




Early detection of banana leaf diseases using CNN, IoT sensors, and RAG-based prototype in the Dominican Republic

Francisco Orgaz-Agüera¹; Gadiel Cascante Cruz²; Cindy Marilyn Cristóbal Marcelino^{3,4}; María Esther Trinidad Domínguez⁵

^{1,2,5}Universidad Tecnológica de Santiago (UTESA), República Dominicana, franorgaz@utesa.edu,
gadielcascante152001@gmail.com, asist.proyectos@utesa.edu





³Universidad ISA, República Dominicana, República Dominicana, ccristobal@isa.edu.do

⁴Universidad de Córdoba, España, z42crmac@uco.es

Abstract– This paper presents the design, development, and validation of the Deep Banana platform, an artificial intelligence (AI)-based solution for the early detection of diseases in banana crops through automated analysis of leaf images. Framed within the international DEEP FARM project, funded by the Erasmus+ program, the system integrates convolutional neural networks (CNNs), data augmentation techniques, transfer learning, and a modular architecture adaptable to the technological conditions of Dominican farms. The platform was trained on a labeled dataset of over 1,900 images classified into seven plant health categories, achieving an accuracy close to 89%. The technical pipeline stages, CNN model architecture, automated retraining system, and the incorporation of a conversational interface with retrieval-augmented generation (RAG) capabilities are detailed.

Keywords– Artificial intelligence, precision agriculture, convolutional neural networks, deep learning, banana.

Detección temprana de enfermedades en hojas de plátano con CNN, sensores IoT y RAG en República Dominicana

Francisco Orgaz-Agüera¹; Gadiel Cascante Cruz²; Cindy Marilyn Cristóbal Marcelino^{3,4}; María Esther Trinidad Domínguez⁵

^{1,2,5}Universidad Tecnológica de Santiago (UTESA), República Dominicana, franorgaz@utesa.edu, gadielcascante152001@gmail.com, asist.proyectos@utesa.edu

³Universidad ISA, República Dominicana, República Dominicana, cristobal@isa.edu.do

⁴Universidad de Córdoba, España, z42crmac@uco.es

Resumen– Este artículo presenta el diseño, desarrollo y validación de la plataforma Deep Banana, una solución basada en inteligencia artificial (IA) para la detección temprana de enfermedades en el cultivo de banano mediante el análisis automático de imágenes foliares. Enmarcado en el proyecto internacional DEEP FARM, financiado por el programa Erasmus+, el sistema integra redes neuronales convolucionales (CNN), técnicas de aumento de datos, aprendizaje transferido y una arquitectura modular adaptable a las condiciones tecnológicas de fincas dominicanas. La plataforma ha sido entrenada con un conjunto etiquetado de más de 1,900 imágenes clasificadas en siete categorías de salud vegetal, logrando una precisión cercana al 89%. Se detallan las etapas del pipeline técnico, la arquitectura del modelo CNN, el sistema de reentrenamiento automatizado y la incorporación de una interfaz conversacional con capacidades de recuperación aumentada (RAG).

Palabras clave: inteligencia artificial, agricultura de precisión, redes neuronales convolucionales, Deep Learning, banano.

I. INTRODUCCIÓN

El uso de la inteligencia artificial (IA) para la detección de enfermedades en plantas surge como una respuesta a la creciente necesidad de optimizar los procesos de diagnóstico fitosanitario, especialmente en contextos donde la rapidez y la precisión son determinantes para evitar pérdidas económicas significativas [1]. Esta problemática, presente tanto en sistemas agrícolas intensivos como en cultivos de pequeña escala, ha llevado a la búsqueda de soluciones tecnológicas capaces de superar las limitaciones inherentes a la inspección visual tradicional, que depende en gran medida del juicio humano, presenta altos márgenes de error y no siempre está disponible en tiempo y forma en las zonas rurales [2][3].

En sus primeras aplicaciones en la agricultura, la inteligencia artificial (IA) se basó en modelos de aprendizaje automático clásico, apoyados en técnicas de visión computacional convencional [4]. Estos sistemas requerían una fase manual de extracción de características visuales —como patrones de color, texturas o formas específicas asociadas a lesiones— para luego ser procesadas por clasificadores como máquinas de vectores de soporte (SVM), árboles de decisión o

redes neuronales artificiales poco profundas [5]. Aunque estos enfoques representaron un avance respecto a los métodos manuales, su desempeño se veía comprometido por la sensibilidad a las condiciones de iluminación, la complejidad de los fondos naturales y la variabilidad morfológica de las hojas, lo cual limitaba su aplicabilidad en escenarios de campo reales [6]. Sin embargo, con el advenimiento del aprendizaje profundo, estos modelos experimentaron una evolución sustancial tanto en arquitectura como en capacidad de generalización. Las redes neuronales convolucionales (CNN), inicialmente entrenadas en entornos controlados, demostraron una capacidad notable para automatizar la extracción de características relevantes y mejorar significativamente la precisión en la clasificación de enfermedades en diversos cultivos [7]. La incorporación posterior de estrategias avanzadas como el aprendizaje por transferencia, la detección multiescala y, más recientemente, el uso de transformadores visuales (Vision Transformers), ha permitido desarrollar soluciones más eficientes, robustas y adaptables a condiciones variables, incluyendo imágenes tomadas directamente en campo mediante dispositivos móviles [8][9].

