

HEALTH DIAGNOSTICS OF FRUIT PLANTS USING DEEP LEARNING IN MOBILE APPLICATIONS: RSL

Nieves N. Antonio-Miranda¹, Leonardo M. Lopez-Lavado², Ivan G. Human-Torres³

^{1,2,3}Universidad Tecnológica del Perú, Perú, u20235861@utp.edu.pe, u20243326@utp.edu.pe, c26994@utp.edu.pe

Abstract— In modern agriculture, identifying diseases or pests in fruit plants is one of the biggest challenges. It is true that there are various methods for making diagnoses, mostly with the help of specialists who traverse the fields checking for any signs of disease in the plants. Given the aforementioned as stated in article [1], many of these techniques are slow and very costly, and even with errors, since diseases are not detected until they have a significant degree of damage. In the present systematic literature review, recent studies that approach the diagnosis of plant health through deep learning in mobile applications were analyzed, with the intention of identifying emerging trends and assessing the efficiency of the employed technologies. The methodology employed consists of the comprehensive search and analysis of each scientific article from academic literature sources, for instance, Web of Science and Scopus. In the selection of these articles, keywords related to fruit plants, mobile applications, deep learning, health, and diagnosis were used, following the established inclusion and exclusion criteria, considering that they are RSL articles or conference papers and open access. Subsequently, these articles were analyzed, comparing different approaches using various deep learning models such as ResNet50, VGG16, and other pre-trained models that achieve a high level of accuracy in image capture through mobile devices. This RSL analyzed the use of innovative tools such as Deep learning that systematize knowledge in this area, optimizing crop production and reducing significant losses, which is crucial for future research.

Keywords— Fruit Plants, Deep Learning, Health Diagnosis.

DIAGNÓSTICO DE SALUD DE PLANTAS FRUTALES MEDIANTE DEEP LEARNING EN APLICATIVOS MÓVILES: RSL

Nieves N. Antonio-Miranda¹, Leonardo M. Lopez-Lavado², Ivan G. Human-Torres³

^{1,2,3}Universidad Tecnológica del Perú, Perú, u20235861@utp.edu.pe, u20243326@utp.edu.pe, c26994@utp.edu.pe

Resumen— En la agricultura moderna, uno de los mayores retos es el proceso de identificación de enfermedades o plagas en plantas frutales. Si bien es cierto existen distintos enfoques para el diagnóstico, en su mayoría con la ayuda de especialistas que recorren los campos haciendo la revisión de algún signo de enfermedad en las plantas [1]. Ante lo mencionado según lo nombrado en el artículo [2], muchas de estas técnicas son lentas y muy costosas, e incluso con errores, ya que las enfermedades no se detectan hasta que tienen un grado significativo de daño. En la presente revisión metódica de literatura se analizaron estudios recientes que abordan el diagnóstico de la salud de plantas mediante deep learning en aplicativos móviles, con el fin de reconocer nuevas tendencias y evaluar la efectividad de las tecnologías utilizadas. La metodología empleada consiste en la búsqueda y análisis completo de cada uno de los artículos científicos a partir de fuentes de literatura académica tanto como de Web of science y Scopus, en la selección de estos artículos se han utilizado palabras clave relacionadas con plantas frutales, aplicaciones móviles, deep learning, salud y diagnóstico, siguiendo las reglas de inclusión y exclusión establecidas, considerando que se trata de artículos de RSL o congresos y de acceso abierto, para posteriormente analizar, comparando diferentes aproximaciones de artículos que utilizaron diversos modelos de deep learning como RestNet50, VGG16 y otros modelos pre-entrenados que consiguen un alto nivel de precisión en la captura de imágenes a través de dispositivos móviles. Esta RSL analizó el uso de herramientas innovadoras como el Deep learning que sistematizan el conocimiento en esta área, optimizando la producción de cultivos y reduciendo pérdidas significativas, lo que es crucial para futuras investigaciones.

Palabras Clave—Plantas frutales, Aprendizaje profundo, Diagnóstico de Salud.

I. INTRODUCCIÓN

El aprendizaje profundo es una tecnología que evidenció un gran potencial, cambiando y mejorando distintos sectores, uno de ellos el sector agrícola, importante en salvaguardar la seguridad alimentaria [3]. Se determinó que actualmente el posible diagnóstico temprano de la salud de plantas frutales viene siendo un desafío en la agricultura; por ello se automatizó este

proceso para llevar un mejor control de las enfermedades evitando la pérdida de los cultivos agrícolas [4]. Este diagnóstico se basó en el análisis de diversos modelos de Deep learning, que con ayuda del procesamiento de imágenes de las hojas de plantas se determinaron de manera temprana las enfermedades y la gravedad en estos cultivos [5].

No obstante, pese a que el aprendizaje profundo ha sido de gran aporte en la evolución de la agricultura, varios agricultores siguen llevando a cabo este proceso de manera manual, haciendo un recorrido visual por los campos, aplicando grandes cantidades de pesticidas u otras operaciones que pueden ser muy costosas y en ocasiones con resultados lentos y con errores, generando un impacto negativo en el ambiente [6, 7]. Ante esto, se buscó tener soluciones tecnológicas eficientes, haciendo uso del Deep learning para automatizar el diagnóstico de la salud de plantas frutales [8].

Con relación a esto, se llevó a cabo una RSL, donde se analizaron diversos modelos de aprendizaje profundo para un diagnóstico preciso. Si bien es cierto, existen modelos ya entrenados, uno de ellos el modelo de red neuronal VGG16, demostrando tener un camino claro en la detección de la enfermedad [9]; también el modelo VGG19 que detectó nueve enfermedades en las hojas del tomate [10]. Además, existen varios aplicativos móviles basados en inteligencia artificial; uno de ellos es "Plantix" que demostró ser una de las más prometedoras dentro de este campo, llevando sus resultados a un ambiente real [11]. Todas estas herramientas permiten que la agricultura adopte soluciones avanzadas para el tratamiento de sus cultivos con mayor eficiencia, demostrando que se haga una clasificación eficaz y determinante de las enfermedades en plantas frutales [12]. La gran cantidad de información desperdigada permitió realizar un análisis que tuvo como propósito comparar resultados obtenidos en estos estudios científicos posterior a una implementación del Deep learning.

El propósito de esta revisión metódica de literatura fue llevar a cabo un estudio sobre perspectivas apoyadas en Deep learning que demuestren ser eficaces en el diagnóstico de la salud de plantas frutales. Además, estos modelos han demostrado ser de gran ayuda para los agricultores, ya que plantean de manera innovadora algunos de los retos existentes en el diagnóstico de enfermedades o plagas en las plantas, ofreciendo un buen rendimiento y precisión [13]. Centrándose también en modelos de Deep learning ya introducidos en aplicativos móviles, siendo este un roce más fácil con la IA para muchos agricultores [14]. Por ello, también se buscó establecer los desafíos actuales que presentaron cada una de estas investigaciones y a partir de ello se propuso posibles soluciones futuras que mejoren la accesibilidad de estas tecnologías en la agricultura.

