

Detección de dos Enfermedad en yuca utilizando YOLOv11**Detection of two diseases in cassava using YOLOv11**

Olguer Alfredo León Gordón, Sixto Edmundo Mayorga Paredes, Walter Eduardo Moreno Castillo & Manolo Muñoz-Espinoza

DIMENSIÓN CIENTÍFICA

Enero - junio, V°7 - N°1; 2026

Recibido: 05-01-2026

Aceptado: 15-01-2026

Publicado: 19-01-2026

PAIS

- Ecuador, Guayaquil
- Ecuador, Guayaquil
- Ecuador, Guayaquil
- Ecuador, Guayaquil

INSTITUCION

- Universidad Técnica de Ambato
- Universidad Técnica de Ambato
- Universidad Técnica de Ambato
- Universidad Técnica de Ambato

CORREO:

- ✉ oa.leon@uta.edu.ec
- ✉ se.mayorga@uta.edu.ec
- ✉ we.moreno@uta.edu.ec
- ✉ mmunoz@uta.edu.ec

ORCID:

- 🌐 <https://orcid.org/0000-0003-2521-8842>
- 🌐 <https://orcid.org/0009-0008-9107-4967>
- 🌐 <https://orcid.org/0000-0003-3907-371X>
- 🌐 <https://orcid.org/0000-0001-5897-1211>

FORMATO DE CITA APA.

León, O., Mayorga, S., Moreno, W. & Muñoz-Espinoza, M. (2026). Detección de dos Enfermedad en yuca utilizando YOLOv11. *Revista G-ner@ndo*, V°7 (N°1). Pág. 299 – 309.

Resumen

Las enfermedades virales de la yuca conocidas como la estría parda de la yuca (CBSD) y el mosaico de la yuca (CMD) representan una amenaza significativa para la producción de este cultivo a nivel mundial. El presente estudio tuvo como objetivo desarrollar un sistema automatizado de identificación empleando YOLOv11. Se utilizó un conjunto de datos relacionado con imágenes de ambas enfermedades disponibles en la plataforma Kaggle. Además, las imágenes fueron etiquetado mediante codificación con Grounding DINO y el aumento de datos se realizó en el sitio web Roboflow, para entrenar y validar el modelo de detección. Se evaluaron métricas tales como: precisión, recall y mAP50. Los resultados mostraron valores máximos de 0.86 en precisión, 0.85 en recall y 0.87 en mAP50, lo cual evidenció un alto desempeño en la detección de ambas enfermedades. Esta metodología contribuyó a la identificación temprana de enfermedades virales foliares de gran importancia en el cultivo de la yuca, y además ofreció un enfoque escalable para ser adoptado en un modelo de agricultura de precisión.

Palabras clave: deep learning; arquitectura; imágenes; agricultura de precisión.

Abstract

Cassava viral diseases—specifically Cassava Brown Streak Disease (CBSD) and Cassava Mosaic Disease (CMD)—constitute a significant threat to global cassava production. This study aimed to develop an automated identification system leveraging YOLOv11. A dataset comprising images of both diseases, publicly available on the Kaggle platform, was employed. Image annotation was performed using Grounding DINO-based labeling, and data augmentation was conducted via the Roboflow web platform to support model training and validation. Model performance was evaluated using standard metrics, including precision, recall, and mean Average Precision at an IoU threshold of 0.5 (mAP50). The system achieved maximum values of 0.86 for precision, 0.85 for recall, and 0.87 for mAP50, demonstrating high efficacy in detecting both viral diseases. The proposed methodology facilitates early detection of foliar viral diseases of critical importance in cassava cultivation and provides a scalable framework suitable for integration into precision agriculture systems.

Keywords: deep learning; architecture; images; precision agriculture.

Introducción

La yuca (*Manihot esculenta* Crantz) constituye uno de los cultivos alimentarios más importantes en regiones tropicales y subtropicales del mundo, desempeñando un papel fundamental en la seguridad alimentaria de más de 800 millones de personas, especialmente en África subsahariana (Sehgal et al., 2021). Su amplia adopción se atribuye a su elevado contenido de almidón, su versatilidad culinaria e industrial, y su notable tolerancia a suelos pobres y condiciones de estrés hídrico (Muiruri et al., 2021).

Sin embargo, a pesar de su resiliencia agronómica, la producción de yuca se ve gravemente amenazada por enfermedades virales de alto impacto, entre las que destacan la Enfermedad del Mosaico de la Yuca (Cassava Mosaic Disease, CMD) y la Enfermedad de la Estría Parda de la Yuca (Cassava Brown Streak Disease, CBSD, ambas enfermedades, causadas por virus transmitidos por la mosca blanca (*Bemisia tabaci*), estas pueden provocar pérdidas de rendimiento superiores al 80% en campos severamente afectados, comprometiendo tanto la disponibilidad de alimentos como los ingresos de pequeños agricultores (Chikoti & Tembo, 2022; Uke et al., 2022).

