

# Detección de enfermedades en cultivos de yuca a través de CNNs

David Hiram Vázquez Santana

Instituto Politécnico Nacional,  
Centro de Investigación en Computación,  
México

[dvazquezs2019@cic.ipn.mx](mailto:dvazquezs2019@cic.ipn.mx)

**Resumen.** Gracias a su gran aportación de carbohidratos, la yuca es de vital importancia para la seguridad alimentaria y ha sido clasificado como el cuarto cultivo básico más importante para casi mil millones de personas. Se estima que la producción mundial asciende a más de 302 millones de toneladas anuales, siendo África el mayor productor con una cuota cercana al 63 % de la producción mundial. Además, es una fuente importante de carbohidratos para más de 200 millones de personas en el África subsahariana y en los últimos años su uso se ha extendido a la producción de pienso y otros fines industriales. La yuca, como cualquier otro cultivo, no está a salvo de sufrir enfermedades y debido a su relevancia, la detección de estas es de gran importancia para mejorar el rendimiento de las plantaciones. Los métodos más usados en la actualidad son intensivos y requieren grandes cantidades de dinero, tiempo y mano de obra especializada, por lo que en este trabajo se propone un método barato y que no requiere de especialistas agrícolas para la detección de cuatro de las enfermedades más comunes en esta planta mediante la clasificación de imágenes a través de tres algoritmos de clasificación y utilizando un banco de datos con imágenes obtenidas por agricultores y etiquetadas por expertos agrónomos, alcanzando valores F1 de 63.60, 73.97, 70.82, 85.77 y 76.22 para las clases CBB, CBSD, CGM, CMD y sana respectivamente.

**Palabras clave:** Yuca, deep learning, visión artificial, detección de enfermedades en cultivos.

## Cassava Crop Diseases Recognition Using CNNs

**Abstract.** Thanks to its high carbohydrate content, cassava is vital for food security and has been ranked as the fourth most important staple crop for almost one billion people. World production is estimated at more than 302 million tons per year, being Africa the largest producer with an estimated 63% quota of the world's production. In addition, it is an important source of carbohydrates for more than 200 million people in sub-Saharan Africa and in recent years its use has been extended to animal feed production and other industrial purposes. Cassava, like any other crop, is not immune to diseases and due to its relevance, the control of these diseases is of great importance to improve the productivity of

the plantations. Currently, the most used methods are intensive and require large amounts of money, time and expert work force. Hence, in this work we propose a cheap method that does not require agro-specialists for the detection of four of the most common diseases in this plant by classifying images through three algorithms and using a dataset with images obtained by farmers and labeled by agro-specialists, reaching F1 values of 63.60, 73.97, 70.82, 85.77 and 76.22 for CBB, CBSD, CGM, CMD and healthy classes, respectively.

**Keywords:** Cassava, deep learning, machine vision, crop disease detection.

## 1. Introducción

Gracias a la facilidad de la yuca para adaptarse a diferentes tipos de suelos y climas, esta es cultivada en varios continentes, incluyendo África, América y Asia. El cultivo es de especial importancia en África, donde es una fuente importante de carbohidratos para más de 200 millones de personas en la región subsahariana.

Además, el continente es responsable de alrededor del 63 % de la producción mundial [13]. La yuca no solo es importante para garantizar la seguridad alimentaria. También es importante para la industria, se utiliza principalmente en la producción de papel, pienso y almidón [2, 19].

