



Artículo original / Original article

Aplicativo móvil para la detección de la enfermedad del mosaico común en la yuca (*Manihot esculenta*) utilizando redes neuronales convolucionales

Mobile application for the detection of common mosaic disease in cassava (*Manihot esculenta*) using convolutional neural networks

Romario Diaz-Holgado ¹; Denis Ricardo Vilcas-Villalba ¹; Ralph Miranda-Castillo ^{1*}; Luis Alberto Holgado-Apaza ¹

¹Universidad Nacional Amazónica de Madre de Dios, Puerto Maldonado, Perú

Recibido: 18/08/2023

Aceptado: 27/10/2023

Publicado: 25/01/2024

*Autor de correspondencia: rmiranda@unamad.edu.pe

Resumen: Se implementó un Aplicativo Móvil usando una Red Neuronal Convolucional capaz de detectar la enfermedad del mosaico en imágenes de hojas de la yuca. Se recolectó 3400 imágenes de hojas de yuca, donde 3000 sirvieron como entrenamiento y 400 para validación. El diseño usado en esta investigación es de tipo pre-experimental. El tipo de estudio utilizado es Aplicada y el Nivel de investigación es de tipo descriptiva. Se tomaron las 400 fotografías correspondientes a la validación, con un celular Redmi Note con cámara trasera de 48 Mpx y cámara frontal de 32 Mpx, haciendo uso de la cámara trasera para tomar las fotografías, de las cuales 200 de ellas son hojas sanas y 200 son hojas enfermas. Se consideraron las métricas arrojadas por defecto por la biblioteca de software Tensorflow 2.0. El aplicativo móvil mejora el proceso de detección de la enfermedad del mosaico, además se desarrolló una arquitectura propia para la clasificación correcta de las imágenes y se determinó que la eficacia de la aplicación influye en gran manera en el proceso para la detección de la enfermedad del mosaico.

Palabras clave: aplicativo móvil; clasificación de imágenes; enfermedad del mosaico; red Neuronal Convolucional; TensorFlow 2.0

Abstract: We developed a mobile application using a Convolutional Neural Network capable of detecting mosaic disease in images of cassava leaves. We collected 3,400 images of cassava leaves, using 3,000 for training and 400 for validation. This research follows a pre-experimental design. The study type is applied, and the research level is descriptive. We captured the 400 validation photographs with a Redmi Note smartphone, using its 48 Mpx rear camera, with 200 images of healthy leaves and 200 of diseased leaves. We considered the default metrics provided by the TensorFlow 2.0 software library. The mobile application enhances the detection process of mosaic disease. Additionally, we developed a proprietary architecture to ensure accurate image classification and confirmed that the application's effectiveness significantly influences the detection process of mosaic disease.

Keywords: mobile application; image classification; mosaic disease; Convolutional Neural Network; TensorFlow 2.0

1. Introducción

El cultivo de yuca (*Manihot esculenta*) se ha reconocido como una de las prácticas agrícolas más rentables a nivel mundial. Sin embargo, este cultivo ha enfrentado diversas amenazas, incluidas enfermedades que han afectado su productividad y calidad. Para mitigar el impacto de estas amenazas, ha sido fundamental que los agricultores posean conocimientos sólidos sobre las enfermedades que pueden afectar sus cultivos y realicen monitoreos constantes para detectar cualquier síntoma de enfermedad a tiempo (Langer & Kühn, 2024; Sambasivam & Opiyo, 2021). En este contexto, esta investigación tuvo como objetivo desarrollar un sistema basado en inteligencia artificial que facilitara el reconocimiento temprano de la enfermedad del mosaico en la planta de yuca, optimizando así los procesos de monitoreo y diagnóstico (Ceballos, 2002).

La propuesta del estudio consistió en una aplicación móvil que ayudó a los agricultores a identificar la enfermedad del mosaico en las hojas de yuca. A través de la cámara del dispositivo móvil, la aplicación fue capaz de analizar las características morfológicas de las hojas y determinar si estas presentaban los signos típicos de infección. Para llevar a cabo esta tarea, se implementó una red neuronal convolucional (CNN) que fue entrenada con un conjunto de datos que comprendió 3,400 imágenes. Este conjunto incluyó 1,500 imágenes de hojas sanas para el entrenamiento y 200 para la validación, así como 1,500 imágenes de hojas enfermas para el entrenamiento y 200 para la validación (Ceballos, 2002).

