

Detección de enfermedades mediante las hojas del maíz utilizando DEEP Learning para los agricultores del distrito de Curahuasi Abancay-2024

Disease detection through corn leaves using DEEP Learning for farmers in the Curahuasi Abancay district-2024

Juan Carlos Valverde-Ramirez^A, Francisco Cari-Incahuanaco^B y Alejandrina Huaylla-Quispe^C

Resumen— El maíz es un cultivo importante en el Perú, esencial para la seguridad alimentaria. Sin embargo, su cultivo enfrenta desafíos significativos debido a enfermedades debilitando como la Trips del maíz, y el virus del Roya del maíz, que pueden conducir a graves pérdidas del rendimiento. Los métodos tradicionales de diagnóstico de enfermedades de las plantas a menudo requieren mucho tiempo y son propensos a errores, lo que requiere enfoque más eficiente. Este estudio explora la aplicación de aprendizaje profundo, especialmente las redes neuronales convolucionales (CNN), en la detección y clasificación automática de enfermedades del maíz. El objetivo de este estudio es comparar la precisión de dos arquitecturas: CNN básico y ResNet18, la imagen de prueba utilizó un conjunto de datos formado de 3087 imágenes que comprenden de enfermedades de las hojas del maíz, las clases están conformados por, Trips, Roya y hojas Sanas. Además, realizamos un ajuste hiperparámetros para mejorar el rendimiento de los modelos y el mapeo de activación de clases ponderado por gradiente, para la interpretabilidad del modelo. Nuestros resultados muestran que el modelo ResNet18 demostró una precisión del 99.38% al distinguir entre plantas sanas y enfermas. Los resultados de este estudio contribuyen al avance de las aplicaciones de IA en la agricultura, en particular en el diagnóstico de enfermedades del maíz en Curahuasi Perú.

Palabras clave: Enfermedades del maíz; Redes neuronales convolucionales; Aprendizaje Profundo; Trips del Maíz y Roya del Maíz.

Abstract— maize is an important crop in Perú, essential for food security. However, its cultivation faces significant challenges due to debilitating diseases such as corn thrips and corn rust virus, which can lead to severe yield losses. Traditional methods of plant disease diagnosis are often time consuming and error prone, requiring more efficient approach. This study explores the application of deep learning, especially convolutional neural networks (CNNs), in the automatic detection and classification of maize diseases. The objective of this study is to compare the accuracy of two architectures. Basic CNN and ResNet18, the test image used a data set consisting of 3087 images comprising of maize leaf diseases, classes consisting of, Thrips, Rust and Healthy Leaves, in addition, we performed hyperparameter adjustment to improve model performance and gradient-weighted class activation mapping for model interpretability. Our results show that the ResNet18 model demonstrated an accuracy of 99.38% in distinguishing between healthy and diseased plants. The results of this study contribute to the advancement of applications in agriculture, particularly in the diagnosis of maize diseases in Curahuasi Perú.

Keywords: Corn diseases; Convolutional neural networks; Deep learning; Corn thrips and Corn rust.

1 DESCRIPCIÓN DEL PROBLEMA

El maíz, conocido como *Zea mays*, es un cultivo alimentario básico vital que desempeña un papel crucial en la seguridad alimentaria mundial, es un grado de semilla imprescindible que se produce en todo el mundo. Es una de las principales fuentes de aceite, almidón, etanol y alimento para los ganados [1]. El valor nutricional del cereal del maíz contribuye a la prevención de enfermedades como la diabetes tipo II, el cáncer y las enfermedades cardíacas [2]. El maíz es

uno de los cereales más utilizados para la dieta de los seres humanos, así, como la alimentación animal y las industrias [3].

Para satisfacer estas necesidades el maíz, el arroz y el trigo son los cultivos principales para la seguridad alimentaria y sostenibilidad del mundo, la producción de estos tres cultivos representan el 90% de su producción total del alimento del ser humano [4]. Entre ellos, el maíz ocupa el segundo lugar del sembrío solo siendo superado por el arroz, es uno de los cereales de consumo principal. El éxito de la

Autores:

- A. **ORCID iD** <https://orcid.org/0009-0006-7654-7151>
Juan Carlos Valverde Ramirez, Universidad Nacional Micaela Bastidas de Apurímac-Perú
162179@unamba.edu.pe
- B. **ORCID iD** <https://orcid.org/0000-0002-2807-0495>
Francisco Cari Incahuanaco, Universidad Nacional Micaela Bastidas de Apurímac-Perú fcari@unamba.edu.pe
- C. **ORCID iD** <https://orcid.org/0000-0002-0258-8632>
Alejandrina Huaylla Quispe, Universidad Micaela Bastidas de Apurímac, Perú. ahuaylla@unamba.edu.pe

agricultura es crucial para la prosperidad de una nación, así, mismo la agricultura no satisface la creciente demanda alimentaria [5]. Según Clotilde et. at., el ministerio de la agricultura del Perú, la producción del maíz aproximadamente es de 88.8%, en su totalidad que se produce entre los meses de la primavera que abarca de octubre a enero, los meses de producción del maíz son de febrero a julio que son el 11.2% [6], así mismo, Apurímac destaca como el principal productor de maíz, siendo uno de los departamento con mayor superficie de siembra, especialmente en la zona de Abancay-Cuarahuasi. En esta esta región se cultiva principalmente el maíz blanco, el cual es también comercializado localmente, por otro lado, se encarga de abastecer a la capital del Perú-Lima. Según Murillo et al., [7], el maíz desempeña un papel crucial como fuente importante de nutracéuticos, conocidas por sus propiedades de prevención de enfermedades y beneficios para la salud. Sin embargo, la sostenibilidad y la productividad del cultivo del maíz están amenazadas debido a diversas plagas y enfermedades de los cultivos. El sector agrícola de esta región reconoce el cultivo de maíz financieramente viable y ambientalmente adaptable. Entre estas enfermedades, trips del maíz, y el virus de la roya del maíz; se detectan como dos de las más dañinas y generalizadas que actualmente amenazan a la seguridad alimentaria en la región. La Fig 1 muestra las hojas del maíz infectadas por Trips y Roya, así como hojas sanas.

El Trips es el resultado de un grupo de hongos transmitidos por el suelo con muchas especies diferentes: ocasionando que las hojas perezcan quemaduras, retraso en el crecimiento, ocasionando perdidas en la producción, se alimenta principalmente de las hojas tiernas [8]. Por el contrario, la Roya, transmitido por chicharitas, causa vetas en las hojas del maíz atrofiando el crecimiento, lo que puede reducir el rendimiento del grano del maíz. Las infestaciones graves de la Roya puede conducir a perdidas de rendimiento de hasta el 100% en la mayoría de los casos [9], se han notificado brotes de estas enfermedades en el distrito de Curahuasi. El impacto de estas enfermedades va más allá de las precauciones agrícolas, ya que conlleva grandes consecuencias para los agricultores, un aumento de los precios del maíz, escasez de alimentos, especialmente para la población que dependen en gran medida del maíz, un estudio de Boddupalli et al. La necrosis letal del maíz porsí sola ha causado una pérdida anual estimada de más de 180 millones de dólares en África Oriental [10], lo que subraya la necesidad crucial de abordar este problema. Por lo tanto, la detección y el diagnóstico preciso de estas enfermedades son cruciales para permitir intervenciones oportunas y desarrollar estrategias de mitigaciones eficaces.

La identificación tradicional para diagnosticar enfermedades en las plantas se basa en la identificación

visual, lo cual permite pérdida de tiempo y conocimientos especializados. La interpretación errónea de los síntomas de las enfermedades puede llevar al uso innecesario o inadecuados pesticidas, por lo consiguiente impacto ambiental negativo y mayor riesgo de efectos tóxicos en el cultivo del maíz. La aplicación de inteligencia artificial (IA) en la agricultura presenta alternativas prometedoras que abordan los desafíos inherentes a los métodos tradicionales al permitir de la detección oportuna y precisa de enfermedades en el cultivo del maíz.

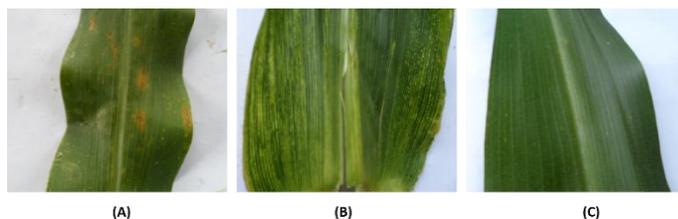


Fig. 1. Ejemplo de hojas de maíz indicadas por: (A) Trips (B) Roya y (C) Sanas.

El aprendizaje profundo ha revolucionado el campo de la visión artificial al proporcionar herramientas potentes para el aprendizaje de características y de representación jerárquica de la información visual. Varias aplicaciones del aprendizaje profundo en la visión artificial incluyen en la clasificación de imágenes, la detección de objetos, reconocimiento facial, generaciones de imágenes y más, entre ellos tenemos, los modelos que incluyen ResNet, VGGNet y EfficientNet se utilizan continuamente en tareas de clasificación de imágenes [11][12]. El aprendizaje profundo abarca una variedad de arquitectura de las redes neuronales, diseñadas para aprender y representar patrones complejos a partir en datos [12].