Los métodos tradicionales de diagnóstico y control de enfermedades suelen ser costosos y consumir tiempo, además de depender de la experiencia de especialistas en fitopatología. El diagnóstico temprano y preciso de estos fitopatógenos es esencial para implementar medidas de manejo efectivas; no obstante, los métodos tradicionales — basados en inspección visual por expertos o análisis moleculares en laboratorio— suelen ser costosos, lentos y dependientes de recursos técnicos escasos en entornos rurales (Tugrul et al., 2022). Ante esta limitación, la visión por computadora asistida por inteligencia artificial ha emergido como una alternativa prometedora para la detección automatizada de

síntomas foliares, permitiendo diagnósticos rápidos, escalables y accesibles incluso mediante dispositivos móviles (Sharma et al., 2023).

En este contexto, los modelos de deep learning, particularmente las arquitecturas orientadas a la detección de objetos en tiempo real han demostrado un alto desempeño en aplicaciones agrícolas. Entre ellas, la familia de modelos YOLO (You Only Look Once) se ha consolidado por su equilibrio entre precisión y velocidad, convirtiéndose en una elección preferida para sistemas de monitoreo en campo (Jocher, 2024; Redmon, 2016).

En el presente estudio, se implementó una versión avanzada del modelo YOLO, adaptada específicamente para la identificación simultánea de los síntomas característicos de CBSD y CMD en imágenes de hojas de yuca.

Para ello, se utilizó el conjunto de datos público Cassava Disease Classification (ErnestMwebaze & Timnit, 2019), compuesto por miles de imágenes reales recolectadas en Uganda. Con el fin de mejorar la calidad y consistencia de las anotaciones, se aplicó la herramienta Grounding DINO, un modelo de etiquetado semiautomático basado en lenguaje que permite una segmentación y localización de objetos más precisa mediante descripciones textuales (Liu et al., 2024). Adicionalmente, se empleó la plataforma Roboflow (Roboflow, 2025) para realizar un exhaustivo proceso de data augmentation, incorporando variaciones de iluminación, rotación, escalado y ruido, con el objetivo de enriquecer la diversidad del conjunto de entrenamiento y mejorar la capacidad de generalización del modelo ante condiciones reales de campo.

Este trabajo busca contribuir al desarrollo de soluciones tecnológicas accesibles y de código abierto que apoyen a los agricultores en la toma de decisiones fitosanitarias oportunas, fortaleciendo así la resiliencia de los sistemas agrícolas frente a amenazas bióticas emergentes.

Métodos y Materiales

Conjunto de Datos

Se utilizó un dataset obtenido de Kaggle que contiene imágenes de hojas de yuca, cada una etiquetada con una de las siguientes clases:

- CBSD (Cassava Brown Streak Disease)
- CMD (Cassava Mosaic Disease)
- Fondo/Background (hojas sanas u otras partes sin enfermedad aparente)

Inicialmente, se contaba con algunos miles de imágenes. Tras una revisión, con el objetivo de mantener solo aquellas con la mejor calidad y con síntomas claramente visibles, se unificó el conjunto en 10 247 imágenes. De éstas, se destinaron 9222 para entrenamiento, 615 para validación y 410 para pruebas finales.

Anotación con Grounding DINO

La anotación de los contornos de las hojas y la correspondiente categoría (CBSD, CMD) se efectuó combinando anotación manual y asistida. Para este fin, se utilizó Grounding DINO, un modelo de detección de objetos basado en transformadores que permite generar propuestas de bounding boxes automáticamente (Liu et al., 2024).

Aumento de Datos con Roboflow

Para compensar la variabilidad de condiciones lumínicas, diferentes ángulos de captura y diversidad fenotípica en las hojas, se aplicaron técnicas de aumento de datos mediante la plataforma Roboflow (Roboflow, 2025). Entre las transformaciones realizadas se incluyeron:

- Rotaciones y volteos (horizontales y verticales).
- Variaciones de brillo, contraste y saturación.
- Recortes aleatorios para enfatizar distintos fragmentos de la hoja.

Como resultado del aumento, el conjunto de datos de entrenamiento se incrementó considerablemente (Maharana et al., 2022), lo que contribuye a evitar sobreajuste y a mejorar la capacidad de generalización del modelo.

Arquitectura YOLOv11 y Entrenamiento

Se eligió la arquitectura YOLOv11 dada su eficiencia en la detección de objetos con bajo consumo computacional y su alto desempeño reportado en tareas de visión por computadora (Khanam & Hussain, 2024). El entrenamiento se llevó a cabo en una estación de trabajo de Google Colab con T4GPU, durante 40 epochs.