El marco teórico se fundamentó en una revisión exhaustiva de la yuca (*Manihot esculenta*), un cultivo de gran importancia económica y alimentaria en diversas regiones tropicales. Se abordaron sus características botánicas, incluyendo su estructura foliar, que es susceptible a diversas enfermedades, como el mosaico, que afecta su rendimiento y calidad. Además, se discutieron las condiciones ambientales óptimas para su crecimiento y los principales factores que influyen en su producción, destacando la necesidad de un monitoreo constante para la detección temprana de enfermedades (Álvarez & Llano Rodríguez, 2015).

Asimismo, se exploraron los principios de la visión artificial, enfocándose en los modelos de redes neuronales convolucionales (CNN), que han revolucionado el análisis de imágenes (Malik et al., 2021; Pinedo et al., 2021). Estos modelos son particularmente eficaces en la extracción de características, permitiendo identificar patrones complejos en las hojas de yuca mediante la segmentación y clasificación de imágenes (Santos et al., 2020). Se describieron técnicas como la convolución, el pooling y la normalización, que son fundamentales en el proceso de aprendizaje automático para mejorar la precisión del diagnóstico. La integración de la inteligencia artificial en la agricultura, específicamente en la detección de enfermedades, ha demostrado ser una herramienta valiosa para optimizar la gestión agrícola y asegurar la productividad de cultivos como la yuca (Langer & Kühn, 2024).

Diversos estudios han abordado el uso de técnicas de visión por computador y aprendizaje profundo para el manejo de plagas y enfermedades en cultivos agrícolas (Santos et al., 2020). Por ejemplo, en la investigación de Fuentes Plaza (2024), se utilizó una red neuronal convolucional (CNN) para crear clasificadores de alta precisión que identifican enfermedades en las plantaciones de papa, empleando técnicas de transferencia de aprendizaje con arquitecturas VGG16 y DenseNet201 (Sambasivam & Opiyo, 2021). Se recopilaron conjuntos de datos de PlantVillage y Fruit360, logrando precisiones superiores al 90% en todas las pruebas experimentales. Asimismo, García Alcalá (2020) desarrolló un sistema de procesamiento de imágenes digitales para identificar la sigatoka negra en cultivos de plátano, utilizando una red neuronal feed-forward que alcanzó un 100% de efectividad en varias categorías. Otros estudios, como el de Pereyra (2020), se enfocaron en plataformas de machine learning para el reconocimiento de enfermedades en cultivos de tomate, mostrando la aplicabilidad de estas tecnologías en el ámbito agrícola.

Además, investigaciones como la de Castro Sandoval (2019) quienes implementaron algoritmos de reconocimiento de la leprosis de cítricos, obteniendo una exactitud del 98% en la detección de

virus en hojas de naranja dulce. Por su parte Ardón Muñoz & Morales Calderón (2021) llevaron a cabo un análisis comparativo de arquitecturas de redes neuronales para detectar el virus del mosaico dorado en frijoles, concluyendo que la red ResNet50 ofreció la mayor precisión con un 96.68%. Por otro lado, Cusme Zambrano & Loor Pinargote (2019) desarrollaron un aplicativo móvil para la detección y clasificación de la roya en hojas de café robusta, logrando una efectividad del 97%. Estos estudios evidencian el potencial de las redes neuronales y el aprendizaje automático en la identificación temprana y gestión de enfermedades en cultivos, contribuyendo a mejorar la productividad agrícola y reducir las pérdidas económicas.

La investigación se centra en el desarrollo de un aplicativo móvil que incorpora una red neuronal convolucional para mejorar la detección de la enfermedad del mosaico en los cultivos de yuca, específicamente en la asociación civil "Unidos Tres Estrellas". El problema principal que se plantea es: ¿De qué manera el aplicativo móvil, que utiliza esta tecnología, mejorará el proceso de detección de la enfermedad? Para abordar esta interrogante, se han formulado preguntas específicas, tales como: ¿Con qué exactitud el modelo entrenado detectará la enfermedad del mosaico? y ¿De qué manera el aplicativo móvil mejorará la eficiencia del diagnóstico en dicha asociación? Estas preguntas guiarán el enfoque metodológico de la investigación y establecerán las bases para evaluar el impacto del sistema propuesto.

