

A Systematic Review of the Performance of Machine Learning Algorithms in Detecting Black Sigatoka in Banana Crops

Gustavo Castañeda-Cubas, Estudiante de Ingeniería de Sistemas e Informática¹; Fabrizio Raúl Hoyos-Obando, Estudiante de Ingeniería de Sistemas e Informática²; Christian Abraham Dios-Castillo, Dr. en Administración de la Educación³

^{1,3}Universidad Tecnológica del Perú, U21205641@utp.edu.pe, U21210481@utp.edu.pe, C16763@utp.edu.pe

Abstract- The banana crop faces critical phytosanitary challenges, notably Black Sigatoka, which significantly reduces productivity. Traditional visual inspection methods are slow and subjective, prompting the use of artificial intelligence (AI) to enhance detection efficiency. This study presents a systematic literature review focused on evaluating the performance of AI models in detecting diseases and assessing banana ripeness, based on experimental studies published between 2020 and 2025. The review applied the PRISMA protocol and included 55 articles indexed in Scopus and Web of Science, selected using strict inclusion criteria involving real image datasets and performance metrics. The results indicate that deep learning models, particularly convolutional neural networks (CNN), outperform traditional machine learning approaches. Among them, SqueezeNet emerged as the most effective model for detecting Black Sigatoka, with precision values exceeding 97% in studies specifically focused on this disease. Other high-performing models include ShuffleNetv2 and MobileNetv3Small. While ResNet50 exhibited excellent metrics in broader disease classification contexts, the data reveal that lightweight architecture such as SqueezeNet offers the highest consistency and performance in field conditions. The study concludes that SqueezeNet is the most suitable architecture for detecting Black Sigatoka, due to its high precision, lightweight structure, and consistent performance across evaluations. These findings support the adoption of efficient deep learning architecture in precision agriculture scenarios.

Keywords: deep learning, machine learning, banana, computer visión, disease detection, artificial intelligence

Revisión Sistemática sobre el Rendimiento de Algoritmos de Machine Learning en la Detección de la Sigatoka Negra del Banano

Gustavo Castañeda-Cubas, Estudiante de Ingeniería de Sistemas e Informática¹; Fabrizio Raúl Hoyos-Obando, Estudiante de Ingeniería de Sistemas e Informática²; Christian Abraham Dios-Castillo, Dr. en Administración de la Educación³

^{1,3}Universidad Tecnológica del Perú, U21205641@utp.edu.pe, U21210481@utp.edu.pe, C16763@utp.edu.pe

Resumen - El cultivo de banano enfrenta graves desafíos fitosanitarios, en particular la Sigatoka Negra, una enfermedad que reduce drásticamente la productividad. Los métodos tradicionales de inspección visual son lentos y subjetivos, lo que ha motivado el uso de inteligencia artificial (IA) para optimizar la detección. Este estudio presenta una revisión sistemática de la literatura para evaluar el desempeño de modelos de IA en la detección de enfermedades y en la estimación de la madurez del banano, basándose en estudios experimentales publicados entre 2020 y 2025. Aplicando el protocolo PRISMA, se filtraron 145 registros y se analizaron 55 artículos indexados en Scopus y Web of Science, seleccionados con criterios rigurosos de inclusión relativos al uso de imágenes reales y métricas de rendimiento. Los resultados destacan la superioridad de los modelos de aprendizaje profundo, especialmente las redes neuronales convolucionales (CNN), frente a los métodos clásicos de machine learning. En particular, arquitecturas ligeras como SqueezeNet alcanzaron precisiones superiores al 97% en la detección de Sigatoka Negra en condiciones de campo. Otros modelos compactos, como ShuffleNet v2 y MobileNet v3Small, mostraron también alta exactitud con baja demanda de cómputo. Aunque redes más pesadas, como ResNet50, ofrecieron resultados sobresalientes en la clasificación general de enfermedades, su tiempo de inferencia y requerimientos de hardware limitan su viabilidad práctica. Se concluye que SqueezeNet es la arquitectura más adecuada para detectar Sigatoka Negra, gracias a su alta precisión, eficiencia y rendimiento estable. Estos hallazgos respaldan la adopción de arquitecturas de IA eficientes en escenarios de agricultura de precisión.

Palabras clave: aprendizaje profundo, aprendizaje automático, banana, visión artificial, detección de enfermedades, inteligencia artificial

I. INTRODUCCIÓN

El banano (*Musa spp.*) ocupa un lugar destacado entre los cultivos tropicales por su valor nutricional, su demanda en los mercados internacionales y su papel en la economía de muchas regiones productoras. Sin embargo, su cultivo enfrenta una de las amenazas fitosanitarias más importantes: la Sigatoka Negra, una enfermedad fúngica causada por *Mycosphaerella fijiensis* que deteriora las hojas, reduce la fotosíntesis y disminuye considerablemente los rendimientos [1]. En muchos países, el control del curso de esta enfermedad está fuertemente influenciado por inspecciones manuales realizadas por personal técnico capacitado. Aunque este método ha sido útil por décadas, su carácter visual, subjetivo y lento representa una desventaja considerable, sobre todo cuando se manejan grandes extensiones de terreno [2]. Frente a este panorama, la automatización de este proceso mediante técnicas de inteligencia artificial (IA) se ha convertido en una línea de investigación cada vez más relevante. Por lo tanto, esta

investigación se justifica debido a que los resultados permiten determinar los modelos de Machine Learning más efectivos para la detección oportuna y precisa de la enfermedad en estudio y optimiza la toma de decisiones en el sistema en emprendimientos empresariales del sector agroindustrial, relacionándose con la temática del LEIRD, 4. Technological in entrepreneurship and innovation, Digital transformation and artificial intelligence. En particular, los enfoques sustentados en modelos de deep learning, en particular las redes neuronales de tipo convolucional (CNN), han demostrado un gran potencial para el diagnóstico visual de enfermedades en cultivos. Estas técnicas permiten procesar imágenes de hojas y detectar patrones asociados a patologías de manera rápida y precisa. Varios estudios han aplicado arquitecturas como MobileNet, EfficientNet, Inception, ResNet y redes híbridas personalizadas, obteniendo resultados prometedores en la detección de enfermedades foliares en el banano, incluyendo la Sigatoka Negra [2]–[5]. Entre los trabajos más destacados se encuentra el de Bhuiyan et al. [3], quienes desarrollaron una red liviana denominada BananaSqueezeNet, alcanzando una precisión del 96.25% al clasificar múltiples enfermedades, entre ellas la Sigatoka Negra. Por otro lado, Sanga et al. [4] abordaron el mismo problema desde un enfoque de accesibilidad, proponiendo modelos optimizados para dispositivos móviles, con buenos resultados en pruebas de campo. En un enfoque más robusto, Deng et al. [5] diseñaron una red llamada GR-ARNet, combinando técnicas avanzadas como Ghost Modules y ResNeSt, con un rendimiento competitivo superior al 96%. A pesar de estos avances, aún existe una alta variabilidad en las métricas, metodologías y condiciones de validación entre los diferentes estudios. Esta falta de uniformidad complica la tarea de identificar qué modelos son realmente aplicables en escenarios reales de cultivo. Por ello, se considera necesaria una revisión comparativa que permita analizar en profundidad el rendimiento de estos sistemas. Este trabajo tiene como propósito analizar el rendimiento de modelos de inteligencia artificial aplicados a la identificación de la Sigatoka Negra en hojas de banano, utilizando como base artículos científicos publicados entre 2020 y 2025, indexados en Scopus y Web of Science. Para ello, se empleó el enfoque PRISMA, estableciendo filtros rigurosos de inclusión que garantizan la validez experimental de los modelos. Con esta revisión, se espera ofrecer una visión clara de los enfoques más efectivos y aportar lineamientos que sirvan para futuras implementaciones tecnológicas en el ámbito agrícola.