Erneste en su estudio, presento dos arquitecturas de CNN profundas: CNN básicas Y una ResNet, con un objetivo de detectar enfermedades del maíz y lograr una mayor precisión en el reconocimiento. Los modelos fueron entrenados con diferentes conjuntos de datos que contienen 3,200 imágenes, incluyendo casos de Trips, Roya y hojas sanas. Se utilizaron diversos hiperparametros, como tasas de abandono (Dropout), tamaño de lote (batch size), función de pérdida (loss function) y tasas de aprendizaje, los cuales fueron optimizados mediante una amplia experimentación. El objetivo principal es investigar la eficacia de estas arquitecturas para identificar y clasificar enfermedades del maíz, en particular la compleja combinación de Trips y Roya. Para ello, se evaluó el rendimiento de los modelos utilizando métricas estándar, que proporcionan información sobre su robustez frente a diversas clases de enfermedades.

- Se desarrollaron varias arquitecturas CNN para la detección automática del virus de Trips y Roya del maíz, fundamentales para el diagnóstico y el tratamiento temprano.
- Optimización de las arquitecturas CNN y mejora su rendimiento para la tarea de diagnóstico.
- Se probaron y evaluaron las arquitecturas CNN para la

detección de enfermedades del maíz, proporcionando un análisis integral de su eficacia y áreas potenciales de mejora, y

- Contribución del avance de las aplicaciones de IA en la agricultura, especialmente en el diagnóstico de enfermedades del maíz, crucial para el distrito de Curahuasi-Abancay_Apurímac_Perú, donde el maíz es un cultivo alimentario básico.

1.1 Trabajos relacionados

Para mitigar los daños causados para las enfermedades del maíz, numerosos estudios han propuesto diversas técnicas para detectar e identificarlas. Estos métodos utilizan algoritmos de aprendizaje profundo para analizar imágenes de plantas de maíz, identificando así patrones indicativos de enfermedades.

En Waheed et al [13], propusieron una arquitectura CNN densa optimizada (DenseNet) para reconocimiento de la roya común del maíz, la mancha gris de la hoja del maíz y las enfermedades NCLB. Para el estudio, se utilizaron 11097, imágenes de entrenamiento y 1235 de prueba, y el modelo DenseNet logro una precisión de rendimiento del 98.06%. El estudio concluyo que DenseNet supero las arquitecturas CNN existentes, como EfficientNet, VGG19Net, NASNet y XceptionNet. Ahila Priyadharshini, Arivazhagan, arun y murnalini [14], utilizaron LeNet modificado, una arquitectura CNN, para la detección de NCLB, mancha gris de la hoja y la enfermedad fungida común de la roya. Aunque LeNet tiene una arquitectura pequeña, la evaluación experimental mostró una precisión del 97.89% de las 3852 imágenes de hojas de maíz. Ishengoma, Rai y Said [15] diseñaron y utilizaron varias arquitecturas CNN, como VGG16, CGG19, inceptionV3 y MobileNetV2, para detectar hojas de maíz infectadas por gusanos cogolleros. El estudio concluyo que el rendimiento de la precisión mejor significativamente de VGG16 al 93.08% a MobileNetV2 al 100% después de aplicar la técnica de detección de esquinas ShiTomass a las 11280 imágenes capturadas.

Recientemente, Li et al. Propusieron varias arquitecturas de CNN, incluyendo DenseNet121, ResNet50, MobileNetV2, NASNetMobile y MDCDenseNet, para detectar 856 casos de NCLB y enfermedad foliar de antrocnosis del Norte del maíz. Después de un proceso de aprendizaje por transferencia de dos etapas. MDCDenseNet logro una precisión de identificación de 98.84% sentando las bases para aplicaciones básicas [16].

2 MATERIALES Y METODOS

2.1 Procedimiento de Conjunto de datos

El conjunto, se realizó la recolección de las hojas de las plantas del maíz, seguidamente se realizó la captura de imágenes

de las hojas de la planta de maíz, estas imágenes representan el conjunto de datos que esta conformado por imágenes digitales capturados por medio de una cámara digital, estas imágenes representan tres clases tal como se describe en la tabla 01, así mismo, las hojas que contiene enfermedades de Trips, Roya y hojas sanas dato que las imágenes se obtuvieron de los agricultores del distrito de Curahuasi-Abancay departamento de Apurímac a una altura de 2697 msnm. Conformando un total de 3200 imágenes de tres clases Trips Roya y hojas sanas.