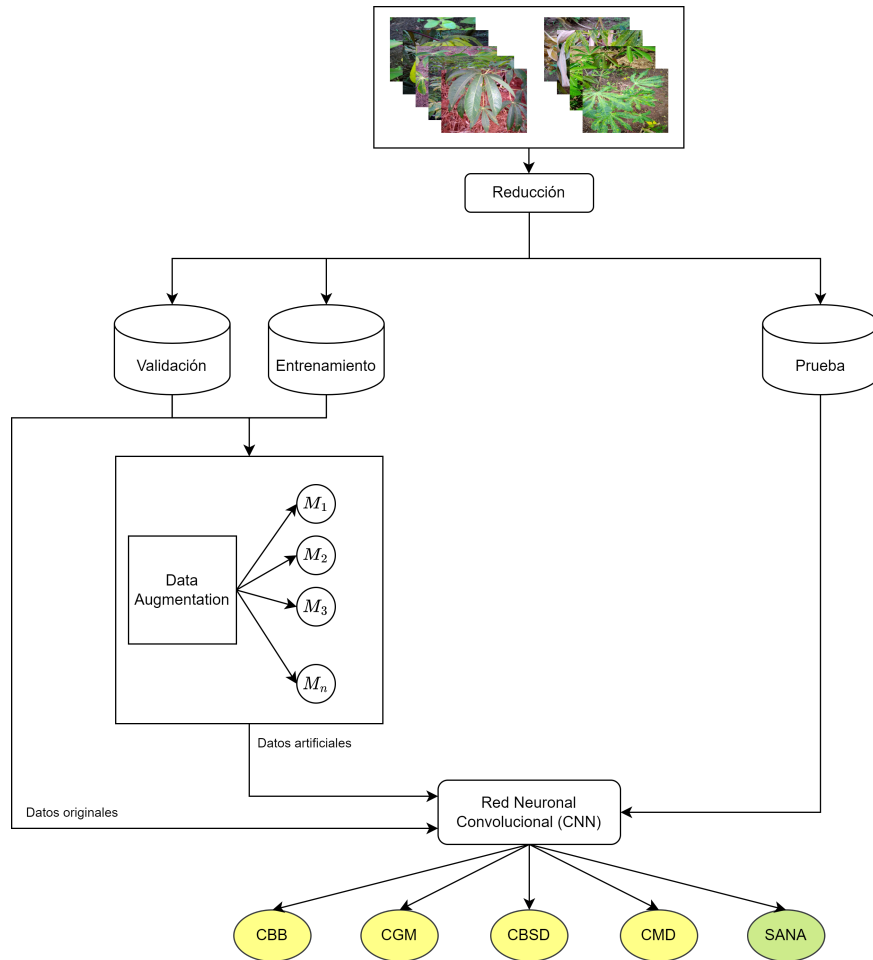
Además, gracias a su alta aportación de carbohidratos, este cultivo ha sido clasificado como el cuarto más importante para casi mil millones de personas [9]. Debido a su alto valor nutricional y económico, la producción de yuca se ha convertido en un tema de interés para los países productores.

Es por eso que el rendimiento de los cultivos es de suma importancia. Existen diversos factores que afectan el rendimiento de los cultivos. Estos pueden agruparse en tres grandes grupos: el primero está compuesto por los factores meteorológicos, como heladas, lluvias torrenciales, sequías, entre otros factores; el segundo grupo está compuesto por los factores relacionados al manejo de los cultivos y del suelo.

Finalmente, el tercer grupo está relacionado con el manejo de enfermedades. No es común que se realice el diagnóstico de enfermedades foliares debido a que, en la mayoría de los casos, es necesario realizarlo de forma manual por expertos agrónomos, lo que lo convierte en un método de diagnóstico costoso e ineficiente, por lo que se vuelve necesario desarrollar métodos más precisos para reducir los costos asociados a la detección de enfermedades y lograr que los agricultores estén dispuestos a implementarlos en sus plantaciones.

En la actualidad, existen diversos trabajos que utilizan una combinación de técnicas de visión artificial, procesamiento de imágenes y Machine Learning (ML). Por ejemplo, Meunkaewjinda A. et al. [10] propusieron un sistema capaz de identificar si una vid tiene sarna, roya o si se encuentra libre de enfermedades a través de la segmentación de las hojas y su posterior clasificación a través de una máquina de soporte vectorial (SVM).

Tal como lo muestra la revisión del estado del arte realizada por Lavika y Jyoti [6], las SVM son una de las técnicas más ampliamente utilizadas en los métodos de detección de enfermedades en plantas para llevar a cabo la fase de clasificación y algunas veces se combina con otras técnicas ML.