En este aspecto, el documento se estructuró de la siguiente forma: Parte 2, donde se describió la metodología que se llevará a cabo para realizar esta RSL, que abarca la selección de los artículos y exploración de datos recopilados. Parte 3, se dieron a conocer los resultados obtenidos del análisis de los estudios revisados. Parte 4, aquí se llevó a cabo la discusión de los hallazgos más importantes y de relevancia, abordando tanto las ventajas como las limitaciones de los métodos empleados. Por último, en la parte 5 se brindaron las conclusiones, las cuales resumen cada uno de los puntos descritos en el estudio, proporcionando las recomendaciones para futuros estudios e interesados en el implemento de tecnologías que se basan en el aprendizaje profundo para el diagnóstico de la salud de plantas.

II. METODOLOGIA

En esta investigación, se elaboró una revisión metódica de literatura con la finalidad de analizar el uso del Deep learning en el diagnóstico de la salud de plantas frutales. La metodología se proyectó siguiendo una guía integral y transparente para instaurar preguntas de investigación, reconocer las fuentes más relevantes, determinar los criterios tanto de inclusión como de exclusión y así esquematizar y sintetizar la información que se dispone en función de las palabras clave características de repositorios académicos pertinentes. [15]. La motivación para esta revisión sistemática fue reconocer las nuevas brechas de conocimiento y plantear modernos ámbitos de investigación en este campo y así mejorar la precisión en el diagnóstico de la salud de plantas [16]. Por ello se determinó una serie de pasos bien concretos que garantizan una revisión sistemática exhaustiva.

1. Selección de un repositorio de artículos científicos de prestigio
2. Desarrollo de una búsqueda exhaustiva a partir de palabras clave
3. Definición de las preguntas PICOC
4. Establecimiento de los criterios de exclusión e inclusión
5. Recopilación y análisis de los artículos obtenidos

Para la búsqueda exhaustiva de los artículos de investigación, Scopus y Web of Science han sido las bases de datos utilizadas. A continuación, se exponen los términos clave empleados.

TABLA I. TERMINOS DE BUSQUEDA

Plantas Frutales	Diagnóstico	Aprendizaje profundo
Aplicativo Móvil	Salud	Enfermedades
Agricultura	Plagas	IA

A. Delimitación de las interrogantes de investigación

Para formular la pregunta principal de la presente investigación se usó el modelo PICOC, donde se desglosaron cada uno de los componentes importantes de esta revisión sistemática.

TABLA II. PREGUNTAS DE INVESTIGACIÓN

Preguntas		
PRINCIPAL	¿Cómo el uso del Deep learning en aplicativos móviles mejora el diagnóstico de salud en plantas frutales, en el marco de tecnologías avanzadas en el sector agrícola?	
P	Población/problema	¿Qué enfermedades y factores son los más habituales que afectan la salud de las plantas frutales?
I	Intervención	¿De qué manera se implementa Deep Learning en aplicativos móviles para diagnosticar la salud en plantas frutales?
C	Comparación	¿Qué ventajas tiene deep learning frente a los métodos tradicionales en el sector agrícola?
O	Resultados	¿Qué impacto tiene deep learning en el diagnóstico de salud de plantas frutales?
C	Contexto	¿Cómo pueden estas tecnologías beneficiar a la agricultura en el diagnóstico de salud de plantas frutales?

A partir de las preguntas PICOC realizadas se hizo la selección de las palabras clave, las cuales han sido aplicadas en la siguiente ecuación de búsqueda:

TITLE ("Fruit plants" OR "fruit crops" OR leaves OR species OR "plant health" OR pests OR pathogens OR "agriculture" OR "crop diseases" OR "farming") AND TITLE-ABS-KEY ("artificial intelligence" OR "deep learning" OR "convolutional neural networks" OR "machine learning" OR "computer vision" OR "image classification" OR "image recognition" OR "plant image scanning" OR "mobile applications for agriculture" OR "diagnostic tools for plants" OR "plant pathology") AND ABS ("Traditional methods" OR "manual plant diagnostics" OR "visual inspection of plants" OR "conventional plant health techniques" OR "non-automated tools in agriculture" OR "comparison with AI in plant diagnostics" OR metrics OR accuracy OR scalability OR cost) AND ABS ("Plant diagnostics" OR "rapid detection in agriculture" OR "error reduction in plant health" OR "plant health monitoring" OR prediction OR "crop management" OR performance OR "pest prevention in crops" OR "agricultural loss reduction" OR "real-time evaluation in agriculture") AND TITLE-ABS-KEY ("Agricultural sector" OR agriculture OR innovation OR "advanced technologies in agriculture" OR "plant diagnostic system" OR "crop monitoring" OR "plant health" OR sustainability OR "food security").

B. Estándares de exclusión e inclusión

Durante la elección de los artículos recopilados se definieron algunos criterios tanto de inclusión como de exclusión para garantizar que se realizó una búsqueda relevante y de calidad.

TABLA III. CRITERIOS

Criterios de inclusión y exclusión	
INCLUSIVOS	EXCLUSIVOS
CI1: Los estudios incluidos deben abordar el diagnóstico de problemas de salud en plantas frutales, incluyendo enfermedades y plagas en plantas frutales.	CE1: Estudios que no incluyan específicamente plantas frutales o que se enfoquen directamente en un cultivo.
CI2: Los estudios deben aplicar o describir métodos basados en aprendizaje profundo para el pronóstico de afecciones en plantas frutales.	CE2: Estudios desarrollados en laboratorios simulados, que no estén relacionados con entornos reales de agricultura.
CI3: Los estudios deben incluir el uso de aplicativos móviles como parte integral de la solución o plataforma utilizada en el diagnóstico.	CE3: Estudios que no utilicen técnicas de aprendizaje profundo o IA
CI4: Los estudios deben reportar resultados cuantitativos que evalúen la precisión o efectividad de los métodos de diagnóstico.	CE4: Estudios que se centren en soluciones tecnológicas no móviles, como el uso de drones u otras plataformas.
CI4: Los estudios deben estar publicados entre los años 2018 y 2024.	CE5: Publicaciones anteriores a 2018, que puedan no reflejar el estado actual del uso de Deep Learning en agricultura.

C. Proceso de selección de estudios

Al culminar el proceso de búsqueda y recopilación de artículos, se siguieron los lineamientos establecidos por PRISMA, donde se organizaron los datos de la información seleccionada [15], llegando a recopilar 135 artículos establecidos en un intervalo del 2019 a 2024.

