453/397>
- 622 Mahjabin, R. (2022). *Conjunto de datos IP102*. <https://www.kaggle.com/datasets/rtlmhjb/np02-dataset>
- 623 Morales, A., Lepe, D., & Díaz, J. (2024). Redes Neuronales Convolucionales para Detección de Carcinoma
624 Basocelular (Cáncer de Piel) por Medio de Imágenes para Pacientes Adultos en la Región Facial. *Ciencia*
625 *Latina Revista Científica Multidisciplinar*, 8(4), 582–599. https://doi.org/10.37811/cl_rcm.v8i4.12300
- 626 Baneru, B., Paneru, B., & Bikram, K. (2021). Analysis of convolutional neural network-based image classifications:
627 a multi-featured application for rice leaf disease prediction and recommendations for farmers.
628 *ResearchGate*, 3(4). <https://doi.org/10.48550/arXiv.2410.01827>
- 629 Peng, Y., & Wang, Y. (2022). CNN and transformer framework for insect pest classification. *Ecological Informatics*,
630 72, 101846. <https://doi.org/10.1016/j.ecoinf.2022.101846>
- 631 Rahman, C., Arko, P., Ali, M., Iqbal, M., Apon, S., Nowrin, F., & Wasif, A. (2020). Identification and recognition of
632 rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, 194, 112–120.
633 <https://doi.org/10.1016/j.biosystemseng.2020.03.020>

- 634Reddy, S., Varma, G., & Davuluri, R. (2023). Resnet-based modified red deer optimization with DLCNN classifier
635 for plant disease identification and classification. *Computers and Electrical Engineering*, 105.
636 <https://doi.org/10.1016/j.compeleceng.2022.108492>
- 637Riehl, K., Neunteufel, M., & Hemberg, M. (2023). Hierarchical confusion matrix for classification performance
638 evaluation. *Revista de La Real Sociedad Estadística, Serie C (Estadística Aplicada)*.
639 <https://doi.org/10.1093/jrsssc/qlad057>
- 640Ríos-Ruiz, W., Torres-Chávez, E., Torres-Delgado, J., Rojas-García, J., Bedmar, E., & Valdez-Núñez, R. (2020).
641 Inoculation of bacterial consortium increases rice yield (*Oryza sativa* L.) reducing applications of nitrogen
642 fertilizer in San Martin region, Peru. *Rhizosphere*, 14. <https://doi.org/10.1016/j.rhisph.2020.100200>
- 643Ruiz-Tamayo, J., Antonio-Zitlali, Becerra, F., Rojas, E., Trasviña, R., Villanueva, L., & Almanza, S. (2024). Evaluación
644 Comparativa de Redes Neuronales Convolucionales ResNet-50 y MobileNet-v2 para el Diagnóstico de
645 Enfermedades Foliares en Cultivos de Maíz. *Cultivos de Maíz Article in Musyarakah Journal of Sharia*
646 *Economic*. <https://doi.org/10.5281/zenodo.13943077>
- 647Sepúlveda, Y. (2020). Inteligencia artificial (IA) y sus aplicaciones en la agricultura moderna. *ResearchGate*.
648 <https://doi.org/10.13140/RG.2.2.17264.89603>
- 649Shafik, W., Tufail, A., Namoun, A., De Silva, L. C., & Apong, R. A. A. H. M. (2023). A Systematic Literature Review
650 on Plant Disease Detection: Motivations, Classification Techniques, Datasets, Challenges, and Future
651 Trends. *IEEE Access*, 11, 59174–59203. <https://doi.org/10.1109/ACCESS.2023.3284760>
- 652Shah, F. M., Razaq, M., & Islam, Y. (2022). Contemporary Management of Insect Pests in Rice. In *Modern*
653 *Techniques of Rice Crop Production* (pp. 349–376). Springer Singapore. [https://doi.org/10.1007/978-981-](https://doi.org/10.1007/978-981-16-4955-4_20)
654 [16-4955-4_20](https://doi.org/10.1007/978-981-16-4955-4_20)
- 655Sharma, K., & Shivandu, S. K. (2024). Integrating artificial intelligence and Internet of Things (IoT) for enhanced
656 crop monitoring and management in precision agriculture. *Sensors International*, 5, 100292.
657 <https://doi.org/10.1016/j.sintl.2024.100292>
- 658Shenoy, H. (2024). *Detección de plagas en la agricultura mediante inteligencia artificial*. GreyB – IP
659 Research&Analytics. <https://www.greyb.com/blog/detecting-pests-using-ai/#>
- 660Tötsch, N., & Hoffmann, D. (2020). Classifier uncertainty: evidence, potential impact, and probabilistic treatment.
661 *PeerJ Computer Science*. <https://doi.org/10.7717/peerj-cs.398>
- 662Valle-Medina, F., Castillo-Heredia, L., Correa-Peralta, M., & Guzmán, J. (2025). Clasificación de enfermedades en
663 hojas de papa utilizando Transformadores de Visión. *Revista Digital de Ciencia, Ingeniería y Tecnología*, 8(1),
664 142–156. <https://doi.org/10.37135/ns.01.15.06>

