

Modelo de Redes Neuronales Convolucionales para detectar enfermedades en las hojas del cultivo de Quinoa (*Chenopodium quinoa*) en el Centro Agronómico K'ayra, San Jerónimo, Cusco 2023

Convolutional Neural Network Model to detect diseases in the leaves of Quinoa (*Chenopodium quinoa*) crop at the Centro Agronómico K'ayra, San Jerónimo, Cusco 2023

Smit Oscco-Ccuiro^A, Elias Huashuayo-Miranda^B, Mario Aquino-Cruz^C.

ORCID: 0009-0009-9111-6124^A, ORCID: 0009-0006-6691-8756^B, ORCID: 0000-0002-2552-5669^C.

(Recepción: 15/04/2024 y aceptación 05/03/2024)

Resumen— En el mundo las enfermedades en los cultivos son la principal causa de reducción en la calidad de producción. Estas enfermedades afectan a los cultivos de quinoa y cada año se producen una gran cantidad de pérdidas económicas. Es esencial identificar estas enfermedades a una etapa temprana para aumentar su producción. Una inspección visual es el método más común para identificar enfermedades, estos errores son comunes a través de la inspección visual. El tiempo es un factor clave para la detección de enfermedades y requiere de experiencia. Este estudio muestra cómo se puede utilizar el reconocimiento de imágenes para la detección de enfermedades. Este trabajo consistió en recolectar un conjunto de datos de imágenes para Mancha Foliar 1,120 imágenes, para Mancha Bacteriana 850 imágenes, para Mildiu 896 imágenes y 1,090 imágenes de sanas consta un total de 3,956 imágenes de las hojas de quinoa del centro agronómico de K'ayra en el sector Leticia, San Jeronimo, Cusco del Perú, de los cuales se consideraron un 70% para entrenamiento, un 20% para validación y un 10% para pruebas. El modelo propuesto funcionó correctamente con una precisión 89.498%, lo cual permitirá a los agricultores de la quinoa detectar tempranamente las enfermedades, esperando que conduzca a un aumento de la producción de la quinoa en todo el mundo.

Palabra clave: Enfermedades de la quinoa, Mancha Bacteriana, Mancha Foliar, Mildiu, Redes Neuronales Convolucionales (CNN).

Abstract— In the world, crop diseases are the main cause of reduction in production quality. These diseases affect quinoa crops and a large amount of economic losses occur each year. It is essential to identify these diseases at an early stage to increase production. A visual inspection is the most common method to identify diseases, these errors are common through visual inspection. Time is a key factor in disease detection and requires experience. This study shows how image recognition can be used for disease detection. This work consisted of collecting a data set of images for leaf spot 1,120 images, for bacterial spot 850 images, for downy mildew 896 images and 1,090 healthy images for a total of 3,956 images of quinoa leaves from the K'ayra agronomic center in the Leticia sector, San Jeronimo, Cusco, Peru, of which 70% were considered for training, 20% for validation and 10% for testing. The proposed model worked correctly with an accuracy of 89.498%, which will allow quinoa farmers to detect diseases early, hopefully leading to an increase in quinoa production worldwide.

Keyword: Quinoa diseases, Bacterial Spot, Leaf Spot, Downy Mildew, Convolutional Neural Networks (CNN).

- A. Smit Oscco Ccuiro, Escuela Académico Profesional de Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac-Perú, smitscoccouiro@gmail.com.
- B. Elias Huashuayo Miranda, Escuela Académico Profesional de Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac-Perú, huashuayo16@gmail.com.
- C. Mario Aquino Cruz, .Escuela Profesional de Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac-Perú, maquino@unamba.edu.pe.

1 INTRODUCCIÓN

Alrededor del mundo las enfermedades de los cultivos, son las que reducen la calidad en la producción; dentro de las causas más frecuentes para el cultivo agrícola son las plagas. Estas plagas se encuentran tanto en los tallos como en las hojas de cada planta.

