



Universidad
Señor de Sipán

**FACULTAD DE INGENIERÍA, ARQUITECTURA Y
URBANISMO**

**ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS**

TRABAJO DE INVESTIGACIÓN

**Redes neuronales convolucionales para la
detección de enfermedades en arroz: una
Revisión Sistemática**

**PARA OPTAR EL GRADO ACADÉMICO DE
BACHILLER EN INGENIERÍA DE SISTEMAS**

Autores

Fernandez Fernandez Kenedy David

ORCID: <https://orcid.org/0009-0007-8177-9763>

Pinglo Cabezas Williams Rafael

ORCID: <https://orcid.org/0009-0005-0629-741X>

Asesor

Dr. Atalaya Urrutia Carlos William

ORCID: <https://orcid.org/0000-0002-2761-4868>

Línea de Investigación

**Ciencias de la información como herramientas
multidisciplinares y estratégicas en el contexto
industrial y de organizaciones**

Sub línea de Investigación

**Informática y transformación digital en el contexto industrial y
organizacional**

Pimentel – Perú

2025

DECLARACIÓN JURADA DE ORIGINALIDAD

Quienes suscriben la **DECLARACIÓN JURADA**, Somos Kenedy David Fernandez Fernandez, Williams Rafael Pinglo Cabezas del programa de estudios de Ingeniería de Sistemas, de la Universidad Señor de Sipán S.A.C, declaramos bajo juramento que somos autores del trabajo titulado:

**Redes neuronales convolucionales para la detección de enfermedades en arroz:
una Revisión Sistemática**

El texto de nuestro trabajo de investigación responde y respeta lo indicado en el Código de Ética del Comité Institucional de Ética en Investigación de la Universidad Señor de Sipán (CIEI USS) conforme a los principios y lineamientos detallados en dicho documento, en relación a las citas y referencias bibliográficas, respetando al derecho de propiedad intelectual, por lo cual informo que la investigación cumple con ser inédito, original y auténtico.

En virtud de lo antes mencionado, firman:

Fernandez Fernandez Kenedy David	DNI: 73448501	
Williams Rafael Pinglo Cabezas	DNI: 47042450	

Pimentel, 13 de enero del 2025.

Dedicatoria

Dedico este logro a todos mis seres queridos y amigos, quienes han estado a mi lado en cada paso de este proceso. Gracias por su apoyo incondicional, por las risas, los consejos y por ser mi fuente constante de motivación. Cada uno de ustedes ha sido fundamental en este viaje, brindándome fuerza en los momentos de dificultad y celebrando conmigo los logros alcanzados. Finalmente, este trabajo está dedicado con todo mi amor y gratitud a mi familia. A mis padres, por su amor eterno, sacrificio y por enseñarme que los sueños se logran con esfuerzo y perseverancia. A mis hermanos, por su apoyo y por ser mi mayor fuente de inspiración. Gracias por estar siempre ahí, por creer en mí y por hacerme sentir que, juntos, somos más fuertes.

Fernandez Fernandez Kenedy David

Dedico este logro a Fiorella Agreda, mi esposa, quien ha sido mi apoyo incondicional, brindándome amor, paciencia y comprensión en cada paso de este proceso. A Piero Pinglo, mi hijo, por ser la fuente de inspiración y alegría que ilumina mi vida. A mis padres, por su amor eterno, sacrificio y por enseñarme que los sueños se logran con esfuerzo y perseverancia. A mis hermanos, por su apoyo y por ser mi mayor fuente de inspiración. A mi familia, por ser la luz que me guía y la motivación constante en mi vida. También quiero expresar mi agradecimiento a mis amigos y seres queridos, por su confianza y aliento incondicional. Y a mi abuela Norma que desde el cielo me está guiando para superarme. Este logro es un reflejo del esfuerzo, amor y fuerza de todos ustedes. ¡Gracias de todo corazón!

Pinglo Cabezas Williams Rafael

Agradecimientos

Agradecemos a Dios por darnos la fortaleza y perseverancia a lo largo de este proceso educativo y también a la Universidad de Señor de Sipán por facilitarnos los recursos para nuestro desarrollo académico.

Quiero expresar mi gratitud a mis profesores, por su enseñanza, consejos y el apoyo brindado para llevar a cabo este trabajo, cuya enseñanza fue fundamental para desarrollarnos académicamente.

A mis familiares y colaboradores por su valiosa asistencia y apoyo durante las diferentes semanas y hacer esta experiencia algo menos tedioso. A nuestro asesor William Atalaya Urrutia este logro en gran parte es de usted que no hubiera sido posible sin la ayuda y dedicación brindada.

Índice

Dedicatoria	3
Agradecimientos	4
Índice de Figuras y tablas	6
Resumen	7
Abstract	8
I. INTRODUCCIÓN.....	9
1.1. Realidad problemática.....	9
1.2. Formulación del problema.....	11
1.3. Hipótesis	12
1.4. Objetivos	12
1.5. Teorías relacionadas al tema	12
II. METODO DE INVESTIGACION.....	23
IV. DISCUSIÓN y CONCLUSIONES	41
V. Referencias	43
ANEXOS.....	49

Índice de Figuras y tablas

Tabla 1. Características de inclusión y exclusión	24
Tabla 2. Fuentes de información.....	26
Tabla 3. Estrategia de búsqueda	26
Tabla 4. Herramientas de evaluación.....	29
Tabla 5. Resultados de estudios usando CNN.....	31
Figura 1. Deep Learning	14
Figura 2. CNN Capas totalmente conectadas	16
Figura 3. Matriz de confusión.....	18
Figura 4. Detección de enfermedades en hojas de arroz	23
Figura 5. Diagrama de flujo de la metodología PRISMA	30
Figura 6. Evaluación de ResNet, VGG-16 Y BEiT.....	39

Resumen

La detección temprana de enfermedades en cultivos de arroz es fundamental para mantener la productividad agrícola y asegurar la seguridad alimentaria a nivel mundial. En los últimos años, las redes neuronales convolucionales (CNN) han mostrado un gran potencial en la identificación y clasificación de enfermedades en plantas. Esta revisión sistemática se enfoca en analizar y sintetizar estudios recientes que emplean CNN para la detección de enfermedades en cultivos de arroz u plantas. Investigando varios artículos con enfoques de clasificación de imágenes, metodologías y la identificación de patrones anormales en las hojas de arroz u otras plantas que también son atacadas por la misma enfermedad. Los resultados obtenidos de los distintos artículos indican que las CNN mejora la precisión en los modelos con porcentajes superior al 90% y una eficiencia cercana al 98% de los modelos entrenados normalmente, superando a las técnicas tradicionales y otros modelos de aprendizaje automático. No obstante, se destacan ciertos desafíos, como la segmentación de imágenes de baja calidad y la escasez de datos etiquetados, además del alto costo computacional asociado. Esta revisión proporciona un estudio sobre las aplicaciones actuales de las CNN para detección temprana enfermedades en arroz u plantas, ubicando tendencias emergentes futuras en la investigación, además de ofrecer recomendaciones prácticas para investigadores y profesionales en el sector agrícola.

Palabras claves: Detección de enfermedades en plantas, redes neuronales convolucionales, revisión sistemática, inteligencia artificial y aprendizaje automático.

Abstract

Early detection of diseases in rice crops is essential to maintain agricultural productivity and ensure global food security. In recent years, convolutional neural networks (CNNs) have demonstrated significant potential in identifying and classifying plant diseases. This systematic review analyzes and synthesizes recent studies that employ CNNs to detect diseases in rice crops and other plants affected by similar pathologies. The reviewed articles cover approaches in image classification, methodologies, and the identification of abnormal patterns in rice leaves and other species. The results indicate that CNNs improve model accuracy, achieving rates above 90% and efficiencies close to 98%, outperforming traditional techniques and other machine learning models. However, challenges remain, such as the segmentation of low-quality images, the scarcity of labeled data, and high computational costs. This review provides an overview of current CNN applications for early disease detection in rice, identifies future research trends, and offers practical recommendations for researchers and agricultural professionals.

Keywords: Disease detection, rice, convolutional neural networks, systematic Review, artificial intelligence and machine learning.

I. INTRODUCCIÓN

1.1. Realidad problemática

Detectar a tiempo y con precisión enfermedades en los cultivos de arroz es crucial para mantener alta la productividad agrícola y asegurar la disponibilidad de alimentos en todo el mundo. El arroz es uno de los principales alimentos básicos, alimentando a más de la mitad de la población mundial [1]. Sin embargo, la producción de arroz se ve constantemente amenazada por diversas enfermedades que pueden reducir significativamente el rendimiento de los cultivos [2]. Entre las enfermedades más comunes del arroz se encuentran la cigarrita o sogata (*Tagosodes orizicolus*), la mosca minadora del arroz (*Hydrellia wirthi*), el gusano cogollero (*Spodoptera frugiperda*), el chinche del tallo (*Tibraca limbativentris*) y el chinche de la espiga (*Oebalus ornatus*), las cuales pueden provocar pérdidas económicas considerables si no se detectan y gestionan a tiempo [3].