**Fig. 1.** Diagrama general del método propuesto.

Tal es el caso del trabajo presentado por Santosh y Manish [8], quienes desarrollaron un método de detección de enfermedades basado en la segmentación de hojas a través de clustering y su clasificación a usando un sistema híbrido compuesto por Random Forest (RF) y una SVM.

Uno de los principales retos al utilizar técnicas ML es la selección y extracción de características. De acuerdo con una revisión sistemática referente a la detección de enfermedades en plantas, las características que más frecuentemente se extraen son la forma, la textura y el color y las especies más estudiadas son el maíz, las papas, la soya y el algodón [6].

Esta investigación se enfoca en mejorar el rendimiento de los cultivos a través de la detección de enfermedades foliares utilizando técnicas de Deep Learning (DL), como las redes neuronales convolucionales (CNNs), las cuales permiten la detección y extracción automática de características importantes.




Fig. 2. Bloque residual.

Algunas de las enfermedades que más afectan la producción son cassava green mite (CGM), cassava bacterial blight (CBB), cassava brown streak disease (CBSD), cassava mosaic disease (CMD), cassava American latent leaf disease (CALD), cassava brown streak Uganda disease (CBSUD) y cassava Colombian symptomless disease (CCSD) [14].

## 2. Materiales y métodos

En esta sección se presenta la estructura general del modelo propuesto, los detalles de las CNNs seleccionadas y el banco de datos utilizado. El modelo propuesto utiliza una red neuronal convolucional como núcleo de funcionamiento. Se decidió no realizar preprocesamiento a las imágenes y dejar que la CNN se encargue de la extracción de características principales. En la Figura 1, se muestra el diagrama general del modelo presentado.

El banco de datos fue dividido en tres conjuntos: entrenamiento, validación y prueba. Posteriormente, con el objetivo de mejorar la generalización obtenida por la CNN, se crean instancias artificiales a partir de instancias reales. Después, la CNN es entrenada utilizando los patrones originales y sintéticos. Finalmente, el conjunto de prueba es presentado al clasificador y se mide el desempeño obtenido por el modelo.

### 2.1. Arquitecturas

Las redes neuronales convolucionales son un tipo particular de redes neuronales artificiales y su funcionamiento se basa en una operación conocida como convolución, la cual permite reducir el número de parámetros. Las CNNs combinan el poder de un extractor automático de rasgos y la capacidad de clasificación de un perceptrón multicapa [1].

La imagen de entrada es considerada como una matriz de tamaño  $M \times N$  y se representa como  $W_{m,n}$ . Posteriormente, se aplica la convolución a la entrada utilizando un kernel  $k_{p,q}$  de tamaño  $P \times Q$ . A continuación, se describen las arquitecturas seleccionadas.