Las enfermedades en los cultivos se han incrementado debido al desgaste de la capa de ozono de la tierra, a causa de la sobrepoblación que construyen las edificaciones en lugares de los cultivos [1,2]. El reconocimiento de enfermedades en los cultivos utilizando el método tradicional es ineficiente debido al elevado tiempo que se requiere para esta actividad. En tal sentido, es necesario sistemas de reconocimiento de enfermedades de precisión para la detección de enfermedades mediante las hojas en su etapa temprana, así de esta manera pueda proteger la calidad y cantidad del producto. Existe una variedad de plagas en la Quinua [3]. Las enfermedades más destacadas son: Mildiu, Mancha Foliar, Mancha Bacteriana [3,4,5], la calidad del producto se degrada bajo estas enfermedades. Según el ministerio de Agricultura INIA promueve acciones concretas para la quinua que exporta alrededor de 37,798 toneladas, sumando así sus ventas alrededor de US\$ 94 millones [7], por otro lado, el mayor productor de esta especie en el Perú es el departamento de Puno, Cusco es uno de los departamentos promedio en cuanto en la producción de esta [8].

El método tradicional consiste en observar las plagas mediante el ojo humano, esto a su vez conlleva consultar a los expertos, sin embargo, el especialista en muchas ocasiones no está disponible a falta de tiempo, lo cual este proceso ocasiona un costo adicional al agricultor [9]. Es por ello que este método de identificar las plagas es ineficiente por las limitadas capacidades del ojo humano en grandes cantidades de sembrío de la quinua, al usar un modelo de Redes Neuronales Convolucionales para detectar enfermedades mediante las hojas de la Quinua ampliará investigaciones, así como en el campo de visión por computadoras y aprendizaje automático [10]. La mayoría de las enfermedades se da en las hojas de la quinua, por lo tanto, las hojas se convierten en una fuente portadora de información de las enfermedades que se encuentran en la quinua [8], así como se analiza [11], la detección temprana de enfermedades en los cultivos permitirá mejorar la calidad de este producto.

Los agricultores utilizan cada vez más modelos automatizados de diagnóstico de enfermedades debido a la llegada de las cámaras digitales y la tecnología informática. En los últimos tiempos, en diagnóstico de la gravedad de las enfermedades de las plantas se ha realizado mediante análisis automático basado en imágenes de aprendizaje profundo [12]. Sin embargo, el

uso de técnicas de aprendizaje profundo para detectar enfermedades de las plantas quinua no es muy común en Cusco, a pesar de su uso generalizado en la agricultura inteligente a nivel mundial. En Alemania, se utilizó la arquitectura LeNet Convolutiva Neural Network (CNN) para clasificar enfermedades de la hoja de plantas como sigatoka y speckle [13].

En este estudio, propusimos una CNN para diagnosticar tres enfermedades frecuentes de la hoja de la quinua que incluyen Mancha Bacteriana, Mancha Foliar, Mildiu. El método propuesto CNN liviano para lograr mejor resultado.

Las principales aportaciones de este estudio son:

- Conjunto de datos sobre las enfermedades de las manchas de las hojas de la quinua: recolectamos un conjunto de datos que incluye imágenes de hojas de la quinua con tres enfermedades principales de la hoja de quinua, incluidas Mancha Bacteriana, Mancha Foliar y Mildiu, así como las hojas sanas el conjunto de datos se recopiló del Centro Agronómico K'ayra de la Universidad Nacional San Antonio Abad de Cusco.
- Aplicación para la identificación de enfermedades de las hojas de la quinua: Desarrollamos una aplicación que pueda diagnosticar enfermedades de las hojas de la quinua a partir de imágenes reales de las hojas de la quinua. La aplicación permitirá a los agricultores tomar medidas de prevención para evitar la pérdida del rendimiento de los frutos de la quinua al detectar la propagación de enfermedades.