TABLA 1

División de datos que muestra el conjunto de entrenamiento, validación y pruebas

No. Clases	Nombre Clase	Número de Imágenes		
		Train	Valid	Test
0	Trips	721	205	103
1	Roya	721	205	103
2	Sanas	721	205	103
	Total	2163	615	309

2.2 Aumento de datos

Tras la división en conjuntos de entrenamiento y validación, se aplicaron técnicas de data aumentación para optimizar la diversidad de las imágenes. Este paso implica aplicar transformaciones como rotación, escalado o inversión a las imágenes existentes, así logrando variabilidad del conjunto de datos. Estas imágenes aumentadas no solo amplían el conjunto de datos, sino que también ayudan a prevenir el sobre ajuste al exponer el modelo a un rango más amplio de variaciones.

2.3 Redes Neuronales Convolucionales Profundas

Las redes neuronales convolucionales profundas, también conocidas como DCNN, CNN o ConvNets, están diseñadas para procesar datos en forma de múltiples matrices y se han convertido en piedra angular en el campo de la visión por computadora y procesamiento de imágenes [17] [18]. Las DCNN pertenecen a una clase de redes neuronales artificiales profundas, pero se diferencia debido a sus capas convolucionales, características de agrupamiento y propiedades no lineales, como sigmoide, unidad lineal rectificada (ReLU) y tanh.

Una arquitectura típica de DCNN consta de capas de neuronas, cada una diseñada para responder a diferentes aspectos de los datos de entrada [19]. La primera capa, generalmente una capa convolucional, realiza una serie de operaciones matemáticas para detectar características, como bordes, texturas y formas, como se aprecia en la figura 2. A esto se siguen las capas de agrupación, reducen el tamaño espacial de la representación, reduciendo así el número de parámetros y cálculo de una red. Después de varias capas convolucionales y de agrupación, la red generalmente incluye capas completamente conectadas. Estas capas son capas de redes neuronales tradicionales donde cada entrada está conectada a cada salida por un peso aprendido. En esta capa, la red combina todas las características aprendidas de las capas anteriores para clasificar o predecir la salida.

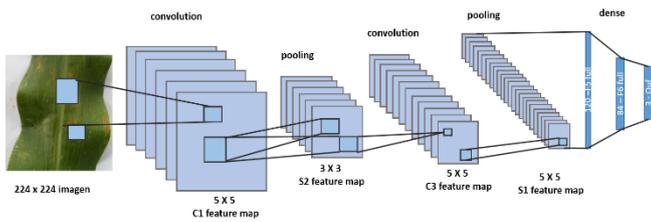


Fig. 2. Una arquitectura de CNN

2.4 ResNet

La arquitectura de Red Residual o ResNet se creó en 2015, introdujeron nuevas conexiones residuales para abordar el desafío del entrenamiento de redes neuronales muy profundas con 50, 101 y 152 capas de peso [20]. Las redes profundas tradicionales presenta el problema del gradiente de desaparición o explosión, lo que dificulta el entrenamiento de modelos con número de capas [21]. ResNet aborda este problema mediante la introducción de conexiones de acceso directo, o conexiones de salto, que omiten uno o más capas durante los pases hacia adelante y hacia atrás.

En una ResNet, los bloques residuales constituyen los componentes básicos de la arquitectura. Cada bloque residual contiene dos rutas principales: la ruta de identidad, que pasa la entrada directamente hacia la salida, y la ruta residual, que aplica una serie de capas apiladas a la entrada. La salida final se obtiene sumando las rutas de identidad y residual, creando una conexión de acceso directo. Este diseño permite que la red aprenda funciones residuales, lo que facilita la optimización del proceso de entrenamiento para redes muy profundas. El componente básico de una ResNet18 es el bloque residual, que puede tener diferentes configuraciones. As configuraciones comunes incluyen bloques básicos como dos convoluciones de 3x3 y un bloque de cuello de botella con una combinación de convoluciones de 1x1 y 3x3-. Estos bloques se apilan para formar la arquitectura general de la ResNet, como se muestra en la fig 3.

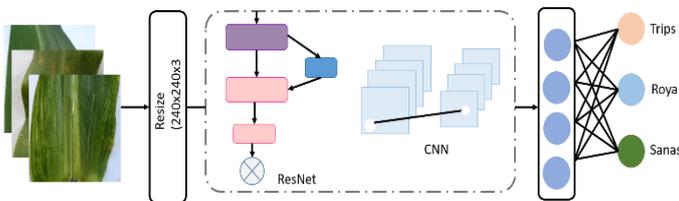


Fig. 3. Una arquitectura ResNet

2.5 Métricas de evaluación

Las métricas de rendimiento se utilizan para medir el rendimiento de los modelos de aprendizaje profundo [22]. Estas métricas son útiles para comprender los atributos de un modelo. Explicamos las métricas utilizadas en este estudio, como la exactitud, precisión, recuperación y puntuación F1, se describen a continuación:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

2.6 Materiales

- Camarra fotográfica digital
- Micro USB para el almacenamiento de imágenes digitales
- USB de 16GB
- Computadora con una tarjeta grafica de 2GB con una memoria de 32GB de RAM, sistema operativo Ubuntu 22.04
- Registro de imágenes de las hojas del maíz
- Archivo con una exteción *.py

2.7 Tipo de investigación

La investigación es de tipo experimental.