II. METODOLOGÍA

Este trabajo adoptó como enfoque metodológico un análisis sistemático de publicaciones, cuyo propósito es reconocer y analizar investigaciones que aplican inteligencia artificial para detectar enfermedades y evaluar la maduración en plantas de banano, prestando especial atención a la enfermedad conocida como Sigatoka Negra. Para asegurar la calidad de las fuentes utilizadas, se recurrió a dos bases de datos académicas reconocidas por su alcance científico y rigor editorial: SCOPUS y Web of Science (WOS). La elección de estas plataformas respondió a la necesidad de garantizar que los estudios revisados contaran con respaldo académico y abordaran de manera pertinente la intersección entre inteligencia artificial y agricultura. Estas preguntas también sirvieron como base para establecer las palabras clave cuidadosamente seleccionados con términos técnicos relacionados con el cultivo del banano, sus enfermedades y los métodos de IA aplicados. La búsqueda bibliográfica se restringió a publicaciones comprendidas entre los años 2020 y 2025, escritas en inglés o español, de acceso abierto, y que reportaran resultados obtenidos mediante el análisis de imágenes reales de hojas de banano. Para estructurar y documentar las etapas del proceso, se aplicó el protocolo PRISMA, el cual facilitó el seguimiento sistemático desde la identificación de registros iniciales hasta la selección final de artículos relevantes. Esta metodología ha sido ampliamente utilizada en estudios recientes orientados al uso de Machine Learning en aplicaciones agrícolas, ya que permite ordenar el conocimiento existente y realizar comparaciones coherentes entre enfoques, modelos y métricas [1]. La Tabla I resume la pregunta principal ¿Cuál es el modelo de inteligencia artificial más efectivo para la detección de la enfermedad en la planta de banano? del estudio, así como las preguntas específicas y los respectivos términos claves que guiarán la búsqueda y selección de información.

TABLA I.
PREGUNTAS ESPECÍFICAS DE INVESTIGACIÓN

Ítem	Preguntas Específicas	Keywords
1	¿Qué tipo de enfermedades y maduraciones en la planta de banano se han estudiado a través de modelos de inteligencia artificial?	Sigatoka, black sigatoka, sigatoka negra, black leaf spot disease, black leaf streak disease, leaf spot disease, mycosphaerella fijiensis, mycosphaerella-induced disease, fungal leaf spot, banana leaf streak, banana, banana plant, banana tree, sigatoka disease
2	¿Qué métodos de inteligencia artificial existen para detectar la enfermedad y maduración en el banano?	machine learning, deep learning, convolutional neural network, deep neural network, AI, artificial intelligence, transfer learning
3	¿Qué niveles de eficiencia y eficacia tienen los métodos	effectiveness, performance, accuracy, evaluation, precision, recall, metrics

	aplicados a la detección en hojas de banano?	
--	--	--

Con base en las preguntas formuladas, se realizaron consultas en las bases de datos SCOPUS y Web Of Science (WOS), empleando la siguiente ecuación de búsqueda: (TITLE-ABS-KEY (("sigatoka" AND "banana") OR ("black sigatoka" AND "banana") OR ("sigatoka negra" AND "banana") OR ("black leaf spot disease" AND "banana") OR ("black leaf streak disease" AND "banana") OR ("leaf spot disease" AND "banana") OR ("mycosphaerella fijiensis" AND "banana") OR ("mycosphaerella-induced disease" AND "banana") OR ("fungal leaf spot" AND "banana") OR ("banana leaf streak" AND "banana") OR ("sigatoka disease" AND "banana") OR ("banana" AND ("plant disease" OR "detection")))) AND TITLE-ABS-KEY (("machine learning" OR "deep learning" OR "convolutional neural network" OR "deep neural network" OR "transfer learning" OR "AI" OR "artificial intelligence" OR "computer vision")) AND TITLE-ABS-KEY (("effectiveness" OR "performance" OR "accuracy" OR "evaluation" OR "precision" OR "recall" OR "metrics")))

La lógica de la cadena de búsqueda se estructura en función a las tres preguntas específicas de la investigación, con el objetivo de recuperar estudios pertinentes y enfocados en el contexto del banano. Para la primera sección de la cadena, se integraron palabras claves relacionados con enfermedades de banana, especialmente aquellas asociadas a la Sigatoka Negra, asegurando que los resultados puedan abordar exclusivamente estas problemáticas. Se incorporaron términos relacionados con la maduración del fruto, ampliando así la cobertura temática hacia estudios que analicen el estado de desarrollo de la planta o del fruto mediante técnicas. Para la segunda y tercera pregunta de investigación, se añadieron términos asociados a modelos de inteligencia artificial como machine learning y deep learning, y a métricas de evaluación como accuracy, precision, y recall. Estos conceptos permiten identificar trabajos que no solo aplican IA, sino que también presentan una evaluación cuantitativa de su desempeño. El uso de operadores booleanos OR y AND permitió articular las secciones temáticas, garantizando que los artículos recuperados abordaran al menos una dimensión técnica modelo o evaluación junto con el foco central en banano. Adicionalmente, se implementaron filtros específicos en la ecuación de búsqueda que se visualiza en la Tabla II

TABLA II.
FILTROS APLICADOS A LA CADENA DE BUSQUEDA

Ítem	Filtro	Nomenclatura	Descripción
1	Tiempo	PUBYEAR > 2019 AND PUBYEAR < 2026	Se limita la búsqueda a estudios publicados entre 2020 y 2025
2	Idioma	LIMIT-TO (LANGUAGE,	Se incluyen únicamente

		"English") OR LIMIT-TO (LANGUAGE, "Spanish")	documentos redactados en inglés o español
3	Tipo de documento	LIMIT-TO (DOCTYPE, "ar") OR LIMIT-TO (DOCTYPE, "cp") OR LIMIT-TO (DOCTYPE, "cr")	Se incluyen artículos científicos, ponencias de conferencia y reseñas de conferencia
4	Acceso	LIMIT-TO (OA, "all")	Se restringe la búsqueda a estudios de acceso abierto

Estos filtros se integraron a la cadena de búsqueda para así garantizar la actualizada como sería la accesibilidad así teniendo esta siguiente ecuación: (TITLE-ABS-KEY ("effectiveness" OR "performance" OR "accuracy" OR "evaluation" OR "precision" OR "recall" OR "metrics")) AND PUBYEAR > 2019 AND PUBYEAR < 2026 AND (LIMIT-TO (DOCTYPE, "ar") OR LIMIT-TO (DOCTYPE, "cp") OR LIMIT-TO (DOCTYPE, "cr")) AND (LIMIT-TO (LANGUAGE, "English") OR LIMIT-TO (LANGUAGE, "Spanish")) AND (LIMIT-TO (OA, "all"))

A continuación, se definieron y aplicaron criterios específicos de inclusión y exclusión, los cuales se detallan en la TABLA III. Estos criterios fueron establecidos con el propósito de delimitar las fuentes recopiladas y asegurar que solo los estudios más relevantes y alineados con los objetivos de la investigación fueran seleccionados para el análisis. Los criterios se centraron en aspectos metodológicos, temporales, idiomáticos y de acceso, así como en la relevancia temática respecto al uso de modelos de inteligencia artificial aplicados al cultivo de banano, específicamente en el contexto de enfermedades como la Sigatoka Negra y la evaluación del estado de madurez.