En los últimos años, las redes neuronales convolucionales (CNN, por sus siglas en inglés) han surgido como una herramienta poderosa en la identificación y clasificación de enfermedades en plantas. Una CNN es un tipo de red neuronal profunda especialmente diseñada para el procesamiento y análisis de imágenes, han demostrado una capacidad excepcional para extraer características relevantes y clasificar patrones complejos en imágenes de hojas de arroz afectadas por diversas enfermedades. Estas redes superan a las técnicas tradicionales y a otros enfoques basados en aprendizaje automático en términos de precisión y eficiencia [4] la adopción de tecnologías avanzadas por parte de los agricultores conlleva a la falta de integración afectando la eficiencia agrícola y limitando el aprovechamiento completo de las herramientas digitales disponibles [5] la integración de tecnologías avanzadas como aprendizaje automático y redes neuronales convolucionales ha demostrado ser efectiva en detección de plagas, lo que permite un mejor control de los cultivos [6].

La calidad de las imágenes de las hojas es crucial para el diagnóstico preciso de enfermedades [7]. Los conjuntos de datos públicos disponibles para la investigación en este campo son limitados, lo que dificulta el desarrollo y la validación de modelos de detección de enfermedades. La presencia de datos ruidosos puede afectar la precisión de las muestras de hojas analizadas, lo que representa un desafío en la identificación confiable de enfermedades [8].

La utilización de modelos predictivos es clave para comprender mejor las dinámicas de las plagas mejorando la eficacia del control [9]. El método utiliza algoritmos de procesamiento de imágenes para detectar hojas y posibles lesiones inducidas por enfermedades en las hojas, calculan varios atributos en función de las dimensiones de las hojas y las lesiones, los números y las formas de las lesiones [10]. El enfoque híbrido CNN-RF combina redes neuronales convolucionales y bosques aleatorios para mejorar la detección de enfermedades en arroz, alcanzando una precisión del 93.5%, superando métodos individuales y optimizando la gestión agrícola y la seguridad alimentaria [11]. El uso de transfer learning, es una técnica que permite ajustar modelos previamente entrenados en grandes conjuntos de datos para tareas específicas con conjuntos de datos más pequeños donde la aplicación de CNN con aprendizaje por transferencia puede mejorar significativamente la clasificación de enfermedades en las hojas de arroz, alcanzando una mayor precisión y eficiencia, incluso con conjuntos de datos limitados de imágenes de enfermedades específicas [12] la eficacia de las redes neuronales profundas en la identificación de enfermedades en plantas incluye técnicas de aumento de datos y procesamiento de imágenes para mejorar el recall de los datos en las carpetas agrupadas [13].

La técnica de transferencia de aprendizaje reutiliza un modelo previamente entrenado de un dataset grande, permitiendo acoplarlo a uno con pocos datos, se una ImageNet es donde se encontrarán los datos luego empleando la técnica se le otorga tareas específicas como es el agrupamiento de carpetas que contienen las distintas hojas capturadas [14] la técnica de bosques aleatorios (Random Forest) aunque su proceso

se base en que es un híbrido [15], el algoritmo empleado ayuda a mejorar la precisión en la clasificación de cada enfermedad agrupada extrayendo características enfocadas, captando patrones visuales para la toma de decisión y hacerla más precisa [16], detector de bordes Canny aplicado con CNN mejora la segmentación extrayendo características más relevantes de una forma más precisa para hacer la distinción de las otras enfermedades agrupadas como puede ser “sana” o “enferma” identificando los contornos de las hojas y sus lesiones [17]

Esta revisión sistemática tiene como objetivo analizar el uso de herramientas de aprendizaje profundo, como CNN y bosques aleatorios (RF), para la detección de enfermedades en cultivos de arroz. Busca explorar cómo la informática y la transformación digital pueden mejorar la gestión agrícola, superando las limitaciones de métodos tradicionales. Se detallan los enfoques utilizados en diversos estudios en cultivos de arroz. Se evaluaron múltiples enfoques basados en CNN, incluyendo clasificación de imágenes, segmentación de lesiones y la detección de patrones anormales en hojas de arroz. A través de esta revisión, se destacan los niveles de precisión y eficiencia que las CNN pueden ofrecer en comparación con técnicas tradicionales y otras metodologías basadas en el aprendizaje automático.

Sin embargo, también se identificaron desafíos importantes, como la necesidad de grandes conjuntos de datos etiquetados y el alto costo computacional asociado con el entrenamiento de redes profundas. Este artículo proporciona una visión comprensiva de las aplicaciones actuales de las CNN en la detección de enfermedades en arroz, destacando tendencias emergentes y futuras direcciones de investigación, y ofreciendo recomendaciones prácticas para investigadores y profesionales del sector agrícola.

1.2. Formulación del problema

¿Cómo pueden las redes neuronales convolucionales mejorar la precisión en plagas de cultivo de arroz?

1.3. Hipótesis

La aplicación de CNN mejora significativamente la detección temprana en enfermedades en cultivos de arroz en comparación con los métodos tradicionales, permitiendo una gestión más efectiva de los cultivos.

1.4. Objetivos

1.4.1. Objetivo general

Analizar las arquitecturas CNN más utilizados en la detección de enfermedades en cultivos de arroz, evaluando su efectividad.

1.4.2. Objetivos específicos

- a. Identificar las técnicas basadas en CNN más efectivas para la detección de enfermedades en el cultivo de arroz.
- b. Evaluar la efectividad de las CNN en la detección de enfermedades del arroz.
- c. Examinar los tipos de datos empleados en el entrenamiento de CNN para la detección de enfermedades en el cultivo de arroz.
- d. Identificar y comparar las métricas de evaluación más utilizadas para medir el rendimiento de las CNN en estudios sobre detección de enfermedades en cultivos de arroz.

1.5. Teorías relacionadas al tema

1.5.1. Inteligencia Artificial (IA)

La inteligencia artificial es un área multidisciplinaria de la informática enfocada en el desarrollo de sistemas capaces de ejecutar tareas que suelen requerir la inteligencia humana, como el reconocimiento de patrones y señales, la toma de decisiones, la resolución de problemas y el aprendizaje automático. La IA puede dividirse en dos enfoques principales:

IA basada en reglas o simbólica: Se basa en sistemas expertos y lógica computacional para resolver problemas mediante reglas predefinidas.

IA basada en el aprendizaje: Emplea modelos matemáticos y estadísticas para aprender patrones a partir de datos, dentro de los cuales destacan el Machine Learning y el Deep Learning.

Machine Learning (ML)

ML, o aprendizaje automático, es una clasificación de la Inteligencia Artificial que permite a las máquinas aprender a partir de datos sin necesidad de una programación explícita para cada tarea. Utiliza modelos estadísticos y algoritmos que identifican patrones en grandes volúmenes de información, permitiendo la predicción y toma de decisiones automatizada.

En el ML se pueden identificar tres enfoques principales:

Aprendizaje supervisado: Se entrena con datos etiquetados, estableciendo relaciones entre entradas y salidas conocidas. Ejemplo: clasificación de imágenes.

Aprendizaje no supervisado: Analiza datos no etiquetados, descubriendo estructuras y relaciones ocultas. Ejemplo: algoritmos de clustering.

Aprendizaje por refuerzo: Un agente interactúa con su entorno y optimiza su comportamiento mediante un sistema de recompensas y penalizaciones. Ejemplo: algoritmos en robótica [18].

Deep Learning (DL)

DL es una subcategoría del ML que utiliza redes neuronales artificiales profundas para procesar datos de manera jerárquica [19]. Inspirado en la estructura y funcionamiento del cerebro humano, el Deep Learning es particularmente eficaz en el procesamiento de grandes volúmenes de datos no estructurados, conformados por imágenes, texto y audio.

Las arquitecturas más utilizadas en Deep Learning incluyen:

CNN: Utilizadas en análisis de imágenes y visión artificial.

Redes Neuronales Recurrentes (RNN): Diseñadas para el procesamiento de secuencias, como reconocimiento de voz y traducción automática.

Transformers: Utilizados en modelos avanzados de procesamiento de lenguaje natural, como GPT y BERT.

Redes Generativas Adversarias (GANs): Aplicadas en la generación de contenido sintético, como imágenes y videos artificiales.

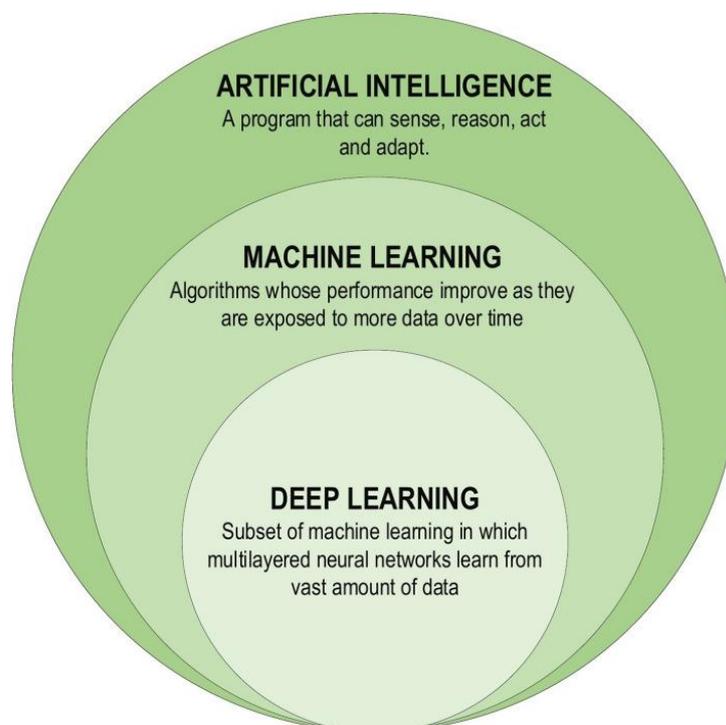


Figura 1. Deep Learning

Fuente: [19]

1.5.2. Redes Neuronales Artificiales (ANN)

Las ANN, son un modelo computacional inspirado en el funcionamiento y estructura del cerebro humano. Están compuestas por neuronas artificiales organizadas en capas interconectadas, capaces de procesar información mediante la propagación y transformación de señales a través de funciones matemáticas.