1.1. Trabajos relacionados

Introdujeron un sistema modificado de DLCNN basado en ResNet para identificar y clasificar enfermedades en las plantas del arroz utilizando imágenes de la base de datos de PlantVillage de las hojas del arroz, utilizaron ResNet-50 para entrenar múltiples características de imágenes con propiedades de textura, utilizaron MRDO para seleccionar características optimizadas tamaño de salida, a la vez utilizaron para el modelo de clasificar. Los resultados fueron en la comparación F1 del 99,73% y el 99,78%, para PlantVillage y del 99,68% y el 99,71% para Rice Plant [11,13].

Propusieron utilizar aprendizaje profundo y optimización bayesiana para detectar enfermedades de la hoja del plátano a partir de imágenes, para la clasificación, aplicaron BananaSqueezeNet, los resultados fueron satisfactorios con una precisión de 95,13% [15]. Propusieron utilizar redes residuales y mecanismos de atención de enfermedades a través de las hojas del arroz a partir de imágenes, para clasificación aplicaron GoogleNet con una precisión de 99,58 con una mejora de 1,72% con la evaluación de E-GoogleNet

[16].

Propuso utilizar red neuronal convolucional eficiente con aumento y reguladores de clasificación de plagas a través de imágenes, para la clasificación aplicaron Deep CNN con una precisión de 71,32% [17].

Propuso un aplicativo web para identificar deficiencia de Zinc de naranjo mediante las hojas a través de imágenes, para clasificación propusieron Redes Neuronales Convolucionales CGG16 con una precisión de 81,12% [18].

Propusieron dos ramas integradas ResNet y CBAM, para la clasificación de enfermedades mediante las hojas de la manzana, la experimentación se realizó con 4479 logrando así una precisión de 95.2% y 97.2% [10].

2 MATERIALES Y METODOLOGÍA

2.1. Materiales

- Cámara fotográfica canon de 16.0 megapíxeles.
- Micro USB para almacenamiento de la imagen.
- USB Kingston de 32GB.
- Computadora de marca Asus con una tarjeta gráfica NVIDIA GeForce de 4GB con un sistema operativo Ubuntu 20.04.
- Registro de imágenes de la quinua.
- Archivos con una extensión *.py.

2.2. Tipo y nivel de investigación

La investigación de tipo aplicada con un nivel descriptivo.

2.3. Modelo propuesto

En la figura 1 se muestra el modelo propuesto de nuestro trabajo para el procedimiento de la investigación.

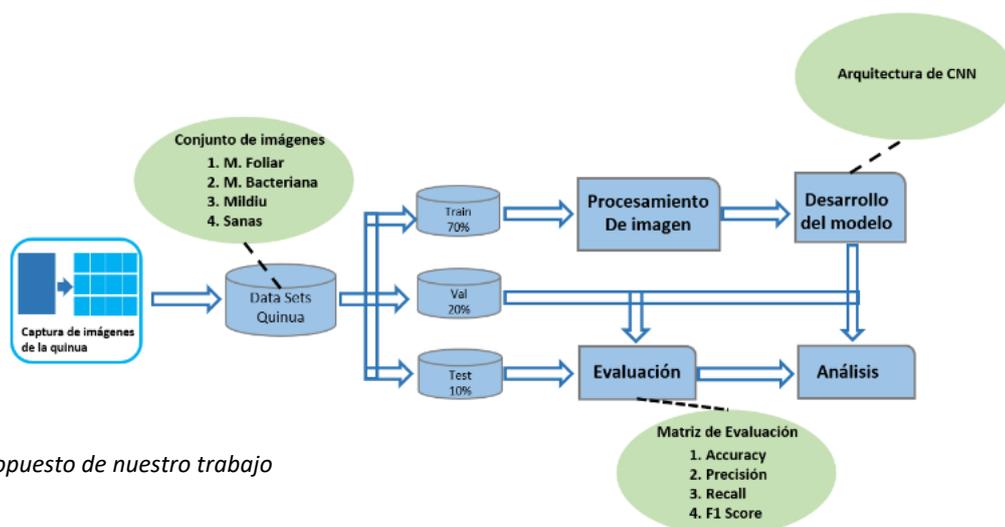


Fig. 1. Modelo Propuesto de nuestro trabajo

- Recolección de imágenes.
- Etiquetado y limpieza de imágenes.