TABLA III.
CRITERIOS DE INCLUSION Y EXCLUSION

Ítem	Criterio de inclusión	Criterio de exclusión
1	Los documentos deben abordar específicamente la enfermedad de la Sigatoka Negra en el cultivo de banano	Se excluirán documentos que no traten sobre la Sigatoka Negra o aborden otras enfermedades
2	Los documentos deben centrarse en el estudio de la planta de banano o el fruto en el contexto de enfermedad o maduración	Se excluirán estudios centrados en otras frutas o especies diferentes al banano
3	Los estudios deben enfocarse exclusivamente en el banano, sin mezclarlo con otras especies vegetales	Se excluirán documentos que analicen múltiples especies sin énfasis exclusivo en el banano
4	Se incluirán estudios que utilicen técnicas de IA (Machine Learning,	Se excluirán estudios que usen únicamente métodos

	Deep Learning, Transfer Learning) en imágenes de hojas de banano	tradicionales sin modelos de IA
5	Los documentos deben presentar modelos implementados y validados con imágenes reales	Se excluirán revisiones teóricas o trabajos sin validación experimental sobre imágenes reales
6	Los estudios deben centrarse exclusivamente en la detección de la Sigatoka Negra o maduración mediante herramientas de IA	Se excluirán estudios que apliquen IA a otras funciones, plagas o cultivos distintos al banano
7	Se incluirán trabajos que reporten métricas de rendimiento claras como precisión, recall, F1-score, entre otros	Se excluirán trabajos que no reporten métricas claras o evidencien bajo rendimiento
8	El enfoque de detección debe estar centrado en la hoja del banano, como superficie principal de análisis	Se excluirán documentos cuyo foco no esté en la hoja de banano
9	Los documentos deben describir detalladamente la metodología y condiciones reales en las que se evaluó el rendimiento	Se excluirán estudios basados en simulaciones o sin validación en entornos reales

La recuperación de documentos mediante esta cadena se alineó con los objetivos planteados y constituyó la base para el análisis sistemático de los artículos. Para este proceso, se aplicó el protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), ampliamente utilizado en estudios de revisión por su capacidad para garantizar un proceso transparente y reproducible de identificación, selección y síntesis de evidencia. En estudios recientes sobre inteligencia artificial aplicada al análisis de enfermedades en banano, como el de Linero-Ramos et al. [2], el uso de PRISMA ha demostrado ser eficaz en la estructuración de revisiones rigurosas. Su implementación permite excluir estudios que no cumplen con criterios predefinidos y consolidar la literatura científica más relevante para el objetivo planteado. Inicialmente, se identificaron 145 registros, provenientes de Scopus (n = 86) y Web of Science (n = 59). Tras eliminar 54 documentos duplicados, se criaron 91 registros. Luego de la revisión de título y resumen, se excluyeron 37 por no cumplir los criterios establecidos. Se recuperaron 54 publicaciones para su evaluación a texto completo, todas accesibles. En esta etapa, 56 fueron evaluadas en detalle, de las cuales una fue excluida por no abordar directamente la temática de Sigatoka Negra. Finalmente, se incluyeron 55 artículos que cumplían con todos los criterios definidos para esta revisión sistemática. La Figura 1 representa este proceso mediante un diagrama de flujo basado en el protocolo PRISMA.

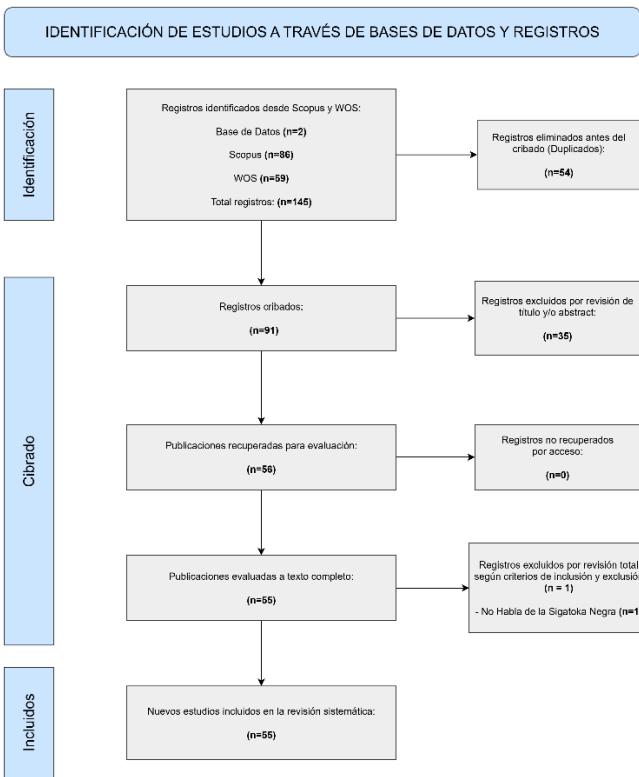


Fig. 1 Diagrama de Prisma

Nota: Especificación del proceso PRISMA realizado

III. RESULTADOS Y DISCUSIONES

Se llevó a cabo un análisis bibliométrico de los artículos seleccionados, clasificándolos por años de publicación con el propósito de llegar a identificar las posibles tendencias en la producción científica sobre el tema de estudio, la detección de la sigatoka negra en la planta de banano. La Figura 2 presenta una distribución anual de publicaciones entre los años 2020 y 2025. En el 2020, se han llegado a registrar 5 publicaciones, que representan el 9%, lo que se muestra es unos escasos de investigación sobre el tema. En el 2021, las publicaciones disminuyeron a 3 artículos (5%), posiblemente se ve reflejado a una fase de exploración o consolidaciones limitadas. No obstante, a partir de 2022, se llega a observar un aumento significativo, con 10 publicaciones (18%), lo que apunta al aumento de interés de investigación. Este crecimiento continuó en el 2023, con 12 artículos (22%), terminando en 2024 con 19 publicaciones, lo que representa un 35% del total examinado y el punto culminante de la producción. Este incremento podría deberse al avance de la tecnología en el transcurso de los años, teniendo una mayor disponibilidad de datos o información del campo como línea de investigación relevante. Comenzando con el año 2025, hasta la fecha de corte de análisis, se han revisado 6 publicaciones (11%). Aunque este número es inferior al de años previos, es fundamental tener en cuenta que el año no ha concluido, por lo que el total definitivo podría ser mayor. Se

observa, a partir de estos hallazgos, una tendencia creciente en la producción científica desde el 2022, con un pico notable en el 2024. Este comportamiento confirma el crecimiento del interés y el progreso en la aplicación de técnicas de Machine Learning para la detección de la Sigatoka Negra en el banano, lo que valida la relevancia y vigencia de esta revisión.

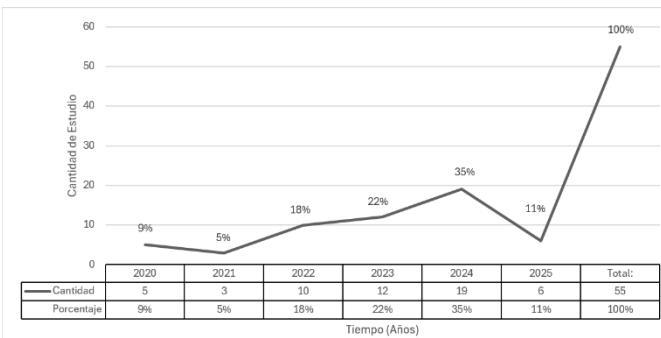


Fig. 2 Cantidad de estudios respecto al tiempo

La Figura 3 representa la distribución de los estudios analizados según los países de procedencia de las publicaciones. India emerge como uno de los mayores países de producción científica, ya que destaca con 17 publicaciones, lo que refleja su fuerte compromiso con el desarrollo para solucionar problemas agrícolas basadas en inteligencia artificial. A continuación, Indonesia y China le siguen con 6 publicaciones cada uno, así como Colombia, con 5 publicaciones, y por último Bangladesh, con 3 publicaciones. Estos países conforman el grupo más activo en las aplicaciones de técnicas de estudio de Machine Learning para la detección de enfermedades como la Sigatoka Negra en el Banano y maduración en el banano. Otros países como Uganda, Ecuador y Tanzania, con 2 publicaciones cada uno, también aportan a esta línea de investigación, indicando una presencia geográfica diversa, especialmente en regiones tropicales productoras de banano. Estos análisis revelan que la investigación de la detección automatizada en la Sigatoka Negra mediante Inteligencia Artificial ha despertado un interés significativo en el contexto agrícola, esto es evidente tanto en potencias científicas como en los países en vías de desarrollo con una fuerte producción bananera.