Las ANN son un elemento fundamental del aprendizaje automático y, en particular, del Deep Learning, pues permiten modelar relaciones complejas entre datos de entrada y salida, facilitando la solución de problemas en visión por computadora, reconocimiento de señales y procesamiento de lenguaje natural.

Una ANN típica consta de tres tipos de capas:

Capa de entrada: Permite el ingreso de los datos y los distribuye a las siguientes capas.

Capas ocultas: Aplican transformaciones mediante pesos sinápticos y funciones de activación no lineales.

Capa de salida: Capa que genera el resultado final del modelo, en función de la tarea específica (clasificación, regresión, segmentación, etc.).

CNN

Las CNN son un tipo especializado de ANN optimizado para el procesamiento de datos con estructuras espaciales, como imágenes y videos [20]. Entre sus características claves podemos destacar:

Capas convolucionales: Aplican filtros sobre los datos de entrada para extraer características relevantes.

Capas de agrupamiento (pooling): Reducen la dimensionalidad de los mapas de características, mejorando la eficiencia computacional.

Capas completamente conectadas: Realizan la clasificación final basada en las características extraídas.

Las CNN han demostrado un gran desempeño en tareas de visión artificial como la detección de objetos, la segmentación semántica y el reconocimiento facial, con arquitecturas avanzadas como AlexNet, VGG, ResNet y EfficientNet.

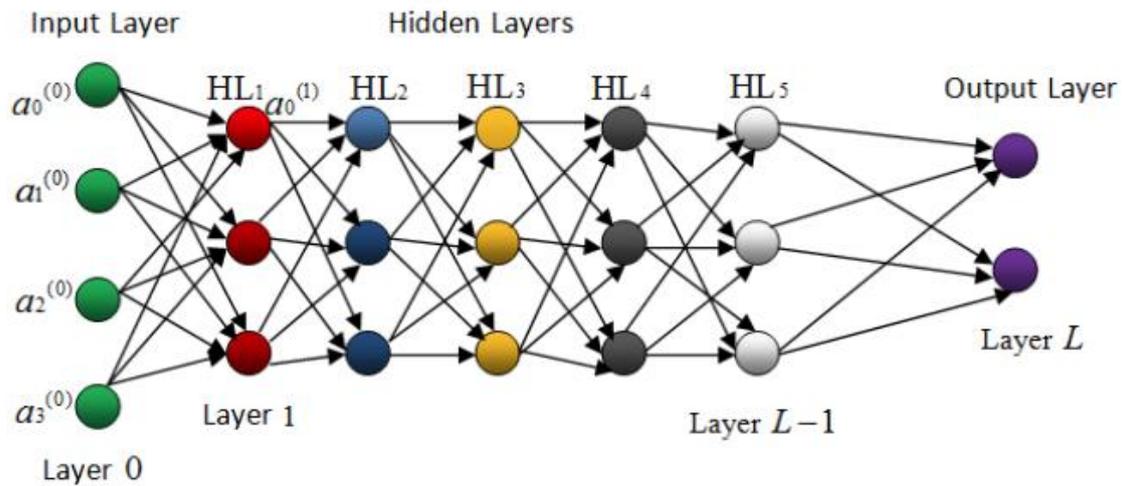


Figura 2. CNN Capas totalmente conectadas

Fuente: [21]

Evaluación de rendimiento de ANN

Para medir la eficacia de una ANN en tareas de clasificación, se utilizan métricas basadas en la matriz de confusión, tales como la precisión, exactitud, recall y F1-score [22].

Precisión (Precision)

Este indicador es el resultado de la proporción de predicciones positivas correctas con respecto a todas las predicciones positivas realizadas. Se expresa como:

$$P = \frac{TP}{TP + FP} \quad (1)$$

donde:

TP (True Positives): Casos que fueron correctamente clasificados como positivos.

FP (False Positives): Casos que fueron incorrectamente clasificados como positivos.

Una alta precisión indica que pocos ejemplos negativos fueron clasificados erróneamente como positivos, lo que es crucial en problemas donde los falsos positivos tienen un alto costo, como la detección de fraudes.

Exactitud (Accuracy)

La exactitud mide la proporción de predicciones correctas sobre todas las predicciones realizadas. Se calcula como:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

donde:

TN (True Negatives): Casos que fueron correctamente clasificados como negativos.

FN (False Negatives): Casos incorrectamente clasificados como negativos.

Aunque es una métrica general útil, la exactitud puede ser engañosa cuando hay un desequilibrio en las clases, ya que un modelo puede lograr alta exactitud prediciendo siempre la clase mayoritaria sin aprender realmente los patrones.

Recall (Sensibilidad o Exhaustividad)

Este indicador mide la proporción de casos positivos que fueron correctamente identificados, en relación con todos los casos positivos reales. Se expresa como:

$$R = \frac{TP}{TP + FN} \quad (3)$$

Un alto recall indica que el modelo detecta la mayoría de los casos positivos, lo que es fundamental en aplicaciones como la detección de enfermedades en cultivos, donde los falsos negativos deben minimizarse.

F1-Score

El F1-score es una métrica que equilibra la precisión y el recall mediante su media armónica:

$$F = 2 * \frac{(P * R)}{(P + R)} \quad (4)$$

Es especialmente útil cuando hay un desequilibrio de clases, proporcionando una evaluación más robusta que la exactitud.

Matriz de Confusión

La matriz de confusión es una herramienta ampliamente utilizada en la evaluación del rendimiento de modelos de clasificación. Es una representación tabular que permite visualizar las predicciones del modelo comparando con los valores reales, facilitando el cálculo de métricas como la precisión, exactitud, recall y F1-score.

		Actual Value (as confirmed by experiment)	
		positives	negatives
Predicted Value (predicted by the test)	positives	TP True Positive	FP False Positive
	negatives	FN False Negative	TN True Negative

Figura 3. Matriz de confusión

Fuente: [23]

1.5.3. Técnicas de procesamiento de imágenes

Este es un campo fundamental en la visión por computadora y la inteligencia artificial, que permite mejorar, transformar y analizar imágenes para extraer información relevante. Dentro de este ámbito, existen diversas técnicas que optimizan la calidad de

los datos y fortalecen el rendimiento de los modelos de ML y DL. Entre estas técnicas, destacan el preprocesamiento de imágenes y el aumento de datos, las cuales buscan mejorar la representación de las características visuales y la capacidad generalizadora de los modelos entrenados.

Preprocesamiento de imágenes

El preprocesamiento de imágenes comprende un conjunto de técnicas que tienen el objetivo de mejorar la calidad de las imágenes antes de ser utilizadas en modelos computacionales. Estas técnicas permiten reducir ruido, corregir variaciones en la iluminación, normalizar tamaños y mejorar la definición de los objetos en la imagen. Algunas de las técnicas más utilizadas incluyen:

Conversión a escala de grises: Reduce la dimensionalidad de los datos eliminando la información de color y manteniendo únicamente la intensidad de los píxeles.

Normalización y estandarización: Ajusta los valores de los píxeles a un rango específico, como $[0,1]$ o $[-1,1]$, para mejorar la estabilidad del entrenamiento en redes neuronales.

Reducción de ruido: Métodos como el filtrado gaussiano o el filtrado mediano permiten suavizar la imagen y eliminar artefactos no deseados.

Detección de bordes: Técnicas como el operador de Sobel o el filtro de Canny resaltan contornos y estructuras dentro de la imagen.

Segmentación: Divide la imagen en regiones de interés, facilitando la identificación de objetos específicos.

Aumento de datos

Técnica utilizada para incrementar la cantidad y diversidad de los datos de entrenamiento mediante transformaciones geométricas, espaciales y espectrales de las imágenes originales. Su objetivo principal es mejorar la capacidad de generalización de

los modelos, reduciendo el sobreajuste (overfitting) y mejorando su robustez ante variaciones en los datos de entrada.

Algunas de las transformaciones más utilizadas en el aumento de datos incluyen:

Rotación: Variación del ángulo de la imagen dentro de un rango determinado.

Escalado: Modificación del tamaño de la imagen, manteniendo sus proporciones.

Traslación: Desplazamiento de la imagen en los ejes horizontal y vertical.

