

# Disease detection system in rice leaves, using Deep Learning models

Villegas-Cubas, Juan Elias, Dr<sup>1</sup>, Valdiviezo-Sandoval, Hector David, Bach<sup>2</sup>

<sup>1,2</sup>Grupo de Investigación en Ciencia de Datos, Inteligencia Artificial y Ciberseguridad, Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Perú, jvillegasc@unprg.edu.pe, hvaldiviezos@unprg.edu.pe

**Abstract**– This research focuses on the issue of diseases in rice cultivation, a critical concern for the Peruvian economy. Early detection of these diseases is vital to mitigate adverse impacts on production. The proposed model was trained using the "Paddy Doctor" dataset, comprising 10,407 RGB images with a resolution of 480 x 640 pixels, categorized into 10 classes. A comparison between a CNN and InceptionV3 revealed InceptionV3's significant superiority in recall (74.107% vs. 46.923%) and precision (87.680% vs. 80.947%) after 100 epochs. For the final evaluation of the InceptionV3 model fine-tuned with 400 epochs, results included a accuracy of 88.00%, precision of 90.31%, and recall of 86.10%. Despite an 88% accuracy, the loss degree suggests potential enhancements, such as augmenting the dataset with more images. The detection system, developed using TensorflowJS and Angular, is accessible online, offering a valuable tool for farmers and promoting enhanced production and sustainability in the rice sector.

**Keywords**-- Rice Diseases, Early Detection, Deep Learning, InceptionV3

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).  
**ISSN, ISBN:** (to be inserted by LACCEI).  
**DO NOT REMOVE**

# Sistema de detección de enfermedades en hojas de arroz, usando modelos de Deep Learning

Villegas-Cubas, Juan Elias, Dr<sup>1</sup>, Valdiviezo-Sandoval, Hector David, Bach<sup>2</sup>

<sup>1,2</sup>Grupo de Investigación en Ciencia de Datos, Inteligencia Artificial y Ciberseguridad, Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Perú, jvillegasc@unprg.edu.pe, hvaldiviezos@unprg.edu.pe

**Resumen**—Esta investigación se enfoca en la problemática de las enfermedades en el cultivo de arroz, que tienen un impacto significativo en la economía peruana. La detección temprana de estas enfermedades es esencial para mitigar los efectos adversos en la producción. Para el entrenamiento del modelo propuesto se utilizó el conjunto de datos "Paddy Doctor" de 13,878 imágenes RGB con una resolución de 480 x 640 píxeles, divididas en 13 clases. Se realizó una comparación entre una CNN e InceptionV3, y luego de 100 épocas se reveló que InceptionV3 superó significativamente a la CNN en la métrica de recall (74.107% frente a 46.923%) y precisión (87.680% frente a 80.947%). Para la evaluación final del modelo InceptionV3 afinado con 400 épocas, se obtuvieron los resultados de una pérdida del 40.059%, una exactitud del 88%, una precisión del 90.310%, y un recall del 86.095%. Aunque la exactitud fue del 88%, el grado de pérdida sugiere mejoras, tal como la recolección de más imágenes para el conjunto de datos. El sistema de detección se desarrolló con TensorflowJS y Angular, y se encuentra disponible en la web. Este sistema, ofrece una herramienta valiosa para los agricultores, promoviendo la mejora de la producción en el sector arrocero.

**Palabras clave** - Enfermedades de Arroz, Detección Temprana, Deep Learning, InceptionV3

## I. INTRODUCCIÓN

Una de las principales problemáticas en el cultivo de arroz en Perú y el mundo es la presencia de enfermedades que afectan la producción y calidad del grano. Entre las enfermedades más comunes y de mayor impacto económico se encuentran la quemazón causada por el hongo *Pyricularia grisea*, el manchado de grano (complejo de hongos, bacterias e insectos), el virus de la hoja blanca o "cinta blanca", el tizón de la vaina y la pudrición de la panícula causado por especies de *Rhizoctonia* y *Sarocladium oryzae*, entre otras [1].

En Perú, el consumo de arroz es el más alto de Latinoamérica, con un consumo promedio por habitante de 54 kg anuales [2]. El arroz representa el 6% del PBI agropecuario del país, con una participación mayor a la de cultivos tradicionales como el café (3%) y la caña de azúcar (4%). Actualmente, existen alrededor de 100,000 productores de arroz a nivel nacional [3]. En cuanto a porcentajes, el consumo per cápita de arroz en Perú ha aumentado desde los 42 kg en el año 2000 hasta aproximadamente 61 kg en la actualidad [4].

El arroz es afectado por varios tipos de plaga, tanto de insectos como enfermedades y malezas que, bajo condiciones normales, pueden causar pérdidas de rendimiento promedio del 30% [5], sin embargo, al conocer con precisión qué causa la enfermedad, se puede crear un plan estratégico que no solo

impida que la enfermedad se propague a nivel regional o nacional, sino que también ayuda a disminuir los efectos negativos en la producción del cultivo afectado [1].

La identificación temprana de las enfermedades en el cultivo de arroz es fundamental para evitar su expansión y reducir su impacto en la producción. Sin embargo, en muchos casos, los agricultores tienen dificultades para diferenciar los síntomas de las enfermedades y realizar un monitoreo adecuado debido a la gran extensión de los arrozales y las condiciones de bajo riego [6].

Para prevenir y controlar las enfermedades en el cultivo de arroz, es importante mantener los campos limpios, libres de malezas y hospederos de enfermedades, así como asegurar una adecuada nutrición de las plantas. Además, es fundamental realizar evaluaciones en campo para detectar cualquier avance o síntoma de enfermedad y actuar de manera rápida y efectiva en su control [7].

En este contexto, surge la necesidad de desarrollar soluciones efectivas para la identificación temprana de enfermedades en hojas de arroz. En respuesta a esta demanda, este estudio propone el desarrollo de un sistema inteligente basado en Deep Learning. La hipótesis subyacente es que este enfoque permitirá la detección temprana de enfermedades en hojas de arroz de manera precisa y exacta. Los objetivos específicos incluyen la selección y análisis de un conjunto de imágenes, la construcción y entrenamiento de modelos de Deep Learning, la optimización del sistema y la evaluación de su rendimiento. Este estudio no solo aborda una brecha significativa en la identificación de enfermedades en el cultivo de arroz, sino que también busca contribuir a la mejora de la producción y sostenibilidad en el sector arrocero peruano.