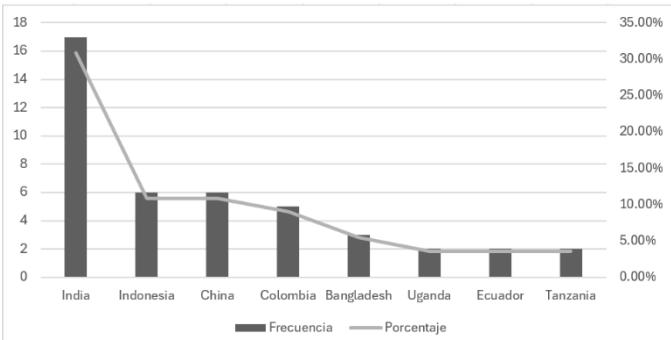


Fig. 3 Documento Indizado por país

En la siguiente Figura 4, se presenta la distribución de las palabras claves (keywords) con más frecuencia en los artículos seleccionados, lo cual nos permite identificar los conceptos centrales de la investigación y su grado de conexión temática. El análisis completo, que se presenta en la Tabla IV, donde se detallan los porcentajes de aparición respecto al total de estudios y la fuerza total de enlace de cada término.

La primera palabra clave es “Deep Learning”, se posiciona como la más representativa, apareciendo en un total de 23 documentos (21.10%) y con una fuerza de enlace total de 46, lo que se puede evidenciar su centralidad como un enfoque predominando en los modelos aplicados al diagnóstico automatizado de enfermedades. Este resultado resalta el protagonismo del Deep Learning en el desarrollo de los sistemas avanzados de detección. Le sigue “Machine Learning”, con 10 ocurrencias (9.17%) y una fuerza de enlace de 20. Este dato refleja su uso como término en el cual se agrupan diferentes metodologías algorítmicas, aunque con menor interconectividad específica dentro de los artículos analizados. Por otro lado, el término “banana” aparece en 7 estudios (6.42%), con una fuerza de enlace de 17, lo que demuestra la relevancia del cultivo en los casos de aplicación particularmente en contextos en la agricultura. Además, “Compute Vision” y “Disease Detection”, ambas con 5 ocurrencias (4.59%), revelan una fuerte vinculación técnica, con una fuerza de enlace de 10 y 13, respectivamente. Estas palabras clave refuerzan el papel de visión en parte de la inteligencia artificial como una herramienta fundamental en la identificación visual de síntomas de enfermedades en las plantas como la sigatoka negra. Finalmente, “Artificial Intelligence”, con 5 menciones (3.67%) y una fuerza de enlace de 9, representa el marco tecnológico general que engloba las metodologías utilizadas en los estudios. En conjunto, estas palabras clave revelan una orientación marcada hacia la aplicación de tecnologías emergentes en el diagnóstico de enfermedades del banano. Las diferencias en la fuerza de enlace entre los términos sugieren niveles variables de especialización temática, destacando la convergencia entre el área agrícola y los avances en el campo de Machine Learning.

**TABLA IV
CO-OCCURRENCIA DE KEYWORDS**

Id	Palabra Clave	Ocurrencia	% de estudios	fuerza total de enlace
1	deep learning	23	21.10%	46
2	machine learning	10	9.17%	20
3	banana	7	6.42%	17
4	computer vision	5	4.59%	10
5	disease detection	5	4.59%	13
6	artificial intelligence	4	3.67%	9

Nota: Elaborada a partir de los documentos analizados

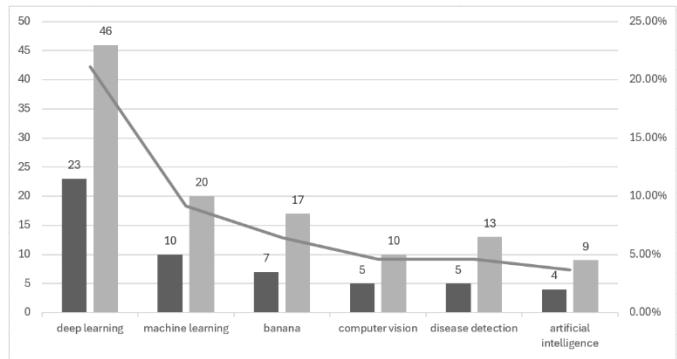


Fig. 4 Frecuencia de aparición de las palabras clave más relevantes en los artículos revisados

Los resultados se basan directamente de preguntas específicas que abordan a la pregunta principal. La primera pregunta que orienta nuestro estudio es: ¿Qué tipo de enfermedades y maduraciones en la planta de banano se han estudiado a través de modelos de Inteligencia Artificial? La Tabla V presenta los principales problemas de enfermedades y maduración del banano abordados en la literatura científica mediante modelos de Inteligencia artificial. De los 55 documentos analizados, el 40% de los estudios se enfoca en la detección de la sigatoka negra (Black Sigatoka). Esta es una enfermedad foliar de alta severidad y distribución global, lo que evidencia su importancia en la investigación agrícola basada en IA. La siguiente enfermedad más estudiada es la Marchitez de Panamá (Fusarium Wilt), que representa el 23.64% de los estudios. Es una patología reconocida por su alto impacto económico y dificultad de control. En menor medida, se identificaron trabajos enfocados en Banana Bunchy Top Virus (BBTV) con un 10.91% de los estudios, esta es una enfermedad viral que afecta el crecimiento del cultivo. Finalmente, se destaca una línea emergente de investigación relacionada con la madurez del plátano, analizada en el 9.09% de los artículos, lo cual refleja interés por aplicar modelos de clasificación no solo en las enfermedades, sino también para evaluar parámetros de calidad de fruto. Es importante señalar que varios estudios abordan más de una enfermedad o condición simultáneamente, por lo que las frecuencias no suman exactamente el total de documentos. No obstante, este análisis evidencia que los modelos de Inteligencia Artificial están siendo aplicados con mayor frecuencia al diagnóstico fitosanitario, aunque también se abren nuevas posibilidades en el ámbito agrónomo y en el análisis de la maduración del plátano.

**TABLA V
TIPOS DE ENFERMEDADES Y MADUREZ DEL BANANO**

Top	Nombre	Frecuencia (1)	Porcentaje (2)	ID Referencia
1	Black Sigatoka / Sigatoka Negra	22	40.00%	[1],[3],[4],[5],[6],[8],[16],[18],[19],[23],[27],[31],[36],[37],[39],[40],[41],[43],[46],[47],[50],[53]
2	Fusarium Wilt /	13	23.64%	[1], [6], [9], [17], [19], [21], [23], [26], [35], [40], [41], [47], [55]

	Marchitez de Panamá			
3	Banana Bunchy Top Virus (BBTV)	6	10.91%	[3], [4], [12], [19], [21], [30]
4	Madurez del plátano	5	9.09%	[28], [44], [45], [48], [49]

(1) El total de frecuencias no suma el total de documentos revisados, debido a que un documento puede estudiar una o más enfermedades.

(2) Considerando un total de 55 documentos analizados, según el diagrama PRISMA.

La siguiente pregunta que aborda nuestra investigación es: ¿Qué métodos de inteligencia artificial existen para detectar la enfermedad y maduración en el banano? La Tabla VI muestra los principales métodos de Inteligencia Artificial aplicados en los estudios realizados para la detección de enfermedades y la evaluación de la maduración en la planta de banano. Se identifica dos grandes enfoques: Deep Learning y Machine Learning. El modelo más utilizado fue la Red Neuronal Convolutacional (CNN), presente en 18 estudios (32.73%). Esto evidencia sus capacidades para el procesamiento de imágenes, especialmente en el diagnóstico visual de enfermedades como la Sigatoka Negra. Le sigue el modelo Inception, basado en Deep Learning, con 13 estudios (23.64%). Este se caracteriza por su arquitectura profunda y eficiente en la extracción de características complejas. El modelo MobileNet, optimizado para entornos con limitados recursos computacionales, aparece en 9 artículos (16.36%), lo que indica su potencial en las aplicaciones móviles o trabajos de campo. Finalmente, en el ámbito de Machine Learning tradicional, destaca el uso de Support Vector Machines (SVM), también con 9 estudios (16.36%), especialmente en investigaciones donde se emplean características textuales o espectrales en lugar de imágenes completas. Cabe señalar que algunos documentos emplean más de un modelo simultáneamente o abordan tanto enfermedades como también madurez, por lo que las frecuencias no corresponden al total de estudios revisados.