Reflexión y volteo: Inversión de la imagen en el eje horizontal o vertical.

Ajuste de brillo y contraste: Modificación de la intensidad luminosa para simular diferentes condiciones de iluminación.

Ruido aleatorio: Introducción de variaciones estocásticas en los valores de los píxeles para mejorar la robustez del modelo ante distorsiones.

1.5.4. Detección de enfermedades utilizando CNN

La detección de enfermedades en cultivos mediante CNN ha emergido como una solución innovadora en el ámbito de la agricultura de precisión y la visión artificial. Este enfoque permite el análisis automatizado de imágenes de plantas para la identificación temprana de enfermedades, facilitando la toma de decisiones y optimizando la producción agrícola.

Las CNN han demostrado ser eficaces en la clasificación y segmentación de imágenes de hojas y frutos, debido a su capacidad de extraer características visuales complejas, como patrones de textura, color y forma, con alta precisión. Su aplicación en la fitopatología digital contribuye a mejorar la productividad y sostenibilidad agrícola mediante sistemas de monitoreo automatizados y no invasivos.

Las CNN para detección de enfermedades en cultivos

Las CNN han sido ampliamente implementadas en la identificación de enfermedades en diversos cultivos, como tomate, papa, maíz, vid y arroz. Su uso se basa en el procesamiento de imágenes capturadas mediante cámaras RGB, hiperespectrales o térmicas, permitiendo la detección de síntomas en etapas tempranas.

El proceso de detección de enfermedades mediante CNN se desarrolla en las siguientes fases:

Adquisición de imágenes: Se recopilan imágenes de hojas, tallos o frutos a través de drones, teléfonos móviles o cámaras de alta resolución.

Preprocesamiento: Se aplican técnicas de normalización, reducción de ruido y segmentación para mejorar la calidad de las imágenes antes de ser ingresadas al modelo.

Entrenamiento de la CNN: Se utiliza un conjunto de datos etiquetado con imágenes de hojas sanas y enfermas para que el modelo aprenda a reconocer patrones característicos de distintas enfermedades.

Clasificación y segmentación: El modelo CNN clasifica las imágenes en categorías de enfermedad y segmenta las regiones afectadas para un análisis detallado.

Evaluación del modelo: Se aplican métricas como precisión, exactitud, recall y F1-score para validar la efectividad del modelo.

Detección de enfermedades en arroz

El arroz es un cultivo de mucha relevancia a nivel mundial y es susceptible a diversas enfermedades que pueden comprometer su producción. Entre las enfermedades más comunes en el arroz se encuentran:

Pyricularia oryzae (Añublo del arroz o Pyriculariosis)

Xanthomonas oryzae (Tizón bacteriano del arroz)

Cercospora oryzae (Mancha marrón del arroz)

El uso de CNN ha demostrado ser altamente eficaz en la detección automática de estas enfermedades a través de imágenes de hojas de arroz. Investigaciones recientes han desarrollado modelos basados en arquitecturas como VGG16, ResNet, MobileNet y EfficientNet, logrando niveles de precisión superiores al 90 % en la clasificación de enfermedades en arroz.

Algunas estrategias utilizadas en la detección de enfermedades en arroz mediante CNN incluyen:

Uso de imágenes multiespectrales para mejorar la detección de síntomas tempranos.

Combinación de CNN con modelos de aprendizaje profundo como LSTM para capturar la evolución temporal de los síntomas.



Figura 4. Detección de enfermedades en hojas de arroz

Fuente: [24]

II. METODO DE INVESTIGACION

La presente investigación se ha desarrollado mediante la metodología de revisión sistemática, siguiendo las directrices de PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Se formuló un protocolo de investigación detallado que delineó el diseño exhaustivo de la revisión sistemática donde [25] utiliza el análisis de componentes principales visualizando las características más significativas de las CNNs reconociendo cuando hacen una predicción u clasificación.

Preguntas de investigación

Para que el estudio de esta investigación se centre en una revisión sistemática se plantearon preguntas que van acorde con nuestra línea de objetivos la cual busca comprender el panorama actual que está destacando las CNN en detección sintetizando información de las tecnologías, métodos u avances identificando tendencias en aplicación práctica en la agricultura.

1. ¿Qué arquitecturas CNN son los más utilizados comúnmente en estudios para detección de enfermedades en el cultivo de arroz?
2. ¿Qué tan efectivas son las redes neuronales convolucionales en la detección de enfermedades de arroz?
3. ¿Cómo son los entrenamientos de la CNN según estudios para detectar las enfermedades en el cultivo de arroz?
4. ¿Qué tipo de datos se utiliza para entrenar la CNN para la detección de enfermedades en cultivos de arroz?
5. ¿Qué métricas de evaluación se usan a menudo en los estudios para medir el desempeño de la CNN en la detección de enfermedades del cultivo de arroz?

Criterios de elegibilidad

Los criterios de inclusión y exclusión para esta investigación enfocada en el estudio de las enfermedades del cultivo de arroz usando CNN incluyen estudios que usan CNN u metodologías adaptadas que son pertinentes y que fueron relevantes para revisión sistemática presentando resultados que brindan precisión en la detección de enfermedades del cultivo, teniendo en cuenta los objetivos y la pregunta de estudio mientras que se descartan los distintos estudios que no encuentre relación con el objetivo u relación con el tema de enfermedades de plantas con CNN [26].

Tabla 1. Características de inclusión y exclusión

Característica	Inclusión	Exclusión
Propósito (P)	Las nuevas tecnologías de predicción y detección de enfermedades	Estudios que no aporten a la predicción o detección de enfermedades de plantas.

	cultivos de arroz que usen CNN.	
Participantes (P)	Variedades de cultivo que estén afrontando enfermedades.	Estudios que no incluyan datos de cultivos.
Intervención (I)	Investigación que implemente tecnologías CNN, aprendizaje automático para la detección de enfermedades en plantas.	Estudios que no aborden las tecnologías para la detección de enfermedades en plantas.
Comparación (C)	Estudios que incluyan el rendimiento de las CNN con otros métodos de detección	Estudios que no cumplen con evidencias claras para una comparación.
Resultados (O)	Estudios que atribuyan resultados del rendimiento de las CNN en la detección de enfermedades en plantas	Estudios que no presenten datos medibles o no brinden el desempeño de las tecnologías de detección.
Contexto (C)	Estudios realizados en los últimos 5 años 2019 a 2025 con el idioma traducible.	Estudios que no están en el rango u idiomas no traducibles.

Fuentes de información

Para la búsqueda de los artículos se hizo el uso las bases de datos Scopus, IEEE, Science Direct [11] estas bases de datos permiten a acceder a investigaciones sobre el uso de CNN mostrando información, idiomas resultados u fechas publicadas, etc.

Tabla 2. Fuentes de información

Fuentes	Características	Tiempo
IEEE	Inglés- español, uso de metodologías en CNN relacionados con la ingeniería	Últimas dos décadas hasta la actualidad
Science Direct	Inglés- español investigación de artículos académicos e implementación de CNN	
Scopus	Inglés- español acceso a estudios relevantes en diversas áreas	

Estrategia de búsqueda

En la tabla 3 se muestra las cadenas de búsqueda utilizada en las bases de datos.

Tabla 3. Estrategia de búsqueda

Base de Datos	Sintaxis de búsqueda
IEEE Xplore	("All Metadata": detection) AND Xplore ("All Metadata": rice) AND Digital ("All Metadata": crops) AND Library ("All

	Metadata": diseases) AND ("All Metadata": CNN)
Scopus	(TITLE-ABS-KEY (rice AND crops) AND TITLE-ABS-KEY (detection) AND TITLE- ABS-KEY (diseases) AND TITLE-ABS- KEY (CNN)) AND PUBYEAR > 2019
Science Direct	detection AND diseases AND CNN OR convolutional neural networks Title, abstract, keywords: rice AND crops

Proceso de selección de estudios

Se identificaron un total de 438 artículos encontrados en las bases de datos IEEE Xplore y ScienceDirect y Scopus donde la revisión sistemática seguirá las buenas prácticas de PRISMA.

Filtrado inicial: Los artículos que no cumplen con la relevancia y el tipo de estudio de detección de enfermedades en plantas no serán tomados en cuenta donde la cuenta final de artículos fue de 183.

Criterios de exclusión: Se tomaron en cuenta los idiomas traducibles y enfocados en detección de plantas teniendo en cuenta que las investigaciones aportaran en el proceso de detección de enfermedades en plantas de arroz u hojas reduciendo los artículos.

Selección final – inclusión: Una vez revisado los artículos restantes se incluyeron para que la revisión sistemática tenga mayor relevancia y fueran incluidos teniendo la cuenta de 16 artículos.

Documentación: Se documenta visualmente para ver como fue el proceso de las etapas mencionadas

Proceso de extracción de datos

Variables de interés: información de autores, año de publicación, metodologías usadas, métricas de evaluación y resultados.

Validación de datos: Los datos son los artículos investigados para obtener un análisis y sintetizar resultados garantizando una buena práctica de validación.

Documentación: Se registra los resultados y sus referencias de donde fueron obtenidos.