## II. BASE TEÓRICA

### A. Deep Learning

El deep learning es una vertiente del machine learning que utiliza redes neuronales con tres o más capas para simular el comportamiento humano. Aunque todas las capas son capaces de hacer predicciones, las capas ocultas adicionales en el deep learning mejoran la precisión. Esta tecnología impulsa aplicaciones de inteligencia artificial (IA) que automatizan tareas analíticas y físicas sin intervención humana, como asistentes digitales y detección de fraudes. La inteligencia artificial (IA) engloba sistemas que imitan la inteligencia humana, y el machine learning es su subconjunto que utiliza datos para mejorar su rendimiento. El deep learning, a su vez, es una evolución del machine learning que emplea redes neuronales más complejas para alcanzar mayores niveles de precisión en tareas específicas [8].

Digital Object Identifier: (only for full papers, inserted by LACCEI).

ISSN, ISBN: (to be inserted by LACCEI).

DO NOT REMOVE

### B. Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales o CNN por sus siglas en inglés son un tipo de red neuronal artificial que se utiliza para el aprendizaje profundo y el análisis de imágenes [10]. Las CNN son particularmente útiles para identificar patrones en imágenes con el fin de reconocer objetos, clases y categorías. Las CNN tienen varias capas, incluyendo una capa convolucional, una capa de agrupación y una capa completamente conectada. Siendo la capa convolucional la encargada de realizar la mayoría de los cálculos. En esta etapa, grupos de píxeles de la imagen son procesados mediante convoluciones con una matriz llamada kernel, generando así una nueva matriz de salida, que representa la nueva capa de neuronas ocultas. La capa de agrupación sigue, contribuyendo a la eficiencia y previniendo el sobreajuste al reducir el tamaño de la imagen de entrada. Esto disminuye la cantidad de parámetros y cálculos requeridos. Finalmente, la capa completamente conectada utiliza las características extraídas por las capas anteriores para clasificar la imagen en una o varias categorías. Estas capas son esenciales para el procesamiento jerárquico de características en una CNN [9].

### C. Inception V3

Inceptionv3 es un modelo de CNN que se utiliza para clasificar imágenes en diferentes categorías. Fue desarrollado por Google como parte del proyecto Inception que se centra en la mejora de las CNN para tareas de visión por computadora [10]. “Inception” proviene del concepto de capas de procesamiento que se asemejan a capas dentro de capas, como una especie de “ensamblaje” de características. Inceptionv3 usa filtros de convolución de distintos tamaños para extraer rasgos de las imágenes y lograr gran precisión en su clasificación. Inceptionv3 es importante en inteligencia artificial para detectar patrones en imágenes y clasificarlas con exactitud.

### D. Métricas de rendimiento

La comparación y evaluación de modelos basados en Deep Learning se realiza mediante la matriz de confusión y las métricas de exactitud, precisión y sensibilidad [11]:

Exactitud (Accuracy): Muestra la proporción de predicciones correctas en relación con el número total de predicciones, es utilizada para medir el rendimiento global de un modelo, es la métrica con mayor uso en medir el rendimiento y se calcula por la fórmula (1)

$$\text{Exactitud} = (\text{VP} + \text{VN}) / (\text{VP} + \text{FP} + \text{FN} + \text{VN}) \quad (1)$$

Precisión (Precision): Mide la proporción de predicciones positivas correctas (verdaderos positivos) con respecto al número total de predicciones positivas, y se calcula por la fórmula (2).

$$\text{Precisión} = (\text{VP}) / (\text{VP} + \text{FP}) \quad (2)$$

Sensibilidad (Recall): Mide la proporción de predicciones positivas correctas (verdaderos positivos) con respecto al número total de instancias positivas en los datos reales, y se calcula por la fórmula (3)

$$\text{Sensibilidad} = (\text{VP}) / (\text{VP} + \text{FN}) \quad (3)$$

### E. Antecedentes relevantes

Para la detección de enfermedades en las hojas de cultivos de arroz, se han desarrollado modelos y sistemas del resultado de un aprendizaje de un conjunto de datos con herramientas de aprendizaje automático y aprendizaje profundo. Se han desarrollado modelos de Support Vector Machine (SVM) que han logrado un rendimiento de 98.55% [12], 97% [13], 96.5% [14], 95% [15] y 94.16% [16] de exactitud; un sistema de detección automática de enfermedades en hojas de arroz utilizando una red neuronal de función de base radial optimizada con el algoritmo Salp Swarm [17], con una exactitud de 98.67%; una aplicación inteligente basada en Internet de las cosas con un algoritmo de red profunda SEWA-SPBO basado en Maxout [18], con una exactitud de 98.50%; un modelo de una red neuronal híbrida mejorada que constaba de dos submodelos: un extractor de características de lesiones mediante un algoritmo de extracción de regiones de interés (ROI) y un modelo de clasificación DenseNet que obtiene una exactitud de 96% [19]; un modelo ShuffleNet V2 que logró un 95% de exactitud [20] y el modelo ICAI-V4 que obtiene una exactitud de 98.5% [21].

Además se han desarrollado modelos basados en Deep learning específicamente redes neuronales convolucionales (CNN) para la detección temprana de las enfermedades en hojas de cultivos de arroz mediante imágenes, como el modelo de aprendizaje integrado basado en stacking que utiliza 4 CNN como aprendices base y SVM como sub aprendiz que obtiene una exactitud de 99.69% [22]; un modelo basado en la CNN WOACW\_SimpleNet que logra una exactitud de 98.5% [23]; el modelo de una CNN con un algoritmo de mejora de datos llamado Progressive Wasserstein Generative Adversarial Network (PWGAN-GP) que logró 98.5% de exactitud [24]; un modelo DenseNet desarrollado en referencia [25] con una exactitud de 98.0%; la CNN con un mecanismo de atención ECA alcanzando 96.5% de exactitud [26]; un modelo de una CNN mejorada con un 96.5% de exactitud [27]; el modelo EC (Bi-GRU, CNN y DMN) + OLIFHA-BA que obtuvo una exactitud de 96% [28]; el modelo de clasificación híbrido GCL con una exactitud de 95.31% [29]; un modelo de una CNN de convolución separable en profundidad que alcanzó una exactitud de 95.3% [30]; un sistema basado en CNN que alcanzó un 95% de exactitud [31]; el modelo que se basó en la técnica “SSSO-based deep learning” y que alcanzó 93.5% de exactitud [32], el modelo basado en YOLO desarrollado por referencia [33] con una exactitud de 96.5%, y los modelos basados en InceptionV3 desarrollados en la referencia [34] y referencia [35] que lograron una exactitud de 96.5% y 94.5% respectivamente.