**TABLA VI
TIPOS DE MODELOS DE INTELIGENCIA ARTIFICIAL**

ID	Modelo	Frecuencia (1)	Porcentaje (2)	ID Referencia
1	CNN	18	32.73%	[1], [10], [14], [20], [22], [23], [24], [26], [29], [30], [32], [34], [36], [38], [40], [43], [45], [47], [50]
2	Inception	13	23.64%	[11], [30], [31], [33], [34], [38], [39], [40], [41], [43], [44], [45], [54]
3	MobileNet	9	16.36%	[1], [25], [34], [39], [40], [43], [45], [46], [54]
4	SVM	9	16.36%	[3], [4], [6], [7], [18], [34], [37], [47], [48]

(1) El total de frecuencias no suma el total de documentos revisados, debido a que un documento puede estudiar una o más enfermedades como también de la maduración

(2) Considerando un total de 55 documentos analizados, según el diagrama PRISMA.

Para la siguiente pregunta que aborda nuestra investigación es: ¿Qué niveles de evaluación de la eficiencia y eficacia de modelos de Inteligencia Artificial en la detección de enfermedades y maduración de la banana? Para poder evaluar el rendimiento de los modelos de inteligencia artificial aplicadas a la detección de enfermedades y maduración del banano, los estudios analizados emplearon diversas métricas cuantitativas estas métricas permiten medir la eficiencia (capacidad del modelo para hacer correctamente su tarea) y eficacia (grado en que cumple su objetivo con precisión), especialmente en tareas de clasificación. A continuación, se describe brevemente las principales métricas identificadas en la revisión:

**TABLA VII
DESCRIPCION DE LAS METRICAS IDENTIFICADAS**

Métrica	Descripción
Precisión (Precision)	Representa la cantidad de aciertos positivos del modelo respecto a todas las veces que predijo un resultado positivo.
Sensibilidad / Exhaustividad (Recall)	Evaluá la habilidad del modelo para reconocer de manera adecuada todos los casos positivos existentes.
F1-Score	Se calcula como la media armónica entre la precisión y la sensibilidad, siendo especialmente útil cuando es necesario equilibrar ambas métricas en contextos con clases desiguales.
Exactitud (Accuracy)	Indica cuántas veces el modelo acertó en sus predicciones en relación con el número total de muestras analizadas.
AUC (Área bajo la curva ROC)	Mide la habilidad del modelo para separar correctamente las clases positivas y negativas; cuanto más próximo a uno, mejor es su desempeño.
IoU (Intersección sobre Unión)	Métrica usada en detección de objetos. Evalúa la superposición entre la predicción del modelo y la ubicación real del objeto.
Tiempo de inferencia (ms)	Tiempo que tarda el modelo en realizar una predicción, relevante para aplicaciones en tiempo real o móviles.

Estas métricas van dependiendo debido a los tipos de modelos datos (imagen, espectro, sensor) y del objetivo (clasificación general, segmentación, detección rápida, etc.). En las siguientes partes se presentará el rendimiento alcanzado por los distintos enfoques de inteligencia artificial según estas métricas.

Los modelos aplicados a la detección de enfermedades y maduración del banano pueden clasificarse en dos enfoques: Deep Learning, especialmente redes convolucionales (CNN) y sus variantes, Machine Learning tradicional, como SVM, HNN o Random Forest.

Estos modelos, entrenados que son principalmente con imágenes RGB de hojas de banano, mostraron altos niveles de rendimiento, con valores de precisión y recall en la mayoría de los casos por encima del 90%. Destacando modelos como ResNet50, VGG16 y EfficientNet, con resultados superiores al 99%

TABLA VIII
RENDIMIENTO DE MODELOS DE DEEP LEARNING

Modelo	Precisión (%)	Recall (%)	F1-Score (%)
MobileNetV2	95.58	92.61	—
MobileNetV3-Small	93.94	93.59	93.59
ShuffleNetV2	96.42	96.39	96.4
SqueezeNet	97.14	97.1	97.12
DenseNet201Plus	90.12	—	—
ResNet50	99.69	99.64	99.62
VGG16	99.44	99.27	99.29
EfficientNet	99.5	99.35	99.32

En comparación, los modelos de Machine Learning clásico presentan un rendimiento más variable y generalmente inferior. Modelos como SVM y KNN alcanzan los resultados aceptables, mientras que otros como Random Forest (RF) o Decision Trees (DT) presentan valores por debajo del 65%.

TABLA IX

RENDIMIENTO DE MODELOS DE MACHINE LEARNING

Modelo	Precisión (%)	Recall (%)	F1-Score (%)
SVM (Lineal)	73	73	73
SVM (RBF)	72	70	70
SVM (Sigmoid)	75	74	74
KNN	76.32	72.7	74
Random Forest (RF)	60	51.33	—
Decision Tree (DT)	62.54	59.41	—
Artificial Neural Network (ANN)	73.54	63.76	—

En términos generales, los modelos tanto como Deep Learning supera ampliamente a los tradicionales, especialmente cuando se trabaja con imágenes, modelos como ResNet50, EfficientNet y VGG16 demostraron un rendimiento cercano al 100% en tareas de clasificación de enfermedades o estado de maduración. Sin embargo, los modelos clásicos siguen siendo útiles cuando se dispone de menos datos o se trabaja con características estructuradas o espectrales. Además del uso de imágenes RGB convencionales, varios estudios emplearon datos espectrales, sensores multiespectrales o características derivadas mediante reducción de dimensionalidad para entrenar modelos de detección de enfermedades o evaluación de la maduración del banano. Estos enfoques no solo se busca mejorar la precisión, su no también poder adaptarse a condiciones agrícolas reales con mayor robustez y menos dependencia visual.

Los modelos aplicados reflejan una tendencia creciente hacia la agricultura de precisión. El modelo 1D-CNN, entrenado con

1645 longitudes de onda, logró una precisión de 95.18% y un recall de 98.3%, mostrando un alto nivel de eficacia. Otros enfoques como PCA-SVM y SPA-SVM, que utilizan componentes principales o selección espectral, también obtuvieron buenos resultados

TABLA X
RENDIMIENTO DE MODELOS APLICADOS A ESPECTROS Y DATOS SENSORIALES

Modelo	Tipo de Entrada	Precisión (%)	Recall (%)	F1-Score (%)
1D-CNN	Espectros (1645 bandas)	95.18	98.3	98.26
PCA-SVM	14 componentes principales	93.98	—	—
SPA-SVM	11 longitudes de onda	91.57	—	—

Aunque los más comunes, como el modelo CNN también fueron evaluados con entradas RGB en estudios de maduración o clasificación simple, mostrando un rendimiento moderado en condiciones más exigentes.

TABLA XI
RENDIMIENTO DE MODELOS DE VALIDACION Y ENTRADA RGB

Modelo	Entrada	Precisión (%) (Validación)	Recall (%)
EfficientNetV2B3	RGB	78.33	64
MobileNetV2	RGB	78.52	39

Los resultados muestran que los modelos aplicados a datos espectrales lograron un mayor rendimiento en precisión y recall, especialmente cuando se utilizan técnicas avanzadas como CNN unidimensionales (1D-CNN) o la reducción espectral. Si bien los modelos con entradas RGB son más accesibles y fáciles de aplicar, su rendimiento puede ser más bajo frente a variaciones de luz o condiciones de campo.

El rendimiento de los modelos de la Inteligencia artificial aplicados al cultivo del banano no solo depende de los tipos de algoritmos si no también el contexto específico en el que se aplican, como la enfermedad, la parte de la planta analizada, el estado del fruto o la necesidad de respuesta rápida. Se va a mostrar los principales hallazgos organizados por tipo de aplicación. En la tabla XII se muestra una comparación entre distintos modelos aplicados a diversas enfermedades que afectan a las hojas del banano. Se observa que modelos de tipo ensamblado alcanzan altos valores de precisión y recall para Sigatoka Amarilla, mientras que modelos CNN presentan resultados variados para la Sigatoka Negra y manchas foliares.