El proceso de extracción de datos inicia con la recolección de estudios incluidos que presentan a los autores y sus metodologías con el objetivo de analizar las CNN en detección de enfermedades de plantas, en el proceso se decidió la interpretación de datos discutiendo las diferencias, consultando a los artículos para la validación de información facilitando la comparación. Finalmente se documenta para la transparencia de recolección de datos permitiendo un análisis coherente en las conclusiones del estudio.

Evaluación del riesgo de sesgo

Para la evaluación de riesgo se tuvo en cuenta que el estudio tenga estudios que incluyan el uso de CNN o tecnologías para detección de enfermedades incluyendo los distintos artículos de las bases de datos IEEE Xplore y ScienceDirect y Scopus para una mayor relevancia de la revisión sistemática.

Se usaron herramientas como Cochrane Risk of Bias Tool (RoB 2.0) y la Newcastle-Ottawa Scale (NOS) [27] visualizando la metodología de los estudios incluidos basándose si el sesgo es bajo, incierto o alto, analizando los resultados de los artículos estudiados.

Tabla 4. Herramientas de evaluación

Herramienta	Evaluación	Riesgo de Sesgo	Análisis
Cochrane Risk of Bias Tool (RoB 2.0)	Participante, resultados de detección y el desempeño de precisión	Bajo, Incierto, Alto	Interpretación de los resultados de la detección de enfermedades de plantas con CNN u otras metodologías
Newcastle-Ottawa Scale (NOS)	Comparación de variables, resultados y calidad de los grupos	Bajo, Incierto, Alto	Resultado final de la precisión de la detención de enfermedades de plantas con CNN

Métodos de síntesis

La síntesis se realizó usando métodos estadísticos que incluyen un análisis descriptivo para visualizar los datos de los artículos incluidos, el análisis de subgrupos evalúa los resultados según características de los artículos utilizando CNN considerando las variables de la tecnología empleada.

Como métodos narrativos se realiza una síntesis cualitativa describiendo las metodologías encontradas para analizar la detección de enfermedades en plantas con CNN para una interpretación solida de los resultados.

III. RESULTADOS

Selección de estudios

En la figura 5 se muestra el diagrama de flujo para realizar la revisión sistemática.

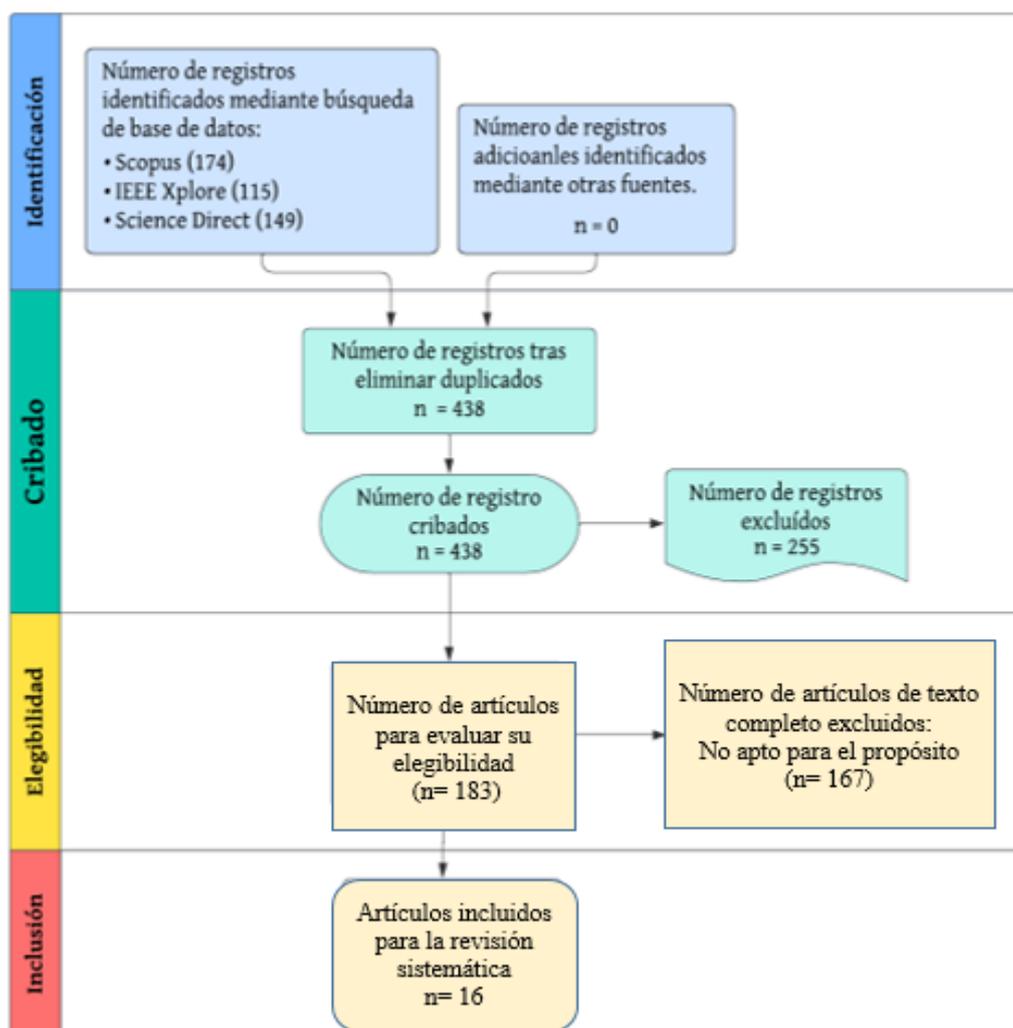


Figura 5. Diagrama de flujo de la metodología PRISMA

Tabla 5. Resultados de estudios usando CNN

N°	Titulo	Año	Técnica/Método	Entrenamiento/ Validación	Diseño	Población	Conjunto de datos	Revista, conferencia o informe	Resultado
1	Using artificial intelligence algorithms to predict rice (Oryza sativa L.) growth rate for precision agriculture [28]	2021	REG, ANN, GEP (Modelos de predicción)	70% de entrenamiento, 20% validación cruzada, 10% prueba	Cuasi-experimental	Tres cultivares de arroz (TK9, TNG71, KH147)	Datos de temperatura y tasas de crecimiento en varias etapas del cultivo (inicial, panícula, floración, madurez).	Computers and Electronics in Agriculture	El modelo ANN alcanzó un R ² de 99.26%, GEP 99.24% y REG 97.37%, destacando ANN por su mayor precisión.
2	Comparison of CNN-based deep learning architectures for rice diseases classification [29]	2023	Transfer Learning, Ensemble (DEX)	60 épocas con Early Stopping, imágenes aumentadas mediante rotación	Experimental	14,118 imágenes de arroz para entrenamien to (34,992 imágenes después de	34,992, donde 7,884 imágenes de prueba 9 clases de enfermedades de arroz: Bacterial leaf, blight, Brown Spot, Hispa, Leaf blast, Leaf smut,	Artificial Intelligence in Agriculture	Mejor resultado con Ensemble DEX: Precisión: 97.62%, Recall: 99%, F1-Score: 99%, Especificidad: 99.84% (Bacterial leaf blight)

						expansión por rotación)	Sheath Blight y Tungro		
3	A study on optimal input images for rice yield prediction models using CNN with UAV imagery and its reasoning using explainable AI [30]	2025	Redes Neuronales Convolucionales (CNN)	Validación cruzada de 4 pliegues (n=499, n=1497)	Experimental	Arroz 5 variedades. 499 para prueba y 1497 para entrenamien to.	1996 imágenes de arroz, de diferentes etapas de maduración con combinaciones de bandas espectrales como verde, rojo, NIR, rojo edge	European Journal of Agronomy	El CNN mostró una precisión moderada (R^2 entre 0.347 y 0.492), con baja variabilidad en el error (RRMSE de 0.167 a 0.148), y alta consistencia (RPIQ entre 1.777 y 1.972)
4	Comprehensive mixed-based data augmentation for detection of rice leaf disease in the wild [7]	2024	Mixed-Based Data Augmentation (Mixup, Cutmix, FMix, Cutout)	70% entrenamiento y 30% validación	Experimental	Hojas de arroz infectadas por enfermedad es 10,000 imágenes, ResNet34: 10,000 imágenes,	Wild Dataset: GoogleNet: Imágenes de hojas de arroz con enfermedades 100,000 imágenes Setup Dataset: 5,000 imágenes	Crop Protection (2024)	Mejoro el promedio en 1.57% en el dataset Wild y un 3.86% en el Setup Dataset, destacando el uso de Mixed-Based Augmentation para mejoras en 2.56% de precision.