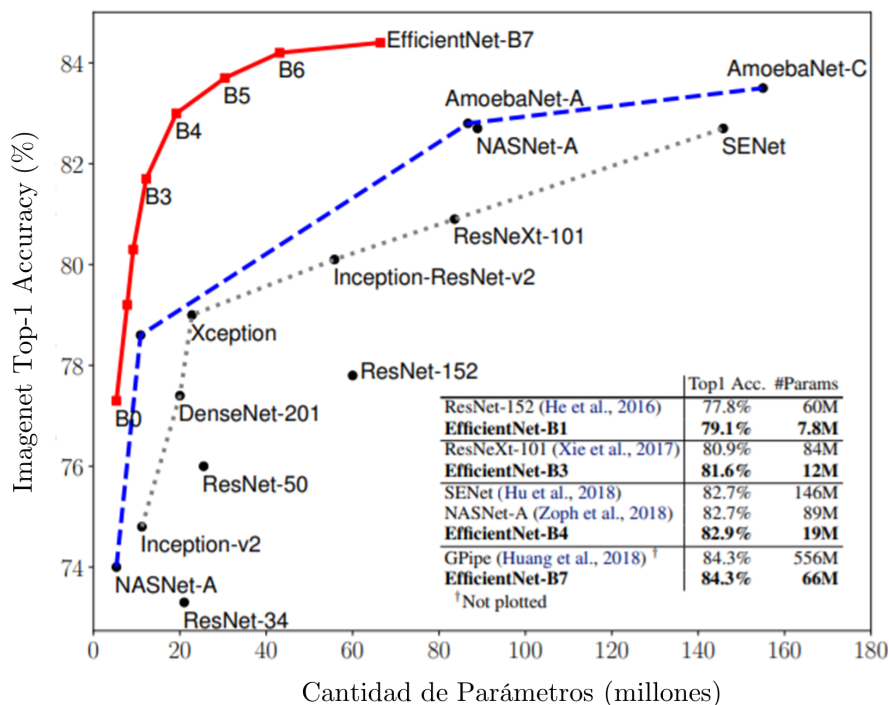



Fig. 3. Comparación de EfficientNets con respecto a otros modelos.

**ResNet-50:** ResNet-50 es un modelo que pertenece a la familia de redes ResNet [7], que es el nombre corto de red residual (residual network). Esta familia fue creada para solucionar el problema del gradiente de desaparición, el cual impide que las redes profundas actualicen sus pesos [4].


Esta CNN, como todas las de su familia, está formada por bloques residuales, los cuales se pueden entender como atajos para saltar 2 o 3 capas y evitar que estas se entrenen. ResNet-50 está formada por 15 bloques residuales como el que se muestra en la figura 2.

En cuestión de capas, está compuesta por 50 capas: 1 capa de entrada, 46 capas convolucionales, 2 capas de pooling y una capa densa con 1,000 neuronas a la salida. Esta es una de las redes neuronales convolucionales más ampliamente usada [5, 12, 16], razón por la cual se decidió implementarla en el modelo presentado en el presente artículo.

**EfficientNet-B4:** Esta arquitectura pertenece a la familia de redes neuronales convolucionales EfficientNets, la cual fue desarrollada por el equipo Google Brain y presentada en el artículo EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [17]. La arquitectura de estas redes se basa en el escalamiento controlado a través de un método conocido como compound scaling y funciona escalando tres atributos al mismo tiempo usando un coeficiente ( $\phi$ ): profundidad, ancho y resolución. En la ecuación 1 se muestra este método:



**Fig. 4.** Ensemble Stacking utilizando ResNet-50 y EfficientNet-B4.



**Fig. 5.** Hojas de yuca con CBB, CBSD, CGM, CMD y sin enfermedades.

$$\begin{aligned}
 \text{profundidad} : d &= \alpha^\phi, \\
 \text{ancho} : w &= \beta^\phi, \\
 \text{resolución} : r &= \gamma^\phi, \\
 \alpha \cdot \beta^2 \cdot \gamma^2 &\approx 2, \\
 \alpha \geq 1, \beta \geq 1, \gamma &\geq 1.
 \end{aligned} \tag{1}$$

Se seleccionó esta arquitectura debido a que su tamaño, tomando como referencia la cantidad de parámetros, es pequeño en comparación con otros modelos más profundos. Además, como se muestra en la figura 3 [17], este modelo presenta una notable mejoría en términos de accuracy alcanzado en el ImageNet comparado con los modelos B0, B1, B2 y B3.

**Ensamble de redes neuronales convolucionales:** Los métodos de ensambles han tomado relevancia en los últimos años, especialmente en la clasificación de patrones [3, 15, 18]. El objetivo de estos modelos es obtener un mejor rendimiento que los algoritmos con los que está compuesto, ya que permiten eliminar los errores no correlacionados de los clasificadores individuales por medio de votación.

Existen diversas estrategias para la creación de ensambles, las más utilizadas son Bagging, Boosting y Stacking. En este trabajo se presenta un ensamble utilizando la técnica Stacking y los modelos ResNet-50 y EfficientNet-B4, tal como se muestra en la figura 4.