TABLA XII
RENDIMIENTO DE MODELOS SEGÚN ENFERMEDADES DETECTADA EN HOJAS DE BANANO

Enfermedad	Modelo	Precisión (%)	Recall (%)	F1-Score (%)
Sigatoka Negra	KNN	94	72	—
Sigatoka Negra	Ensamble	95	77	—
Sigatoka Amarilla	SVM	91	64	—
Sigatoka Amarilla	Ensamble	96	83	—
Leaf Spot	CNN	81.96	—	—
Black Sigatoka	CNN	83	78	72
Black Sigatoka	Xanthomonas	81	90	81
Mancha (Speckle)	CNN	97.37	96	96
Saludable	Ensamble	100	100	100

Estos resultados muestran que las condiciones saludables y ciertas enfermedades específicas como la Mancha o Sigatoka Amarilla pueden ser detectadas con alta precisión. En cambio, otras como la Sigatoka Negra presentan mayor dificultad, especialmente en etapas tempranas.

En otros estudios que involucran clasificación de frutas por su estado (fresco o deteriorado), se puede observar altos niveles de exactitud, especialmente con modelos como ResNet-50 y MobileNetV2.

TABLA XIII
COMPARACION DE RENDIMIENTO SEGÚN EL TIPO Y ESTADO DEL FRUTO

Clase	Modelo Propuesto (%)	ResNet-50 (%)	MobileNetV2 (%)
Fresh Apples	99.22	93.62	98.67
Rotten Banana	99.81	98.59	99.67
Fresh Oranges	97.89	92.29	96.5

En aplicaciones donde la velocidad de procesamiento es crítica como sería el monitoreo en tiempo real, se evalúa el desempeño de modelos como YOLOv3, YOLOv4 y YOLOv7, comparados con técnicas tradicionales como HOG+SVM. Los resultados reflejan un alto rendimiento en precisión, especialmente en YOLOv4, y menor tiempo de inferencia en YOLOv7.

TABLA XIV
COMPARACION DE MODELOS DE DETECCION RAPIDA

Modelo	Precisión (%)	Recall (%)	F1-Score (%)	IoU (%)	Tiempo (ms)
YOLOv7	84	84	84	77	96
YOLOv4	99.29	99.29	98.26	—	—
YOLOv3	90.78	90.78	90.78	—	—

HOG+SV M	89.63	89.63	89.63	—	—
----------	-------	-------	-------	---	---

Esto sugiere que, si bien YOLOv4 ofrece la mayor precisión, YOLOv7 es más adecuado para entornos que requieren detección rápida con resultados competitivos. Finalmente, se analizó el rendimiento de los modelos según la **parte del banano** donde se aplica la detección. Como se muestra en la **Tabla H**, los resultados más altos se alcanzan en el raquis y el racimo, mientras que la **hoja presenta menor recall**, posiblemente por su variabilidad visual o condiciones de campo.

TABLA XV
RENDIMIENTO DE MODELOS SEGÚN PARTE DE LA PLANTA ANALIZADA

Parte de la Planta	Precisión (%)	Recall (%)	F1-Score (%)
Raquis	98	98	98
Hoja	90	65	75
Fruta Cortada	95	91	93
Racimo	97	88	92

El rendimiento de los modelos varía no solo por arquitectura, sino también por el contexto en el que se aplican. Los mejores resultados se observan cuando se trabaja con frutas enteras o zonas menos variables como el raquis. Por otro lado, la hoja, aunque es la parte más afectada por enfermedades presenta mayores desafíos en términos de recall, lo que destaca la necesidad de optimizar los modelos para trabajar con imágenes foliares en condiciones reales.

El metaanálisis de los resultados de rendimiento son los siguientes:

TABLA XVI
DISTRIBUCIÓN DE RESULTADOS POR MÉTRICAS

Métricas	Media	Frecuencia	Media	Mediana	Desv.Est.	Coef.Var.
Exactitud	92.07	4				
F1 Score	92.54	62	92.5	95	8.6	9.30%
Porcentaje	92.80	3				
Precisión	92.60	100	92.6	94.3	6.69	7.22%
Total	92.57	169				

El promedio de resultados por métricas muestra un valor total de 92.57, lo cual significa que aproximadamente en cada experimento se obtuvo este resultado.

TABLA XVII
RESULTADOS DE PRUEBA DE NORMALIDAD

Métrica	Prueba	Resultado Estadístico	p-valor
F1 Score	Kolmogorov-Smirnov	0.241	0.002
Precisión	Kolmogorov-Smirnov	0.144	0.032

Las pruebas F1 Score y Precisión tienen la mayor cantidad de experimentos, y ambos muestran un comportamiento ligeramente heterogéneo. Lo cual evidencia que existen experimentos cuyos resultados no se encuentran dentro del valor promedio.

IV. CONCLUSIONES

En los 55 estudios revisados, la detección de Sigatoka Negra concentra el 40 % de los trabajos, seguida por la Marchitez de Panamá (23,6 %) y el Banana Bunchy Top Virus (10,9 %), mientras que un 9,1 % aborda la maduración del fruto. Este patrón confirma el foco principal en patologías de alto impacto y un interés emergente en calidad postcosecha. Si bien las redes profundas (CNN 32,7 %, Inception 23,6 %, MobileNet 16,4 %) demuestran alta precisión en tareas de visión, los modelos de Machine Learning, por ejemplo SVM y Random Forest, equilibran muy bien exactitud (alrededor del 92,6 % en métricas clave) con interpretabilidad y bajo coste computacional, facilitando su adopción práctica en campo. Las pruebas de normalidad ($p = 0,002$ en F1 Score; $p = 0,032$ en Precisión) indican variabilidad entre experimentos, lo que refuerza la necesidad de estandarizar protocolos de validación y ampliar las muestras. En definitiva, para potenciar la viabilidad de soluciones de IA en banano, recomendamos centrar futuros esfuerzos en técnicas de Machine Learning clásico, mejorar la transparencia de los modelos y diversificar las fuentes de datos. Así se avanzará hacia herramientas más accesibles, eficientes y sostenibles para el diagnóstico de enfermedades y la evaluación de madurez en el cultivo bananero.

IV. AGRADECIMIENTO/RECONOCIMIENTO

Expresamos el agradecimiento al Dr. Oscar Alex Serquen yparrauirre (C23024@utp.edu.pe) y Dr. Christian Abraham Dios Castillo (C16763@utp.edu.pe), por su colaboración en el presente manuscrito.