- Reducción de imágenes.
- División y distribución.
- Entrenamiento de reconocimiento de enfermedades en la quinua utilizando Redes Neuronales Convolucionales (CNN).
- Pruebas.

2.4. Procedimiento

Primero se realizó la recolección de datos el cual consta de imágenes de hojas de la quinua de cuatro categorías. Estas son hojas afectadas de Mildiu, hojas afectadas de Mancha Foliar, hojas afectadas de Mancha Bacteriana y hojas Sanas, las imágenes se obtuvieron del Centro Agronómico K'ayra de la Universidad Nacional San Antonio Abad de Cusco. Se utilizó una cámara fotográfica digital para tomar las imágenes. Existe un total de 3,974 imágenes de 4 clases: sanas, mildiu, mancha bacteriana y mancha foliar.

Segundo se etiquetó cuidadosamente las imágenes, con ayuda de un científico de datos se realizó la limpieza de datos para eliminar las imágenes inconsistentes.

Tercero se preprocesaron las imágenes utilizando diferentes técnicas de preprocesamiento que incluyen cambio de tamaño y de normalización. Las imágenes constan de 3 canales de tamaño 238 x 246 píxeles sin perder la calidad de cada imagen, para ello se utilizó la siguiente fórmula.

$$V_{flip}(m, n) = V_I(m, (n_{max} - n) + 1)$$

Donde V_{flip} es la matriz de entrada (output) de la imagen que corresponde a la transformación de que produce un movimiento de la columna m , filas n a la columna m y fila $(n_{max} - n) + 1$, para n_{max} de la dirección de n .

Cuarto se dividió el conjunto de datos en pruebas, validación y entrenamiento, y se realizó la distribución de las imágenes para entrenamiento el 70%, para validación el 20% y para pruebas el 10%. Para el conjunto de entrenamiento se contabilizaron 763 imágenes de hojas sanas, 627 imágenes de hojas afectadas por mildiu, 595 imágenes de hojas afectadas por la enfermedad mancha bacteriana y 784 imágenes de hojas afectadas por la enfermedad de mancha foliar. Para el conjunto de validación 218 imágenes de hojas sanas, 179 imágenes de hojas afectadas por la enfermedad mildiu, 170 imágenes de hojas afectadas por la enfermedad de mancha bacteriana y 224 imágenes de hojas afectadas de la enfermedad de mancha foliar. El conjunto de prueba tiene 109 imágenes de hojas sanas, 90 imágenes de hojas afectadas por la enfermedad de mildiu, 85 imágenes de hojas afectadas por la enfermedad de mancha bacteriana y 112 imágenes de hojas afectadas por la enfermedad de mancha foliar, como se muestra en la Figura 2 el cual ilustra el conjunto que conforman imágenes.

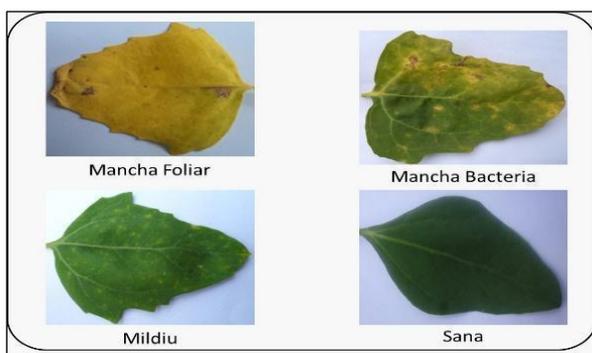


Fig. 2. Conjunto de datos de imágenes de la Quinua.

Estas son hojas sanas, hojas afectadas por mancha foliar, hojas afectadas por mancha bacteriana y hojas afectadas de mildiu.

La tabla 1 ilustra la cantidad de imágenes de las diferentes clases en el conjunto de entrenamiento, validación y prueba.