							MobileNetV			
							3: 10,000			
							imágenes			
5	Optimizing dataset diversity for a robust deep-learning model in rice blast disease identification to enhance crop health assessment across diverse conditions [31]	2025	Convolutional Neural Networks (CNN)	10 Epochs, Batch Size 32	Exploratorio	Imágenes de las etapas de crecimiento y severidad de la enfermedad del arroz	16,000 imágenes de plantas de arroz en etapas de crecimiento y severidad de la enfermedad.	Smart Agricultural Technology Journal	El modelo demuestra 95,26% de precisión y la validación en un 94,43% indicando que va mejorando la adaptabilidad a datos mas grandes.	
6	An interpretable fusion model integrating lightweight CNN and transformer architectures for rice leaf disease identification [32]	2024	BEiT Model (BERT-based Vision Transformer) + LIME	Entrenamiento 50 épocas (Epochs), Validación K-fold (10)	Experimental	Plantas de arroz y 1106 imágenes por cada clase	Dhan-Shomadhan: 10,000 imágenes, variabilidad en tipos de enfermedades. PlantVillage: 54,000 imágenes,	Ecological Informatics	El modelo BEiT que alcanzó una precisión del 98.1%, precisión del 98.2%, recall de 97.7%, F1-score de 96.5%, y una pérdida de 0.120.	

								variedad de cultivos.		
7	Noninvasive Raman spectroscopy for the detection of rice bacterial leaf blight and bacterial leaf streak [33]	A	2025	CNN estándar Con la técnica Espectroscopía Raman	Espectros Raman lesiones etapa 1: visibles, etapa 2: pequeñas, etapa 3: grandes Validación independiente.	experimental	Hojas de arroz infectadas con Xoo	2626 espectros de hojas infectadas y sanas	Talanta	Precisión en la detección en etapa I: 82.67 % para Xoo y 78.38 % para Xoc. En etapa II: 91.18 % para Xoo y Xoc. En etapa III: 93.33 % para Xoo y Xoc.
8	DeepRice: deep learning and deep feature based classification of Rice leaf disease subtypes [34]	A	2024	Redes Neuronales Convolucionales (CNN) Custom VGG-16	70% para entrenamiento, 20% para validación cruzada y 10% para prueba, 60 épocas	Cuasi-experimental	imágenes de hojas de arroz,	5932 imágenes de hojas de arroz con 9 tipos de enfermedades	Artificial Intelligence in Agriculture	Precisión: 99.7%, Recuerdo: 99.7%, F1 Score: 99.7%, Exactitud: 99.7% donde Entrenamiento por 50 épocas y tiempo de entrenamiento: 14,500 segundos.
9	An IoT-based intelligent farming using CNN for early disease		2022	Redes Neuronales Convolucionales (CNN)	80% entrenamiento, 20% validación	Experimental	Imágenes de arroz	10,000 imágenes de arroz con Brown Spot y	Microprocessors and Microsystems	Precisión de prueba: 97.7%, Pérdida mínima: 5.42%

Detection of Rice Diseases [37]												
12	Custom Convolutional Neural Network for Detection and Classification of Rice Plant Diseases [38]	2023	CNN (Custom architecture)	80% de entrenamiento 20% de validación	de Cuasi-experimental	5932 imágenes de arroz	5932 imágenes de arroz	4 clases de enfermedades saludables de arroz	Procedia Computer Science	99.83% precisión en 4 clases, 99.66% precisión en 5 clases con saludables		
13	Rice diseases detection and classification using attention based neural network and bayesian optimization [39]	2021	ADSNN-BO Attention-based Depthwise Separable Neural Network Bayesian Optimization	Validación cruzada, Cross-validation		Imagen de arroz enfermo	100 imágenes por clase, Brown Spot, Rice, Hispa damage, Leaf Blast	Expert Systems with Applications Expert Systems with Applications	ADSNN-BO: Precisión de prueba de 94.65%, superior a otros modelos. Análisis de activación y filtros visualizados.			
14	E2ETCA: End-to-end training of CNN and attention ensembles for	2024	CNN Inception V3, DenseNet 201, Vision Transformer, Ensemble	Entrenamiento experimental End-to-End		11 clases de enfermedad es	BRRRI dataset: 33,210 imágenes de arroz de 11 clases de enfermedades	Journal of Agricultural Informatics	Precisión: 99.1%, Recall: 98.7%, F1-Score: 98.7%, Specificity: 97.1%			

	rice disease diagnosis [40]		Attention-Based Model (E2ETCA)							
15	RiceNet: A two stage machine learning method for rice disease identification [41]	2023	Siamese Network	80% de entrenamiento y 20% de validación	de experimental	200 imágenes de arroz en campo	626 imágenes de 4 enfermedades comunes del arroz Panicle Neck Blast, False Smut, Leaf Blast, Stem Blast	Biosystems Engineering		mAP: 95.58%, FPS: 68.91%, Tamaño: 34.36 Mb
16	A novel Moore-Penrose pseudo-inverse weight-based Deep Convolution Neural Network for bacterial leaf blight disease detection system in rice plant [42]	2022	MPW-DCNN	80% entrenamiento y 20% validación		120 imágenes Arroz enfermedad es por BLB	Rice Leaf Diseases Data Set	Advances in Engineering Software		Precisión: 97.5% Sensibilidad: 95.24% Especificidad: 94.13% Precisión: 95.78% Recall: 92% F1-Score: 93.85% FDR: 0.12% FPR: 0.0245%

En los estudios revisados, el uso de CNN ha demostrado ser altamente eficaz en la detección de enfermedades en el cultivo de arroz. Donde los resultados globales indican que las CNN alcanzan altos niveles de precisión, con un rango promedio de 97% a 99%. En cuanto a los entrenamientos de los modelos, la mayoría de los estudios usaron un 70% de los datos para entrenamiento, 20% para validación, y 10% para prueba.

El uso de CNN [43] para la detección de enfermedades en el cultivo de arroz, se observó que los resultados obtenidos son generalmente positivos, con altos niveles de precisión en la mayoría de los modelos analizados. Sin embargo, es crucial considerar el riesgo de sesgo en los estudios individuales, que puede haber influido en la validez de los resultados globales. Un factor clave en este riesgo es el sesgo de selección, ya que algunos estudios se basaron en conjuntos de datos limitados o específicos de ciertas variedades o regiones de arroz. Esto limita la capacidad de generalizar los resultados para evaluar el desempeño de la CNN en otros cultivos.

Aunque los estudios muestran un rendimiento notable, también existe una desigualdad en los resultados, principalmente debido a factores como la calidad y variabilidad de las imágenes utilizadas, así como las diferencias en las etapas de desarrollo de las enfermedades [44]. Algunos estudios también mostraron un sesgo potencial debido al tamaño limitado de los conjuntos de datos o a la falta de representación de todas las variaciones posibles de las enfermedades.

Para llevar a cabo esta revisión sistemática los resultados se presentan descritos en las respuestas a las preguntas de investigación realizadas.

1. ¿Qué arquitecturas CNN son los más utilizados comúnmente en estudios para detección de enfermedades en el cultivo de arroz?

Las arquitecturas CNN más utilizados para la detección de enfermedades en el cultivo de arroz incluyen principalmente arquitecturas estándar como VGG-16, ResNet y variantes personalizadas de CNN. Además, en los últimos años,

se ha observado un creciente uso de modelos híbridos que integran CNN con otras arquitecturas avanzadas, como el Vision Transformer, BEiT [32] mejora el rendimiento en tareas complejas de clasificación de enfermedades. Los modelos híbridos combinan lo mejor de las CNN para la extracción de características espaciales con los Transformer para la atención a secuencias, lo que mejora el rendimiento en tareas complejas de clasificación de enfermedades.

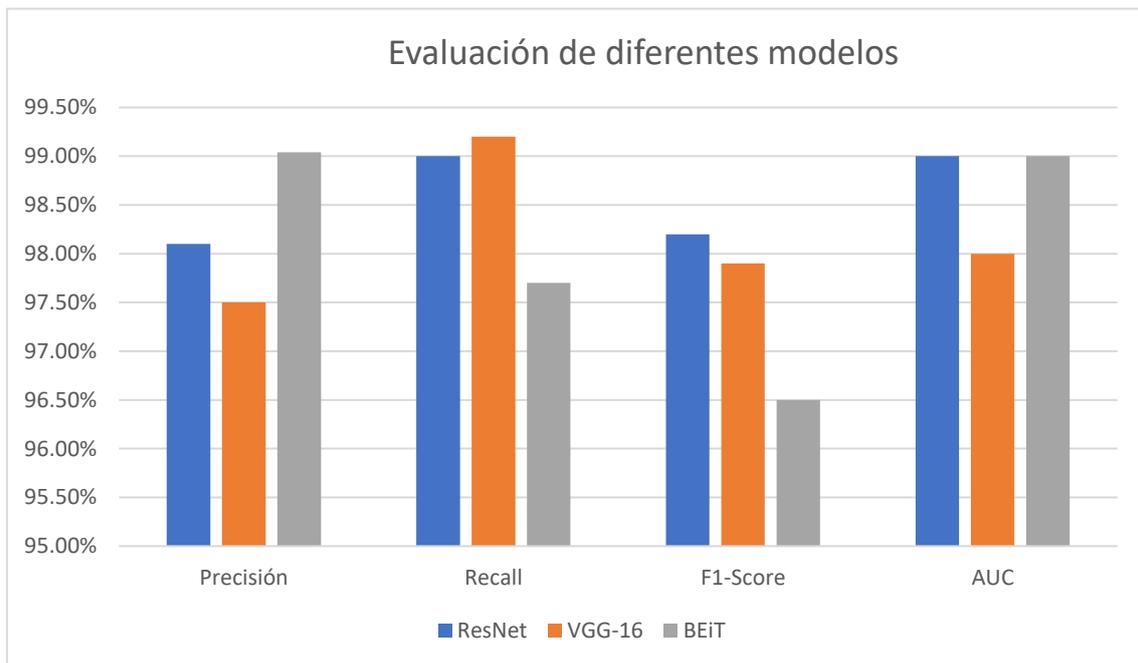


Figura 6. Evaluación de ResNet, VGG-16 Y BEiT

- ¿Qué tan efectivas son las redes neuronales convolucionales en la detección de enfermedades de arroz?