Los objetivos se articulan en torno a la implementación de un aplicativo móvil que utilice una red neuronal convolucional con el fin de mejorar el proceso de detección de la enfermedad del mosaico. El objetivo general es lograr esta implementación en la asociación civil "Unidos Tres Estrellas". Para ello, se plantean objetivos específicos que incluyen determinar el nivel de exactitud del modelo de red neuronal convolucional en la detección de la enfermedad y mejorar la eficiencia del diagnóstico a través del aplicativo móvil. Estos objetivos son esenciales para validar la efectividad de la solución propuesta y su aplicabilidad en el contexto agrícola.

La hipótesis general de esta investigación postula que la implementación del aplicativo móvil, que utiliza una red neuronal convolucional, mejorará el proceso de detección de la enfermedad del mosaico en la asociación civil "Unidos Tres Estrellas". Las hipótesis específicas respaldan esta afirmación, sugiriendo que el nivel de exactitud del modelo entrenado es adecuado para la detección de la enfermedad y que la implementación del aplicativo incrementará la eficacia del diagnóstico. Estas hipótesis fueron probadas a lo largo del estudio, contribuyendo a una mejor comprensión del papel de la inteligencia artificial en la agricultura y su potencial para optimizar los procesos de identificación de enfermedades en cultivos.

Finalmente, se presentaron los resultados obtenidos tras la implementación de la aplicación y la red neuronal convolucional en la Asociación Civil Unidos Tres Estrellas. Estos resultados validaron las hipótesis planteadas, proporcionando una base sólida para las conclusiones del estudio. A partir de los hallazgos, se ofrecieron recomendaciones prácticas que pueden ser consideradas para futuros desarrollos en el ámbito de la inteligencia artificial aplicada a la agricultura.

2. Materiales y métodos

El estudio realizado en esta investigación se clasifica como una investigación aplicada, también conocida como "investigación práctica" o "investigación empírica". Este tipo de investigación se caracteriza por el uso de estudios previos y la adquisición de nuevos conocimientos, lo que permite una comprensión estructurada, sistemática y rigurosa de la realidad (Cordero, 2009). La presente tesis adopta un diseño pre-experimental con un solo grupo que incluye pretest y postest. En este contexto, se analiza cómo la variable independiente, es decir, el aplicativo móvil, influye en la variable dependiente, la detección de la enfermedad del mosaico, y se evalúa el efecto de la variable interviniente, que corresponde a la red neuronal convolucional, sobre la variable independiente (Gaspar García, 2011).

La investigación se define como descriptiva, con el objetivo de recopilar información sobre características, dimensiones y aspectos relevantes de los objetos de estudio, lo que permite probar hipótesis o responder preguntas sobre la situación actual de estos (Esteban Nieto, 2018). Para llevar a cabo esta tarea, se implementó una red neuronal convolucional (CNN) que fue entrenada con un conjunto de datos que comprendió 3,400 imágenes. Este conjunto incluyó 1,500 imágenes de hojas sanas para el entrenamiento y 200 para la validación, así como 1,500 imágenes de hojas enfermas para el entrenamiento y 200 para la validación. Las imágenes fueron capturadas por los investigadores, asegurando la diversidad y representatividad necesaria para un análisis efectivo.

Se empleó un teléfono celular REDMI NOTE con cámara trasera de 48 Mpx, que se utilizó para capturar imágenes de los cultivos. Esto facilitó el análisis de las variables estudiadas en la investigación, proporcionando información valiosa para la validación del modelo y la mejora de los procesos de detección de la enfermedad del mosaico.

Para evaluar el rendimiento del modelo de red neuronal convolucional implementado en esta investigación, se consideraron varias métricas clave que son fundamentales en la validación de modelos de aprendizaje automático. Estas métricas incluyeron la precisión, que mide la proporción de predicciones correctas realizadas por el modelo en relación con el total de predicciones, y la sensibilidad, que evalúa la capacidad del modelo para identificar correctamente los casos positivos, es decir, las hojas infectadas con la enfermedad del mosaico. Asimismo, se utilizó la especificidad, que indica la habilidad del modelo para reconocer correctamente los casos negativos, como las hojas sanas. Además, se calculó la exactitud global, que proporciona una visión general del desempeño del modelo al considerar tanto los verdaderos positivos como los verdaderos negativos en el conjunto de datos. Estas métricas permitieron una evaluación integral de la efectividad del modelo en la detección de la enfermedad y contribuyeron a la validación de su aplicabilidad en un entorno real.