Tabla 1. Distribución de clases de imágenes en el conjunto de datos de Quinua

Clase	Conjunto de datos		
	Train	Val	Test
Mildiu	627	179	90
M-Bacteriana	595	170	85
M-Foliar	784	224	112
Saludables	763	218	109
Total	2769	791	396

Quinto se realizó el entrenamiento en Python usando PyTorch [19], el entrenamiento se desarrolló en una computadora de 64 bit con un sistema operativo Ubuntu

20.04. En el entrenamiento se utilizó 40 épocas y demoró alrededor de 3:30 Hrs (tres horas con treinta minutos), se utilizaron las siguientes herramientas y librerías con sus distintas versiones: Python==3.8, Numpy==1.24, Pandas==2.0, Matplotlib==3.7, Scikit-Learn==1.3, Scipy==1.10, Torch==1.12+cu116, Torchvision==0.12+cu116, Zipp==3.17, OpenCV-Python==4.8.

La arquitectura generada tiene cuatro capas convolucionales. Y que cada capa subsiguiente tiene el doble de número anterior, cada una de las capas convolucionales va seguida de la actividad de ReLU y Max-Pool, tenemos una capa lineal con cuatro números de clases en el conjunto de datos, las primeras capas convolucionales tienen núcleos de 5x5, luego el siguiente de 3x3 y la última nuevamente de 5x5 de núcleos.

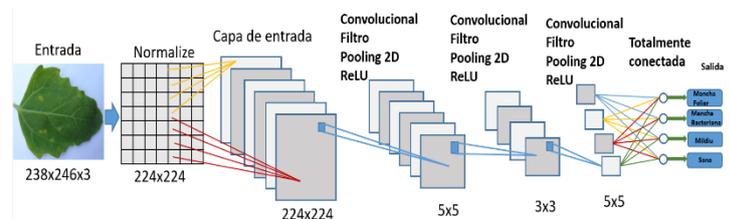


Fig. 3. Arquitectura de Modelo de Red Neuronal Convolucional.

De la figura 3, Se utilizó la red neuronal convolucional (CNN) para realizar la tarea de clasificación. CNN tiene dos tipos de capas: capas de extracción de características y capas de clasificación. Las capas de extracción de características extraen las características de la imagen, mientras que la capa de clasificación realiza la clasificación de la imagen en función de las características extraídas. Tamaño del modelo CNN debe ser pequeña ya que pretendemos implementar identificar para distintos dispositivos para que los agricultores puedan usarlo en el campo. Por esta razón, entrenamos por el modelo de CNN liviano [20]. El beneficio de utilizar este modelo liviano es que se pueden implementar en dispositivos integrados, ya que son de tamaño muy pequeño.

Por último, se realizaron las pruebas con las imágenes separadas para este proceso.

2.5. Medición de desempeño

Se han utilizado varias métricas de rendimiento para medir el rendimiento de nuestro modelo, incluida la exactitud, la precisión, la recuperación, la puntuación. Se utilizaron las siguientes ecuaciones para calcular la exactitud,

la precisión, la recuperación y la puntuación.

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

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

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

$$F1 = 2x \frac{Precision * Recall}{Precision + Recall}$$

La cantidad de muestras verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos están representados por TP, TN, FP y FN, respectivamente.

3 RESULTADOS

3.1. Resultados de evaluación

En la figura 4 se muestra la matriz de confusión para nuestro modelo. Las imágenes sanas fueron clasificadas con un 89.92% de precisión, tres imágenes de mildiu y cinco de mancha bacteriana fueron clasificadas erróneamente como sanas. Las imágenes de mildiu se clasificaron al 80.03% de precisión, una imagen como mancha foliar y una como mancha bacteriana fueron clasificadas erróneamente. Las sanas también tienen la tasa promedio de falsos positivos. El modelo tuvo problemas para clasificar las imágenes de mancha foliar.