Los estudios revisados muestran un rango de precisión que varía entre el 97% y el 99%, lo que resalta la capacidad de estos modelos para clasificar correctamente las enfermedades con una baja tasa de falsos negativos recalcando que la mayoría de los estudios reportaron una sensibilidad (recall) superior al 99%, lo que implica que las CNN son particularmente eficaces en detectar casos positivos (enfermedades) sin dejar pasar muchas instancias de enfermedad. Esto confirma la efectividad de las CNN como herramientas

confiables en el diagnóstico de enfermedades en arroz. Esto es consistente con los resultados de estudios como el de Oliva et al. [35] que reportan una precisión del 97.7% en la detección de enfermedades específicas en arroz.

3. ¿Cómo son los entrenamientos de la CNN según estudios para detectar las enfermedades en el cultivo de arroz?

El entrenamiento de las CNN se realiza generalmente con una división estándar de los datos: 70% para entrenamiento, 20% para validación y 10% para prueba. Los modelos son entrenados por un número de épocas que varía entre 50 y 100, y se utilizan técnicas avanzadas como Early Stopping y Transfer Learning para evitar el sobreajuste y mejorar la precisión. Estos enfoques están bien documentados en estudios como el de Haikal et al. [7] que utilizaron un entrenamiento de 50 épocas y validación cruzada para evaluar su modelo Mixed-Based.

4. ¿Qué tipo de datos se utiliza para entrenar la CNN para la detección de enfermedades en cultivos de arroz?

Los datos utilizados consisten en imágenes de hojas de arroz, se complementan estos datos con información espectral y ambiental como es temperatura y las tasas de crecimiento de las plantas. En el estudio de Ritharson et al. se utilizaron más de 16,000 imágenes de arroz para entrenar un modelo CNN VGG-16 donde muestra grandes volúmenes de datos para entrenar el modelo haciéndolo más efectivo.

5. ¿Qué tipo de datos se utiliza para entrenar la CNN para la detección de enfermedades en cultivos de arroz?

Las métricas más comúnmente utilizadas para evaluar el rendimiento de los modelos CNN en la detección de enfermedades en arroz incluyen precisión, recall, F1-Score y AUC. Estas métricas permiten una evaluación completa del rendimiento del modelo, equilibrando tanto la capacidad de detectar correctamente los casos positivos (recall) como la precisión en las

predicciones (precisión). El modelo híbrido Modelo híbrido CNN y Transformer, ResViT-Rice reportó una precisión de 99.04% para el diagnóstico de la enfermedad del arroz [37].

IV. DISCUSIÓN y CONCLUSIONES

Discusión

El uso de las CNN para detectar enfermedades en cultivos de arroz muestra resultados consistentes en su efectividad para el diagnóstico temprano. Modelos como ResViT-Rice alcanzan una precisión del 99.04%, combinando CNN y Transformers. Sin embargo, existen contradicciones en otras métricas como el recall y el F1-Score, lo que indica que algunos modelos pueden clasificar bien los casos negativos, pero fallar en detectar positivos [45]. La falta de grandes conjuntos de datos etiquetados limita el rendimiento de las CNN. A pesar de los resultados prometedores, hay desafíos relacionados con la calidad de los datos y la generalización de los modelos [46]. La implementación de modelos como ResViT-Rice tiene potencial, pero es crucial abordar las limitaciones para optimizar su desempeño en la práctica agrícola [37].

Mientras las arquitecturas CNN no híbridos han mostrado un desempeño positivo en la detección de enfermedades en cultivos de arroz, aunque presentan limitaciones. Son efectivos para identificar patrones visuales, pero tienen dificultades para manejar relaciones espaciales a largo plazo. Aunque logran alta precisión, su recall y F1-Score son más bajos que los modelos híbridos, lo que es crítico para la detección temprana de enfermedades [47]. Además, dependen de grandes cantidades de datos de entrenamiento etiquetados, y la calidad de las predicciones está relacionada con la diversidad de las imágenes. A pesar de estos desafíos, los CNN no híbridos son una opción válida, especialmente con conjuntos de datos representativos y técnicas de mejora de imagen [48]. Sin embargo, su capacidad de generalización sigue siendo una limitación clave.

Conclusiones

Esta revisión sistemática ha demostrado que el uso de CNN para la detección de enfermedades en cultivos de arroz es altamente efectivo, logrando niveles de precisión entre el 97% y el 99%. La capacidad de estas arquitecturas para extraer características relevantes de imágenes de hojas de arroz ha permitido mejorar significativamente la identificación de enfermedades en comparación con métodos tradicionales. Además, la combinación de CNN con modelos híbridos como Transformers ha optimizado aún más el rendimiento de clasificación y detección temprana.

A pesar de estos avances, la implementación práctica enfrenta desafíos importantes. La calidad y diversidad de los conjuntos de datos son factores críticos que afectan la capacidad de generalización de los modelos, lo que sugiere la necesidad de bases de datos más representativas y variadas. Asimismo, los costos computacionales elevados y la necesidad de hardware especializado limitan la aplicación de estas soluciones en entornos agrícolas con recursos limitados.

Los resultados analizados indican que el uso de técnicas como Transfer Learning, Data Augmentation y modelos híbridos ha permitido superar parcialmente algunas limitaciones de las CNN. Sin embargo, la escasez de datos etiquetados y la variabilidad en las condiciones de captura de imágenes siguen representando barreras que deben abordarse en futuras investigaciones.

En este sentido, se recomienda el desarrollo de estrategias de adquisición de datos más eficientes, la implementación de modelos más livianos y optimizados para dispositivos con menor capacidad de cómputo, y la integración de sensores remotos con sistemas basados en inteligencia artificial para mejorar la detección en tiempo real. La combinación de CNN con técnicas de aprendizaje semi-supervisado o auto-supervisado podría ser una vía prometedora para mitigar la dependencia de grandes volúmenes de datos etiquetados y mejorar la aplicabilidad de estos modelos en el sector agrícola.

V. Referencias

- [1] P. J. A. A. a. J. A. M. G. F. C. Gavilánez Luna, «Dimensiones adecuadas de parcela experimental para ensayos de arroz en jujan, ecuador,» vol. Vol. 34, nº 3, pp. 245-252, 2022.
- [2] C. A. M. Carpio, «Manejo integrado de los principales Chrysomelidae defoliadores en el cultivo de la Soja,» 23 Julio 2024.
- [3] E. R. S. A. a. M. C. V. Ruiz, «Dinámica poblacional de los principales insectos plaga y benéficos en el cultivo de arroz,» 2022.
- [4] J. V. A. A. a. M. A. C. Molina, «Clasificación de frutas basadas en redes neuronales convolucionales,» *Polo del Conocimiento: Revista científico-profesional*, pp. 3-22, January 2020.
- [5] G. R. Y. Z. e. a. S.-W. Chin, *Smart Agricultural Technology* 8., 2024.
- [6] U. N. A. P. V. S. V. S. M. S. y. C. D. R. Tarai, «Plant growth regulators in pomegranate,» de *Proc. Plant Growth Regulators in Tropical and Sub-tropical Fruit Crops*, Boca Raton, FL, USA, 2022.
- [7] N. Y. A. R. Ahmad Luthfi Azmi Haikal, «Comprehensive mixed-based data augmentation for detection of rice leaf disease in the wild,» *Crop Protection*, p. 106816, 2024.
- [8] T. N. D. H. G. Chandrasekaran, «Multimodal sentimental analysis for social media applications: A comprehensive review,» *Wiley Interdisciplinary Reviews*, vol. 11, nº 5, 2021.

- [9] S. T. Y. J. L. D. J. L. K. & W. R. Dong, «ESA-Net: An efficient scale-aware network for small crop pest detection,» *Expert Systems With Applications*, vol. 236, p. 121308, 2023.
- [10] S. Chawathe, «Rice Disease Detection by Image Analysis,» *10th Annual Computing and Communication Workshop and Conference (CCWC)*, 2020.
- [11] K. R. N. G. V. K. y. R. S. I. Govindharaj, «Enhancing Rice Crop Health Assessment: Evaluating Disease Identification with a CNN-RF Hybrid Approach,» *International Conference on Innovations and Challenges in Emerging Technologies (ICICET)*, 2024.
- [12] S. G. a. K. Sarkar, «Rice Leaf Diseases Classification Using CNN With Transfer Learning,» *Calcutta Conference (CALCON)*, pp. 230-236, 2020.
- [13] V. K. y. P. Dhiman, «A Deep Neural Network based disease detection scheme for Citrus fruits,» de *2020 International Conference on Smart Electronics and Communication (ICOSEC)*, Trichy, India, 2020.
- [14] S. C. P. K. T. S. A. O. Poornima Singh Thakur, «Vision transformer meets convolutional neural network for plant disease classification,» *Ecological Informatics*, p. 102245, 2023.
- [15] M. U. L. P. B. Kanchi Lohitha Lakshmi, «Optimized truncated singular value decomposition and hybrid deep neural network with random forest for automated disease prediction,» *Biomedical Signal Processing and Control*, vol. 128, p. 107010, 2025.
- [16] S. R. A. S. M. A. A. A. E. B. A. A. Roopali Dogra, «Deep learning model for detection of brown spot rice leaf disease with smart agriculture,» *Computers and Electrical Engineering*,, vol. 109, p. 108659, 2023.