### III. MÉTODO

La investigación se desarrolló con las etapas que se muestran en la Fig. 1.

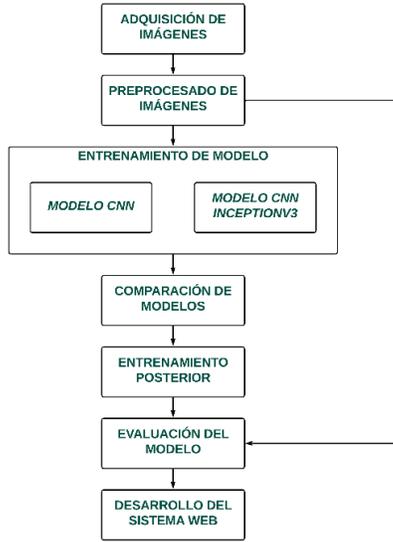


Fig. 1 Etapas de la investigación

Se inicia con la adquisición de las imágenes de hojas de arroz etiquetadas, luego las imágenes son procesadas a tensores de  $224 \times 224 \times 3$ , luego se construyen dos modelos una red neuronal convolucional particular y una red neuronal pre entrenada basada en InceptionV3, posteriormente se realizó una comparativa de ambos modelos entrenados, para luego optimizar el modelo que obtiene mejores resultados, posteriormente se evalúa el rendimiento del modelo en la detección de enfermedades de hojas de arroz, y finalmente se desarrolla una plataforma para la detección automática de enfermedades de hojas de arroz en una imagen ingresada.

### IV. RESULTADOS

#### A. Conjunto de datos

Se utilizó el conjunto de datos de Paddy Doctor: Paddy Disease Classification publicada por referencia [36], contiene 13,878 imágenes de hojas de arroz, y está disponible públicamente en la web de Kaggle. Es el mayor conjunto de datos de imágenes visuales anotadas por expertos para experimentar y comparar algoritmos Deep learning y visión por computadora, y ha sido utilizado por referencia [26]. También proporcionan metadatos adicionales para cada imagen, como la variedad de arroz y la edad.

Los datos están separados en dos carpetas, una para el entrenamiento y otra para la evaluación o pruebas. Además de archivos CSV con la descripción del conjunto de entrenamiento, validación y la de evaluación. Las imágenes del conjunto de datos están categorizadas en 10 clases, de las cuales 9 son de enfermedades diferentes del arroz y una clase de hojas sanas.

El conjunto de datos tiene origen de una competencia de Kaggle, por lo que la carpeta test\_images, no tiene clases, es por lo cual se consideró realizar una segmentación de la carpeta train\_images, en una carpeta trainImages que serviría para el entrenamiento, otra carpeta valImages que serviría para el conjunto de datos de la validación, y la última carpeta testImages que se usó para la evaluación del modelo entrenado, la proporción que se tuvo de estas carpetas fue del 70%, 20% y 10% del total de imágenes respectivamente por cada clase, así como se puede observar en la tabla I.

TABLA I  
CONJUNTO DE IMÁGENES DE HOJA DE ARROZ

Clase	Número de imágenes			
	Train	Val	Test	Total
bacterial_leaf_blight	335	95	49	479
bacterial_leaf_streak	266	76	38	380
bacterial_panicle_blight	235	67	35	337
blast	1216	347	175	1738
brown_spot	675	193	97	965
dead_heart	1009	288	145	1442
downy_mildew	434	124	62	620
hispa	1115	318	161	1594
normal	1234	352	178	1764
tungro	761	217	110	1088
Total	7280	2077	1050	10407

Las imágenes se cargan al entorno de programación, en la Fig. 2, se muestra un ejemplo de imágenes de hojas de arroz etiquetadas con su clase respectiva.

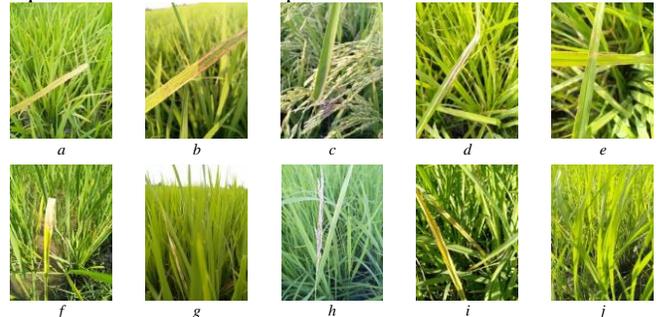


Fig. 2 Imágenes de enfermedades en arroz (a) Bacterial Leaf Blight (b) Bacterial Leaf Streak (c) Bacterial Panicle Blight (d) Blast (e) Brown spot (f) Downy Mildew (g) Hispa (h) Dead Heart (i) Tungro (j) Normal.

#### B. Procesamiento de imágenes

Las imágenes originales se adquirieron a color RGB, en formato JPEG, y con una resolución de  $1080 \times 1440$  píxeles; para reducir el procesamiento y uso de recursos se hizo uso de las librerías Keras y Tensorflow para cargar las imágenes y preprocesarlas en un tensor de  $224 \times 224 \times 3$  de tamaño. En la Fig. 3, se muestran 5 imágenes de entrenamiento preprocesadas, y las dimensiones del tensor.