Estas herramientas tecnológicas han sido fundamentales para el desarrollo de una agricultura más saludable, garantizando la seguridad alimentaria global y promoviendo la sostenibilidad ambiental, aspectos esenciales para el bienestar de las comunidades. La protección de los cultivos contra enfermedades es particularmente relevante en regiones donde la agricultura constituye una de las principales actividades económicas y una fuente esencial de sustento para las familias. En este contexto, el banano “*Musa spp.*” es uno de los cultivos tropicales más importantes a nivel mundial, tanto por su volumen de producción como por su peso en el comercio internacional. En términos de dieta, junto con el plátano “*Musa paradisiaca L.*”, el banano figura entre los cuatro cultivos alimentarios de mayor importancia global, siendo esencial para la seguridad alimentaria de unos 400 millones de personas en países productores [10]. Asimismo, es actualmente la fruta más consumida y exportada en el mundo [10]. Su producción mundial supera los 130 millones de toneladas anuales en años

recientes [11], cultivadas en más de 130 países de regiones tropicales y subtropicales. Una fracción significativa de esta producción ingresa en el mercado mundial: por ejemplo, alrededor del 20% de la cosecha global se destina a la exportación [8][9]. Estas cifras evidencian la enorme relevancia económica y social del banano a nivel internacional.

La República Dominicana tiene una larga tradición bananera y ocupa un lugar particular dentro del mercado global de esta fruta; en 2018 ocupaba el puesto 21 a nivel global en producción total de banano. El país se ha destacado por su especialización en banano orgánico destinado a la exportación [12]. De acuerdo con estadísticas de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), la República Dominicana llegó a aportar cerca del 50–60% de la producción mundial de banano orgánico en años recientes, situándose como líder internacional en este segmento [12][13]. Esto significa que más de la mitad de los bananos orgánicos que se consumen en mercados extranjeros provienen de fincas dominicanas certificadas.

En el entramado de la economía agroexportadora dominicana, el cultivo de banano constituye un eje estratégico de primer orden [12]. Las provincias noroccidentales de Montecristi, Valverde, Azua y Santiago concentran vastas extensiones de producción, favorecidas por condiciones edafoclimáticas particularmente propicias en valles irrigados. Este aparato productivo está compuesto por un entramado de aproximadamente 1,800 a 2,000 agricultores, predominando las unidades de pequeña y mediana escala, organizadas en asociaciones y cooperativas. La oferta nacional abarca tanto el banano tipo Cavendish, dirigido prioritariamente a la exportación, como cultivares locales destinados al mercado interno. Resulta particularmente relevante que entre el 80 % y el 90 % del banano exportado por el país posee certificación orgánica bajo estándares internacionales, lo que posiciona a la República Dominicana como referente en este nicho de mercado [12].

Sin embargo, el desempeño agronómico del cultivo se ve comprometido por una diversidad de enfermedades de etiología fúngica, bacteriana y viral, que inciden negativamente en la productividad y sostenibilidad del sistema. Entre las patologías con mayor impacto se identifican la Sigatoka Negra (*Mycosphaerella fijiensis*), altamente virulenta y de rápida diseminación [14]; el Virus del Mosaico de las Brácteas (*Banana Bract Mosaic Virus Disease*), que induce anomalías morfoestructurales y merma en la producción; la Enfermedad de Moko (*Ralstonia solanacearum*), de carácter bacteriano y letal [15]; y la Enfermedad de Panamá (*Fusarium oxysporum f. sp. cubense*), que colapsa el sistema vascular del vegetal [16]. También se registran la Sigatoka Amarilla (*Banana Yellow Sigatoka Disease*), de menor agresividad, pero con efectos negativos sobre la superficie foliar funcional, y la afectación por insectos fitófagos (*Banana Insect Pest Disease*), que

compromete tanto la estructura foliar como los frutos [17]. Esta compleja dinámica fitosanitaria evidencia la imperiosa necesidad de incorporar tecnologías avanzadas que permitan la identificación precoz, el diagnóstico diferencial y la gestión eficiente de estos agentes patógenos [18].