- [17] S. Venu, T. L. Surekha, P. Vasavi y P. V. Kumar, «Deep Learning based Leaf Disease Detection using Convolutional Neural Network,» *2023 5th International Conference on Inventive Research in Computing Applications (ICIRCA)*, pp. 01-05, 2023.
- [18] B. A. R. D. Mohsen Soori, «Artificial intelligence, machine learning and deep learning in advanced robotics, a review,» *Cognitive Robotics*, vol. 3, pp. 54-70, 2023.
- [19] Z. J. H. A. J. A.-D. A. D. Y. A.-S. O. J. F. M. A. A.-A. M. F. L. Alzubaidi Laith, «Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,» *Journal of Big Data*, vol. 8, pp. 2196-1115, 2021.
- [20] A. K. G. S. M. P. A. Sakshi Indolia, «Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach,» *Procedia Computer Science*, pp. 679-688, 2018.
- [21] A. N. K. A. J. A. H. Sakib Shadman, «An Overview of Convolutional Neural Network: Its Architecture and Applications,» *Preprints*, 2019.
- [22] L. S. A. S. Z. Ahsan Md M, «Machine-Learning-Based Disease Diagnosis: A Comprehensive Review,» *Healthcare*, vol. 10, pp. 2227-9032, 2022.
- [23] Devopedia, «Matriz de Confusión,» *Devopedia*, vol. 6, 2019.
- [24] A. C. D. A. D. L. V. C. Arcila Diaz Juan, «Real-time Identification of Rice Leaf Diseases using Convolutional Neural Networks,» *International Journal of Computing*, vol. 23, p. 4, 2024.
- [25] T. Szandała, «Unlocking the black box of CNNs: Visualising the decision-making process with PRISM,» *Information Sciences*, vol. 642, p. 119162, 2023.

- [26] A. B. G. F. Douglas Leite, «Advancements and outlooks in utilizing Convolutional Neural Networks for plant disease severity assessment: A comprehensive review,» *Smart Agricultural Technology*, vol. 9, nº 100573, 2024.
- [27] K. E. B. D. K. P. A. B. T. Kwame Antwi, «On the application of image augmentation for plant disease detection: A systematic literature review,» *Smart Agricultural Technology*, vol. 9, p. 100590, 2024.
- [28] X. M. Y.-M. W. C.-T. L. W.-S. L. Li-Wei Liu, «Using artificial intelligence algorithms to predict rice (*Oryza sativa* L.) growth rate for precision agriculture,» *Computers and Electronics in Agriculture*, vol. 187, p. 106286, 2021.
- [29] Y. L. B. S. T. B. Md Taimur Ahad, «Comparison of CNN-based deep learning architectures for rice diseases classification,» *Artificial Intelligence in Agriculture*, vol. 9, pp. 22-35, 2023.
- [30] T. T. T. S. T. T. O. K. K. Tomoaki Yamaguchi, «A study on optimal input images for rice yield prediction models using CNN with UAV imagery and its reasoning using explainable AI,» *European Journal of Agronomy*, vol. 164, p. 127512, 2025.
- [31] J. L. S. F. K. Reuben Alfred, «Optimizing dataset diversity for a robust deep-learning model in rice blast disease identification to enhance crop health assessment across diverse conditions,» *Smart Agricultural Technology*, vol. 10, p. 100726, 2025.
- [32] S. T. A. M. F. U. I. S. M. A. S. S. M. Amitabha Chakrabarty, «An interpretable fusion model integrating lightweight CNN and transformer architectures for rice leaf disease identification,» *Ecological Informatics*, vol. 82, p. 102718, 2024.
- [33] J. X. J. S. W. W. X. Z. Z. W. W. L. J. L. Y. V. F. N. X. Xuehan Ji, «Noninvasive Raman spectroscopy for the detection of rice bacterial leaf blight and bacterial leaf streak,» *Talanta*, vol. 282, p. 126962, 2025.

- [34] K. R. X. A. M. J. E. R. A. J. P. Isaac Ritharson, «DeepRice: A deep learning and deep feature based classification of Rice leaf disease subtypes,» *Artificial Intelligence in Agriculture*, vol. 11, pp. 34-49, 2024.
- [35] H. N. S. Oliva Debnath, «An IoT-based intelligent farming using CNN for early disease detection in rice paddy,» *Microprocessors and Microsystems*, vol. 94, p. 104631, 2022.
- [36] S. C. D. K. S. Anshuman Nayak, «Application of smartphone-image processing and transfer learning for rice disease and nutrient deficiency detection,» *Smart Agricultural Technology*, vol. 4, p. 100195, 2023.
- [37] Y. Zhang, L. Zhong, Y. Ding, H. Yu y Z. Zhai, «ResViT-Rice: A Deep Learning Model Combining Residual Module and Transformer Encoder for Accurate Detection of Rice Diseases,» *Agriculture*, vol. 13, p. 1264, 2023.
- [38] K. P. K. J. D. S. D. D. Sanasam Premananda Singh, «Custom Convolutional Neural Network for Detection and Classification of Rice Plant Diseases,» *Procedia Computer Science*, vol. 218, pp. 2026-2040, 2023.
- [39] H. W. Z. P. Yibin Wang, «Rice diseases detection and classification using attention based neural network and bayesian optimization,» *Expert Systems with Applications*, vol. 178, p. 114770, 2021.
- [40] M. N. M. A. R. M. I. P. F. A. M. A. R. A. Md. Zsaim Uddin, «E2ETCA: End-to-end training of CNN and attention ensembles for rice disease diagnosis1,» *Journal of Integrative Agriculture*, pp. 2095-3119, 2024.
- [41] T. W. Q. W. Jinchao Pan, «RiceNet: A two stage machine learning method for rice disease identification,» *Biosystems Engineering*, vol. 225, pp. 25-40, 2023.

- [42] S. V. T. Daniya, «A novel Moore-Penrose pseudo-inverse weight-based Deep Convolution Neural Network for bacterial leaf blight disease detection system in rice plant,» *Advances in Engineering Software*, vol. 174, p. 103336, 2022.
- [43] J. Z. Xiaozhong Yu, «A Review on the Application of Deep Learning Methods in Detection and Identification of Rice Diseases and Pests,» *Computers, Materials and Continua*, vol. 78, pp. 197-225, 2024.
- [44] A. B. S. R. K. D. K. P. S. A. M. N. S. D. S. B. D. S. M. Deepa Joshi, «Label-free non-invasive classification of rice seeds using optical coherence tomography assisted with deep neural network,» *Optics & Laser Technology*, vol. 137, p. 106861, 2021.
- [45] M. K. S. S. S. A. A. M. M. A. a. S. S. I. H. M. Alshahrani, «Quantum-Inspired Moth Flame Optimizer Enhanced Deep Learning for Automated Rice Variety Classification,» *IEEE Access*, vol. 11, 2023.
- [46] L. S. J. H. J. Y. K. H. Qi Yang, «A near real-time deep learning approach for detecting rice phenology based on UAV images,» *Agricultural and Forest Meteorology*, p. 107938, 2020.
- [47] L. Y. H. L. S. P. H. H. H. X. M. L. Hongxing Peng, «Different life cycles of rice pests' images recognition based on adaptive lightweight DC-ghost module,» *Expert Systems with Applications*, vol. 255, p. 124645, 2024.
- [48] K. C. S. D. J. T. A. W. R. H. Y. J. Ning Yang, «Rapid image detection and recognition of rice false smut based on mobile smart devices with anti-light features from cloud database,» *Biosystems Engineering*, vol. 218, pp. 229-244, 2022.

ANEXOS

Anexo 1. Reporte de similitud

Fernandez Fernandez Kenedy Dav Pinglo Cabezas ...

Redes neuronales convolucionales para la detección de enfermedades en arroz: una Revisión Sistemática

 Universidad Señor de Sipán

Detalles del documento

Identificador de la entrega

trn:oid:::26396:428465036

Fecha de entrega

9 feb 2025, 11:59 p.m. GMT-5

Fecha de descarga

10 feb 2025, 12:00 a.m. GMT-5

Nombre de archivo

turnitin BachillerPinglo_Fernandez.docx

Tamaño de archivo

634.8 KB

34 Páginas

6,620 Palabras

38,396 Caracteres



Página 2 of 42 - Descripción general de integridad

Identificador de la entrega trn:oid:::26396:428465036

23% Similitud general

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

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 8 palabras)

Fuentes principales

12%  Fuentes de Internet

5%  Publicaciones

19%  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.