Fig. 3 Visualización de imágenes procesadas

### C. Entrenamiento

1) *CNN*. Se propone una red neuronal convolucional particular que fue construida en base a prueba y error desde cero; esta CNN particular inicia con una capa de entrada que recibe las imágenes procesadas de  $224 \times 224 \times 3$  dimensiones, luego una capa convolucional (Conv2D) que aplica 32 filtros de tamaño  $3 \times 3$ , generando mapas de activación para resaltar características locales. A esta capa le sigue una operación de agrupación máxima (MaxPooling2D) que reduce la resolución a la mitad, preservando los 32 canales resultantes. Posteriormente, se implementa otra capa convolucional (Conv2D) con 64 filtros de  $3 \times 3$ , seguida de una nueva operación de agrupación máxima que disminuye la dimensionalidad de los mapas de activación a  $54 \times 54$  píxeles con 64 canales. La arquitectura continúa con una tercera capa convolucional (Conv2D) que utiliza 128 filtros de  $3 \times 3$ , seguida nuevamente por una capa de agrupación máxima que reduce la resolución a  $26 \times 26$  píxeles con 128 canales.

Después de estas capas de extracción de características, se utiliza una capa de aplanado (Flatten) para convertir la salida en un vector unidimensional de 86,528 elementos. Este vector alimenta capas totalmente conectadas (Dense) con 256, 128 y 10 neuronas, respectivamente. La presencia de capas de desactivación (Dropout) entre las capas totalmente conectadas contribuye a mitigar el sobreajuste al apagar selectivamente neuronas durante el entrenamiento. La última capa, con 10 neuronas, representa la salida de la red y se adapta a problemas de clasificación con 10 categorías. En resumen, la arquitectura propuesta busca automáticamente identificar patrones y características relevantes en las imágenes de entrada, permitiendo una clasificación precisa en el contexto de un conjunto de datos específico, la arquitectura de la CNN particular se muestra en la Fig. 4.

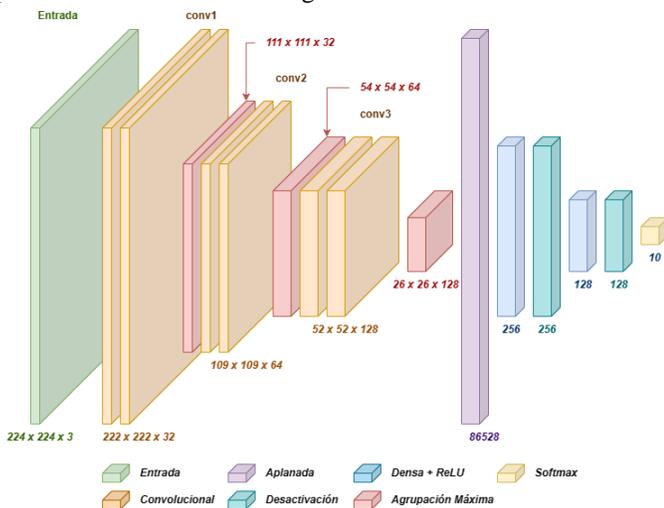


Fig. 4 Arquitectura de la CNN propuesta

Para el entrenamiento de la red neuronal convolucional se tomó en cuenta a las 10,407 imágenes de entrenamiento preprocesadas, 7280 se utilizaron para entrenar y 2077 se utilizaron para validar la CNN propuesta; lo restante se utilizó para el testeó del modelo en la siguiente etapa.

El modelo CNN particular se entrenó con 100 épocas para obtener el mejor rendimiento. En la Fig. 5, se muestra la curva de aprendizaje de la CNN particular después de 100 épocas de entrenamiento. Se puede observar que la curva de aprendizaje va en crecimiento exponencial sin embargo después de la cantidad significativa de épocas la CNN no ha llegado a un alto porcentaje de precisión, ya que solo logró un 68.36% de precisión.

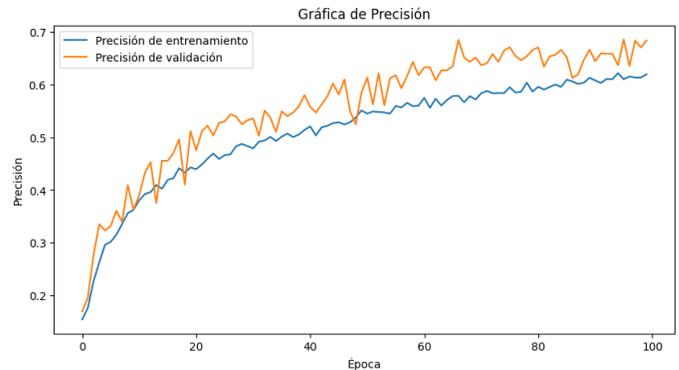


Fig. 5 Curva de aprendizaje de la CNN propuesta

2) *InceptionV3*. Se empleó la arquitectura pre entrenada InceptionV3, una red neuronal convolucional del ámbito de la Deep learning y visión por computadora, para abordar el problema de detección de enfermedades en hojas de cultivos de arroz. La adaptación de la arquitectura incluyó la omisión de las capas de clasificación finales, para la incorporación de capas personalizadas para ajustar el modelo a las necesidades del problema. La salida de la última capa convolucional fue procesada mediante una capa de agrupamiento por promedio global (Average Pooling) para reducir la dimensionalidad, seguida de una capa densa con 1024 neuronas y activación ReLU. La capa final consistió en un conjunto de neuronas igual al número de clases en la tarea de clasificación, utilizando una función de activación softmax para generar probabilidades de pertenencia a cada clase. En la Fig. 6 se muestra la arquitectura de la CNN inception V3 propuesta.

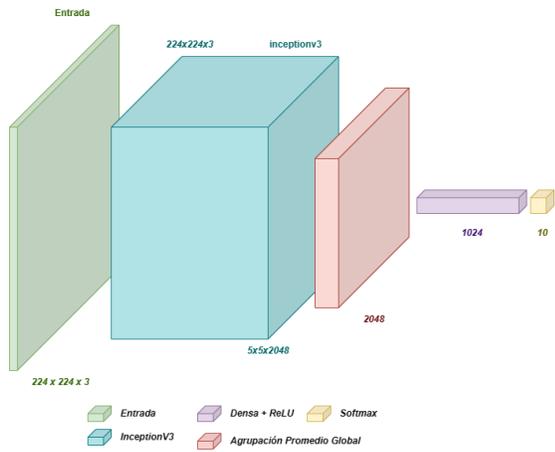


Fig. 6 Arquitectura de la CNN Inception V3 propuesta

Este enfoque permitió aprovechar las capacidades de extracción de características de InceptionV3 mientras se adaptaban las capas finales para la identificación de enfermedades en hojas de arroz.