No obstante, el andamiaje tecnológico del sector bananero dominicano presenta notorias deficiencias que limitan su capacidad para enfrentar estas amenazas con eficacia. La preeminencia de métodos convencionales, centrados en la observación visual, ha demostrado ser insuficiente para la detección temprana de enfermedades como la Sigatoka Negra, el Moko y la Enfermedad de Panamá. Su escasa sensibilidad y especificidad, sumadas a la dependencia de la experticia del evaluador, retardan la aplicación de medidas de control, facilitando la expansión de los focos de infección y agravando las pérdidas económicas [19]. Esta problemática se intensifica ante la carencia de infraestructura diagnóstica moderna, como laboratorios con equipamiento para técnicas moleculares (PCR, ELISA), y la ausencia de herramientas digitales adaptadas al contexto local, tales como aplicaciones móviles de inteligencia artificial orientadas a la sanidad vegetal [20].

A pesar de los avances significativos en la implementación de sistemas inteligentes de monitoreo fitosanitario en otros contextos, su adopción en la realidad dominicana permanece incipiente. Este rezago se atribuye a restricciones estructurales como la limitada inversión pública y privada en investigación aplicada, la escasa capacitación técnica del capital humano rural y la inexistencia de mecanismos de vigilancia automatizada mediante sensores remotos o plataformas digitales [21]. En consecuencia, la brecha tecnológica persiste como un factor crítico que restringe la resiliencia del sistema productivo ante brotes epidémicos, comprometiendo no solo la competitividad del sector en los mercados internacionales, sino también su sostenibilidad agronómica y socioeconómica en el largo plazo [22]. Por esta razón, el objetivo de esta investigación es presentar el diseño y validación de la plataforma Deep Banana en República Dominicana, herramienta desarrollada para la detección automática, rápida y precisa de enfermedades en plantas de banano mediante técnicas de inteligencia artificial, con el fin de fortalecer la capacidad diagnóstica de los productores, mejorar la eficiencia en la gestión fitosanitaria y contribuir a la sostenibilidad del cultivo en contextos rurales y de exportación.

II. ANTECEDENTES DE LA IA EN LA DETECCIÓN DE ENFERMEDADES

El uso de inteligencia artificial (IA) en la detección de enfermedades en cultivos ha experimentado un notable crecimiento en la última década, posicionándose como una herramienta esencial para el diagnóstico automatizado, rápido y preciso de patologías vegetales [1][2]. Diversas investigaciones han demostrado su aplicabilidad y eficacia en

una amplia gama de cultivos, desde el arroz y el tomate, hasta el café, el cacao o los cítricos, consolidando su papel como un pilar tecnológico de la agricultura de precisión [3].

Complementariamente, estudios han explorado la aplicabilidad de algoritmos de aprendizaje profundo para distintos cultivos, evidenciando que la clasificación automática de enfermedades mediante CNN puede alcanzar precisiones superiores al 95%, reduciendo drásticamente el tiempo de diagnóstico [23]. En particular, se ha documentado el uso de arquitecturas como *AlexNet*, *VGG16* y *MobileNet*, que han sido entrenadas con conjuntos de datos etiquetados, logrando la diferenciación eficaz entre múltiples afecciones con síntomas visuales similares. Estas investigaciones resaltan la importancia de contar con bases de datos balanceadas y representativas, así como con mecanismos de validación cruzada robustos que garanticen la generalización del modelo a contextos reales de campo [6][8].

En el ámbito aplicado, Lujan y Humberto [24] desarrollaron una aplicación móvil basada en reconocimiento de imágenes para la detección de enfermedades en cultivos de tomate, empleando modelos ligeros como *MobileNetV3* y *SqueezeNet*. Los resultados de su estudio indicaron una reducción del tiempo promedio de diagnóstico de 20 minutos a menos de un minuto, así como una mejora significativa en el *recall* de las enfermedades detectadas, incrementándose de 0.67 a 0.83 [9]. Este tipo de soluciones demuestra el potencial de la IA tanto para automatizar el diagnóstico como para empoderar a los agricultores mediante herramientas accesibles y funcionales en dispositivos móviles, incluso en zonas rurales con conectividad limitada.

En términos metodológicos, la mayoría de las investigaciones coinciden en una estructura común que abarca desde la captura y preprocesamiento de imágenes (normalización, aumento sintético, detección de ruido) hasta la clasificación automática mediante modelos CNN entrenados con optimizadores como Estimación Adaptativa de Momentos (*Adam*) o Descenso de gradiente estocástico (*SGD*) [10][11]. Las métricas más empleadas para validar los modelos incluyen precisión, *recall*, *F1-score* y matriz de confusión, siendo estas indispensables para evaluar la capacidad discriminativa de los algoritmos ante múltiples clases [6].

Adicionalmente, estudios recientes han comenzado a integrar sistemas de aprendizaje por transferencia y arquitecturas más avanzadas como *Vision Transformers* (ViTs), así como marcos de despliegue de operaciones de aprendizaje automático (*MLOps*) que permiten reentrenar los modelos de forma dinámica con datos obtenidos en campo [12]. Estas innovaciones consolidan una tendencia hacia la personalización y actualización constante de las soluciones, mejorando su aplicabilidad en contextos locales y su adaptación a nuevas enfermedades emergentes. Por lo tanto, la IA ha dejado de ser

una promesa teórica para convertirse en una tecnología de alto impacto en el diagnóstico fitosanitario.