	Bacteriana	Foliar	Mildiu	Sanas
Bacteriana	13	0	1	5
Foliar	1	29	1	0
Mildiu	2	2	18	3
Sanas	1	2	0	20

Fig. 4. Matriz de confusión del conjunto de datos de entrenamiento

El entrenamiento de nuestra red neuronal convolucional muestra parámetros que impactan significativamente en el rendimiento del modelo. Los optimizadores determinan cómo actualizar los pesos del modelo durante el

entrenamiento, mientras que la función de pérdida determina cómo se penalizará el modelo cuando se realicen predicciones incorrectas. La cantidad de épocas determina la cantidad de veces que el modelo encontrara todo el conjunto de datos de entrenamiento. En este trabajo utilizamos el optimizador Adam, el número de épocas se estableció en 40. Durante los experimentos se utilizó aprendizaje por transferencia para mejorar el entrenamiento en el rendimiento.

La figura 5 muestra el cambio de precisión con el número de épocas para nuestro modelo de arquitectura. A medida que se aumenta el número de épocas, la precisión no aumenta pues tiene una curva de aprendizaje accidentada.

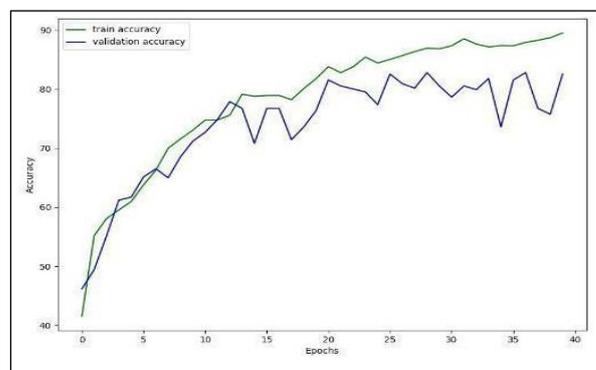


Fig. 5. Análisis de Precisión del Modelo Propuesto

En la figura 6 muestra la pérdida, disminuye hasta alcanzar la saturación para el modelo por lo que logró una curva de aprendizaje más fluida.

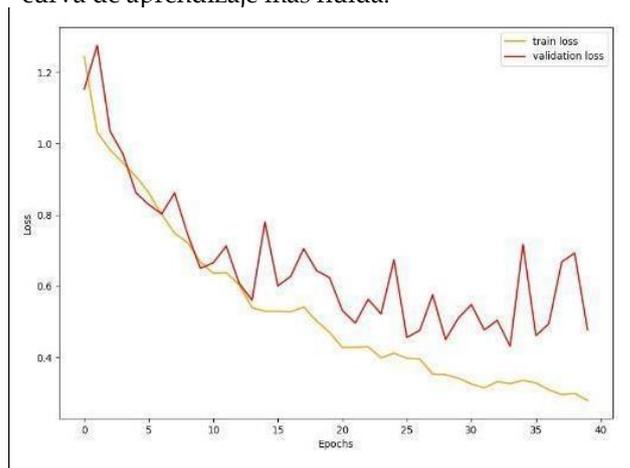


Fig. 6. Análisis de pérdida del modelo propuesto.

La tabla 2 muestra la matriz de confusión para las enfermedades de la quinua en la cual se observa los resultados en nuestro modelo propuesto de entrenamiento CNN, con un accuracy bastante viable. En la figura 6 muestra los resultados de la predicción en las enfermedades de la

quinua, en la que se puede observar que nuestro modelo propuesto obtiene un valor de 89.50.

Tabla 2 Matriz de confusión para enfermedades de la quinua

	Precisión	Recall	F1-Score	Support
0	0.87	0.81	0.84	16
1	0.91	0.73	0.80	20
2	0.64	1.00	0.78	9
3	0.82	0.88	0.82	12
Accuracy			89.50	40

La matriz de confusión del modelo propuesto, presenta una precisión por clase que se encuentra entre 89.50%.