3 RESULTADOS

Se presenta los resultados experimentales de los modelos en diferentes duraciones de entrenamiento. Se evaluaron el rendimiento de cada modelo en dos etapas clave de entrenamiento: tras 20 y 70 épocas. Las principales métricas utilizadas para la evaluación son la precisión de entrenamiento, precisión de validación y la pérdida de entrenamiento. La precisión de entrenamiento mide la capacidad del modelo para aprender del conjunto de datos de entrenamiento; un porcentaje mayor indica un aprendizaje más efectivo. La precisión de validación es fundamental para evaluar la capacidad del modelo para generalizar datos no vistos; u porcentaje mayor indica una capacidad de generalización superior. Por último, la pérdida de entrenamiento cuantifica el error o la pérdida de los datos de entrenamiento; un valor menor indica una disminución de los errores de entrenamiento.

3.1 Precisión y pérdida

Los resultados muestran una tendencia de los modelos mejoran su precisión y reducen la pérdida a medida que aumenta el número de épocas de entrenamiento. A 20 épocas, el modelo CNN básica alcanza un accuracy, recall, precisión y F1-score del 95.22% (fig. 4). Con un mayor entrenamiento, su rendimiento mejora significativamente, alcanzando una precisión de accuracy, recall, precisión, F1-score del 98.18% a 70

épocas, acompañada de una pérdida de entrenamiento sustancialmente. De forma similar, el modelo ResNet18 demuestra mejoras notables métricas de accuracy, recall, precisión, F1-Score alcanzando un 96.53% en 20 épocas (véase la Fig. 5). Posteriormente, en 70 épocas, estas métricas mejoran hasta un 99.39%, lo que evidencia una optimización significativa del rendimiento. Además, se reduce considerablemente la necesidad de pruebas adicionales con solo 20 épocas, destacando la diferencia del modelo en el aprendizaje de datos.

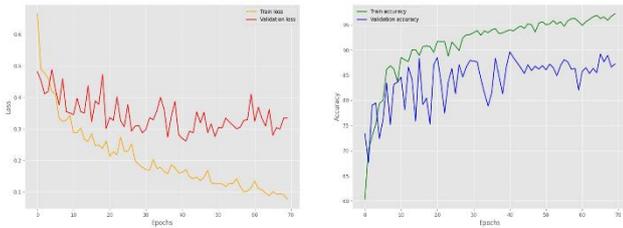


Fig. 5. CNN básica, que muestra la precisión y el resultado de pérdida del modelo.

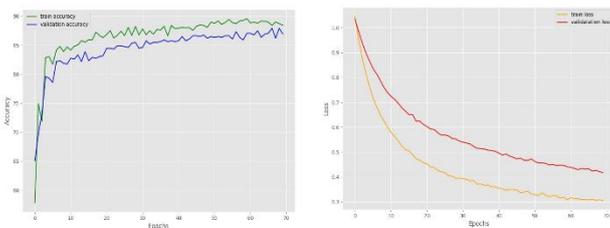


Fig. 4. ResNet18, que muestra la precisión y el resultado de pérdida del modelo.

3.2 Evaluación del desempeño

Las tablas 2 y 3 presentan una evaluación detallada de los modelos en diferentes etapas de su proceso de entrenamiento, centrándose especialmente en su rendimiento tras 20 y 70 épocas, respectivamente. En la Tabla 2, los modelos se evalúan tras 20 épocas de entrenamiento. La CNN básica muestra una precisión del 95.22%, con todas las demás métricas al 95.22%, incluyendo precisión, recall y F1-score, lo que indica un rendimiento consistente en todas las métricas. ResNet18 destacó como el modelo con mejor rendimiento, con una precisión alta del 96.53%.

ResNet18 mantuvo un alto rendimiento, aunque con una ligera disminución desde la etapa de 20 épocas. CNN exhibió una mejora significativa, logrando 98.18% en todas las métricas. En la etapa de 70 épocas (Tabla 3), mejoraron o mantuvieron sus altos niveles de rendimiento. La CNN básica continuó mostrando una mejora gradual. ResNet18 sobresalió, manteniendo un Accuracy, Recall, precisión F1-Score del 99.39%.