III. IMPORTANCIA DEL CASO DE USO

Considerando las limitaciones tecnológicas que restringen la eficacia del control fitosanitario del cultivo del banano en República Dominicana, este ha sido seleccionado como caso de estudio en el marco del proyecto internacional DEEP FARM, financiado por el programa Erasmus+ de la Unión Europea. Esta iniciativa impulsa la cooperación interinstitucional entre Madagascar, Costa de Marfil, Haití y República Dominicana, promoviendo el desarrollo de soluciones innovadoras adaptadas a problemáticas agrícolas regionales específicas [12]. En este contexto, surge el proyecto Deep Banana, una propuesta integral basada en inteligencia artificial aplicada a la agricultura tropical, diseñada explícitamente para la detección temprana de enfermedades foliares mediante CNN, optimizando la toma de decisiones en campo y reforzando la resiliencia del sistema productivo.

Desde una perspectiva nacional, el cultivo de banano tiene un peso estratégico en la economía rural dominicana. Las regiones del noroeste del país concentran una extensa red de productores pequeños y medianos que dependen de esta actividad como fuente primaria de ingresos. Sin embargo, estos actores enfrentan múltiples desafíos: acceso limitado a tecnología, ausencia de servicios técnicos especializados, escasa infraestructura diagnóstica y una alta dependencia de métodos visuales convencionales para el monitoreo fitosanitario [21]. Esta situación compromete la productividad de las fincas y debilita la capacidad del país para mantener sus estándares de exportación orgánica [13].

El caso del banano, además, representa un ejemplo paradigmático de cómo las tecnologías de inteligencia artificial pueden adaptarse a contextos productivos reales, donde convergen restricciones técnicas, económicas y sociales. Adicionalmente, la implementación de una plataforma como Deep Banana responde a una necesidad agronómica inmediata y, también, se alinea con los objetivos de desarrollo sostenible (ODS), particularmente en lo relativo a la seguridad alimentaria (ODS 2), el trabajo decente y crecimiento económico (ODS 8), la innovación e infraestructura rural (ODS 9) y la acción por el clima (ODS 13) [12]. Por lo tanto, reduciendo el uso innecesario de agroquímicos, mejorar la eficiencia del manejo sanitario y empoderar a los agricultores locales mediante herramientas basadas en ciencia de datos, la solución propuesta contribuye directamente al fortalecimiento de un modelo agrícola más justo, resiliente y sostenible.

De esta manera, el proyecto Deep Banana representa un avance tecnológico en el ámbito del aprendizaje automático aplicado a la agricultura, pero también se configura como una solución con profundo impacto social y económico. Su replicabilidad en otras regiones productoras de banano y en

otros cultivos tropicales refuerza su potencial como modelo escalable de innovación agrícola centrada en el usuario [3].

IV. ARQUITECTURA

Desde una perspectiva técnica, Deep Banana adopta una arquitectura modular que integra sistemáticamente las etapas de adquisición, preprocesamiento, clasificación e interpretación de imágenes, adaptadas a las condiciones operativas propias de las fincas locales. Las imágenes, capturadas mediante dispositivos móviles, atraviesan un pipeline de procesamiento que implica redimensionamiento uniforme a 456x456 píxeles, normalización cromática y técnicas avanzadas de aumento sintético (rotación, escalado y reflexión horizontal), destinadas a incrementar la robustez del modelo frente a variaciones lumínicas y morfológicas inherentes al contexto agrícola [14].

El núcleo central del sistema consiste en una red neuronal convolucional implementada sobre los marcos *TensorFlow* y *Keras*, formulada para abordar un problema de clasificación multiclase con siete categorías diagnósticas: Sigatoka Negra, Sigatoka Amarilla, Enfermedad de Moko, Enfermedad de Panamá, Virus del Mosaico de las Brácteas, daños por insectos y hojas sanas. El modelo ha sido diseñado con una estructura secuencial que conjuga eficiencia computacional y adecuada capacidad de generalización, incluyendo tres bloques convolucionales con filtros sucesivos de 64, 128 y 64 unidades, núcleos de convolución de 3x3, activaciones Unidad Lineal Rectificada (*ReLU*) y *padding* "same". Cada bloque está acompañado por capas de normalización por lotes (*BatchNormalization*) y reducción dimensional mediante *MaxPooling2D* (2x2) [15].