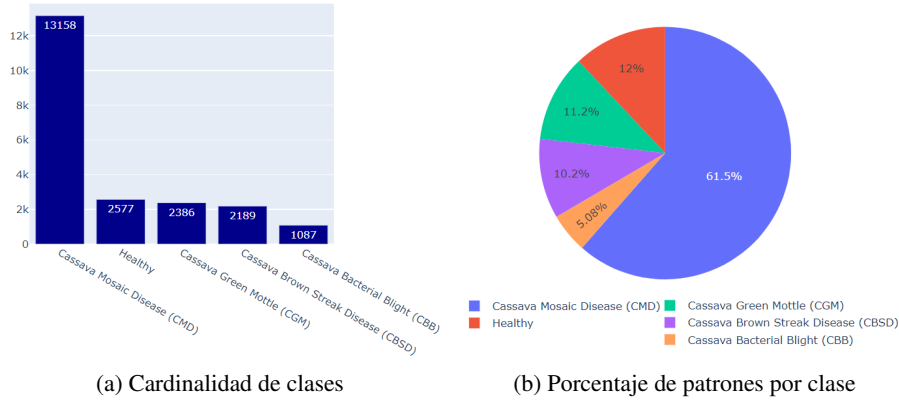


Fig. 6. Distribución de clases en el banco de datos.

## 2.2. Banco de datos

Para entrenar los modelos seleccionados, se utilizó un el Cassava Leaf dataset con 21,397 imágenes capturadas por agricultores de plantaciones en Uganda y etiquetadas por expertos del Instituto Nacional de Investigación de Recursos Agrícolas (NaCRRI) en colaboración con el laboratorio de IA de la Universidad de Makerere en Kampala [11]. 1,087 imágenes corresponden a cassava bacterial blight (CBB), 13,158 a cassava mosaic disease (CMD), 2,189 a cassava brown streak disease (CBSD), 2,386 a cassava green spot (CGM) y 2,577 a hojas sanas.

En la figura 5, se muestran cinco imágenes extraídas del banco de datos, cuatro de hojas de yuca con alguna enfermedad y una que no presenta ninguna enfermedad. En la figura 6, se muestra la distribución de las 21,397 imágenes en las 5 clases dentro del banco de datos. Se observa que, con 13,158 imágenes la clase 3 (CMD) es la clase mayoritaria, mientras que la clase 0 (CBB) con 1,087 imágenes es la clase minoritaria. Como se muestra en la ecuación 2, el banco de datos esta extremadamente desbalanceado, por lo que no es posible utilizar accuracy como métrica de desempeño:

$$IR = \frac{13,158}{1,087} = 12.105. \quad (2)$$

## 3. Métricas de desempeño

Debido a la imposibilidad de utilizar accuracy como métrica de desempeño, es necesario aplicar otras más adecuadas derivadas de la matriz de confusión.

### 3.1. Precisión

Se asocia a la calidad del modelo y se refiere a la capacidad del modelo para identificar instancias positivas entre las instancias recuperadas. Matemáticamente, es la cantidad de verdaderos positivos (TP) entre la suma de verdaderos positivos (TP) y falsos positivos (FP), tal como se muestra en la ecuación 3:

Clase real	CBB	146	7	13	34	17
	CBSD	8	327	14	68	21
	CGM	12	24	316	94	31
	CMD	134	164	173	1977	184
	Sana	7	14	16	37	441
		CBB	CBSD	CGM	CMD	Sana
		Clase predicha				

(a) EfficientNet-B4, matriz de confusión

Clase real	CBB	127	12	22	36	20
	CBSD	11	298	21	74	34
	CGM	23	37	263	95	59
	CMD	164	183	213	1824	248
	Sana	14	18	26	62	395
		CBB	CBSD	CGM	CMD	Sana
		Clase predicha				

(b) ResNet-50, matriz de confusión

Fig. 7. Matrices de confusión.

$$\text{precision} = \frac{TP}{TP + FP}. \tag{3}$$

### 3.2. Recall

Se asocia a la cantidad de instancias que el modelo es capaz de identificar y se refiere a la capacidad del clasificador de identificar instancias positivas. Se calcula de acuerdo con la ecuación 4:

$$\text{recall} = \frac{TP}{TP + FN}. \tag{4}$$

### 3.3. F1

La métrica F1 combina las métricas precision y recall en un solo valor. Es muy útil para comparar el rendimiento combinado de la calidad y exhaustividad entre varios algoritmos; el valor de F1 es la media armónica de precision y recall y se calcula de acuerdo con la ecuación 5:

$$F1 = \frac{2(\text{precision} \times \text{recall})}{\text{precision} + \text{recall}}. \tag{5}$$