Cabe destacar el alto rendimiento constante de modelo como ResNet18 en todas las épocas y métricas. Por el contrario, CNN mantiene una mejora paulatina en su rendimiento en diferentes etapas de validación. Lo que resalta la importancia de elegir un número adecuado de épocas para cada modelo. En general, los modelos mostraron F1-score mejoras en varias épocas, lo que demuestra su capacidad para clasificar con precisión los casos positivos y minimizar eficazmente los falsos positivos. Esta mejora entre épocas sugiere que los modelos no solo están

aprendiendo, sino que también mejoran su precisión predictiva con el tiempo.

Además, se utilizó una matriz de confusión para representar el rendimiento de nuestros modelos de clasificación en un conjunto de datos con valores verdaderos conocida. Esta matriz nos permite evaluar visualmente la precisión del modelo al mostrar verdaderos positivos, falsos positivos, verdaderos negativos, falsos negativos en un formato cuadrícula. La Fig 6 muestra el rendimiento del modelo CNN. El modelo identificó con precisión 710 casos trips, demostrando una alta precisión, como lo demuestra el número significativo de verdaderos positivos. Solo tres casos se clasificaron erróneas como roya, lo que resulta en un falso positivo. En la categoría Royas, el modelo detectó 696 verdaderos positivos, clasificando con precisión 696 instancias como roya, sin embargo, encontró 17 falsos negativos, donde las instancias royas se clasificaron incorrectamente como no roya, y tres falsos positivos, donde las instancias no roya se clasificaron erróneamente como roya. El modelo clasificó correctamente 712 instancias como sanas, con una impresionante tasa de verdaderos positivos. Cabe destacar la ausencia de falsos negativos en esta categoría, lo que indica una identificación con 4 falsos negativos.

TABLA 2
Evaluación experimental de los modelos después de 20 épocas.

Modelo	Accuracy %	Precisión %	Recall %	F1-Score %
CNN básico	95.22	95.22	95.22	95.22
ResNet18	96.53	96.53	96.53	96.53

		Confusion Matrix		
		Trips	Roya	Sanas
Trips	Trips	710	3	0
	Roya	17	696	6
Sanas	Trips	4	7	712
		Trips	Roya	Sanas

Fig. 6. Predicción de resultados del modelo CNN básico.

El rendimiento del modelo ResNet18, como muestra en la Fig 7. Exhibe alta precisión en la clasificación de casos Trips, con un recuento de 715 verdaderos positivos, el modelo también registró 6 falsos positivos y un falso negativo en esta categoría, lo que demuestra su fuerte capacidad para identificar individuos de Trips. En la detección de Royas, el modelo aseguró 700 verdaderos positivos, pero encontró un número notable de errores, incluyendo 7 falsos negativos y 4 falsos positivos. Esto sugiere que el modelo enfrenta algunos desafíos para distinguir con precisión Royas de otras afecciones. Para la clasificación de sana,

el modelo identificó 712 verdaderos positivos, 3 falsos positivos y 7 falsos negativos, lo que demuestra su efectividad en el rendimiento de casos sanos. Si bien el modelo muestra una precisión prometedora, hay margen de mejora, especialmente en la minimización de clasificación errónea. En particular con respecto a Roya.

TABLA 3

Evaluación experimental de los modelos después de 70 épocas.

Modelo	Accuracy %	Precisión %	Recall %	F1-Score %
CNN básica	98.18	98.28	98.28	98.28
ResNet18	99.39	99.39	99.39	99.39

		Confusion Matrix		
		Trips	Roya	Sanas
Trips		715	1	0
Roya		4	700	3
Sanas		2	3	712
		Trips	Roya	Sanas

Fig. 7. Predicción de resultados del modelo ResNet18

4 CONCLUSIONES

En este estudio se demostró la aplicación de dos arquitecturas de redes neuronales convolucionales profundas para la clasificación de enfermedades en hojas de maíz, enfocados especialmente de Trips y Roya. El análisis comparativo entre una CNN Básica y el modelo ResNet18, utilizando un conjunto de datos de 3087 imágenes, arrojó resultados significativos. ResNet18 destacó por su alto rendimiento, alcanzando una precisión del 99.39% en la identificación de plantas de maíz sanas y enfermas.

La capacidad de este modelo para detectar enfermedades específicas tiene implicancias prometedoras para la agricultura en Curahuasi, Perú, al ofrecer una herramienta eficaz para la detección temprana y el manejo oportuno de enfermedades como Trips y Roya. Un diagnóstico rápido y preciso, como el permite ResNet18, es fundamental para implementar intervenciones eficaces que contribuyen a mitigar la pérdida de cultivos y a fortalecer la seguridad alimentaria en la región.