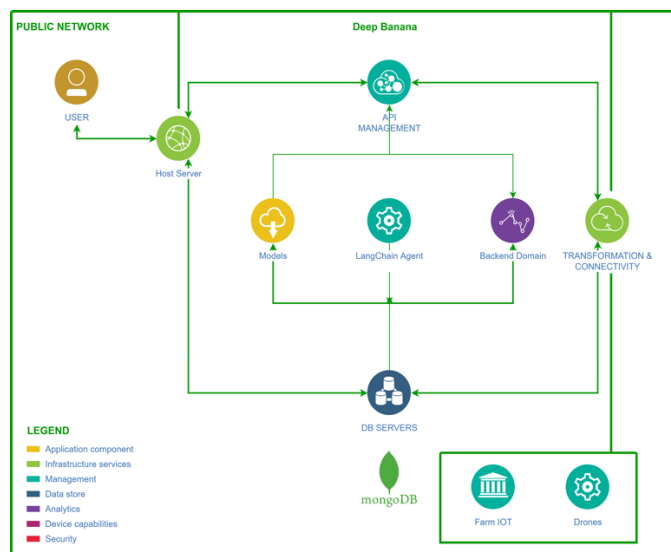


Figura 1. Arquitectura del sistema

V. ENTRENAMIENTO Y FUNCIONAMIENTO DE LA PLATAFORMA

Para el entrenamiento del modelo, se ha utilizado el conjunto de datos *Banana Disease Recognition Dataset*, desarrollado por Mafi et al. (2023) y disponible públicamente en la plataforma *Kaggle*. Este *dataset* fue seleccionado por su accesibilidad abierta, su resolución homogénea de 512x512 píxeles y por estar compuesto por imágenes capturadas en condiciones reales de campo, lo que lo hace especialmente adecuado para aplicaciones en contextos tropicales como el dominicano. La base de datos incluye un total de 1,996 imágenes etiquetadas, distribuidas en siete categorías diagnósticas de relevancia fitosanitaria: 328 imágenes de Sigatoka Negra, 245 del Virus del Mosaico de las Brácteas, 421 de hojas sanas, 421 de daños por insectos, 269 de Enfermedad de Moko, 200 de Enfermedad de Panamá y 112 de Sigatoka Amarilla. La selección de este conjunto responde a la necesidad de contar con datos representativos de distintas condiciones fisiopatológicas observadas en campo, y a su valor práctico para entrenar modelos de visión por computadora robustos. Además, se aplicaron técnicas de aumento sintético —incluyendo rotación, traslación, escalado, inversión horizontal y ajuste de brillo— con el objetivo de ampliar la variabilidad morfológica y lumínica del conjunto, fortaleciendo la capacidad de generalización del modelo frente a condiciones operativas diversas. La efectividad del modelo fue validada mediante diversas métricas cuantitativas, incluyendo precisión, recall, F1-score (Figura 1) y matriz de confusión (Figura 2).

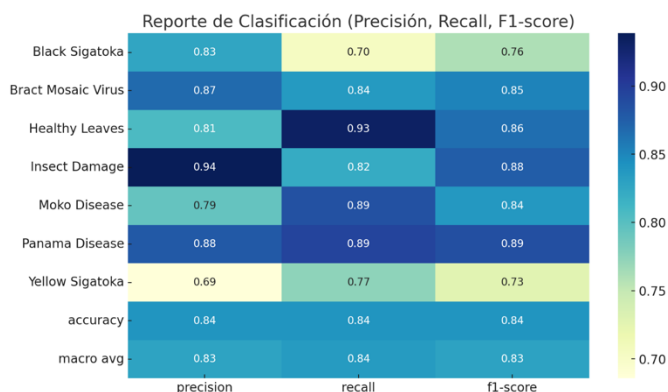


Figura 2. Resultados de las métricas de precisión, *recall*, y *F1-score*.

Los resultados revelaron una exactitud cercana al 89%, destacando que el modelo presentó desafíos específicos para la identificación precisa de la Sigatoka Negra, con cierta frecuencia confundida con otras clases afines.




Figura 3. Matriz de confusión.

El entrenamiento del modelo fue realizado utilizando el optimizador *Adam* en combinación con una estrategia adaptativa de reducción dinámica de la tasa de aprendizaje (*ReduceLRonPlateau*), favoreciendo así una convergencia más estable en contextos caracterizados por una considerable variabilidad intraclase [14]. Esta configuración permitió al modelo extraer representaciones visuales robustas, capaces de discriminar efectivamente características complejas vinculadas a la morfología, textura y cromaticidad de las lesiones foliares, incluso en condiciones ambientales adversas [14].

Paralelamente, se ha diseñado e implementado una arquitectura integral *de MLOps* que facilita el reentrenamiento continuo del modelo mediante la incorporación progresiva de datos provenientes de condiciones reales de campo, y permite la integración rápida y eficiente de nuevos modelos en formato *H5*, habilitando su despliegue inmediato en producción para predicciones en tiempo real [12]. En cuanto a la estructura de la plataforma móvil, ha sido desarrollada utilizando *Flutter* y el patrón Modelo-Vista-VistaModelo (*MVVM*), elección arquitectónica que optimiza la comunicación y separación lógica entre componentes, promoviendo así una mayor mantenibilidad y escalabilidad del sistema [25]. La interacción entre la aplicación móvil y el *backend* ha sido gestionada mediante una *API*, desde la cual se exponen los modelos predictivos. Para la gestión eficiente de *embeddings* utilizados en el sistema *RAG*, se ha empleado *MongoDB* como solución de almacenamiento, ofreciendo una alta eficiencia en consultas y una escalabilidad adecuada para escenarios operativos reales [12].