## 4. Resultados

### 4.1. Parámetros de aprendizaje

Se utilizaron los mismos parámetros de aprendizaje en todas las arquitecturas. La función de activación seleccionada fue softmax y sparse categorical crossentropy como función de pérdida. El entrenamiento se realizó utilizando el método mini-batch Learning con tamaño 20 y una tasa de aprendizaje de 0.004. Tanto ResNet-50, como EfficientNet-B4 fueron entrenadas durante 200 épocas. Las imágenes fueron redimensionadas a 200 x 250 píxeles.



**Tabla 1.** Resultados EfficientNet-B4.

Clase	Precision	Recall	F1-score
CBB	47.56	67.28	55.73
CBSD	61.01	74.66	67.15
CGM	59.40	66.25	62.64
CMD	89.46	75.11	81.66
Sana	63.54	85.63	72.95

**Tabla 2.** Resultados ResNet-50.

Clase	Precision	Recall	F1-score
CBB	37.46	58.53	45.68
CBSD	54.38	68.04	60.45
CGM	48.26	55.14	51.47
CMD	87.23	69.30	77.24
Sana	52.25	76.70	62.16

#### 4.2. Desempeño

El banco de datos fue dividido en los conjuntos de entrenamiento, validación y prueba con proporción 70/10/20 y el proceso de entrenamiento se realizó utilizando el método de validación hold-out. En la figura 3.1, se muestra el desempeño obtenido en el conjunto de prueba por EfficientNet-B4 (3.1) y ResNet-50 (3.1). Se observa que ambos modelos están sesgados hacia la clase cassava mosaic disease (CMD), la cual es la clase mayoritaria. En el caso de EfficientNet-B4, el 15.66 %, 15.52 %, 19.71 % y 7.18 % de los patrones de las clases CBB, CBSD, CGM y Sana respectivamente fueron clasificados como CMD.

Por otro lado, el 16.59 %, 16.89 %, 19.92 % y 12.04 % de los patrones de las clases CBB, CBSD, CGM y Sana respectivamente clasificados a través de ResNet-50, fueron clasificados como CMD. En la tabla 1, se muestra el desempeño obtenido por EfficientNet-B4 en cada una de las clases del banco de datos. Como era de esperarse, la clase más difícil de clasificar por esta CNN es cassava bacterial blight (CBB), ya que es la clase minoritaria. Por el contrario, la clase más fácil de clasificar para este modelo es cassava mosaic disease (CMD), ya que es la clase mayoritaria.

En la tabla 2, se muestran los resultados de la clasificación de imágenes de enfermedades foliares obtenidos a través de la CNN ResNet-50. Se observa un comportamiento similar al obtenido con EfficientNet-B4, sin embargo, ResNet-50 no logró alcanzar el mismo desempeño. En la figura 8, se muestra la matriz de confusión obtenida por el ensamble propuesto. Se observa que el modelo fue capaz de mejorar el desempeño obtenido de forma individual por las dos arquitecturas por las que está compuesto.

La tabla 3 muestra los valores de las métricas de desempeño seleccionadas obtenidas por el ensamble propuesto. La clase que resultó más beneficiada del uso del modelo combinado fue CBB, ya que fue la clase que obtuvo un mayor aumento proporcional de patrones correctamente clasificados, pasado de un valor F1 mínimo de 45.68 % obtenido a través de ResNet50 a 63.60 % con el uso del ensamble propuesto.

Clase real	CBB	152	7	13	32	13
	CBSD	7	351	13	46	21
	CGM	6	16	358	76	21
	CMD	89	127	136	2116	164
	Sana	7	10	14	32	452
		CBB	CBSD	CGM	CMD	Sana
		Clase predicha				

Fig. 8. Ensemble ResNet-50-EfficientNet-B4, matriz de confusión.