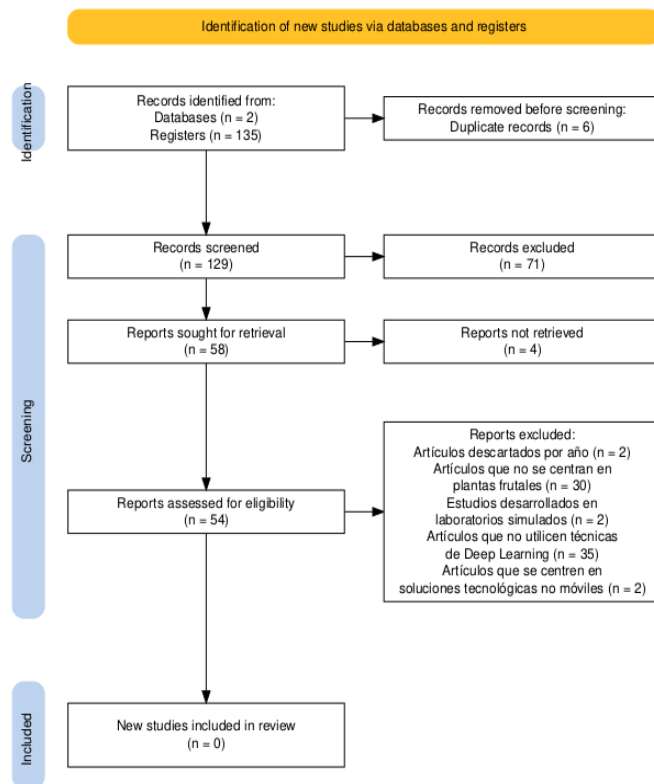


Fig. 1. Flujoograma PRISMA

III. RESULTADOS

1. Resultados bibliométricos

En este apartado se dan a conocer los artículos seleccionados que se usaron en esta revisión sistemática, donde para cada investigación se mostrará su información más sobresaliente, como lo es el año en el que se publicó, el país, su sector de aplicación y las herramientas que han implementado en el estudio. Los artículos contienen grandes investigaciones con respecto al uso del Deep Learning en el sector agrícola, demostrando su eficiencia y eficacia en este sector. Esta revisión sistemática será de gran aporte en el uso de nuevas tecnologías dentro del sector agrícola, ayudando a detectar y clasificar con mayor precisión las enfermedades u otros factores en las plantas frutales [17].

TABLA IV. ARTICULOS RELEVANTES

Artículo	Año	País	Sector de aplicación	Herramienta(s) Implementada(s)
[18]	2022	Italia	Agriculture	PlantVillage Nuru
[19]	2024	China	Agriculture	AI GrapeCare
[20]	2023	USA	Agricultura	ResNet-50
[21]	2022	China	Agricultura	Deep Learning, YOLOv5, Metric Learning
[22]	2022	Bangladés	Agriculture	Deep Neural Architecture
[23]	2022	USA	Agriculture	Self-supervised Learning, Convolutional Neural Networks
[24]	2022	Italia	Agriculture	Deep Learning Generative Model Approach
[25]	2024	India	Agriculture	EfficientNet's Transfer Learning Approach
[26]	2023	India	Agriculture	Multi-Instance Learning Approach for Pest Detection
[27]	2022	China	Agriculture	Red neuronal YOLO V5-CAcT
[28]	2022	China	Agricultura	Transfer Learning, Feature Fusion
[29]	2021	China	Agricultura	SCrop, Internet-of-Agro-Things, Convolutional Neural Network (CNN)
[30]	2021	Suiza	Agriculture	Deep Neural Networks
[31]	2022	China	Agriculture / Plant Science	Residual Neural Networks
[32]	2024	India	Agriculture / Plant Science	IoT, Deep Learning
[33]	2022	India	Agriculture / Plant Science	Hybrid Convolutional Neural Network
[34]	2019	China	Agriculture / Plant Science	Graph-Related High-Order Neural Network
[35]	2021	China	Agriculture / Plant Science	Convolutional Neural Networks
[36]	2023	Arabia Saudita	Agriculture	EfficientNetV2S
[37]	2021	Suiza	Agricultura	AgriPest, conjunto de datos para detección de plagas
[38]	2021	Mexico	Agriculture	Deep Learning, CNN, NRBVI, NGBVI
[39]	2023	China	Agriculture	YOLOv7, Adam optimizer
[40]	2023	China	Agriculture	Deep Learning, DBCLNet
[41]	2023	Bélgica	Agriculture	GoogLeNet
[42]	2024	Corea del Sur	Agriculture	GPT-4
[43]	2023	India	Agricultura	CNN
[44]	2020	India	Agricultura	Conjunto de datos PlantDoc

La figura 2 reflejó la cantidad de artículos encontrados según su año de publicación, donde se incluyó un total de 54 artículos publicados entre 2019 a 2024 relacionados con el diagnóstico de la salud de plantas frutales mediante Deep learning registrándose un aumento significativo desde 2020 hasta 2024, donde se

puede observar un interés más creciente en el uso del Deep learning en la industria agrícola, resaltando su importancia y potencial.

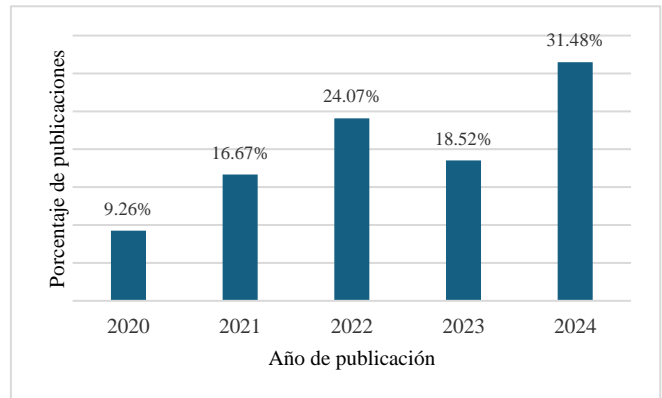


Fig. 2. Cantidad de artículos por año

En cuanto a la figura 3, esta gráfica respalda que las investigaciones relacionadas con la implementación de Deep learning para evaluar la salud de las plantas frutales están en constante crecimiento a nivel global, donde se mostró una gran concentración de investigaciones en países de Asia y Oceanía en los últimos 5 años, predominando India con 17 investigaciones [3] [4] [5] [8] [10] [13] [16] [18] [25] [26] [32] [33] [43] [44] [47] [53] [54] y China con 11, siendo los mayores aportantes. Esto sugiere un interés creciente en el uso de tecnologías avanzadas en la agricultura dentro de estas regiones.

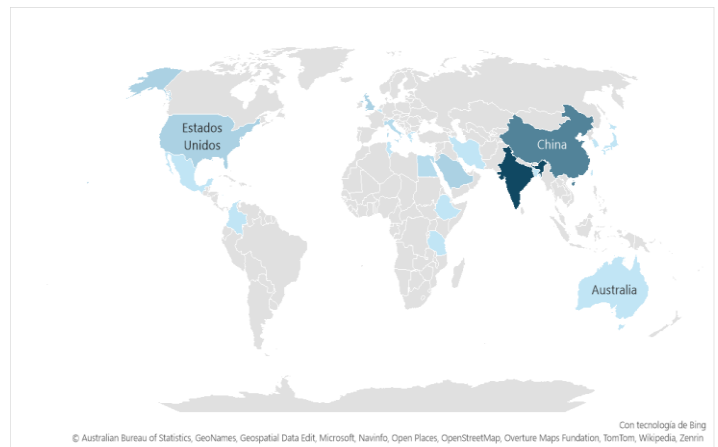


Fig. 3. Cantidad de artículos por país

La figura 4 dio a conocer cómo los artículos seleccionados se encuentran distribuidos en una variedad de editoriales, donde IEE es la editorial con la mayor cantidad de publicaciones en esta área, teniendo un total de 11 artículos, lo cual evidencia su fuerte enfoque en la innovación y tecnología, seguidos de MDPI y Elsevier, que también se presentan de manera elevada con 9 [11]

[19] [20] [31] [33] [37] [38] [48] [53] y 8 [1] [2] [3] [7] [28] [47] [51] [54] artículos.

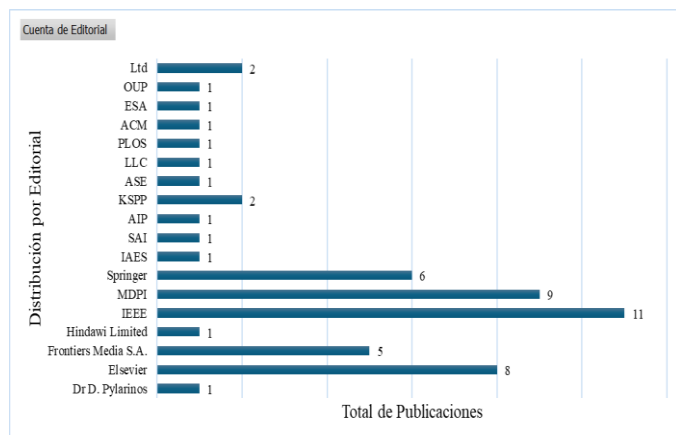


Fig. 4. Cantidad de artículos según su editorial

2. Resultados extraídos de las RSL seleccionadas

La figura 5 demostró que un 41% de los artículos analizados utilizaron Redes Neuronales Convolucionales (CNN), siendo el método más aplicado, lo que refleja su amplia aplicación y efectividad en el análisis de imágenes para identificar enfermedades y plagas en plantas [45]. Seguido del Aprendizaje por Transferencia con un 20%, métodos como el conjunto de datos y el procesamiento en tiempo real abarcan un 11% y 9%, respectivamente, mientras que la segmentación de imágenes y el aprendizaje híbrido alcanzan un 6% y 4%. Otros métodos abarcan un 9%, reflejando la diversidad en las estrategias utilizadas.

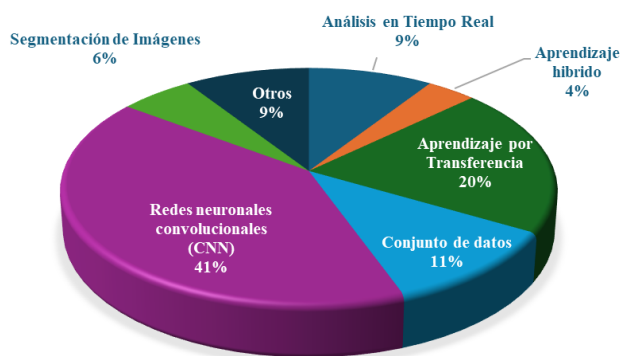


Fig. 5. Método de implementación de DL

La tabla V evidenció las principales arquitecturas de Deep learning para el diagnóstico de la salud de plantas frutales mediante aplicaciones móviles, donde las CNN en general fueron las arquitecturas más usadas, con un 17% de artículos analizados, las cuales fueron muy efectivas para detectar enfermedades en plantas,

mientras que un 11% de los artículos aplicaron la arquitectura YOLO. Este modelo resultó ser muy eficaz, ya que tiene la capacidad de detectar objetos en tiempo real [46].

TABLA V. ARQUITECTURAS DL APLICADAS SEGÚN LAS RSL

Arquitecturas de diagnóstico	Porcentaje	Autores
Redes neuronales convolucionales	17%	[5] [8] [13] [17] [29] [43] [45] [53]
YOLO	11%	[21] [27] [32] [39] [44]
VGG16	9%	[9] [15] [19] [46]
Redes neuronales convolucionales profundas	9%	[6] [30] [47] [48]
ResNet	9%	[2] [12] [14] [46]
VGG19	7%	[10] [46] [49]
GoogleNet	7%	[14] [41] [49]
EfficientNet	7%	[25] [33] [36]
AlexNet	7%	[3] [14] [49]
InceptionV3	7%	[14] [15] [49]
MobileNet	4%	[22] [54]
L2L	2%	[24]
GPT-4	2%	[42]
DBCLNet	2%	[40]
DenseNet	2%	[4]

Estos resultados reflejaron que las arquitecturas más usadas fueron las CNN, YOLO, CNNs, VGG16 y ResNet, lo que hace una notable preferencia por arquitecturas que ayuden a que el diagnóstico de salud de plantas sea más preciso [47]. Por otro lado, las arquitecturas restantes se emplean en una cantidad reducida de publicaciones; no obstante, estas arquitecturas también mostraron resultados satisfactorios, demostrando ser eficientes en cada uno de estos artículos.

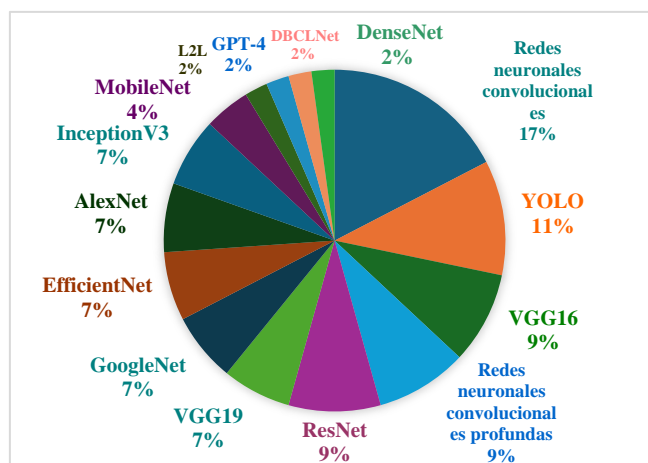


Fig. 6. Arquitecturas DL

En la figura 7 se analizaron artículos en función a su contexto de aplicación más común en el uso de DL en la agricultura, siendo el diagnóstico de enfermedades el ámbito más común donde se aplican estas tecnologías, lo

cual sugirió un impacto potencial del Deep learning en áreas donde los agricultores enfrentan distintos desafíos para salvaguardar la salud de las plantas [48]. La implementación de DL en este ámbito no solo mejora la precisión, sino también facilita una detección oportuna de la enfermedad [49].

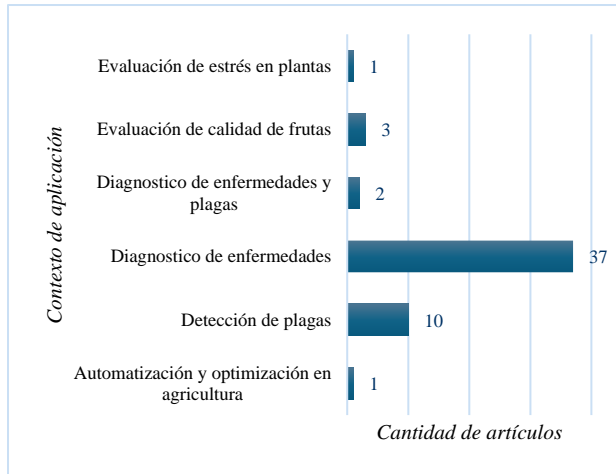


Fig. 7. Artículos según su contexto de aplicación más común de DL

La figura 8 evaluó aquellos artículos que desarrollaron o mencionaron el uso de una app móvil para el diagnóstico de la salud de plantas. En su mayoría, 44 estudios no indicaron haber usado o desarrollado un aplicativo móvil. Sin embargo, se demostró que los modelos de DL aplicados en cada uno de estos estudios podrían integrarse fácilmente en un aplicativo móvil, lo que sería beneficioso para hacerlos accesibles para todos, especialmente para el sector agrícola [50]. Estos resultados revelaron un bajo número de aplicaciones desarrolladas o usadas, donde solo 5 estudios desarrollaron una app, mientras que los estudios [3], [15], [18], [19], [42], usaron apps ya existentes.

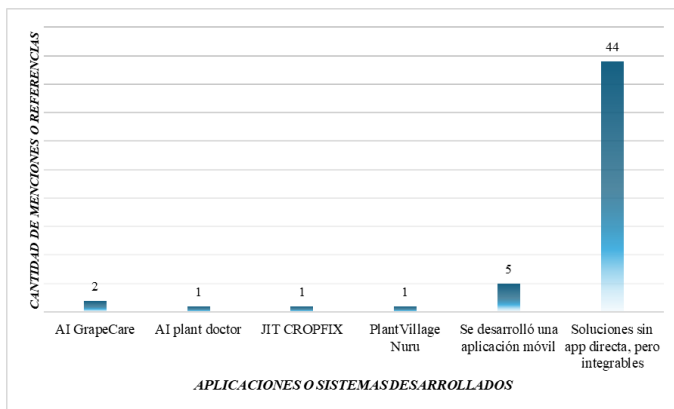


Fig. 8. Artículos que han desarrollado o hacen uso de una app móvil

Con respecto a la figura 9, se mostraron los factores y tipos de enfermedades más comunes que afectan a la

salud de plantas frutales, donde destacaron las enfermedades causadas por hongos con un 30.56% presente en 30 artículos [3] [4] [5] [8] [9] [12] [14] [16] [17] [20] [22] [23] [24] [26] [27] [29] [30] [31] [34] [35] [36] [38] [40] [43] [44] [45] [47] [51] [53] [54], lo cual sugirió que es uno de los mayores desafíos para la salud de las plantas frutales, seguido de las plagas, que resultó ser un factor de gran impacto en la producción frutal [51] y, por último, los virus y enfermedades microbianas que no solo afectan la salud de las plantas, sino que, además, impactan en el desempeño y calidad de la cosecha [52].

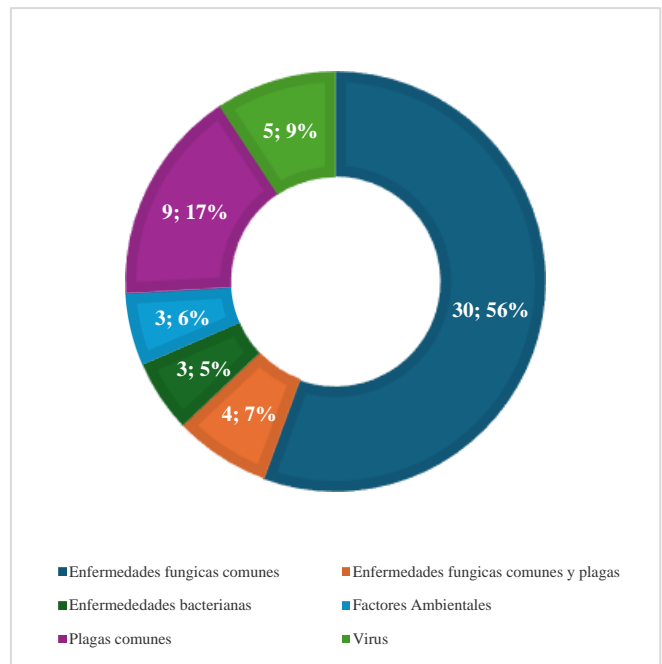


Fig. 9. Enfermedad y factor más común en la salud de plantas

IV. DISCUSIONES

En esta sección se llevó a cabo el estudio de los resultados derivados de los gráficos mostrados anteriormente, con la finalidad de interpretar y discutir los hallazgos de manera detallada.

Durante esta revisión metódica, se pudo obtener datos sobre la cantidad de artículos que aplicaron Deep learning para el diagnóstico de salud de plantas según su año de publicación, donde se mostró una gran diferencia que abarca desde el 2020 a 2024. Así mismo, se identificó que el uso de Deep Learning en el ámbito agrícola empezó con un 9.96% en el 2020, en comparación con el año 2024, que denotó un crecimiento en publicaciones con un 31.48%, donde 17 artículos [1], [2], [6], [7], [8], [9], [10], [11], [12], [13], [15], [19], [25], [32], [42], [52], [53] implementaron el

uso de Deep learning más avanzado para un diagnóstico preciso de la salud de plantas frutales.

Del mismo modo, en la figura 3 se analizaron los resultados sobre la distribución geográfica del uso de Deep learning en la agricultura. Entre 2020 y 2024 se notó un crecimiento en la cantidad de investigaciones publicadas, destacándose países como China e India. China registró una concentración de 11 publicaciones [2], [19], [21], [27], [28], [29], [31], [34], [35], [39], [40] relevantes en este campo, a diferencia de lo reportado en India, que lideró con un total de 17 publicaciones [3], [4], [5], [8], [10], [13], [16], [18], [25], [26], [32], [33], [43], [44], [47], [53], [54], evidenciando un mayor interés y compromiso con el avance de la tecnología agrícola.

Así mismo, se analizó el uso de diversas arquitecturas de Deep learning en el diagnóstico de la salud de plantas, destacando que la mayoría de los estudios optaron por entrenar una red neuronal convolucional propia, liderando con un 17% de preferencia y estando presente en 8 artículos [5], [8], [13], [17], [29], [43], [45], [53], resaltando por su efectividad para identificar enfermedades en plantas, en comparación con otros modelos como YOLO, el cual fue aplicado en un 11%, estando presente en 5 artículos [21], [27], [32], [39], [44], reconocido por su velocidad en la detección de objetos, siendo beneficioso para integrarse en apps móviles y predecir la afección en tiempo real, por el contrario VGG16 no se aplicó en gran cantidad debido a que requiere una mayor potencia para su integración, sin embargo resultó ser uno de los modelos que ofrece mayor precisión en el diagnóstico aplicándose en 4 estudios [9], [15], [19], [46], por otro lado, las tecnologías restantes como MobileNet, DenseNet se aplicaron en menor cantidad con un 4% y 2% respectivamente, debido a que son poco común, sin embargo ofrece una precisión alta a comparación de los modelos ya mencionados con anterioridad.

De igual forma, en la figura 7 se observó que la mayoría de los artículos enfocan el uso del Deep learning en el diagnóstico de enfermedades de plantas, representado por un 77%, lo cual sugiere que la aplicación de estas tecnologías avanzadas es debido a su gran impacto en la productividad agrícola, evitando que sea una amenaza para la seguridad alimentaria [53]. Otros contextos de aplicación menos comunes, pero de importancia, incluyeron la detección de plagas con 18.52% y la evaluación de la calidad de frutas con 5.56%; la baja cantidad de estudios en estas áreas se debe a que no requieren de mucha atención o están en etapas iniciales de desarrollo.

La evaluación de la figura 8 dio a conocer aquellos artículos que desarrollaron o mencionaron el uso de una app móvil para el diagnóstico de la salud de plantas, demostrando que 44 artículos no desarrollaron o usaron aplicaciones móviles. Aunque los modelos de DL presentados en dichos estudios sean fácilmente integrables en estas plataformas, evidencian un potencial desaprovechado en comparación con los estudios [2], [10], [11], [29]. Los cuales, sí desarrollaron un aplicativo móvil, señalando un avance significativo de estas tecnologías; no obstante, reflejan una iniciativa limitada frente al volumen total de investigaciones en esta área.

En la figura 9 se analizó el factor y enfermedad más común que afecta a la salud de las plantas, destacando los hongos con un 30.56% en 30 de los estudios [3] [4] [5] [8] [9] [12] [14] [16] [17] [20] [22] [23] [24] [26] [27] [29] [30] [31] [34] [35] [36] [38] [40] [43] [44] [45] [47] [51] [53] [54]. Este dato refuerza la importancia de los hongos como uno de los principales desafíos en la agricultura, debido a su notable influencia en la productividad y calidad de los cultivos frutales [54]. A diferencia de las plagas, con un 9.17% en 9 estudios [6], [26], [30], [32], [37], [39], [46], [48], [49], muestran una menor incidencia, debido al limitado uso de Deep Learning en su diagnóstico. Por último, los virus representaron el 5.9%, siendo menos comunes pero relevantes por su rápida propagación y los retos en su diagnóstico temprano.

Para finalizar la discusión, se destaca el potencial de Deep Learning como una herramienta prometedora para el diagnóstico de la salud de plantas frutales, optimizando la productividad agrícola y minimizando las pérdidas causadas por enfermedades. Se sugiere que futuras investigaciones se centren en la mejora de modelos para su integración en dispositivos móviles y en la ampliación del uso de estas tecnologías a áreas menos exploradas, como el diagnóstico de plagas y virus, contribuyendo así a un sector agrícola más eficiente, sostenible y resiliente.

V. CONCLUSION

Esta investigación evaluó el uso de modelos de Deep Learning en el diagnóstico de la salud de plantas frutales, con énfasis en su implementación en aplicaciones móviles para optimizar la detección de enfermedades y plagas. Tras revisar diversos estudios sobre la aplicación de Deep Learning en el sector agrícola, se concluye que las Redes neuronales convolucionales (CNN) son las más eficientes para este tipo de diagnóstico, destacándose modelos como MobileNet, que ofrece un equilibrio entre precisión y

eficiencia computacional, permitiendo su integración efectiva en aplicaciones móviles. Esta característica es crucial, ya que los dispositivos móviles requieren modelos ligeros que puedan ejecutarse en tiempo real sin comprometer la calidad del diagnóstico.

Dentro de los métodos más eficientes para el diagnóstico, se destacaron las redes neuronales convolucionales (CNN), que constituyeron un enfoque esencial dentro del Deep Learning. Este sobresalió debido a su capacidad para aprender de grandes volúmenes de datos y generar diagnósticos más precisos. Su implementación en dispositivos móviles es cada vez más viable gracias a la optimización de modelos ligeros, que permiten la integración en aplicaciones con una baja carga computacional.

En cuanto a las técnicas utilizadas, se observaron modelos como YOLO y EfficientNet, que demostraron ser efectivos en el diagnóstico de la salud de las plantas. YOLO sobresalió por su velocidad en la detección de objetos, mientras que EfficientNet destacó por su capacidad para equilibrar precisión y eficiencia computacional. No obstante, MobileNet se perfiló como la técnica más adecuada para aplicaciones móviles debido a su bajo requerimiento de recursos computacionales y su capacidad para ofrecer resultados precisos en entornos móviles.

Finalmente, se recomienda que futuras investigaciones continúen con la optimización de modelos para aplicaciones móviles, asegurando que sean ligeros, rápidos y precisos. Además, se debe ampliar el uso de estas tecnologías para incluir la detección de plagas y enfermedades virales, que aún presentan retos importantes y menos investigación en el campo. De esta forma, se podrían desarrollar aplicaciones más completas que no solo mejoren el diagnóstico de enfermedades fúngicas y bacterianas, sino que también aborden todos los aspectos que afectan la salud de las plantas frutales, lo que contribuiría a una agricultura más sostenible y eficiente.

REFERENCIAS

[1] M. Rezaei, D. Diepeveen, H. Laga, M. G. K. Jones, and F. Sohel, "Plant disease recognition in a low data scenario using few-shot learning," *Computers and Electronics in Agriculture*, vol. 219, p. 108812, Apr. 2024, doi: 10.1016/j.compag.2024.108812.

[2] M. Yang, A. Sekhari Seklouli, L. Ren, Y. He, X. Yu, and Y. Ouzrout, "A new mobile diagnosis system for estimation of crop disease severity using deep transfer learning," *Crop Protection*, vol. 184, 2024, doi: 10.1016/j.cropro.2024.106776.

[3] U. Sanath Rao et al., "Deep Learning Precision Farming: Grapes and Mango Leaf Disease Detection by Transfer Learning," *Global Transitions Proceedings*, vol. 2, no. 2, pp. 535–544, Nov. 2021, doi: 10.1016/j.gltp.2021.08.002.

[4] P. Kartikeyan and G. Shrivastava, "Impact Evaluation of Deep Learning Models in the Context of Plant Disease Detection," vol. 288. 2022. doi: 10.1007/978-981-16-5120-5_40.

[5] R. N. Jogeekar and N. Tiwari, "A Review of Deep Learning Techniques for Identification and Diagnosis of Plant Leaf Disease," vol. 182. 2021. doi: 10.1007/978-981-15-5224-3_43.

[6] D. J. Leybourne, N. Musa, and P. Yang, "Can artificial intelligence be integrated into pest monitoring schemes to help achieve sustainable agriculture? An entomological, management and computational perspective," *Agricultural and Forest Entomology*, 2024, doi: 10.1111/afe.12630.

[7] S. M. Javidan, A. Banakar, K. Rahnema, K. A. Vakilian, and Y. Ampatzidis, "Feature engineering to identify plant diseases using image processing and artificial intelligence: A comprehensive review," *Smart Agricultural Technology*, vol. 8, p. 100480, Aug. 2024, doi: 10.1016/j.atech.2024.100480.

[8] V. Gautam, R. K. Ranjan, P. Dahiya, and A. Kumar, "ESDNN: A novel ensemble stack deep neural network for mango leaf disease classification and detection," *Multimedia Tools and Applications*, vol. 83, no. 4, pp. 10989–11015, Jan. 2024, doi: 10.1007/s11042-023-16012-6.

[9] A. A. Alatawi, S. M. Alomani, N. I. Alhawiti, and M. Ayaz, "Plant Disease Detection using AI based VGG-16 Model," *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 4, pp. 718–727, 2022, doi: 10.14569/IJACSA.2022.0130484.

[10] A. Yadav, J. Ramaprabha, and G. K. Sandhia, "Tomato Leaf Disease Detection using Convolution Neural Network and VGG19," in *AIP Conference Proceedings*, 2024. doi: 10.1063/5.0217177.

[11] P. Christakakis et al., "Smartphone-Based Citizen Science Tool for Plant Disease and Insect Pest Detection Using Artificial Intelligence," *Technologies*, vol. 12, no. 7, 2024, doi: 10.3390/technologies12070101.

[12] B. Tej et al., "AI-based smart agriculture 4.0 system for plant diseases detection in Tunisia," *Signal, Image and Video Processing*, vol. 18, Suppl. 1, 2024, pp. 97–111, doi: 10.1007/s11760-024-03134-z.

[13] P. Chaudhary, A. Verma, V. Kukreja, and R. Sharma, "Integrating Deep Learning and Ensemble Methods for Robust Tomato Disease Detection: A Hybrid CNN-RF Model Analysis," Mar. 2024, doi: 10.1109/icrito61523.2024.10522213.

[14] M. Adi et al., "An Overview on Plant Disease Detection Algorithm Using Deep Learning," 2021 2nd International Conference on Intelligent Engineering and Management (ICIEM), Apr. 2021, doi: 10.1109/iciem51511.2021.9445336.

[15] M. G. F. Odounfa, C. D. S. J. Gbemavo, S. P. G. Tahi, and R. L. Glèlè Kakaï, "Deep learning methods for enhanced stress and pest management in market garden crops: A comprehensive analysis," *Smart Agricultural Technology*, vol. 9, p. 100521, Dec. 2024, doi: 10.1016/j.atech.2024.100521.

[16] S. Vijh et al., "USMA-BOF: A Novel Bag-of-Features Algorithm for Classification of Infected Plant Leaf Images in Precision Agriculture," *IEEE Robotics and Automation Magazine*, vol. 30, no. 4, pp. 30–40, 2023, doi: 10.1109/MRA.2023.3315929.

[17] W. B. Demilie, "Plant disease detection and classification techniques: a comparative study of the performances," *Journal of Big Data*, vol. 11, no. 1, p. 5, Jan. 2024, doi: 10.1186/s40537-023-00863-9.

[18] A. Coletta, N. Bartolini, G. Maselli, A. Kehs, P. McCloskey, and D. P. Hughes, "Optimal Deployment in Crowdsensing for Plant Disease Diagnosis in Developing Countries," *IEEE Internet of Things Journal*, vol. 9, no. 9, pp. 6359–6373, May 2022, doi: 10.1109/JIOT.2020.3002332.

[19] O. Elsherbiny, A. Elaraby, M. Alahmadi, M. Hamdan, and J. Gao, "Rapid Grapevine Health Diagnosis Based on Digital Imaging and Deep Learning," *Plants*, vol. 13, no. 1, p. 135, Jan. 2024, doi: 10.3390/plants13010135.

[20] M. O. Ojo and A. Zahid, "Improving Deep Learning Classifiers Performance via Preprocessing and Class Imbalance Approaches in a Plant Disease Detection Pipeline," *Agronomy*, vol. 13, no. 3, p. 887, Mar. 2023, doi: 10.3390/agronomy13030887.

[21] Y. Peng and Y. Wang, "Leaf disease image retrieval with object detection and deep metric learning," *Frontiers in Plant Science*, vol. 13, 2022, doi: 10.3389/fpls.2022.963302.

[22] S. Ahmed, M. B. Hasan, T. Ahmed, M. R. K. Sony, and M. H. Kabir, "Less is More: Lighter and Faster Deep Neural Architecture for Tomato Leaf Disease Classification," *IEEE Access*, vol. 10, pp. 68868–68884, 2022, doi: 10.1109/ACCESS.2022.3187203.

- [23] A. Siddique, A. Tabb, and H. Medeiros, "Self-Supervised Learning for Panoptic Segmentation of Multiple Fruit Flower Species," *IEEE Robotics and Automation Letters*, vol. 7, no. 4, pp. 12387–12394, 2022, doi: 10.1109/LRA.2022.3217000.
- [24] A. Benfenati, D. Bolzi, P. Causin, and R. Oberti, "A deep learning generative model approach for image synthesis of plant leaves," *PLOS ONE*, vol. 17, 2022, doi: 10.1371/journal.pone.0276972.
- [25] P. Buchke and A. V. R. Mayuri, "Recognize and classify illnesses on tomato leaves using EfficientNet's transfer learning approach with different size dataset," *Signal, Image and Video Processing*, vol. 18, pp. 731-746, 2024, doi: 10.1007/s11760-024-03188-z.
- [26] L. Chand, A. S. Dhiman, and S. Singh, "A multi-instance learning based approach for whitefly pest detection," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 31, pp. 1050-1060, 2023, doi: 10.11591/ijeecs.v31.i2.pp1050-1060.
- [27] G. Dai and J. Fan, "An Industrial-Grade Solution for Crop Disease Image Detection Tasks," *Frontiers in Plant Science*, vol. 13, 2022, doi: 10.3389/fpls.2022.921057.
- [28] X. Fan, P. Luo, Y. Mu, R. Zhou, T. Tjahjadi, and Y. Ren, "Leaf image based plant disease identification using transfer learning and feature fusion," *Computers and Electronics in Agriculture*, vol. 196, 2022, doi: 10.1016/j.compag.2022.106892.
- [29] V. Udutalappally, S. P. Mohanty, V. Pallagani, and V. Khandelwal, "SCrop: A Novel Device for Sustainable Automatic Disease Prediction, Crop Selection, and Irrigation in Internet-of-Agro-Things for Smart Agriculture," *IEEE Sensors Journal*, vol. 21, no. 16, pp. 17525–17538, 2021, doi: 10.1109/JSEN.2020.3032438.
- [30] M. Grünig, E. Razavi, P. Calanca, D. Mazzi, J. D. Wegner, and L. Pellissier, "Applying deep neural networks to predict incidence and phenology of plant pests and diseases," *Ecosphere*, vol. 12, 2021, doi: 10.1002/ecs2.3791.
- [31] P. S. Kanda, K. Xia, A. Kyslytysna, and E. O. Owoola, "Tomato Leaf Disease Recognition on Leaf Images Based on Fine-Tuned Residual Neural Networks," *Plants*, vol. 11, 2022, doi: 10.3390/plants11212935.
- [32] A. B. Kathole, K. N. Vhatkar, and S. D. Patil, "IoT-Enabled Pest Identification and Classification with New Meta-Heuristic-Based Deep Learning Framework," *Cybernetics and Systems*, vol. 55, pp. 380-408, 2024, doi: 10.1080/01969722.2022.2122001.
- [33] P. Kaur, S. Harnal, R. Tiwari, S. Upadhyay, S. Bhatia, A. Mashat, and A. M. Alabdali, "Recognition of Leaf Disease Using Hybrid Convolutional Neural Network by Applying Feature Reduction," *Sensors*, vol. 22, 2022, doi: 10.3390/s22020575.
- [34] J. Kong, C. Yang, Y. Xiao, S. Lin, K. Ma, and Q. Zhu, "A Graph-Related High-Order Neural Network Architecture via Feature Aggregation Enhancement for Identification Application of Diseases and Pests," *Journal of Electrical and Computer Engineering*, 2021, doi: 10.1155/2022/4391491.
- [35] Y. Li and X. Chao, "Toward Sustainability: Trade-Off Between Data Quality and Quantity in Crop Pest Recognition," *Frontiers in Plant Science*, vol. 12, 2021, doi: 10.3389/fpls.2021.811241.
- [36] M. H. Ashmafee, T. Ahmed, S. Ahmed, M. B. Hasan, M. N. Jahan, and A. B. M. Ashikur Rahman, "An Efficient Transfer Learning-based Approach for Apple Leaf Disease Classification," in *3rd International Conference on Electrical, Computer and Communication Engineering, ECCE 2023*, 2023, doi: 10.1109/ECCE57851.2023.10101542.
- [37] R. Wang, L. Liu, C. Xie, P. Yang, R. Li, and M. Zhou, "Agripest: A large-scale domain-specific benchmark dataset for practical agricultural pest detection in the wild," *Sensors*, vol. 21, no. 5, pp. 1–15, 2021, doi: 10.3390/s21051601.
- [38] A. Yee-Rendon, I. Torres-Pacheco, A. S. Trujillo-Lopez, K. P. Romero-Bringas, and J. R. Millan-Almaraz, "Analysis of new rgb vegetation indices for phyvv and tmv identification in jalapeño pepper (*Capsicum annuum*) leaves using cnns-based model," *Plants*, vol. 10, no. 10, 2021, doi: 10.3390/plants10101977.
- [39] C. Zhang, Z. Hu, L. Xu, and Y. Zhao, "A YOLOv7 incorporating the Adan optimizer based corn pests' identification method," *Frontiers in Plant Science*, vol. 14, 2023, doi: 10.3389/fpls.2023.1174556.
- [40] W. Zhang et al., "Dual-branch collaborative learning network for crop disease identification," *Frontiers in Plant Science*, vol. 14, 2023, doi: 10.3389/fpls.2023.1117478.
- [41] A. Tempelaere, L. van Doorselaer, J. He, P. Verboven, T. Tuytelaers, and B. Nicolai, "Deep Learning for Apple Fruit Quality Inspection using X-Ray Imaging," in *Proceedings - 2023 IEEE/CVF International Conference on Computer Vision Workshops, ICCVW 2023*, 2023, pp. 552–560, doi: 10.1109/ICCVW60793.2023.00062.
- [42] Y. Hue et al., "Artificial Intelligence Plant Doctor: Plant Disease Diagnosis Using GPT4-vision," *Research in Plant Disease*, vol. 30, no. 1, pp. 99–102, Mar. 2024, doi: 10.5423/RPD.2024.30.1.99.
- [43] G. Praveen, V. Dinesh Kumar, and K. Shishir, "Diagnosis of Plant Leaf Diseases Using Image Based Detection and Prediction Using Machine Learning Approach," *ECONOMIC COMPUTATION AND ECONOMIC CYBERNETICS STUDIES AND RESEARCH*, vol. 57, no. 4/2023, pp. 293–312, Dec. 2023, doi: 10.24818/18423264/57.4.23.18.
- [44] D. Singh, N. Jain, P. Jain, P. Kayal, S. Kumawat, and N. Batra, "PlantDoc: A dataset for visual plant disease detection," in *ACM International Conference Proceeding Series*, 2020, pp. 249–253, doi: 10.1145/3371158.3371196.
- [45] T. Akagi et al., "Explainable Deep Learning Reproduces a 'Professional Eye' on the Diagnosis of Internal Disorders in Persimmon Fruit," *Plant and Cell Physiology*, vol. 61, no. 11, pp. 1967–1973, Nov. 2020, doi: 10.1093/pcp/pcaa111.
- [46] X. Gong and S. Zhang, "An Analysis of Plant Diseases Identification Based on Deep Learning Methods," *Plant Pathology Journal*, vol. 39, no. 4, pp. 319–334, 2023, doi: 10.5423/PPJ.OA.02.2023.0034.
- [47] Nitin, S. B. Gupta, R. Yadav, F. Bovand, and P. K. Tyagi, "Developing precision agriculture using data augmentation framework for automatic identification of castor insect pests," *Frontiers in Plant Science*, vol. 14, 2023, doi: 10.3389/fpls.2023.1101943.
- [48] J. F. Restrepo-Arias, J. W. Branch-Bedoya, and G. Awad, "Plant Disease Detection Strategy Based on Image Texture and Bayesian Optimization with Small Neural Networks," *Agriculture*, vol. 12, no. 11, p. 1964, Nov. 2022, doi: 10.3390/agriculture12111964.
- [49] S.-L. Wu, H.-Y. Tung, and Y.-L. Hsu, "Deep Learning for Automatic Quality Grading of Mangoes: Methods and Insights," in *Proceedings - 19th IEEE International Conference on Machine Learning and Applications, ICMLA 2020*, 2020, pp. 446–453, doi: 10.1109/ICMLA51294.2020.00076.
- [50] L. Loyani and D. Machuve, "A Deep Learning-based Mobile Application for Segmenting Tuta Absoluta's Damage on Tomato Plants," *Engineering, Technology & Applied Science Research*, vol. 11, no. 5, pp. 7730–7737, Oct. 2021, doi: 10.48084/etasr.4355.
- [51] Q.-J. Wang et al., "Pest24: A large-scale very small object data set of agricultural pests for multi-target detection," *Computers and Electronics in Agriculture*, vol. 175, p. 105585, Aug. 2020, doi: 10.1016/j.compag.2020.105585.
- [52] M. F. Shahid, T. J. S. Khanzada, M. A. Aslam, S. Hussain, S. A. Baowidan, and R. B. Ashari, "An ensemble deep learning models approach using image analysis for cotton crop classification in AI-enabled smart agriculture," *Plant Methods*, vol. 20, no. 1, p. 104, Jul. 2024, doi: 10.1186/s13007-024-01228-w.
- [53] S. Natarajan, P. Chakrabarti, and M. Margala, "Robust diagnosis and meta visualizations of plant diseases through deep neural architecture with explainable AI," *Scientific Reports*, vol. 14, no. 1, p. 13695, Jun. 2024, doi: 10.1038/s41598-024-64601-8.
- [54] M. Agarwal, A. Singh, S. Arjaria, A. Sinha, and S. Gupta, "ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network," *Procedia Computer Science*, vol. 167, pp. 293–301, 2020, doi: 10.1016/j.procs.2020.03.225.