Asimismo, la arquitectura contempla la integración de información meteorológica externa a través de la *API OpenMeteo*, posibilitando estudios longitudinales sobre la influencia climática en el desarrollo fisiológico de las plantas

[26]. Finalmente, se incorporó la capacidad de comunicación mediante *WebSockets* para interactuar en tiempo real con sensores de internet de las cosas (IoT), facilitando la recolección continua de variables ambientales, cuyo análisis predictivo permite anticipar respuestas vegetativas frente a variaciones futuras en condiciones climáticas [26].

VI. DESAFÍOS ENFRENTADOS

La disponibilidad limitada de datos de alta calidad representa uno de los obstáculos estructurales más determinantes en el desarrollo de sistemas de diagnóstico automatizado basados en inteligencia artificial en contextos agrícolas tropicales. En el caso de Deep Banana, esta carencia de repositorios estandarizados y accesibles —o *data commons*— ha condicionado de manera crítica la posibilidad de entrenar modelos robustos, precisos y generalizables. A diferencia de otros dominios donde los ecosistemas de datos abiertos son consolidados y funcionales, regiones como el Caribe o África Subsahariana enfrentan una escasez persistente de conjuntos de imágenes balanceados, diversos y rigurosamente anotados, lo que dificulta la representación adecuada de la heterogeneidad morfológica de las enfermedades foliares del banano [22].

En este marco, el desbalance de clases se manifiesta como una fuente persistente de sesgo. Enfermedades como la Sigatoka Negra o el Moko suelen estar sobrerrepresentadas en nuestro modelo debido a su mayor visibilidad o impacto productivo, mientras que otras condiciones menos documentadas —como el Virus del Mosaico de las Brácteas o la Sigatoka Amarilla— cuentan con un número significativamente inferior de muestras, lo cual compromete la capacidad del modelo para capturar patrones representativos. Esta disparidad obliga a recurrir a estrategias compensatorias como la ponderación de clases, el uso intensivo de técnicas de aumento de datos y, en ciertos casos, la reutilización de muestras modificadas sintéticamente. No obstante, estas soluciones paliativas no garantizan de forma automática una mejora en la generalización del modelo, sobre todo cuando se enfrenta a imágenes capturadas bajo condiciones reales no controladas y con una alta variabilidad ambiental [27].

Por tanto, la creación de un modelo que mantenga una precisión operativa aceptable bajo estas restricciones implica un esfuerzo continuo de curación, expansión y refinamiento del *dataset*, junto con una exploración rigurosa de arquitecturas y funciones de pérdida adaptativas. Este desafío estructural trasciende lo técnico y pone en evidencia la necesidad urgente de infraestructuras colaborativas de datos agrícolas abiertos, interoperables y contextualizados a nivel regional [22]. En paralelo, se vuelve indispensable articular una arquitectura *de MLOps* que acompañe este esfuerzo desde su concepción, capaz de integrarse de manera orgánica con los flujos de datos y

adaptarse dinámicamente al crecimiento y diversificación del conjunto de entrenamiento [12].

Por lo tanto, la sostenibilidad tecnológica de Deep Banana depende en gran medida de la capacidad del sistema para reentrenarse periódicamente sin comprometer su operatividad, incorporando nuevas clases diagnósticas, afinando los parámetros del modelo y manteniendo trazabilidad sobre las versiones generadas. En contextos donde los datos se recolectan de forma asíncrona y con calidad variable, el diseño de pipelines automatizados para la validación, limpieza y anotación se convierte en una prioridad operativa. Asimismo, la integración de la capa de inferencia con sistemas distribuidos—como interfaces de programación de aplicaciones (APIs) y servicios conversacionales— exige una orquestación fluida entre los módulos de predicción, almacenamiento, recuperación de conocimiento y visualización [12].

VI. CONCLUSIONES

La plataforma Deep Banana constituye una contribución sustantiva al campo de la inteligencia artificial aplicada a la agricultura de precisión en contextos tropicales, respondiendo a desafíos estructurales y operativos específicos del cultivo de banano en República Dominicana. Su diseño modular, sustentado en redes neuronales convolucionales y complementado por una arquitectura *MLOps* escalable, demuestra la viabilidad de implementar soluciones inteligentes para la detección temprana de enfermedades foliares en escenarios de alta variabilidad ambiental y limitada infraestructura tecnológica [12].