## 5. Conclusiones y trabajo a futuro

En este trabajo se presenta un método de detección de enfermedades foliares en plantaciones de yuca a través de la clasificación de imágenes usando redes neuronales convolucionales. Los modelos seleccionados fueron entrenados utilizando imágenes RGB reales y sintéticas. El modelo propuesto permite a los productores de yuca detectar cuatro enfermedades foliares sin la intervención de agrónomos, reduciendo así el tiempo y los costos asociados al diagnóstico de enfermedades foliares.

El productor podrá capturar imágenes de plantas sospechosas y presentarlas al modelo para obtener un diagnóstico probable. En comparación con varios métodos actualmente disponibles para el diagnóstico de enfermedades foliares basados en CNNs, el propuesto en esta investigación es capaz de realizar el diagnóstico sin necesidad de segmentar las hojas ni realizar procesos intensivos de preprocesamiento, reduciendo así la cantidad de recursos computacionales necesarios para su ejecución.

En el estudio también se presenta la comparación del desempeño obtenido por varios modelos DL en el banco de datos cassava leaf disease, en concreto, el desempeño obtenido por ResNet-50, EfficientNet-b4 y un ensemble tipo stacking. En todos los casos, la clase más difícil de clasificar fue CBB, mientras que la clase CMD fue la que obtuvo el mejor resultado a través de la métrica F1.

A través del análisis de las matrices de confusión, se observa que, en cuanto a desempeño individual, EfficientNet-B4 supera a ResNet-50, alcanzando valores más altos en las métricas de desempeño para todas las clases. Además, se observa que el desempeño obtenido por el ensemble tipo stacking supera al desempeño individual obtenido por las CNNs utilizadas para crearlo, alcanzando valores F1 de 63.60 %, 73.97 %, 70.82 %, 85.77 % y 76.22 % para las clases CBB, CBSD, CGM, CMD y Sana respectivamente.

Tras analizar los resultados obtenidos por las arquitecturas seleccionadas en esta investigación, se considera que el desempeño exhibido por el modelo basado en ensambles de CNNs es lo suficientemente bueno como para poder mejorar el rendimiento de los cultivos de yuca a través del diagnóstico de enfermedades foliares sin necesidad de intervención humana.

**Tabla 3.** Resultados ensamble ResNet-50 - EfficientNet-B4.

Clase	Precision	Recall	F1-score
CBB	58.24	70.05	63.60
CBSD	68.69	80.14	73.97
CGM	67.04	75.05	70.82
CMD	91.92	80.40	85.77
Sana	67.36	87.77	76.22

Durante el desarrollo de la presente investigación, se observó que la cardinalidad de las clases es de gran importancia para el correcto aprendizaje de las redes neuronales convolucionales. Con el objetivo de mejorar los resultados obtenidos y como trabajo futuro, se propone aumentar la cardinalidad de las clases minoritarias a través de la adición de ejemplos reales y la creación de otros de forma sintética. Además, se propone utilizar modelos más profundos de las mismas familias de redes neuronales convolucionales seleccionadas para la creación del ensamble.

Es importante resaltar que, a pesar del uso del modelo presentado, la obtención de imágenes sigue siendo un trabajo intensivo, por lo que es necesario idear un método más eficiente para la captura de estas. Una posible solución sería montar una cámara sobre un dron. Con esta adición se reduciría mucho la cantidad de tiempo requerida para la obtención de diagnósticos probables.