Para el entrenamiento de la CNN InceptionV3, se tomaron en cuenta las mismas imágenes de entrenamiento preprocesadas. Para este modelo el entrenamiento fue de 200 épocas para obtener el mejor rendimiento y hacer una comparación con la CNN propuesta anteriormente. En la Fig. 7, se muestra la curva de aprendizaje de la CNN después de 200 épocas de entrenamiento. Se puede observar que la curva de aprendizaje va en crecimiento exponencial sin embargo no ha conseguido un resultado estable, el punto más alto que logró fue de 85.65% de precisión en la validación, por lo que sugirió seguir el entrenamiento por más épocas.

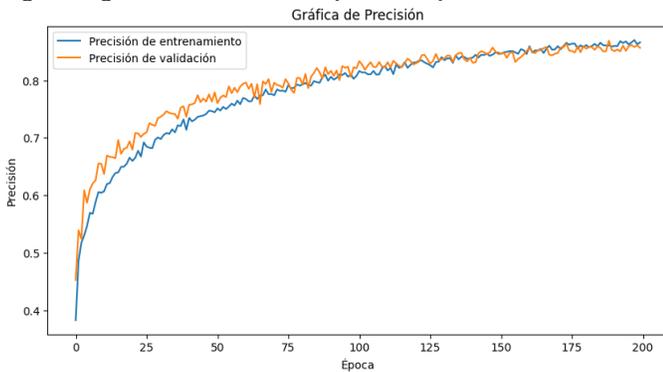


Fig. 7 Curva de aprendizaje de la CNN Inception V3 propuesta

3) *CNN vs InceptionV3*. Se realizó una comparativa entre los modelos de la CNN y la CNN InceptionV3, el punto de comparación fue en la época 100. Para esta comparativa se hizo uso de la métrica precisión y sensibilidad (recall)

La precisión mide la proporción de casos positivos que el modelo identificó correctamente en relación con todos los casos clasificados como positivos; en la Fig. 8, se muestra la curva de la precisión de los dos modelos propuestos.

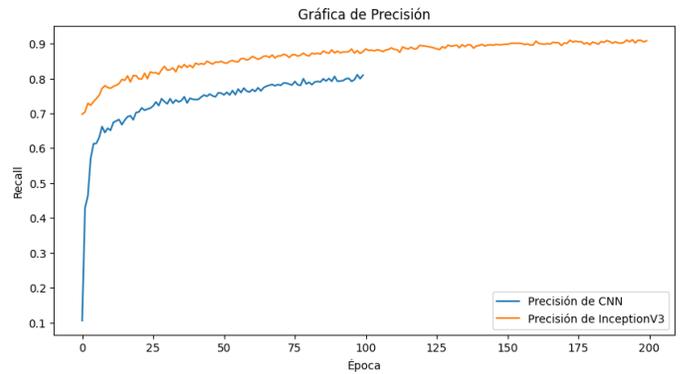


Fig. 8 Curva de precisión de los modelos propuestos

Se observa que en la época 100, el valor de la precisión para la CNN es de 80,947%, mientras que el modelo de la CNN InceptionV3 en la misma época obtuvo una precisión de 87,68%.

La sensibilidad destaca la capacidad de un modelo de clasificación para identificar correctamente todos los casos positivos reales, es decir mide la capacidad del modelo para recuperar o encontrar todos los casos positivos. En la Fig. 9, al ubicarnos en la época 100, el valor del recall para la CNN propuesta es de 46.923%, mientras que el modelo de CNN InceptionV3 en la misma época el valor del recall es de 74,107%.

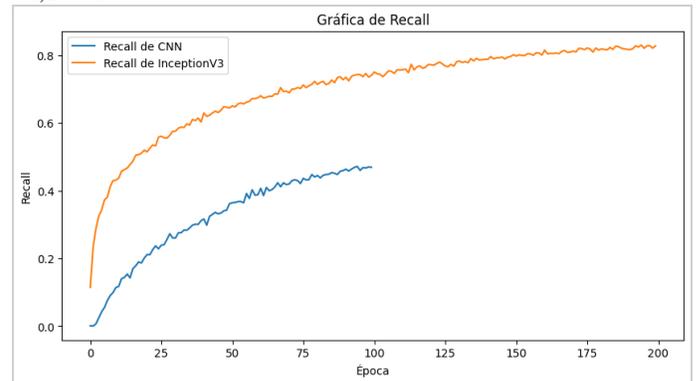


Fig. 9 Curva de sensibilidad de los modelos propuestos

Esto evidencia, ya desde un entrenamiento prolongado, de 100 épocas para ambos modelos, que la CNN InceptionV3 es mejor para este problema en comparación de la CNN; por lo que se afina el modelo CNN InceptionV3 con 400 épocas y se visualiza que la exactitud en el entrenamiento del modelo mejora, pero en la evaluación ya no; en la Fig. 10 se muestra la exactitud de la CNN Inception V3 en el entrenamiento y en la validación; donde se determina que en la época 175 logran resultados similares.