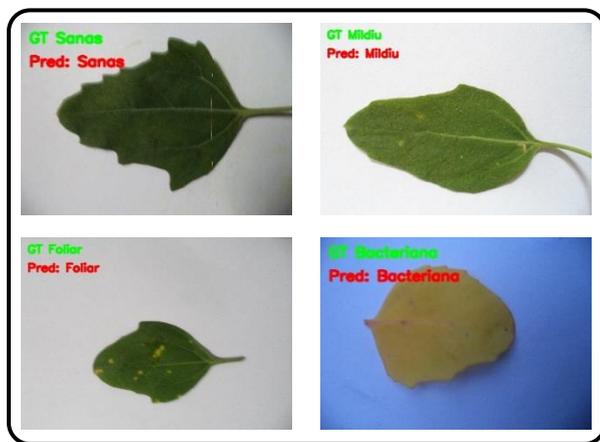


Fig. 7. Predicción para las enfermedades de la quinua.

4 CONCLUSIÓN Y RECOMENDACIONES

4.1. Conclusión

En este trabajo, se demostró cómo se puede detectar a partir de imágenes diferentes enfermedades que afectan la hoja, y por consiguiente el fruto de la quinua. Recopilamos un conjunto de datos de imágenes de hojas de quinua del Centro Agronómico K'ayra de la Universidad Nacional San Antonio Abad de Cusco, se implementó una arquitectura de CNN que puede identificar enfermedades a partir de imágenes de hojas de la quinua con una alta precisión de 89.50%.

4.2. Recomendaciones

Este modelo se puede implementar en una plataforma web para el libre acceso de los agricultores y partes interesadas, para que puedan utilizar el modelo para realizar el diagnóstico temprano de las enfermedades de la hoja de la

quinua y para tomar medidas de precaución.

En futuras investigaciones se mejore la eficacia del modelo para identificar enfermedades en las hojas de la quinua. También se debe instruir a los agricultores sobre qué medidas tomar en función de la gravedad de la enfermedad.

Agradecimientos

Los reconocimientos a la Universidad Nacional San Antonio Abad del Cusco, Facultad de Agronomía y Zootecnia por facilitarnos acceso a los cultivos de su centro Agronómico en el sector Leticia de K'ayra San Jeronimo para la recopilación de las hojas de quinua para poder conformar nuestro DataSets, el cual se usó para el entrenamiento de nuestra red neuronal y posteriormente para las pruebas.

Los reconocimientos a nuestros Co-Asesores: Julio Cesar Llocli Champi, guiándonos en sus conocimientos en modelos de clasificación de nuestra DataSets con redes neuronales, a Leonardo Ccuyro Quispe por brindarnos su conocimiento en enfermedades de las hojas de quinua especialista en plagas en las plantas.

REFERENCIAS

- [1] H. Duan, T. R. Miller, G. Liu, and V. W. Y. Tam, "Construction debris becomes growing concern of growing cities," *Waste Manag.*, vol. 83, pp. 1-5, Jan. 2019, doi: 10.1016/J.WASMAN.2018.10.044.
- [2] M. Bravo, M., Reyna R., J., Gómez Sánchez, I., & Huapaya H., "ESTUDIO QUÍMICO Y NUTRICIONAL DE GRANOS ANDINOS GERMINADOS DE QUINUA (CHENOPODIUM QUINOA) Y KIWICHA (AMARANTUS CAUDATUS)." p. 16, 2013. [Online]. Available: <https://revistasinvestigacion.unmsm.edu.pe/index.php/quim/article/view/6558>
- [3] "INIAP -Estación Experimental Santa Catalina," 16-18, p. 8, 1985, [Online]. Available: http://181.112.143.123/bitstream/41000/2827/1/iniap_sc322est.pdf
- [4] D. Solveig and T. Ames, "EL MILDIU (Peronospora farinosa) DE LA QUINUA (Chenopodium quinoa) en la zona andina. Manual práctico para el estudio de la enfermedad y del patógeno," *Cent. Int. la papa*, p. 38, 2000, [Online]. Available: <http://cipotato.org/wp-content/uploads/2014/10/AN60198.pdf>
- [5] G. McAvoy, "Una solución para la Mancha foliar por Alternaria," 2017. <https://www.hortali-zas.com/author/gmavoy/>
- [6] M. F. Yañez-Yazlle, N. Romano-Armada, M. M. Acreche, V. B. Rajal, and V. P. Irazusta, "Halotolerant bacteria isolated from extreme environments induce seed germination and growth of chia (*Salvia hispanica* L.) and quinoa