REFERENCIAS

- [1] S. Nassor, M. Mushthofa, and K. Priandana, “Deep learning model for detection and classification of banana diseases based on leaf images,” in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics, 2024. doi: 10.1088/1755-1315/1359/1/012010.
- [2] P. Baglat, A. Hayat, F. Mendonça, A. Gupta, S. S. Mostafa, and F. Morgado-Dias, “Non-Destructive Banana Ripeness Detection Using Shallow and Deep Learning: A Systematic Review,” Jan. 01, 2023, *MDPI*. doi: 10.3390/s23020738.
- [3] A. P. Singh, P. Sahu, A. Chug, and D. Singh, “A Systematic Literature Review of Machine Learning Techniques Deployed in Agriculture: A Case Study of Banana Crop,” 2022, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/ACCESS.2022.3199926.
- [4] V. Chaudhari and M. P. Patil, “Detection and Classification of Banana Leaf Disease Using Novel Segmentation and Ensemble Machine Learning Approach,” *Applied Computer Systems*, vol. 28, no. 1, pp. 92–99, Jun. 2023, doi: 10.2478/acss-2023-0009.
- [5] L. F. Mbo Nkoulou *et al.*, “Perspective for genomic-enabled prediction against black sigatoka disease and drought stress in polyploid species,” Oct. 28, 2022, *Frontiers Media S.A.* doi: 10.3389/fpls.2022.953133.
- [6] J. D. Thiagarajan *et al.*, “Analysis of banana plant health using machine learning techniques,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-63930-y.
- [7] X. Chu *et al.*, “A Vis/NIR spectra-based approach for identifying bananas infected with *Colletotrichum musae*,” *Front Plant Sci*, vol. 14, 2023, doi: 10.3389/fpls.2023.1180203.
- [8] R. Bhagwat and Y. Dandawate, “Towards robust crop disease detection for complex real field background images,” *Vietnam J Sci Technol*, vol. 62, no. 5, pp. 990–1004, Oct. 2024, doi: 10.15625/2525-2518/18914.
- [9] R. Sangeetha, J. Logeshwaran, J. Rocher, and J. Lloret, “An Improved Agro Deep Learning Model for Detection of Panama Wilt Disease in Banana Leaves,” *AgriEngineering*, vol. 5, no. 2, pp. 660–679, Jun. 2023, doi: 10.3390/agriengineering5020042.
- [10] J. Ni, J. Gao, L. Deng, and Z. Han, “Monitoring the Change Process of Banana Freshness by GoogLeNet,” *IEEE Access*, vol. 8, pp. 228369–228376, 2020, doi: 10.1109/ACCESS.2020.3045394.
- [11] P. Sajitha, A. Diana Andrushia, N. Mostafa, A. Younes Shdefat, S. S. Suni, and N. Anand, “Smart farming application using knowledge embedded-graph convolutional neural network (KEGCNN) for banana quality detection,” *J Agric Food Res*, vol. 14, Dec. 2023, doi: 10.1016/j.jafr.2023.100767.
- [12] M. Gomez Selvaraj *et al.*, “Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 169, pp. 110–124, Nov. 2020, doi: 10.1016/j.isprsjprs.2020.08.025.
- [13] M. K. A. Mazumder, M. M. Kabir, A. Rahman, M. Abdullah-Al-Jubair, and M. F. Mridha, “DenseNet201Plus: Cost-effective transfer-learning architecture for rapid leaf disease identification with attention mechanisms,” *Heliyon*, vol. 10, no. 15, Aug. 2024, doi: 10.1016/j.heliyon.2024.e35625.
- [14] F. Valentino, T. W. Cenggoro, G. N. Elwirehardja, and B. Pardamean, “Energy-efficient deep learning model for fruit freshness detection,” *IAES International Journal of Artificial Intelligence*, vol. 12, no. 3, pp. 1386–1395, 2023, doi: 10.11591/ijai.v12.i3.pp1386-1395.
- [15] L. Fu *et al.*, “Fast and accurate detection of banana fruits in complex background orchards,” *IEEE Access*, vol. 8, pp. 196835–196846, 2020, doi: 10.1109/ACCESS.2020.3029215.
- [16] S. Fredy, G. Edwar Jacinto, and S. Fernando Martínez, “Model for the identification of diseases in the banana plant using a convolutional neural network,” *International Journal of Engineering Research and Technology*, vol. 13, no. 10, pp. 2668–2673, 2020, doi: 10.3762/IJERT/13.10.2020.2668-2673.
- [17] C. Li, D. Xiang, S. Yang, X. Wang, and C. Li, “Fusarium Wilt of Banana Latency and Onset Detection Based on Visible/Near Infrared Spectral Technology,” *Agronomy*, vol. 14, no. 12, Dec. 2024, doi: 10.3390/agronomy14122994.
- [18] J. Ugarte Fajardo, M. Maridueña-Zavala, J. Cevallos-Cevallos, and D. Ochoa Donoso, “Effective Methods Based on Distinct Learning Principles for the Analysis of Hyperspectral Images to Detect Black Sigatoka Disease,” *Plants*, vol. 11, no. 19, Oct. 2022, doi: 10.3390/plants11192581.
- [19] J. J. Mora, G. Blomme, N. Safari, S. Elayabalan, R. Selvarajan, and M. G. Selvaraj, “Digital framework for georeferenced multiplatform surveillance of banana wilt using human in the loop AI and YOLO foundation models,” *Sci Rep*, vol. 15, no. 1, p. 3491, Dec. 2025, doi: 10.1038/s41598-025-87588-2.
- [20] C. ERGELDI and O. FEYZIOGLU, “Circular Supply Chains: An Internet of Things Application for Rotten Product Detection in Aggregate Food Industry,” *The Eurasia Proceedings of Science Technology Engineering and Mathematics*, vol. 22, pp. 210–216, Sep. 2023, doi: 10.55549/epstem.1347745.
- [21] K. L. Narayanan *et al.*, “Banana Plant Disease Classification Using Hybrid Convolutional Neural Network,” *Comput Intell Neurosci*, vol. 2022, 2022, doi: 10.1155/2022/9153699.
- [22] N. Ismail and O. A. Malik, “Real-time visual inspection system for grading fruits using computer vision and deep learning techniques,” *Information Processing in Agriculture*, vol. 9, no. 1, pp. 24–37, Mar. 2022, doi: 10.1016/j.inpa.2021.01.005.
- [23] C. A. Elinisa and N. Mduma, “Mobile-Based convolutional neural network model for the early identification of banana diseases,” *Smart Agricultural Technology*, vol. 7, Mar. 2024, doi: 10.1016/j.atech.2024.100423.