## Referencias

1. Albawi, S., Mohammed, T. A., Al-Zawi, S.: Understanding of a convolutional neural network. In: International Conference on Engineering and Technology (ICET), pp. 1–6 (2017) doi: 10.1109/ICEngTechnol.2017.8308186
2. Anyanwu, C., Ibeto, C., Ezeoha, S., Ogbuagu, N.: Sustainability of cassava (*manihot esculenta crantz*) as industrial feedstock, energy and food crop in Nigeria. *Renewable Energy*, vol. 81, pp. 745–752 (2015) doi: 10.1016/j.renene.2015.03.075
3. Balasubramaniam, S., Sathesh Kumar, K.: Optimal ensemble learning model for COVID-19 detection using chest X-ray images. *Biomedical Signal Processing and Control*, vol. 81, pp. 104392 (2023) doi: 10.1016/j.bspc.2022.104392
4. Basodi, S., Ji, C., Zhang, H., Pan, Y.: Gradient amplification: An efficient way to train deep neural networks. *Big Data Mining and Analytics*, vol. 3, no. 3, pp. 196–207 (2020) doi: 10.26599/BDMA.2020.9020004
5. Civilibal, S., Cevik, K. K., Bozkurt, A.: A deep learning approach for automatic detection, segmentation and classification of breast lesions from thermal images. *Expert Systems with Applications*, vol. 212, pp. 118774 (2023) doi: 10.1016/j.eswa.2022.118774
6. Goel, L., Nagpal, J.: A systematic review of recent machine learning techniques for plant disease identification and classification. *Institution of Electronics and Telecommunication Engineers Technical Review*, vol. 40, no. 3, pp. 423–439 (2022) doi: 10.1080/02564602.2022.2121772
7. He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778 (2016) doi: 10.1109/CVPR.2016.90
8. Kumar-Sahu, S., Pandey, M.: An optimal hybrid multiclass SVM for plant leaf disease detection using spatial fuzzy C-Means model. *Expert Systems with Applications*, vol. 214, pp. 118989 (2023) doi: 10.1016/j.eswa.2022.118989

9. Latif, S., Müller, J.: Potential of cassava leaves in human nutrition: A review. *Trends in Food Science and Technology*, vol. 44, no. 2, pp. 147–158 (2015) doi: 10.1016/j.tifs.2015.04.006
10. Meunkaewjinda, A., Kumsawat, P., Attakitmongcol, K., Srikaew, A.: Grape leaf disease detection from color imagery using hybrid intelligent system. In: 5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, vol. 1, pp. 513–516 (2008) doi: 10.1109/ECTICON.2008.4600483
11. NaCRRRI: Cassava leaf disease classification (2020) <https://www.kaggle.com/competitions/cassava-leaf-disease-classification/data>
12. Olayemi-Alebiosu, D., Dharmaratne, A., Hong Lim, C.: Improving tuberculosis severity assessment in computed tomography images using novel DAvoU-Net segmentation and deep learning framework. *Expert Systems with Applications*, vol. 213, pp. 119287 (2023) doi: 10.1016/j.eswa.2022.119287
13. Omondi, J. O., Yermiyahu, U.: Improvement in cassava yield per area by fertilizer application. *Cassava*, chapter 6 (2021) doi: 10.5772/intechopen.97366
14. Oyewola, D. O., Dada, E. G., Misra, S., Damaševičius, R.: Detecting cassava mosaic disease using a deep residual convolutional neural network with distinct block processing. *PeerJ Computer science*, vol. 7, pp. e352 (2021) doi: 10.7717/peerj-cs.352
15. Rashidpoor-Toochaei, M., Moeini, F.: Evaluating the performance of ensemble classifiers in stock returns prediction using effective features. *Expert Systems with Applications*, vol. 213, pp. 119186 (2023) doi: 10.1016/j.eswa.2022.119186
16. Rustam, F., Ashraf, I., Jurcut, A. D., Bashir, A. K., Zikria, Y. B.: Malware detection using image representation of malware data and transfer learning. *Journal of Parallel and Distributed Computing*, vol. 172, pp. 32–50 (2023) doi: 10.1016/j.jpdc.2022.10.001
17. Tan, M., Le, Q.: Efficientnet: Rethinking model scaling for convolutional neural networks. In: *International Conference on Machine Learning*, pp. 6105–6114 (2019) doi: 10.48550/arXiv.1905.11946
18. Tavana, P., Akraminia, M., Koochari, A., Bagherifard, A.: An efficient ensemble method for detecting spinal curvature type using deep transfer learning and soft voting classifier. *Expert Systems with Applications*, vol. 213, pp. 119290 (2023) doi: 10.1016/j.eswa.2022.119290
19. Tonukari, N., Ezedom, T., Enuma, C., Sakpa, S., Avwioroko, O., Eraga, L., Odiyoma, E.: White gold: Cassava as an industrial base. *American Journal of Plant Sciences*, vol. 6, pp. 972–979 (2015) doi: 10.4236/ajps.2015.67103