3. Resultados y discusión

3.1. Procesamiento y evaluación de resultados de la CNN implementada

Utilizaremos los datos arrojados por la Red Neuronal Convolucional al momento de entrenar y validar los datos, evidenciados en la siguiente tabla:

Tabla 1. Resultados de la Exactitud del modelo

N°	Med.	N°	Med.	N°	Med.	N°	Med.	N°	Med.
1	78%	13	92%	25	92%	37	95%	49	95%
2	80%	14	97%	26	96%	38	96%	50	98%
3	91%	15	94%	27	93%	39	95%	51	93%
4	92%	16	92%	28	92%	40	94%	52	95%
5	92%	17	97%	29	94%	41	95%	53	96%
6	96%	18	94%	30	94%	42	95%	54	96%
7	92%	19	93%	31	94%	43	95%	55	95%
8	93%	20	95%	32	95%	44	93%	56	93%
9	91%	21	97%	33	94%	45	95%	57	95%
10	98%	22	96%	34	94%	46	94%	58	94%
11	94%	23	93%	35	95%	47	95%	59	97%
12	97%	24	94%	36	95%	48	98%	60	98%

3.2. En la prueba de hipótesis general

Se estableció la hipótesis nula (H_0) que postulaba que no existía una diferencia significativa entre la mediana de los puntajes obtenidos antes y después de la implementación de un aplicativo

móvil que utiliza una red neuronal convolucional para la detección de la enfermedad del mosaico en la asociación civil "Unidos Tres Estrellas".

Rangos				
		N	Rango promedio	Suma de rangos
deteccion_postest - deteccion_pretest	Rangos negativos	1 ^a	3,50	3,50
	Rangos positivos	12 ^b	7,29	87,50
	Empates	0 ^c		
	Total	13		

a. deteccion_postest < deteccion_pretest
 b. deteccion_postest > deteccion_pretest
 c. deteccion_postest = deteccion_pretest

Figura 1. Rangos obtenidos para el valor W de Wilcoxon

3.3. Por otro lado, la hipótesis alternativa (H1)

Afirmaba que sí existía una diferencia significativa. Con un nivel de significancia de $\alpha = 0.05$ y un valor Z crítico de $Z_t = 1.96$, los resultados del software SPSS mostraron que el valor Z calculado (Z_c) era de $|-2.97|$, superando el valor crítico. Además, el valor p fue de 0.003, que es menor que 0.05. Esto llevó a rechazar H_0 y aceptar H_1 , evidenciando que la implementación del aplicativo tuvo un efecto positivo en el diagnóstico, aumentando la exactitud en un 20% y reduciendo el tiempo de detección de 6 minutos a 1 minuto.

Estadísticos de contraste ^a	
	deteccion_po stest - deteccion_pre test
Z	-2,950 ^b
Sig. asintót. (bilateral)	,003

a. Prueba de los rangos con signo de Wilcoxon
 b. Basado en los rangos negativos.

Figura 2. Resultados del valor p y Z_c basado en signos negativos

3.4. Para evaluar la media de la exactitud del modelo entrenado

Se plantearon también hipótesis nula (H_0) y alternativa (H_1). La hipótesis nula afirmaba que la media de exactitud era menor o igual al 90%, mientras que la alternativa sostenía que era mayor al 90%. Utilizando la prueba t de Student para una muestra, se encontró un valor p de 0.00, que también es menor que 0.05. Esto resultó en el rechazo de H_0 y la aceptación de H_1 , indicando que la media de exactitud del modelo era efectivamente superior al 90% con un nivel de significancia del 5%.