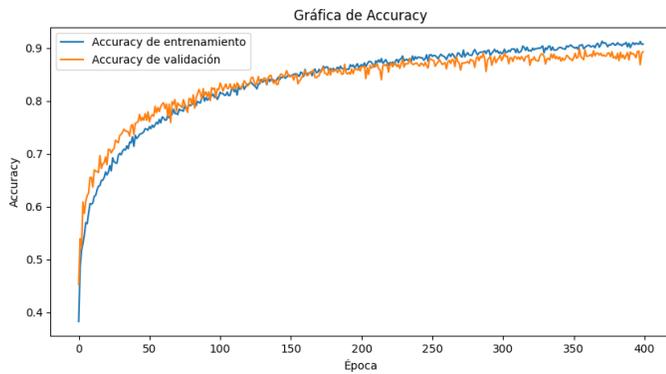


Fig. 10 Curva de exactitud del modelo CNN Inception V3 optimizada

#### D. Evaluación del modelo

La evaluación se realizó con los resultados obtenidos en la matriz de confusión, con 1050 pruebas realizadas. El modelo es capaz de hacer las mejores predicciones en la clase 3, 5, 7 y 8 que son las enfermedades “Blast”, “Corazón muerto”, “Hispa”, “Normal”, “Tungro”, ya que estas clases el modelo logró predecir 29, 24, 28 y 33 imágenes respectivamente, que pertenecían a esa clase realmente. Por otro lado, las clases, “Mancha foliar bacteriana”, “Rayado bacteriano de las hojas”, “Mancha bacteriana del panículo”, “Mancha café” y “Mildiú veloso” no terminan de identificar bien cuando es o no la clase real a la que pertenece. Como se muestra en la Fig. 11.

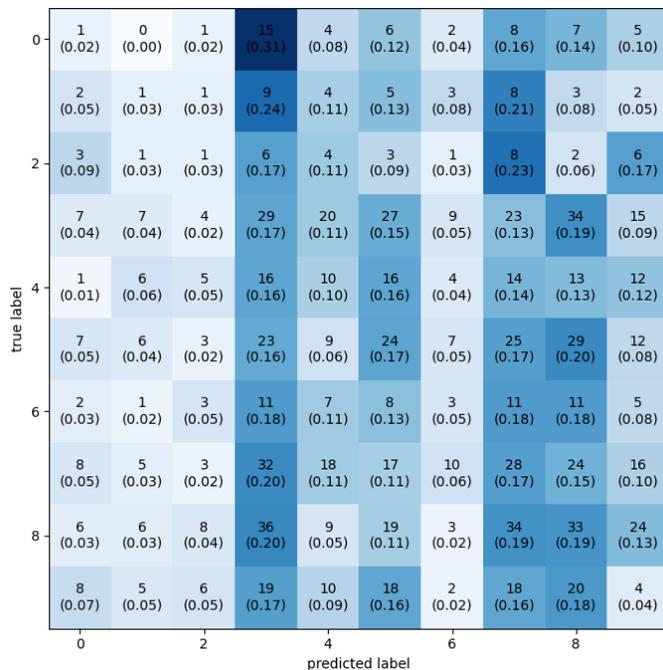


Fig. 11 Matriz de confusión de los resultados de InceptionV3

Se calcularon las métricas de exactitud, precisión y sensibilidad; con las fórmulas (1), (2) y (3) respectivamente. Los resultados obtenidos se muestran en la Tabla II.

TABLA II

MÉTRICAS DE RENDIMIENTO DE LA CNN INCEPTION V3

Métrica Evaluada	Resultado
Exactitud	88.00%
Precisión	90.31%
Sensibilidad	86.10%

El modelo CNN Inception V3 desarrollada en esta investigación logra un 88.00% de exactitud lo que indica que el 88% de las predicciones del modelo son correctas en forma global; una precisión de 90.31% lo que significa que el modelo tiene una alta precisión en la clasificación de las instancias positivas y una sensibilidad de 86.10% lo que indica que el modelo es capaz de identificar correctamente el 86.095% de todas las instancias positivas en los datos.

#### E. Sistema inteligente

Finalmente se desarrolló un sistema inteligente que hace uso del modelo CNN inception V3 para la predicción de enfermedades en sembríos de arroz; tiene una interfaz web, donde en la parte izquierda se ingresa una imagen con sembríos de arroz y el sistema en la parte derecha de la misma se muestra las diez clases entrenadas que se ordenan de acuerdo con la probabilidad de existencia de la enfermedad según el aprendizaje realizado por el modelo.

Para el desarrollo del sistema se usó la librería TensorflowJS para poder convertir el modelo de origen de keras en un archivo JSON, y pueda ser usado en el framework de desarrollo Angular, con el que fue desarrollado el sistema y publicado en un servidor web en la nube para el acceso desde cualquier lugar con internet. En la Fig. 12 se muestra la interfaz del sistema con una prueba realizada.

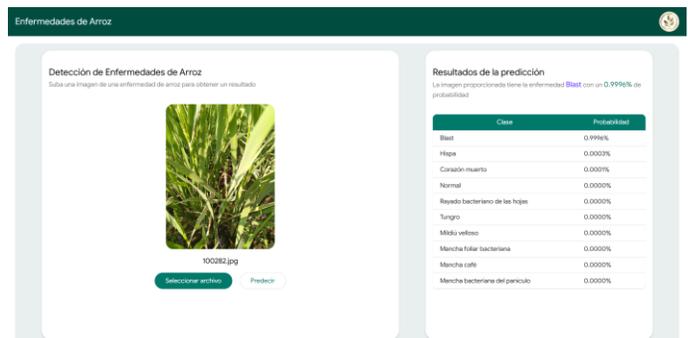


Fig. 12 Interfaz web del sistema de predicción de enfermedades en sembrío de arroz.

## F. Discusión de resultados

Después de haber obtenido los resultados, se observó que el modelo InceptionV3 demostró un rendimiento significativamente superior en comparación con la propuesta de CNN, en las pruebas realizadas durante las primeras 100 épocas. Durante el análisis de la curva de aprendizaje, se destacó que InceptionV3 logró una curva distintiva, lo cual motivó la continuación del entrenamiento a lo largo de varias épocas adicionales.

En cuanto a las métricas del modelo InceptionV3, se observó que, al inicio del entrenamiento, los valores de exactitud, precisión y sensibilidad eran consistentemente inferiores en comparación con las métricas de validación. Este patrón persistió hasta aproximadamente la época 300, momento en el cual las métricas de validación tendieron a situarse por debajo de las métricas de entrenamiento, fenómeno que se mantuvo hasta la época 400.

Algunos antecedentes utilizaron menos número de clases como la referencia [26] que obtuvieron un rendimiento de 96.5%, un valor mayor al rendimiento que se obtuvo en esta investigación, sin embargo, cabe resaltar que ellos usaron solamente 5 clases del mismo conjunto de datos, siendo la mitad de las clases totales.