665 Venu Vasantha, S., Samreen, S., & Lakshmi Aparna, Y. (2022). Rice Disease Diagnosis System (RDDS). *Computers,*
666 *Materials&Continua*, 73(1), 1895–1914. <https://doi.org/10.32604/cmc.2022.028504>

667 Yan, Z., Zhang, H., Piramuthu, R., Jagadeesh, V., DeCoste, D., Di, W., & Yu, Y. (2015). HD-CNN: Hierarchical Deep
668 Convolutional Neural Networks for Large Scale Visual Recognition. In IEEE (Ed.), *Proceedings of the IEEE*
669 *International Conference on Computer Vision (ICCV)* (pp. 2740–2748). IEEE.
670 [https://openaccess.thecvf.com/content_iccv_2015/html/Yan_HD-](https://openaccess.thecvf.com/content_iccv_2015/html/Yan_HD-CNN_Hierarchical_Deep_ICCV_2015_paper.html)
671 [CNN_Hierarchical_Deep_ICCV_2015_paper.html](https://openaccess.thecvf.com/content_iccv_2015/html/Yan_HD-CNN_Hierarchical_Deep_ICCV_2015_paper.html)


672 Zapeta, A., Galindo, G., Juan, H., & Martínez, M. (2022). Métricas de rendimiento para evaluar el aprendizaje
673 automático en la clasificación de imágenes petroleras utilizando redes neuronales convolucionales. *Ciencia*
674 *Latina Revista Científica Multidisciplinar*, 6(5), 4624–4637. https://doi.org/10.37811/cl_rcm.v6i5.3420

675

676

677 Tables and Figures

678




679

680

681 **Figure 1.** Flujo de trabajo del sistema Basado en ResNet-50 para la detección de plagas en cultivos de arroz.

682

683



684

685 **Figure 2.** Diseño, Arquitectura e Ingeniería.

686

687




Figure 3. Imágenes de muestra del dataset IP102.





Figure 4. División del conjunto de datos para prueba, entrenamiento y validación.

706




707

708 **Figure 5.** Análisis de eficiencia de modelos de aprendizaje profundo para la detección de plagas en arroz.

709

710

711



712

713

714

715

716

717

718

719

720

721

722

723 **Figure 6.** Arquitectura de ResNet-50: estructura y componentes.

724




Figure 7. Métricas de rendimiento por época en las fases de entrenamiento y validación





Figure 8. Evolución de la pérdida durante el entrenamiento y validación del modelo.

	precision	recall	f1-score	support
rice leaf roller	0.928856	0.920464	0.939698	143
rice leaf caterpillar	0.944034	0.945771	0.922226	298
paddy stem maggot	0.924449	0.935214	0.949278	305
asiatic rice borer	0.925383	0.937076	0.944946	120
yellow rice borer	0.930519	0.924248	0.948941	222
rice gall midge	0.927844	0.928356	0.92679	216
Rice Stemfly	0.923378	0.926199	0.936302	184
brown plant hopper	0.939963	0.926126	0.925888	215
white backed plant hopper	0.934221	0.925829	0.935524	175
small brown plant hopper	0.946749	0.935141	0.936545	315
rice water weevil	0.946689	0.940655	0.937878	205
rice leafhopper	0.933325	0.931491	0.934544	208
grain spreader thrips	0.931875	0.942549	0.937622	350
accuracy	0.936607	0.936607	0.936607	0.936607
macro avg	0.933637	0.93224	0.936629	2956
weighted avg	0.933637	0.93224	0.936629	2956

731

732 **Figure 9.** Matriz de clasificación con métricas de evaluación del modelo.

733



734

Figure 10. Matriz de Confusión del Modelo.




Figure 11. Interfaz del sistema de monitoreo en tiempo real




Figure 12. Ventana Principal del Monitor de Plagas – GUI DropGuard

756

757 **Table 1.** Revisión comparativa de estudios previos sobre aplicaciones de aprendizaje automático en la
758 detección plagas en arroz.

759

<i>Investigación</i>	<i>Año</i>	<i>País</i>	<i>Modelo</i>	<i>Precisión</i>	<i>Despliegue real</i>	<i>Validación en campo</i>
Dey et al. (*Comput.&Elect r. Agric.*)	2022	Bangladesh	MobileNetV 2, etc.	71.5%	No	No
Sharma et al. (*Insects*)	2024	India	EfficientNet B0, VGG16	>85%	No	No
Dutta et al. (*Scientific Reports*)	2023	India	DenseNet2 01 + Attention	>90%	No	Parcial (entorno controlado)
Rajeshwari et al. (*IRJASH*)	2021	India	CNN personaliza da	~85%	No	No
Zhao et al. (*Frontiers*)	2022	China	CNN + Atención paralela	>90%	Parcial	Simulado
Raza et al. (*IEEE Xplore*)	2024	Pakistán	Transfer Learning	>80%	No	No
Esta investigación (tesis actual)	2025	Perú	ResNet-50	92–95%	Sí (sistema completo)	Sí (dron + entorno real)

760

761

762