Prueba para una muestra						
	Valor de prueba = 90					
	t	gl	Sig. (bilateral)	Diferencia de medias	95% Intervalo de confianza para la diferencia	
					Inferior	Superior
resultado	9,352	59	,000	4,01667	3,1573	4,8761

Figura 3. Resultados de la prueba T de Student para la Hipótesis Específica 1

3.5. En la prueba de hipótesis específica 2

Se utilizó la prueba Rho de Spearman para evaluar la relación entre la eficacia del aplicativo móvil y el diagnóstico de la enfermedad del mosaico. La hipótesis nula planteaba que la eficacia del aplicativo no influía significativamente en el diagnóstico, mientras que la alternativa afirmaba lo contrario. Con un nivel de significancia de $\alpha = 0.05$ y un valor Z crítico de 1.96, se obtuvo un valor

Z calculado de 2.37, que superaba el valor crítico, junto con un valor p de 0.037, que es menor que 0.05. Así, se rechazó la hipótesis nula y se aceptó la alternativa, concluyendo que la eficacia del aplicativo móvil que utiliza redes neuronales convolucionales influye significativamente en el proceso de detección de la enfermedad del mosaico.

Correlaciones				
			proceso_de_deteccion	eficiencia_aplicativo
Rho de Spearman	proceso_de_deteccion	Coefficiente de correlación	1,000	,581*
		Sig. (bilateral)	.	,037
		N	13	13
	eficiencia_aplicativo	Coefficiente de correlación	,581*	1,000
		Sig. (bilateral)	,037	.
		N	13	13

*. La correlación es significativa al nivel 0,05 (bilateral).

Figura 4. Resultado de la correlación entre la variable dependiente e independiente

3.6. Imágenes de entrenamiento

Se obtuvieron las imágenes de entrenamiento de la plataforma kaggle, estas nos servirán para poder entrenar a la Red Neuronal Convolutiva.



Figura 5. Imágenes de hojas sanas para entrenamiento

3.7. Imágenes de validación

Se hizo uso de un teléfono móvil Redmi Note 12 utilizando la cámara trasera de 48 Mpx, tomando las fotografías para la recolección de imágenes que nos ayudaran a validar la Red Neuronal Convolutiva con la cámara trasera del teléfono celular.




Figura 6. Imágenes de hojas sanas para validación

Se eligió el Algoritmo ADAM (Adaptive moment estimation) como algoritmo de optimización de la Red Neuronal Convolutiva, este utiliza momentos adaptativos y además es considerado uno de los algoritmos de optimización más robustos en la actualidad.

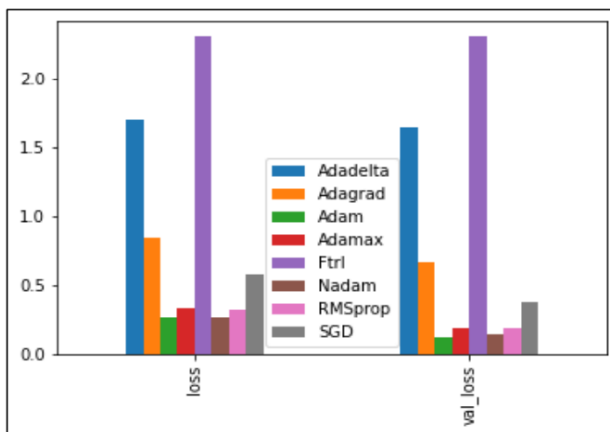


Figura 7. Convergencia de los diferentes optimizadores en clasificador CNN




Figura 8. Función de activación lineal rectificada, utilizada por las unidades ReLU

3.8. Entrenamiento

En esta fase, empezamos con el entrenamiento de nuestro modelo de Red Neuronal Convolutiva, utilizando así imágenes de hojas enfermas, las cuales están conformadas por 1500 para entrenamiento y 200 para validación e imágenes de hojas sanas, las cuales están conformadas por 1500 para entrenamiento y 200 para validación (Ver Figura 9).