Los resultados obtenidos, con una exactitud cercana al 89%, validan la eficacia del enfoque adoptado y evidencian el potencial de la plataforma para su despliegue operativo en fincas reales [14]. La integración de un sistema de reentrenamiento continuo, el uso de técnicas de aumento de datos, la incorporación de bases de datos externas como *MongoDB* para la gestión de *embeddings* y la conexión con *APIs* externas—incluyendo servicios meteorológicos y sensores IoT— posicionan a Deep Banana como una herramienta robusta, dinámica y adaptable [12][26].

A nivel metodológico, la adopción del patrón *MVVM* en la aplicación *Flutter* ha permitido una arquitectura limpia, mantenible y orientada a una comunicación eficiente con el *backend*, asegurando fluidez en la entrega de predicciones y escalabilidad en el despliegue de futuras versiones del modelo [25]. Asimismo, la capacidad de respuesta inmediata mediante el uso de modelos en formato *H5* habilita una operatividad ágil y flexible, ajustada a los requerimientos del entorno productivo [12].

No obstante, persisten desafíos relevantes, entre ellos la necesidad de ampliar y diversificar los conjuntos de datos,

establecer *data commons* agrícolas regionales y fomentar alianzas que impulsen la infraestructura digital rural [22]. En este sentido, Deep Banana es una propuesta tecnológica concreta basada en un modelo de innovación abierta que puede escalarse a otros cultivos, regiones y sistemas productivos, siempre que se acompañe de políticas públicas y estrategias institucionales orientadas al fortalecimiento del ecosistema de datos agrícolas.

AGRADECIMIENTO/RECONOCIMIENTO

Esta investigación ha sido financiada por la Agencia Ejecutiva Europea de Educación y Cultura (EACEA) mediante el proyecto número 101128032 – DEEP FARM – ERASMUS-EDU-2023-CBHE, coordinado por la Ecole Supérieure des Technologies Industrielles Avancées (ESTIA, Francia) y donde han participado investigadores e instituciones de Francia, Italia, Turquía, Madagascar, Costa de Marfil, Haití y República Dominicana.

REFERENCIAS

- [1] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers in Plant Science*, vol. 7, pp. 1419, Oct. 2016. <https://doi.org/10.3389/fpls.2016.01419>
- [2] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Computers and Electronics in Agriculture*, vol. 145, pp. 311–318, Feb. 2018. <https://doi.org/10.1016/j.compag.2018.01.009>
- [3] T. B. Shahi, C. Xu, A. Neupane, and W. Guo, "Recent Advances in Crop Disease Detection Using UAV and Deep Learning Techniques," *Remote Sensing*, vol. 15, no. 9, Art. 2450, 2023. <https://doi.org/10.3390/rs15092450>
- [4] R. Salazar Moreno, "Aprendizaje Automático y sus aplicaciones en la agricultura," en *9no Congr. Int. Investig. En Cienc. Basicas Agron.*, Chapingo, México, 12 de noviembre de 2020.
- [5] Y. Chimate, S. Patil, K. Prathapan, J. Patil, and J. Khot, "Optimized sequential model for superior classification of plant disease," *Scientific Reports*, vol. 15, Art. 3700, Jan. 2025. <https://doi.org/10.1038/s41598-025-86427-8>
- [6] Sladojević, M. Arsenović, A. Anderla, D. Culibrk, and D. Stefanović, "Deep neural networks based recognition of plant diseases by leaf image classification," *Computational Intelligence and Neuroscience*, vol. 2016, pp. 1–11, 2016. <https://doi.org/10.1155/2016/3289801>
- [7] C. A. Campos Rodríguez "Reconocimiento de imágenes basado en la IA para la identificación de MONILIOPHTHORA ROERI en granos de THEOBROMA CACAO" en *3er Foro de Innovación en el Agro.*, Tolima, Colombia, 2024.
- [8] M. Arsenović, S. Sladojević, A. Anderla, and D. Stefanović, "Solving current limitations of deep learning for plant disease detection," *Symmetry*, vol. 11, no. 7, pp. 939, July 2019. <https://doi.org/10.3390/sym11070939>
- [9] G. Li, Z. Zhang, Y. Zhang, and Y. Zhou, "PMVT: a lightweight vision transformer for plant disease identification on mobile devices," *Frontiers in Plant Science*, vol. 14, pp. 1256773, Aug. 2023. <https://doi.org/10.3389/fpls.2023.1256773>
- [10] International Institute for Sustainable Development, "Global Market Report: Bananas," IISD, 2023. <https://www.iisd.org>
- [11] A. J. Martínez Durán, V. A. Rodríguez Núñez, and J. del C. Castillo Jáquez, "Use of biosolids from wastewater treatment plants and other organic fertilizers in agriculture—a preliminary results of a case study in banana cultivation in the Dominican Republic," *Frontiers in Water*, vol. 5, 2023. <https://doi.org/10.3389/frwa.2023.1236924>
- [12] R. D. Noar, E. Thomas, and M. E. Daub, "Genetic characteristics and metabolic interactions between *Pseudocercospora fijiensis* and banana: progress toward controlling Black Sigatoka," *Plants*, vol. 11, no. 7, Art. 948, 2022. <https://doi.org/10.3390/plants11070948>