- Las principales variables registradas en cada época incluyeron:
- Precision(B): Precisión media en la detección de las clases (CBSD y CMD)
- Recall(B): Exhaustividad media de detección
- mAP50(B): Mean Average Precision al 50% de umbral de intersección sobre la unión (IoU)

.

Análisis de resultados

Curvas de entrenamiento

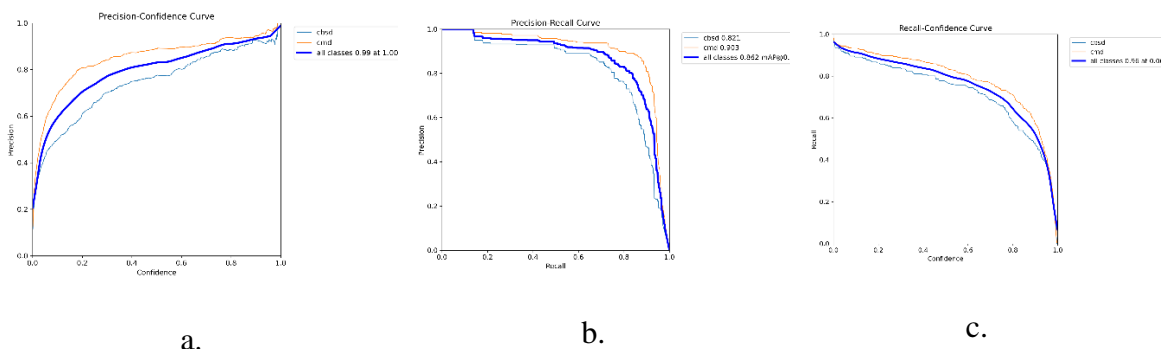
En la Tabla 1 se presenta un extracto de los resultados de entrenamiento para las 40 épocas analizadas. Se observa una tendencia creciente tanto en la precision como en el recall y la mAP, lo que indica un proceso de aprendizaje continuo del modelo.

Tabla 1. *Evolución de las métricas más relevantes durante 40 épocas de entrenamiento*

epoch	precision(B)	recall(B)	mAP50(B)
1	0.35	0.54	0.41
5	0.67	0.73	0.72
10	0.81	0.79	0.83
20	0.84	0.79	0.85
30	0.82	0.82	0.86
40	0.81	0.83	0.86
Máximos:	0.86	0.85	0.87

En la Figura 1 se ilustran las curvas de Precision-Confidence (a), Precision-Recall (b) y Recall-Confidence(c). La clase cmd es más fácil de detectar o está mejor representada, pues alcanza tanto mayor precisión como recall que cbsd. En la clase cmd, el comportamiento ascendente de la precisión y el descenso de la exhaustividad a medida que aumenta el umbral de confianza son característicos de los sistemas de clasificación binaria (en este caso, dos enfermedades más el fondo).


Figura 1. Gráficas (Precision-Confidence (a), Precision-Recall (b) y Recall Confidence(c)).



Matriz de Confusión

En la figura 2 se presenta la matriz de confusión, esta confirma lo que se intuye en las curvas anteriores: “cmd” se clasifica generalmente mejor que “cbnd”, y la confusión más frecuente es entre las clases principales y el fondo. Sin embargo, el desempeño general (aciertos en la diagonal) luce bastante sólido, con áreas de mejora específicas en la distinción de “cbnd” frente a “background”.

Figura 2. Matriz de confusión para la detección de CBSD, CMD y fondo



Como se puede apreciar, el modelo tiende a confundir levemente CBSD con CMD, lo que puede atribuirse a la similitud visual de ciertas lesiones y la variabilidad fenotípica de las hojas enfermas.

Discusión

Los resultados obtenidos demuestran la efectividad de YOLOv11 para la detección de enfermedades en yuca, confirmando estudios previos que reportan un alto desempeño de la familia YOLO en tareas de identificación de enfermedades en cultivos (Husaini et al., 2025). El uso de herramientas de etiquetado como Grounding DINO no solo reduce el tiempo de etiquetado, sino que mejora la coherencia de las etiquetas al proponer regiones de interés basadas en modelos de visión profunda (Yuen et al., 2024).

Por otra parte, el aumento de datos (data augmentation) es un factor clave para el buen desempeño del modelo, ya que maximiza la probabilidad de exposición a variaciones de iluminación, perspectiva y condiciones fisiológicas de la hoja (Maharana et al., 2022). Esto se refleja en la estabilización de la precisión y el recall hacia las últimas épocas.

La confusión residual entre CBSD y CMD podría mejorarse introduciendo características espectrales adicionales (por ejemplo, imágenes hiperespectrales o multiespectrales) o integrando información fenológica de la planta. Adicionalmente, la expansión del conjunto de datos con imágenes provenientes de diferentes regiones geográficas ayudaría a reforzar la robustez del modelo y su aplicación en contextos con diversidad genética de la yuca.