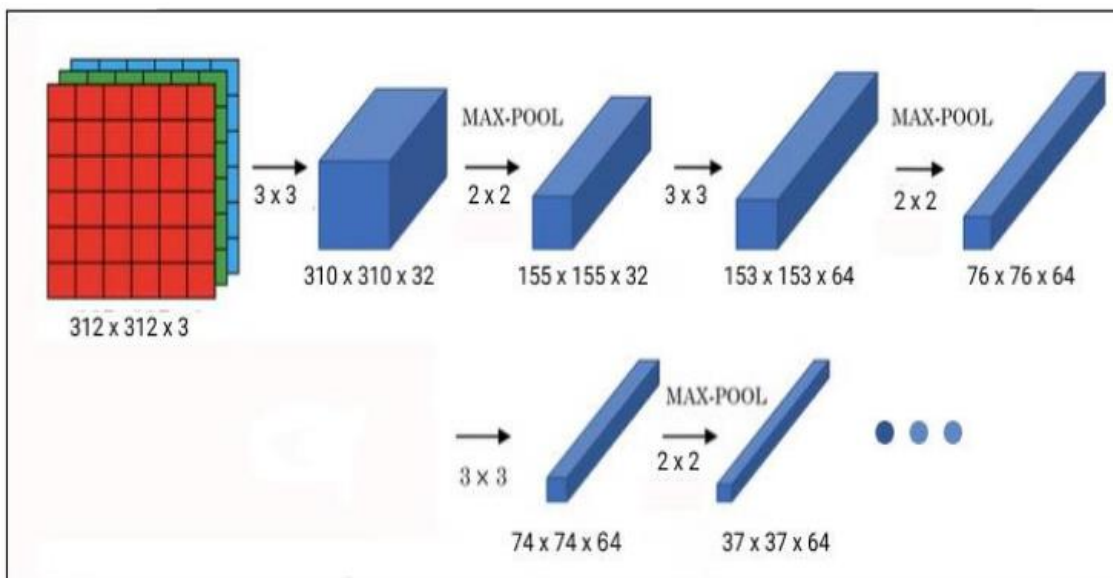


Figura 9. Modelo de Red Neuronal Convolutiva Utilizada

El modelo de Red Neuronal Convolutiva recibe imágenes de dimensiones $312 \times 312 \times 3$, en la primera capa convolutiva tiene 32 filtros de dimensiones 3×3 con función de activación ReLU. Luego, le seguirá una capa de agrupamiento con dimensiones de 2×2 . En la segunda capa convolutiva tiene 64 filtros de dimensiones 3×3 con función de activación ReLU, seguida de una capa de agrupamiento con dimensiones de 2×2 . Luego, en la tercera, cuarta, quinta y sexta capa convolutiva tiene 64 filtros de dimensiones 3×3 con función de activación ReLU seguida de una capa de agrupamiento con dimensiones de 2×2 cada una. Seguidamente, tiene una capa "dropout" que previene del sobreajuste a nuestro modelo. Finalmente, tiene una capa densa con 512 neuronas, la cual dará paso a la última capa densa de clasificación con 2 neuronas de salida, las cuales arrojan 0 si está enferma y 1 si está sana.

3.9. Aplicativo móvil

El aplicativo móvil captura mediante la cámara del teléfono móvil las características que muestra la hoja. Las imágenes sacadas serán enviadas mediante el teléfono celular a un servidor que, convirtiendo primero las imágenes en matrices y seguidamente en tensores, envía la información de la imagen al Modelo de Red Neuronal Convolutiva.



Figura 10. Pantalla de historial de clasificación del aplicativo móvil desarrollado

El aplicativo móvil, que utiliza una Red Neuronal Convolutiva, busca mejorar el proceso de diagnóstico en las plantas de yuca que padecen la enfermedad del mosaico. El aplicativo móvil captura mediante la cámara del teléfono móvil las características que muestra la hoja. Las imágenes sacadas serán enviadas mediante el teléfono celular a un servidor que, convirtiendo primero las imágenes en matrices y seguidamente en tensores, envía la información de la imagen al Modelo de Red Neuronal Convolutiva.

El Modelo de Red Neuronal Convolutiva toma la imagen y la procesa para posteriormente hacer un diagnóstico. La imagen pasa a través de las capas de convolución, las cuales extraen las características esenciales, luego pasa por las capas densas, las cuales toman la imagen, y la envían a una última capa con 2 salidas, las cuales toman la decisión de si la imagen tomada pertenece a una hoja enferma, o si, por el contrario, pertenece a una hoja sana real.

4. Conclusiones

Esta investigación evidencia que la implementación de un aplicativo móvil para la detección de la enfermedad del mosaico en la asociación civil “Unidos Tres Estrellas” ha generado una diferencia significativa en los resultados obtenidos antes y después de su uso. Los análisis realizados demostraron que la media de la exactitud del modelo entrenado superó el 90%, lo que resalta la efectividad del sistema propuesto en la identificación de esta enfermedad agrícola. Además, se concluye que la eficacia del aplicativo móvil influye de manera significativa en el diagnóstico de la enfermedad, mejorando así el proceso de monitoreo y control por parte de los agricultores. Estos hallazgos subrayan la importancia de integrar tecnologías de inteligencia artificial en la agricultura, específicamente en la gestión de enfermedades, lo que no solo optimiza la producción, sino que también contribuye a la sostenibilidad del cultivo de yuca en la región.