La Fig. 8, muestran los resultados de clasificación donde se identifican una hoja de maíz afectada por la enfermedad de Roya, donde hace una confusión de reconocimiento de enfermedad de Roya debió de clasificarse como hoja Sana, esas pruebas se llevaron, también se realizaron

Juan Carlos Valverde-Ramirez, Francisco Cari-Incahuanaco y Alejandrina Huaylla-Quispe

las pruebas con las imágenes que se tiene para realizar las pruebas que al momento de entrenar no se logran identificar.



Fig. 8. Pruebas realizadas muestra los resultados, donde hace una confusión con hojas sanas con la enfermedad de la Roya.

AGRADECIMIENTOS

Los reconocimientos a los agricultores de Curahuasi por las facilidades que nos facilitaron el acceso a las plantaciones de sus cultivos del maíz para su recolección y conformación del dataset el cual se usó para entrenar nuestras redes neuronales comparativas para posteriormente poder realizar nuestras pruebas.

REFERENCIAS

- [1] V. Singh, Varsha, and A. K. Misra, "Detection of unhealthy region of plant leaves using image processing and genetic algorithm," in 2015 International Conference on Advances in Computer Engineering and Applications, 2015, pp. 1028-1032. doi: 10.1109/ICACEA.2015.7164858.
- [2] Y. Li and J. Yang, "Few-shot cotton pest recognition and terminal realization," Comput. Electron. Agric., vol. 169, p. 105240, Feb. 2020, doi: 10.1016/J.COMPAG.2020.105240.
- [3] F. Saeed, M. A. Khan, M. Sharif, M. Mittal, L. M. Goyal, and S. Roy, "Deep neural network features fusion and selection based on PLS regression with an application for crops diseases classification," Appl. Soft Comput., vol. 103, p. 107164, May 2021, doi: 10.1016/J.ASOC.2021.107164.
- [4] P. J. Garcia Mendoza, "El cultivo del maíz en el mundo y en Perú 'The cultivation of corn in the world and in Peru,'" Peru, vol. 1, no. 0, pp. 1-7, 2017.
- [5] J. K. Patil, "Color Feature Extraction of Tomato Leaf Diseases," Int. J. Eng. Trends Technol., vol. 2, no. 2, pp. 72-74, 2011.
- [6] L. C. G. Clotilde Quispe Bustamante, Franco Oviedo Anguis, Maíz Amiláceo. 2011.
- [7] J. R. León-Murillo *et al.*, "Tortillas Made With Extruded Flours of Blue Maize and Chía Seeds As a Nutritious and Nutraceutical Food Option," *Agrociencia*, vol. 55, no. 6, pp. 487-506, 2021, doi: 10.47163/agrociencia.v55i5.2555.
- [8] D. G. Gabriela, "Trips: otra plaga más que ataca al maíz," 16-05-2013. [Online]. Available: [https://semillastodotereño.com/2013/05/trips-otra-plaga-mas-que-ataca-al-maiz#:~:text=El trips \(Frankliniella spp.\),las primeras etapas del cultivo.](https://semillastodotereño.com/2013/05/trips-otra-plaga-mas-que-ataca-al-maiz#:~:text=El%20trips%20(Frankliniella%20spp.),las%20primeras%20etapas%20del%20cultivo.)
- [9] D. N. S. and D. P. M. and A. V. and J. A. T. and E. P. R. and H. H. Klump, "Restoration of native folding of single-stranded DNA sequences through reverse mutations: An indication of a

new epigenetic mechanism," *Arch. Biochem. Biophys.*, vol. 453, no. 0003-9861, pp. 108-122, 2006, doi: <https://doi.org/10.1016/j.abb.2005.12.009>.

algorithm to train very deep multi-layer neural networks without vanishing gradients," *Knowledge-Based Syst.*, vol. 230, no. 0950-7051, p. 107391, 2021, doi: <https://doi.org/10.1016/j.knosys.2021.107391>.