- [24] M. Knott, F. Perez-Cruz, and T. Defraeye, "Facilitated machine learning for image-based fruit quality assessment," *J Food Eng*, vol. 345, May 2023, doi: 10.1016/j.jfoodeng.2022.111401.
- [25] V. Hasbi Athala, S. Lun Lau, R. Aryanto, and A. Haris Rangkuti, "Comparative Analysis of Banana Detection Models," *International journal of electrical and computer engineering systems*, vol. 15, no. 4, pp. 335–367, Mar. 2024, doi: 10.32985/ijeces.15.4.6.
- [26] K. Yan, M. K. C. Shisher, and Y. Sun, "A Transfer Learning-Based Deep Convolutional Neural Network for Detection of Fusarium Wilt in Banana Crops," *AgriEngineering*, vol. 5, no. 4, pp. 2381–2394, Dec. 2023, doi: 10.3390/agriengineering5040146.
- [27] B. O. Olivares, A. Vega, M. A. Rueda Calderón, E. Montenegro-Gracia, M. Araya-Almán, and E. Marys, "Prediction of Banana Production Using Epidemiological Parameters of Black Sigatoka: An Application with Random Forest," *Sustainability (Switzerland)*, vol. 14, no. 21, Nov. 2022, doi: 10.3390/su142114123.
- [28] G. Wang, Y. Gao, F. Xu, W. Sang, Y. Han, and Q. Liu, "A Banana Ripeness Detection Model Based on Improved YOLOv9c Multifactor Complex Scenarios," *Symmetry (Basel)*, vol. 17, no. 2, Feb. 2025, doi: 10.3390/sym17020231.
- [29] U. Patayon and R. V. Crisostomo, "Automatic Identification of Abaca Bunchy Top Disease using Deep Learning Models," in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 321–329. doi: 10.1016/j.procs.2021.01.012.
- [30] A. Simango, S. Mananze, and J. Bila, "Application of Artificial Intelligence in the Identification of Banana Bunch Top Virus (BBTV) in Mozambique," *Engineering, Technology and Applied Science Research*, vol. 14, no. 6, pp. 18734–18740, Dec. 2024, doi: 10.48084/etasr.7442.
- [31] Andreanov Ridhovan, Aries Suharso, and Chaerur Rozikin, "Disease Detection in Banana Leaf Plants using DenseNet and Inception Method," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 5, pp. 710–718, Oct. 2022, doi: 10.29207/resti.v6i5.4202.
- [32] P. Kanupuru and N. V. Uma Reddy, "A Deep Learning Approach to detect the spoiled fruits..," *WSEAS Transactions on Computer Research*, vol. 10, pp. 74–87, 2022, doi: 10.37394/232018.2022.10.10.
- [33] G. Farjon, Y. Itzhaky, F. Khoroshevsky, and A. Bar-Hillel, "Leaf Counting: Fusing Network Components for Improved Accuracy," *Front Plant Sci*, vol. 12, Jun. 2021, doi: 10.3389/fpls.2021.575751.
- [34] A. A and B. N, "A Hybrid Feature Extraction and Classification using Xception-RF for Multiclass Disease Classification in Plant Leaves," *Applied Artificial Intelligence*, vol. 37, no. 1, 2023, doi: 10.1080/08839514.2023.2176614.
- [35] J. J. Mora, M. G. Selvaraj, C. I. Alvarez, N. Safari, and G. Blomme, "From pixels to plant health: accurate detection of banana Xanthomonas wilt in complex African landscapes using high-resolution UAV images and deep learning," *Discover Applied Sciences*, vol. 6, no. 7, Jul. 2024, doi: 10.1007/s42452-024-06073-z.
- [36] Ilham Rahmana Syihad, Muhammad Rizal, Zamah Sari, and Yusuf Azhar, "CNN Method to Identify the Banana Plant Diseases based on Banana Leaf Images by Giving Models of ResNet50 and VGG-19," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 6, pp. 1309–1318, Dec. 2023, doi: 10.29207/resti.v7i6.5000.
- [37] J. Manrique-Silupu, J. C. Campos, E. Paiva, and W. Ipanaqué, "Thrips incidence prediction in organic banana crop with Machine learning," *Heliyon*, vol. 7, no. 12, Dec. 2021, doi: 10.1016/j.heliyon.2021.e08575.
- [38] A. R. K. P and G. S, "Hyperparameter Optimization in Transfer Learning for Improved Pathogen and Abiotic Plant Disease Classification," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 8, 2024, doi: 10.14569/IJACSA.2024.01508110.
- [39] Y. H. Genet, N. T. Sinshaw, B. G. Assefa, and S. K. Mohapatra, "Sigatoka and Xanthomonas Banana Leaf Disease Detection Via Transfer Learning," *Scientia Iranica*, vol. 0, no. 0, pp. 0–0, May 2024, doi: 10.24200/sci.2024.62306.7766.
- [40] M. A. B. Bhuiyan, H. M. Abdullah, S. E. Arman, S. Saminur Rahman, and K. Al Mahmud, "BananaSqueezeNet: A very fast, lightweight convolutional neural network for the diagnosis of three prominent banana leaf diseases," *Smart Agricultural Technology*, vol. 4, Aug. 2023, doi: 10.1016/j.atech.2023.100214.
- [41] S. L. Sanga, D. Machuve, and K. Jomanga, "Mobile-based Deep Learning Models for Banana Disease Detection," *Engineering, Technology & Applied Science Research*, vol. 10, no. 3, pp. 5674–5677, Jun. 2020, doi: 10.48084/etasr.3452.
- [42] B. Ashoka S et al., "Explainable AI Based framework for Banana Disease Detection," in *2024 5th International Conference on Innovative Trends in Information Technology (ICITIIT)*, IEEE, Mar. 2024, pp. 1–6. doi: 10.1109/ICITIIT61487.2024.10580364.
- [43] J. Deng, W. Huang, G. Zhou, Y. Hu, L. Li, and Y. Wang, "Identification of banana leaf disease based on KVA and GR-ARNET," *J Integr Agric*, vol. 23, no. 10, pp. 3554–3575, Oct. 2024, doi: 10.1016/j.jia.2023.11.037.
- [44] M. Zhao, Z. You, H. Chen, X. Wang, Y. Ying, and Y. Wang, "Integrated Fruit Ripeness Assessment System Based on an Artificial Olfactory Sensor and Deep Learning," *Foods*, vol. 13, no. 5, Mar. 2024, doi: 10.3390/foods13050793.
- [45] N. Aherwadi, U. Mittal, J. Singla, N. Z. Jhanjhi, A. Yassine, and M. S. Hossain, "Prediction of Fruit Maturity, Quality, and Its Life Using Deep Learning Algorithms," *Electronics (Switzerland)*, vol. 11, no. 24, Dec. 2022, doi: 10.3390/electronics11244100.
- [46] R. Linero-Ramos, C. Parra-Rodríguez, A. Espinosa-Valdez, J. Gómez-Rojas, and M. Gongora, "Assessment of Dataset Scalability for Classification of Black Sigatoka in Banana Crops Using UAV-Based Multispectral Images and Deep Learning Techniques," *Drones*, vol. 8, no. 9, Sep. 2024, doi: 10.3390/drones8090503.
- [47] Ravi Kumar Tirandasu, "A Novel Classifier for Plant Health Monitoring: A Focus on Banana Leaf Disease Detection Using Deep Learning," *Journal of Information Systems Engineering and Management*, vol. 10, no. 1s, pp. 184–197, Dec. 2024, doi: 10.52783/jisem.v10i1s.114.
- [48] R. M and P. Voola, "Developing an IoT and ML-driven platform for fruit ripeness evaluation and spoilage detection: A case study on bananas," *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 11, Mar. 2025, doi: 10.1016/j.prime.2025.100896.
- [49] L. Yang et al., "Automatic Detection of Banana Maturity—Application of Image Recognition in Agricultural Production," *Processes*, vol. 12, no. 4, Apr. 2024, doi: 10.3390/pr12040799.
- [50] N. Helmawati and E. Utami, "Utilization of the Convolutional Neural Network Method for Detecting Banana Leaf Disease," *Jurnal RESTI*, vol. 8, no. 6, pp. 799–805, Dec. 2024, doi: 10.29207/resti.v8i6.1410.
- [51] N. Jiménez, S. Orellana, B. Mazon-Olivio, W. Rivas-Asanza, and I. Ramírez-Morales, "Detection of Leaf Diseases in Banana Crops Using Deep Learning Techniques," *AI (Switzerland)*, vol. 6, no. 3, Mar. 2025, doi: 10.3390/ai6030061.
- [52] T. C. Pham, T. N. Nguyen, and V. D. Nguyen, "Ambiguity-aware semi-supervised learning for leaf disease classification," *Sci Rep*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-95849-3.
- [53] V. G. Krishnan, J. Deepa, P. V. Rao, V. Divya, and S. Kaviarasan, "An automated segmentation and classification model for banana leaf disease detection," *J Appl Biol Biotechnol*, vol. 10, no. 1, pp. 213–220, Jan. 2022, doi: 10.7324/JABB.2021.100126.
- [54] B. Subburaj, R. M. S. Ananthanarayanan, and D. Won, "Plantention: A general-purpose, lightweight and attention-based model for multi-crop leaf disease classification," *Results in Engineering*, vol. 26, Jun. 2025, doi: 10.1016/j.rineng.2025.105075.
- [55] T. Ritter, D. Alvarez, L. E. Mosquera, E. Martey, and J. Mockshell, "A socioeconomic and cost benefit analysis of Tropical Race 4 (TR4) prevention methods among banana producers in Colombia," *PLoS One*, vol. 19, no. 10 October, Oct. 2024, doi: 10.1371/journal.pone.0311243.
- [56] A. Espejo-Castillo, A. Romero-González, and P. Salas-Zárate, "Revisión Sistématica de Literatura sobre el Uso de Machine Learning en el Sector Agrícola," *Revista Contribution*, vol. 1, no. 1, pp. 25–33, 2023. [Online]. Available: <https://contribution.revista.rectorado.una.py/index.php/contribution/article/view/238>
- [57] R. Linero-Ramos, C. Parra-Rodríguez, A. Espinosa-Valdez, J. Gómez-Rojas y M. Gongora, "Assessment of Dataset Scalability for Classification of Black Sigatoka in Banana Crops Using UAV-Based Multispectral Images and Deep Learning Techniques," *Drones*, vol. 8, art. 503, pp. 1–21, 2024. [Online]. Available: <https://doi.org/10.3390/drones8090503>