Conclusiones

En este trabajo, se desarrolló un sistema de detección de CBD y CMD en hojas de yuca basado en YOLOv11, el cual alcanza valores cercanos al 0.86 de precisión, 0.85 de recall y 0.87 de mAP50 en el mejor punto de entrenamiento. El uso de Grounding DINO para la anotación y el aumento de datos con Roboflow fueron elementos esenciales que permitieron aumentar la robustez del modelo.

Los resultados sugieren que la adopción de técnicas de visión por computadora en el diagnóstico de enfermedades de la yuca puede reducir significativamente el tiempo de identificación y mejorar la toma de decisiones en el campo. A futuro, se recomienda explorar arquitecturas de red más livianas para facilitar la implementación en dispositivos móviles y sistemas de baja potencia, así como considerar datos adicionales (por ejemplo, mediciones de reflectancia) para incrementar la precisión de la clasificación entre enfermedades con rasgos muy similares.

Referencias bibliográficas

- Chikoti, P. C., & Tembo, M. (2022). Expansion and impact of cassava brown streak and cassava mosaic diseases in Africa: A review. *Frontiers in Sustainable Food Systems*, 6, 1–12. <https://doi.org/doi:10.3389/fsufs.2022.1076364>
- ErnestMwebaze, & Timnit, G. (2019, June 1). Cassava Disease Classification. <https://www.kaggle.com/c/cassava-disease/data>
- Husaini, M. Al, Raharja, A. R., Putra, V. H. C., & Lukmana, H. H. (2025). Enhanced Plant Disease Detection Using Computer Vision YOLOv11: Pre-Trained Neural Network Model Application. *Journal of Computer Networks, Architecture and High Performance Computing*, 7(1), 82–95. <https://doi.org/10.47709/CNAHPC.V7I1.5146>
- Jocher, G. (2024). Ultralytics. <https://Github.Com/Ultralytics/Assets/Releases/Download/v8.3.0/Yolo11n.Pt>
- Liu, S., Zeng, Z., Ren, T., Li, F., Zhang, H., Yang, J., Jiang, Q., Li, C., Yang, J., Su, H., Zhu, J., & Zhang, L. (2024). Grounding DINO: Marrying DINO with Grounded Pre-Training for Open-Set Object Detection. <https://arxiv.org/abs/2303.05499>
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91–99. <https://doi.org/https://doi.org/10.1016/j.gltp.2022.04.020>
- Muiruri, S. K., Ntui, V. O., Tripathi, L., & Tripathi, J. N. (2021). Mechanisms and approaches towards enhanced drought tolerance in cassava (*Manihot esculenta*). *Current Plant Biology*, 28, 100227. <https://doi.org/10.1016/J.CPB.2021.100227>
- Redmon, J. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- roboflow. (2025). <https://roboflow.com/>
- Sehgal, D., Zou, Z., Egesi CEgesi, C., Gaby Nkouaya Mbanjo, E., Yusuf Rabbi, I., Elizabeth Ferguson, M., Ismail Kayondo, S., Hwa Eng, N., Tripathi, L., Kulakow, P., & Egesi, C. (2021). Technological Innovations for Improving Cassava Production in Sub-Saharan Africa. <https://doi.org/10.3389/fgene.2020.623736>
- Sharma, S., Verma, K., & Hardaha, P. (2023). Implementation of Artificial Intelligence in Agriculture. *Journal of Computational and Cognitive Engineering*, 2(2), 155–162. <https://doi.org/10.47852/bonviewJCCE2202174>
- Tugrul, B., Elfatimi, E., & Eryigit, R. (2022). Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review. *Agriculture*, 12(8). <https://doi.org/10.3390/agriculture12081192>
- Uke, A., Tokunaga, H., Utsumi, Y., Anh Vu, N., Thi Nhan, P., Srean, P., Huu Hy, N., Huy Ham, L., Augusto Becerra Lopez-Lavalle, L., Ishitani, M., Hung, N., Ngoc Tuan,
-

L., Van Hong, N., Quang Huy, N., Xuan Hoat, T., Takasu, K., Seki, M., Ugaki, M., & Seki motoakiseki, M. (2022). Cassava mosaic disease and its management in Southeast Asia Sub-Department of Plantation and Plant Protection of Tay Ninh Province, Hanoi, Vietnam. 109, 301–311. <https://doi.org/10.1007/s11103-021-01168-2>

Yuen, K., Zou, J., & Uchida, K. (2024). Generalized DINO: DINO via Multimodal Models for Generalized Object Detection. ACM International Conference Proceeding Series, 776–783. <https://doi.org/10.1145/3672758.3672887>.