- [13] L. Tripathi, V. O. Ntui, and J. N. Tripathi, "Control of bacterial diseases of banana using CRISPR/Cas-based gene editing," *International Journal of Molecular Sciences*, vol. 23, no. 7, Art. 3619, 2022. <https://doi.org/10.3390/ijms23073619>
- [14] M. Buda, A. Maki, and M. A. Mazurowski, "A systematic study of the class imbalance problem in convolutional neural networks," *Neural Networks*, vol. 106, pp. 249–259, 2018. <https://doi.org/10.1016/j.neunet.2018.07.011>
- [15] J. Chamorro-Padial, R. García, and R. M. Gil, "A systematic review of open data in agriculture," *Computers and Electronics in Agriculture*, vol. 205, Art. 108775, 2024. <https://doi.org/10.1016/j.compag.2024.108775>
- [16] S.P. López-Zapata, y J. Castaño-Zapata. "Manejo integrado del mal de Panamá [Fusarium oxysporum Schlechtend.: Fr. sp. cubense (E.F. SM.) W.C. Snyder & H.N. Hansen]: una revisión," *Rev Udca Actual Divulg Cient.*, vol. 22, no. 2, 2019. <http://dx.doi.org/10.31910/rudca.v22.n2.2019.1240>
- [17] A. Aviles-Noriega, L.M. Serrato-Diaz, M.C. Giraldo-Zapata, H.E. Cuevas, L.I. Rivera-Vargas, "The Sigatoka Disease Complex Caused by Pseudocercospora spp. and Other Fungal Pathogens Associated with Musa spp. in Puerto Rico," *Plant Dis*, vol. 108, no. 5, 1320–30, 2024. <http://dx.doi.org/10.1094/PDIS-03-23-0433-RE>
- [18] M. Venbrux, S. Crauwels, and H. Rediers, "Current and emerging trends in techniques for plant pathogen detection," *Frontiers Plant Sci.*, vol. 14, 1120968, 2023. <http://dx.doi.org/10.3389/fpls.2023.1120968>
- [19] M. Iftikhar, I. A. Kandhro, N. Kausar, A. Kehar, M. Uddin, and A. Dandoush, "Plant disease management: a fine-tuned enhanced CNN approach with mobile app integration for early detection and classification," *Artificial Intelligence Review*, 2024. <https://doi.org/10.1007/s10462-024-10809-z>
- [20] Y. M. Wang, B. Ostendorf, D. Gautam, N. Habili, and V. Pagay, "Plant viral disease detection: From molecular diagnosis to optical sensing technology—A multidisciplinary review," *Remote Sens* (Basel), vol. 14, no. 7, p. 1542, 2022. <http://dx.doi.org/10.3390/rs14071542>
- [21] A. Toonen, "Agricultores dominicanos obtienen beneficios con tecnología neerlandesa", *Acento*, 19 de septiembre de 2024. [En línea]. <https://acento.com.do/ecologia/agricultores-dominicanos-obtienen-beneficios-con-tecnologia-neerlandesa-9396188.html>
- [22] S. Ioffe and C. Szegedy, "Batch normalization: accelerating deep network training by reducing internal covariate shift," in *Proc. 32nd Int. Conf. Machine Learning (ICML)*, 2015. <https://arxiv.org/abs/1502.03167>
- [23] B. Roldán Ortega, R. Roshan Biswal y E. Sánchez Delacruz, "Detección de enfermedades en el sector agrícola utilizando Inteligencia Artificial", *Res. Comput. Sci.*, vol. 148, n.º 7, pp. 419–427, 2019. <https://doi.org/10.13053/rcs-148-7-31>
- [24] O. Lujan, y L. Humberto, "Aplicación móvil con reconocimiento de imágenes basada en Inteligencia Artificial para la detección de enfermedades en cultivos de tomate," Universidad César Vallejo, Lima, Perú, 2024. <https://hdl.handle.net/20.500.12692/152798>
- [25] M. Balpande, K. Mahajan, J. Bhandarkar, G. Borse, and S. Badjate, "AI Powered Agriculture Optimization Chatbot Using RAG and GenAI," *Proc. IEEE SILCON*, 2024, pp. 1–6.
- [26] S. Lee and C. M. Yun, "A deep learning model for predicting risks of crop pests and diseases from sequential environmental data," *Plant Methods*, vol. 19, Art. 145, 2023. <https://doi.org/10.1186/s13007-023-01122-x>
- [27] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, pp. 1929–1958, 2014. <https://dl.acm.org/doi/pdf/10.5555/2627435.2670313>