Otros estudios previos utilizaron menor cantidad de imágenes como la referencia [34] que utilizaron solamente 3000 imágenes, entrenaron con una CNN Inception V3 y lograron un rendimiento de 96.5%, un resultado mayor que el obtenido en esta investigación, pero eso es debido a que el conjunto de imágenes y las clases que utilizaron es menor a la de la presente investigación.

## V. CONCLUSIONES

En la revisión bibliográfica se evidenció que los modelos de redes neuronales convolucionales son los más utilizados para la detección de enfermedades en hojas de arroz utilizando imágenes.

Se seleccionó el conjunto de datos de Paddy Doctor Competition, donde posteriormente se analizó y preprocesó, para ser usado en la construcción de dos modelos.

Los modelos CNN e InceptionV3 fueron entrenados, el modelo de InceptionV3 resultó ser el mejor, por lo que se afinó con 400 épocas, logrando una exactitud de 88.00%, una precisión de 90.31% y una sensibilidad de 86.10%.

Con el modelo ya entrenado se desarrolló un sistema web basado en Deep learning usando InceptionV3, como base y posteriormente se alojó en un servidor web en la nube, donde está accesible.

Algunas clases del conjunto de datos no tienen la suficiente cantidad de imágenes como otras clases, por lo que existe un desequilibrio al momento de aprender, en cuando a la cantidad, esto ha hecho que el modelo no llegue a aprender de forma correcta las clases que tienen pocas imágenes las cuales son, “Mancha foliar bacteriana”, “Rayado bacteriano de las hojas”, “Mancha bacteriana del panículo”, “Mancha café”, “Mildió veloso”.

Es por lo anterior que se recomienda, para un trabajo futuro, obtener y considerar más imágenes de estas clases para tener una cantidad homogénea de imágenes para entrenar al modelo, y que pueda identificarlas de una manera óptima.

## REFERENCES

- [1] AGROPERÚ INFORMA. (2022). *Enfermedades que ponen en riesgo la producción de arroz*. AGROPERÚ INFORMA. <https://www.agroperu.pe/enfermedades-que-ponen-en-riesgo-la-produccion-de-arroz/>
- [2] Ministerio de Agricultura y Riego (2023). *Mercado de Arroz*. MIDAGRI. <https://www.midagri.gob.pe/portal/26-sector-agrario/arroz/220-mercado>
- [3] Ministerio de Agricultura y Riego (2023). *Producción de Arroz*. MIDAGRI. <https://www.midagri.gob.pe/portal/26-sector-agrario/arroz>
- [4] Agencia Agraria De Noticias. (2022, August 17). *Consumo per cápita de arroz en Perú alcanza un volumen aproximado de 61 kilos*. Agraria.Pe. <https://agraria.pe/noticias/consumo-per-capita-de-arroz-en-peru-alcanza-un-volumen-aprox-28976>
- [5] Agencia Agraria De Noticias. (2019, November 25). *Plaga, enfermedades y malezas pueden causar pérdidas en promedio de 30% en el rendimiento productivo del arroz*. Agraria.Pe. <https://agraria.pe/noticias/plaga-enfermedades-y-malezas-pueden-causar-perdidas-en-promedio-20303>
- [6] Gutiérrez S., & Cúdom M. (2013). *Guía para la Identificación de Enfermedades del Cultivo del Arroz (Oryza sativa L.) en la Provincia de Corrientes*. Gobierno Provincial de Corrientes. [https://www.acpaarrozcorrientes.org.ar/Paginas/Guia\\_de\\_enfermedades.pdf](https://www.acpaarrozcorrientes.org.ar/Paginas/Guia_de_enfermedades.pdf)
- [7] Hortus. (2023). *Prevenir o Contrarrestar enfermedades en arroz*. Hortus. <https://www.hortus.com.pe/detalle-noticia/prevenir-o-contrarrestar-enfermedades-en-arroz>
- [8] IBM. (2023). *¿Qué es el deep learning?* www.Ibm.Com. <https://www.ibm.com/mx-es/topics/deep-learning>
- [9] Bonilla Carrión, C. (2020). *Redes Convolucionales*. Universidad de Sevilla, Sevilla. <https://hdl.handle.net/11441/115221>
- [10] Oyarzo, M. (2020). *Aprendizaje Supervisado en Detección de Osteoartritis de Rodilla a partir de Imágenes de Resonancia Magnética*. <https://doi.org/10.13140/RG.2.2.10452.32649>
- [11] Zapeta Hernández, A., Galindo Rosales, G. A., Juan Santiago, H. J., & Martínez Lee, M. (2022). *Métricas de rendimiento para evaluar el aprendizaje automático en la clasificación de imágenes petroleras utilizando redes neuronales convolucionales*. *Ciencia Latina Revista Científica Multidisciplinar*, 6(5), 4624–4637. [https://doi.org/10.37811/cl\\_rcm.v6i5.3420](https://doi.org/10.37811/cl_rcm.v6i5.3420)
- [12] Goluguri, N. R., Devi K, S., & CH, P. (2022). *Infectious diseases of Rice plants classified using a deep learning-powered Least Squares Support Vector Machine Model*. *Indian Journal of Computer Science and Engineering*, 13(5), 1640–1659. <https://doi.org/10.21817/indjcs/2022/v13i5/221305186>
- [13] Lamba, S., Kukreja, V., Baliyan, A., Rani, S., & Ahmed, S. H. (2023). *A Novel Hybrid Severity Prediction Model for Blast Paddy Disease Using Machine Learning*. *Sustainability*, 15(2), 1502. <https://doi.org/10.3390/su15021502>
- [14] Chen, L., Zou, J., Yuan, Y., & He, H. (2023). *Improved domain adaptive rice disease image recognition based on a novel attention mechanism*. *Computers and Electronics in Agriculture*, 208, 107806. <https://doi.org/10.1016/j.compag.2023.107806>
- [15] Chaudhary, S., & Kumar, U. (2022). *Analysis of Methods of Machine Learning Techniques for Detection and Classification of Brown Spot (Rice) Disease*. *Universal Journal of Agricultural Research*, 10(5), 464–473. <https://doi.org/10.13189/ujar.2022.100502>
- [16] Dogra, R., Rani, S., Singh, A., Albahar, M. A., Barrera, A. E., & Alkhayyat, A. (2023). *Deep learning model for detection of brown spot rice leaf disease with smart agriculture*. *Computers and Electrical Engineering*, 109, 108659. <https://doi.org/10.1016/j.compeleceng.2023.108659>
- [17] Ramkumar Raja, M., V. J., Shajin, F. H., & Roopa Devi, E. M. (2023). *Radial basis function Neural Network optimized with Salp Swarm*