Financiamiento

Ninguno.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses.

Contribución de autores

Conceptualización: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Curación de datos: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Análisis formal: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Adquisición de fondos: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Investigación: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Metodología: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Administración del proyecto: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Recursos: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Software: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Supervisión: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Validación: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Visualización: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Escritura - preparación del borrador original: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto

Escritura - revisión y edición: Diaz-Holgado, Romario; Vilcas-Villalba, Denis Ricardo; Miranda-Castillo, Ralph; Holgado-Apaza, Luis Alberto.

Referencias bibliográficas

- Álvarez, E., & Llano Rodríguez, G. A. (2015). La yuca en el Tercer Milenio: Sistemas modernos de producción, procesamiento, utilización y comercialización. In C. I. de A. T. (CIAT) (Ed.), *Manejo de enfermedades y plagas*. Consorcio Latinoamericano para la Investigación y el Desarrollo de la Yuca. <https://hdl.handle.net/10568/55242>
- Ardón Muñoz, C. D., & Morales Calderón, B. J. (2021). Clasificación automática de la severidad del Virus del Mosaico Dorado en frijol. *Revista Ciencia Multidisciplinaria CUNORI*, 5(1 SE-Artículos científicos), 41-50. <https://doi.org/10.36314/cunori.v5i1.151>
- Castro Sandoval, M. M. (2019). *Identificación de Citrus leprosis virus C en Citrus sinensis mediante redes neuronales convolucionales de imágenes digitales*. Instituto Politécnico Nacional.

- Ceballos, H. (2002). *La yuca en Colombia y el mundo: nuevas perspectivas para un cultivo milenario*. Centro Internacional de Agricultura Tropical - CIAT. <http://hdl.handle.net/20.500.12324/18087>
- Cusme Zambrano, K. D., & Loo Pinargote, A. M. (2019). *Aplicación móvil de detección y clasificación de "la roya" en hojas de café robusta mediante aprendizaje automático* [ESPAMMFL]. <http://repositorio.esпам.edu.ec/handle/42000/1104>
- Fuentes Plaza, F. N. (2024). *Visión por computadora para el manejo de plagas y enfermedades en cultivos de papa*. [Universidad de Concepción]. <https://repositorio.udec.cl/handle/11594/6716>
- García Alcalá, I. S. (2020). *Procesamiento De Imagen Digital Utilizando Redes Neuronales Para Identificar El Sistema Negro En El Cultivo De Plantas* [Tecnológico Nacional de México]. <https://rinacional.tecnm.mx/jspui/handle/TecNM/1499>
- Langer, G., & Kühn, S. (2024). Perception and acceptance of robots in dairy farming – a cluster analysis of German citizens. *Agriculture and Human Values*, 41(1), 249–267. <https://doi.org/10.1007/s10460-023-10483-x>
- Malik, J., Kiranyaz, S., & Gabbouj, M. (2021). Self-organized operational neural networks for severe image restoration problems. *Neural Networks*, 135, 201–211. <https://doi.org/10.1016/j.neunet.2020.12.014>
- Pereyra, M. E. (2020). *Detección de enfermedades y plagas en cultivos mediante Machine Learning* [Universidad Nacional de La Plata]. <http://sedici.unlp.edu.ar/handle/10915/118496>
- Pinedo, J. C. S. M., López, C. A. R., Grández, C. R., & Estrella, C. W. G. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*, 1(2), 15–26. <https://doi.org/10.51252/RCSI.V1I2.131>
- Sambasivam, G., & Opiyo, G. D. (2021). A predictive machine learning application in agriculture: Cassava disease detection and classification with imbalanced dataset using convolutional neural networks. *Egyptian Informatics Journal*, 22(1), 27–34. <https://doi.org/10.1016/J.EIJ.2020.02.007>
- Santos, D., Dallos, L., & Gaona-García, P. A. (2020). Motion tracking algorithms using AI and machine learning techniques. *Informacion Tecnologica*, 31(3), 23–38. <https://doi.org/10.4067/S0718-07642020000300023>