- (Chenopodium quinoa Willd.) under saline stress," *Eco-toxicol. Environ. Saf.*, vol. 218, p. 112273, Jul. 2021, doi: 10.1016/J.ECOENV.2021.112273.
- [7] Fairlie.A, La quinua en el Perú. 2016. [Online]. Available: http://repositorio.pucp.edu.pe/index/bitstream/handle/123456789/54092/Nro_6_Fairlie_quinua_Perú.pdf?sequence=1&isAllowed=y
- [8] M. de D. A. y Riego, "El Perú se consolida como el primer productor y exportador mundial de quinua," 2021. <https://www.gob.pe/institucion/midagri/noticias/324394-el-peru-se-consolida-como-el-primer-productor-y-exportador-mundial-de-quinua>
- [9] E. Efraín and J. Lepe, "CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS SUPERIORES DEL IPN A beginner ' s tutorial for CNN," pp. 1-35, 2017.
- [10] R. Ding et al., "Improved ResNet Based Apple Leaf Diseases Identification," *IFAC-PapersOnLine*, vol. 55, no. 32, pp. 78-82, 2022, doi: 10.1016/j.ifacol.2022.11.118.
- [11] 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.
- [12] G. Wang, Y. Sun, and J. Wang, "Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning," *Comput. Intell. Neurosci.*, vol. 2017, 2017, doi: 10.1155/2017/2917536.
- [13] J. Amara, B. Bouaziz, and A. Algergawy, "A deep learning-based approach for banana leaf diseases classification," *Lect. Notes Informatics (LNI), Proc. - Ser. Gesellschaft fur Inform.*, vol. 266, pp. 79-88, 2017.
- [14] R. E. Castañeda Valdivieso, J. R. Guerrero Meza, B. E. Renteros Parra, and J. A. Villanueva Mejía, "Detección de nutrientes del suelo y planta, y pestes en campos de cultivo de banano orgánico con Machine Learning," *Pirhua*, 2021, [Online]. Available: <https://hdl.handle.net/11042/5204>
- [15] M. A. B. Bhuiyan, H. M. Abdullah, S. E. Arman, S. Saminur Rahman, and K. Al Mahmud, "BananaSqueezeNet: A very fast, lightweight convolutional neural network for the diagnosis of three prominent banana leaf diseases," *Smart Agric. Technol.*, vol. 4, no. February, p. 100214, 2023, doi: 10.1016/j.atech.2023.100214.
- [16] L. Yang et al., "GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases," *Comput. Electron. Agric.*, vol. 204, p. 107543, Jan. 2023, doi: 10.1016/J.COMPAG.2022.107543.
- [17] A. Setiawan, N. Yudistira, and R. C. Wihandika, "Large scale pest classification using efficient Convolutional Neural Network with augmentation and regularizers," *Comput. Electron. Agric.*, vol. 200, p. 107204, Sep. 2022, doi: 10.1016/J.COM-PAG.2022.107204.
- [18] F. D. E. I. Y. Arquitectura, "Shiane Lizceth Farfan Vergara," 2021.
- [19] David Beazley and B. K. Jones, *Python Cookbook: 3rd Edition*. 2013.
- [20] F. Coban, "The Role of the Media in International Relations: From the CNN Effect to the Al -Jazeera Effect," *J. Int. Relations Foreign Policy*, vol. 4, no. 2, pp. 45-61, 2016, doi: 10.15640/jirfp.v4n2a3.

BIOGRAFÍA

Smit Oscco Ccuiro, bachiller en Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac.

Elias Huashuayo Miranda, bachiller en Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac.

Mario Aquino Cruz, Docente en la Universidad Nacional Micaela Bastidas de Apurímac - Perú, MSc. In Informática, Investigador en las áreas de informática educativa, IoT, Inteligencia artificial y ciberseguridad.