- algorithm espoused paddy leaf disease classification. *Biomedical Signal Processing and Control*, 86, 105038. <https://doi.org/10.1016/j.bspc.2023.105038>
- [18] Shanmugam, V., Madhusudhana Rao, T. V., Rao, H. J., & Maram, B. (2023). Internet of things based smart application for rice leaf disease classification using optimization integrated deep maxout network. *Concurrency and Computation: Practice and Experience*, 35(6), 1–1. <https://doi.org/10.1002/cpe.7545>
- [19] Liu, W., Yu, L., & Luo, J. (2022). A hybrid attention-enhanced DenseNet neural network model based on improved U-Net for rice leaf disease identification. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.922809>
- [20] Zhou, Y., Fu, C., Zhai, Y., Li, J., Jin, Z., & Xu, Y. (2023). Identification of Rice Leaf Disease Using Improved ShuffleNet V2. *Computers, Materials & Continua*, 75(2), 4501–4517. <https://doi.org/10.32604/cmc.2023.038446>
- [21] Zeng, N., Gong, G., Zhou, G., & Hu, C. (2023). An Accurate Classification of Rice Diseases Based on ICAI-V4. *Plants*, 12(11), 2225. <https://doi.org/10.3390/plants12112225>
- [22] Yang, L., Yu, X., Zhang, S., Zhang, H., Xu, S., Long, H., & Zhu, Y. (2023). Stacking-based and improved convolutional neural network: a new approach in rice leaf disease identification. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1165940>
- [23] Lu, Y., Zhang, X., Zeng, N., Liu, W., & Shang, R. (2022). Image classification and identification for rice leaf diseases based on improved WOACW\_SimpleNet. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1008819>
- [24] Lu, Y., Tao, X., Zeng, N., Du, J., & Shang, R. (2023). Enhanced CNN Classification Capability for Small Rice Disease Datasets Using Progressive WGAN-GP: Algorithms and Applications. *Remote Sensing*, 15(7), 1789. <https://doi.org/10.3390/rs15071789>
- [25] Jiang, M., Feng, C., Fang, X., Huang, Q., Zhang, C., & Shi, X. (2023). Rice Disease Identification Method Based on Attention Mechanism and Deep Dense Network. *Electronics*, 12(3), 508. <https://doi.org/10.3390/electronics12030508>
- [26] Ni, H., Shi, Z., Karungaru, S., Lv, S., Li, X., Wang, X., & Zhang, J. (2023). Classification of Typical Pests and Diseases of Rice Based on the ECA Attention Mechanism. *Agriculture*, 13(5), 1066. <https://doi.org/10.3390/agriculture13051066>
- [27] Cui, J., & Tan, F. (2023). Rice Plaque Detection and Identification Based on an Improved Convolutional Neural Network. *Agriculture*, 13(1), 170. <https://doi.org/10.3390/agriculture13010170>
- [28] Sakhamuri, S., & Kumar, K. K. (2023). Optimal Training Ensemble of Classifiers for Classification of Rice Leaf Disease. *International Journal of Advanced Computer Science and Applications*, 14(3), 94–105. <https://doi.org/10.14569/IJACSA.2023.0140311>
- [29] Lamba, S., Baliyan, A., & Kukreja, V. (2023). A novel GCL hybrid classification model for paddy diseases. *International Journal of Information Technology*, 15(2), 1127–1136. <https://doi.org/10.1007/s41870-022-01094-6>
- [30] Prottasha, Md. S. I., & Reza, S. M. S. (2022). A classification model based on depthwise separable convolutional neural network to identify rice plant diseases. *International Journal of Electrical and Computer Engineering (IJECE)*, 12(4), 3642. <https://doi.org/10.11591/ijece.v12i4.pp3642-3654>
- [31] Latif, G., Abdelhamid, S. E., Mallouhy, R. E., Alghazo, J., & Kazimi, Z. A. (2022). Deep Learning Utilization in Agriculture: Detection of Rice Plant Diseases Using an Improved CNN Model. *Plants*, 11(17), 2230. <https://doi.org/10.3390/plants11172230>
- [32] Daniya, T., & Srinivasan, V. (2023). Shuffled shepherd social optimization based deep learning for rice leaf disease classification and severity percentage prediction. *Concurrency and Computation: Practice and Experience*, 35(4). <https://doi.org/10.1002/cpe.7523>
- [33] Jain, S., Sahni, R., Khargonkar, T., Gupta, H., Verma, O. P., Sharma, T. K., Bhardwaj, T., Agarwal, S., & Kim, H. (2022). Automatic Rice Disease Detection and Assistance Framework Using Deep Learning and a Chatbot. *Electronics*, 11(14), 2110. <https://doi.org/10.3390/electronics11142110>
- [34] Simhadri, C. G., & Kondaveeti, H. K. (2023). Automatic Recognition of Rice Leaf Diseases Using Transfer Learning. *Agronomy*, 13(4), 961. <https://doi.org/10.3390/agronomy13040961>
- [35] Nayak, A., Chakraborty, S., & Swain, D. K. (2023). Application of smartphone-image processing and transfer learning for rice disease and nutrient deficiency detection. *Smart Agricultural Technology*, 4. <https://doi.org/10.1016/j.atech.2023.100195>
- [36] Petchiammal, Kiruba, B., Murugan, & Arjunan, P. (2023). Paddy Doctor: A Visual Image Dataset for Automated Paddy Disease Classification and Benchmarking. *Proceedings of the 6th Joint International Conference on Data Science & Management of Data (10th ACM IKDD CODS and 28th COMAD)*, 203–207. <https://doi.org/10.1145/3570991.3570994>