- [10] P. Boddupalli et al., "Maize lethal necrosis (MLN): Efforts toward containing the spread and impact of a devastating transboundary disease in sub-Saharan Africa," *Virus Res.*, vol. 282, no. October 2019, p. 197943, 2020, doi: [10.1016/j.virusres.2020.197943](https://doi.org/10.1016/j.virusres.2020.197943).
- [11] J. Chai, H. Zeng, A. Li, and E. W. T. Ngai, "Deep learning in computer vision: A critical review of emerging techniques and application scenarios," *Mach. Learn. with Appl.*, vol. 6, no. March, p. 100134, 2021, doi: [10.1016/j.mlwa.2021.100134](https://doi.org/10.1016/j.mlwa.2021.100134).
- [12] K. Aruleba et al., "Applications of computational methods in biomedical breast cancer imaging diagnostics: A review," *J. Imaging*, vol. 6, no. 10, 2020, doi: [10.3390/JIMAGING6100105](https://doi.org/10.3390/JIMAGING6100105).
- [13] A. Waheed, M. Goyal, D. Gupta, A. Khanna, A. E. Hassanien, and H. M. Pandey, "An optimized dense convolutional neural network model for disease recognition and classification in corn leaf," *Comput. Electron. Agric.*, vol. 175, no. January, p. 105456, 2020, doi: [10.1016/j.compag.2020.105456](https://doi.org/10.1016/j.compag.2020.105456).
- [14] T. O'Halloran, G. Obaido, B. Otegbade, and I. D. Mienye, "A deep learning approach for Maize Lethal Necrosis and Maize Streak Virus disease detection," *Mach. Learn. with Appl.*, vol. 16, no. May, p. 100556, 2024, doi: [10.1016/j.mlwa.2024.100556](https://doi.org/10.1016/j.mlwa.2024.100556).
- [15] F. S. I. and I. A. R. and R. N. Said, "Identification of maize leaves infected by fall armyworms using UAV-based imagery and convolutional neural networks," *Comput. Electron. Agric.*, vol. 184, no. 0168-1699, p. 106124, 2021, doi: <https://doi.org/10.1016/j.compag.2021.106124>.
- [16] E. L. and L. W. and Q. X. and R. G. and Z. S. and Y. Li, "A novel deep learning method for maize disease identification based on small sample-size and complex background datasets," *Ecol. Inform.*, vol. 75, no. 1574-9541, p. 102011, 2023, doi: <https://doi.org/10.1016/j.ecoinf.2023.102011>.
- [17] K. Golhani, S. K. Balasundram, G. Vadamalai, and B. Pradhan, "A review of neural networks in plant disease detection using hyperspectral data," *Inf. Process. Agric.*, vol. 5, no. 3, pp. 354-371, 2018, doi: [10.1016/j.inpa.2018.05.002](https://doi.org/10.1016/j.inpa.2018.05.002).
- [18] G. LeCun, Yann; Bengio, Yoshua; Hinton, "Deep learning," *Nature*, vol. 436, no. 7553, p. 444, 2015, doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539).
- [19] L. Yann and B. Yoshua, "Convolutional Networks for Images, Speech, and Time-Series," *Handb. brain theory neural networks*, pp. 255-258, 1995, [Online]. Available: https://www.researchgate.net/profile/Yann_Lecun/publication/2453996_Convolutional_Networks_for_Images_Speech_and_Time-Series/links/0deec519dfa2325502000000.pdf%0Ahttps://www.researchgate.net/profile/Yann_Lecun/publication/2453996_Convolutional_Networks_fo
- [20] S. R. G. Reddy, G. P. S. Varma, and R. L. Davuluri, "Resnet-based modified red deer optimization with DLCNN classifier for plant disease identification and classification," *Comput. Electr. Eng.*, vol. 105, no. November 2022, p. 108492, 2023, doi: [10.1016/j.compeleceng.2022.108492](https://doi.org/10.1016/j.compeleceng.2022.108492).
- [21] I. A. and B. A. M. and H. Faris, "Oriented stochastic loss descent

- [22] E. Mortaz, "Imbalance accuracy metric for model selection in multi-class imbalance classification problems," *Knowledge-Based Syst.*, vol. 210, no. 0950-7051, p. 106490, 2020, doi: <https://doi.org/10.1016/j.knosys.2020.106490>.

BIOGRAFÍA

Primer Autor. Juan Carlos Valverde Ramirez, Bachiller en Ingeniería informática y sistemas, bachiller obtenido en la Universidad Nacional Micaela Bastidas de Apurímac en el año 2025.

Segundo autor. Francisco Cari Incahuanaco, Maestro en Investigación y Docencia Universitaria, Ingeniero Estadístico e Informático con Segunda Especialidad en Ingeniería de Sistemas. Experiencia en docencia universitaria, actual docente ordinario en la Universidad Nacional Micaela Bastidas de Apurímac, desarrollando asignaturas de investigación.

Tercer autor. Alejandrina Huaylla Quispe, Ingeniero de Sistemas e Informática, maestría en Gestión público de la Universidad Cesar Vallejo, Egresado de la Maestría en Proyectos de Inversión de la Universidad Tecnológica de los Andes, docente contratado adscrito al departamento de Ingeniería, Escuela Profesional de Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac.