ISBN: 978-628-96613-0-9. ISSN: 2414-6390. Digital Object Identifier: https://dx.doi.org/10.18687/LEIRD2024.1.1.862

Machine Learning's contribution to mango cultivation and production

Oscar Efraín Capuñay-Uceda[1,2], Juan Elías Villegas-Cubas[1,2], Luis Otake[1,2]
Organización: 1: Grupo de Investigación en Ciencia de Datos, Inteligencia Artificial y Ciberseguridad, Universidad Nacional Pedro Ruiz Gallo; 2: Universidad Nacional Pedro Ruiz Gallo - (PE)

Abstract– This research explores and evaluates the application of Machine Learning techniques in the field of agriculture, with a particular focus on mango cultivation and production. The research addresses traditional challenges in the identification, classification, and detection of diseases in mango crops, areas where manual assessments have proven to be error-prone and subjective. The paper highlights how advanced techniques, such as convolutional neural networks and transfer learning, have significantly improved accuracy and efficiency in these critical processes, overcoming the limitations of traditional methods. Several methodologies are presented, ranging from automatic fruit identification using computer vision to non-destructive fruit quality assessment using colour and X-ray images. The results show that the implementation of these technologies has led to an improvement in quality standards and product competitiveness in global markets, consolidating ML as an indispensable tool for the sustainable development of mango cultivation. In conclusion, the study underlines the need to integrate advanced technologies in agriculture to improve both efficiency and quality of mangoes, suggesting that these innovations are key to address contemporary challenges in agricultural production.

Keywords: Mango, Machine Learning.

Aportes del Machine Learning al cultivo y producción del mango

Oscar Efraín Capuñay-Uceda[1,2], Juan Elías Villegas-Cubas[1,2], Luis Otake[1,2]
Organización: 1: Grupo de Investigación en Ciencia de Datos, Inteligencia Artificial y Ciberseguridad, Universidad Nacional Pedro Ruiz Gallo; 2: Universidad Nacional Pedro Ruiz Gallo - (PE)

Resumen– Esta investigación explora y evalúa la aplicación de técnicas de Machine Learning en el ámbito de la agricultura, con un enfoque particular en el cultivo y producción del mango. La investigación aborda los desafíos tradicionales en la identificación, clasificación, y detección de enfermedades en los cultivos de mango, áreas donde las evaluaciones manuales han demostrado ser propensas a errores y subjetividades. El trabajo destaca cómo las técnicas avanzadas, como las redes neuronales convolucionales y el aprendizaje de transferencia, han mejorado significativamente la precisión y eficiencia en estos procesos críticos, superando las limitaciones de los métodos tradicionales. Se presentan diversas metodologías que incluyen desde la identificación automática de frutas mediante visión por computadora, hasta la evaluación no destructiva de la calidad de los frutos utilizando imágenes de color y rayos X. Los resultados muestran que la implementación de estas tecnologías ha permitido una mejora en los estándares de calidad y competitividad de los productos en mercados globales, consolidando al ML como una herramienta indispensable para el desarrollo sostenible del cultivo del mango. En conclusión, el estudio subraya la necesidad de integrar tecnologías avanzadas en la agricultura para mejorar tanto la eficiencia como la calidad del mango, sugiriendo que estas innovaciones son claves para afrontar los desafíos contemporáneos en la producción agrícola.

Palabras clave— Mango, Machine Learning.

I. Introducción

El cultivo y producción de mango, una de las frutas tropicales más valiosas y comercializadas a nivel global, enfrenta numerosos desafíos en su cadena de valor. Entre estos desafíos destacan la necesidad de identificar y clasificar de manera precisa y eficiente las diferentes variedades de mango, la detección de enfermedades en el cultivo y la evaluación no destructiva de la calidad del fruto. El objetivo de esta investigación fue explorar y evaluar la efectividad de diversas técnicas de Machine Learning (ML) y Deep Learning (DL) utilizadas en los procesos. Tradicionalmente, estos procesos han dependido de evaluaciones manuales, las cuales son propensas a errores humanos, inconsistencias y altos costos laborales. Además, la subjetividad inherente a estas evaluaciones puede llevar a una clasificación inexacta, lo que impacta negativamente en la calidad del producto final y, por ende, en su valor en el mercado internacional [1]. La implementación efectiva de estas tecnologías en la agricultura, específicamente en el cultivo de mango, presenta retos significativos, como la necesidad de grandes conjuntos de datos etiquetados, la variabilidad de las condiciones de cultivo y la diversidad de variedades de mango con características visuales similares [2]. Uno de los principales aportes del ML en este campo es la identificación automática de frutas utilizando técnicas avanzadas de visión por computadora, como las redes neuronales convolucionales (CNN). Estas técnicas han demostrado ser eficaces para identificar diferentes variedades de mango, mejorando la precisión y la velocidad del proceso de clasificación, lo cual es esencial para la comercialización y exportación de productos agrícolas [3]. Además, el ML ha sido fundamental en la creación de modelos predictivos para la detección de enfermedades en los cultivos de mango, lo que permite una intervención temprana y, por ende, la reducción de pérdidas significativas en la producción. Estudios recientes han propuesto el uso de modelos CNN para detectar enfermedades en las hojas de los árboles de mango, mostrando un alto grado de precisión en la identificación de patologías comunes, lo que facilita la toma de decisiones rápidas y efectivas por parte de los agricultores [4]. El desarrollo de conjuntos de datos a mediana escala para la evaluación no destructiva de la calidad de las frutas ha permitido una mejora en los estándares de calidad de los productos. Este tipo de evaluaciones es esencial para garantizar que los mangos cumplan con los requisitos internacionales de calidad, lo que es crucial para la competitividad en mercados globales [5]. Estos avances demuestran cómo el ML se ha convertido en una herramienta indispensable para el desarrollo sostenible del cultivo y producción del mango, contribuyendo significativamente a mejorar tanto la eficiencia como la calidad en este sector agrícola.

II. Identificación y Clasificación

En el ámbito del cultivo y producción de mango, se han implementado diversas técnicas de Machine Learning y Deep Learning (DL) para mejorar la identificación automática y la clasificación de las variedades de mango. Estas técnicas han demostrado ser efectivas en optimizar la precisión y eficiencia en la clasificación de los frutos, lo cual es crucial para mantener la calidad en mercados competitivos. A continuación, se describen las principales técnicas utilizadas:

Redes Neuronales Convolucionales (CNN): las redes neuronales convolucionales son una de las técnicas más

empleadas para la identificación y clasificación de frutas, incluyendo el mango. Estas redes son particularmente efectivas para tareas de clasificación de imágenes debido a su capacidad para detectar patrones visuales complejos. Por ejemplo, en un estudio se utilizó una arquitectura CNN para clasificar variedades de mango basándose en imágenes de hojas, logrando una precisión significativa en la identificación de especies de mango [6]. Otro estudio destacó el uso de CNN para la detección automática de defectos en mangos, logrando una precisión del 98% en la clasificación de calidad del fruto [7]. Además, CNNs han sido utilizadas en la evaluación de calidad interna y externa de mangos mediante imágenes de color y rayos X, alcanzando una precisión del 95.1% y 98.7%, respectivamente, lo que subraya la versatilidad y eficacia de estas redes para diversas aplicaciones en la industria del mango[5].

Aprendizaje de Transferencia: el aprendizaje de transferencia ha sido utilizado para mejorar la precisión de los modelos de clasificación cuando los conjuntos de datos son limitados. Esta técnica permite aprovechar modelos preentrenados en tareas similares y adaptarlos para la clasificación específica de variedades de mango. Por ejemplo, en un estudio reciente, se empleó TensorFlow Lite como herramienta de aprendizaje de transferencia para clasificar diferentes variedades de mango, obteniendo una precisión del 95% [8]. De manera similar, otro trabajo implementó aprendizaje de transferencia con la arquitectura ResNet50 para clasificar enfermedades en hojas de mango, combinando técnicas de aumento de datos para mejorar la precisión del modelo, lo que resultó en un 98.54% de precisión en el conjunto de prueba. Este enfoque demuestra cómo el aprendizaje de transferencia puede ser una solución eficaz cuando se dispone de conjuntos de datos limitados pero se requiere una alta precisión en la clasificación [9].

Métodos Basados en Características Físicas y Texturales: otra técnica común es el uso de análisis de características físicas y texturales para la clasificación de mangos. Estos métodos incluyen la extracción de características basadas en la geometría, textura y color de las imágenes del fruto, que luego son procesadas por algoritmos de ML como las redes neuronales de retropropagación o clasificadores de funciones discriminantes. Estos enfoques han mostrado una alta precisión en la clasificación de la calidad del mango [10]. En otro estudio, se utilizó una red neuronal de base radial para identificar diferentes tipos de mangos basándose en las características texturales extraídas mediante filtros de Gabor. Este enfoque logró una precisión del 100%, lo que demuestra la capacidad de las técnicas basadas en características físicas para clasificar de manera efectiva las variedades de mango, superando la subjetividad y errores humanos inherentes a los métodos manuales [11].

Algoritmos de Machine Learning Clásicos: además de las técnicas de DL, se han empleado algoritmos clásicos de ML como el k-Nearest Neighbors (k-NN), Support Vector Machines (SVM), y Naive Bayes para la clasificación de mangos. Estos métodos han sido combinados con técnicas de preprocesamiento y selección de características para mejorar la eficiencia y precisión de la clasificación. Por ejemplo, el uso de SVM combinado con la selección de características logró una precisión de hasta el 97% en la clasificación de variedades de mango basadas en imágenes de hojas [12]. Además, en otro estudio, se implementaron diferentes clasificadores de ML para determinar el grado de madurez de mangos, comparando su desempeño. El modelo de redes neuronales artificiales (FANN) mostró el mejor rendimiento con una precisión del 89.6% en la clasificación de mangos en estados de inmadurez, madurez y sobremadurez, lo que subraya la utilidad de estos algoritmos en aplicaciones prácticas en la agricultura [1].

III. Detección de Enfermedades

La detección temprana de enfermedades en cultivos de mango es crucial para prevenir la propagación de plagas y enfermedades que afectan la producción y calidad de la fruta. Los modelos de CNN y otras técnicas de ML han demostrado ser efectivos en la identificación automática de estas enfermedades en hojas y frutos.

Modelos CNN basados en Aprendizaje Federado: Un estudio reciente propuso un modelo de CNN basado en aprendizaje federado para la detección de enfermedades en hojas de mango, que logró precisiones de hasta 98%, permitiendo un manejo más efectivo de las enfermedades sin comprometer la privacidad de los datos [13]. Un segundo estudio desarrolló un modelo FL-CNN para la categorización de enfermedades en hojas de mango en cuatro niveles de severidad, con promedios macro de precisión de hasta 96%, demostrando la eficiencia del aprendizaje federado en la detección de enfermedades [14]. Otro caso similar implementó un sistema de clasificación y predicción de enfermedades basado en un modelo CNN, logrando una precisión del 97.7% al utilizar un conjunto de datos de hojas de mango afectadas por diversas enfermedades [15].

Técnicas de Aumento de Datos: La combinación de técnicas de aumento de datos, como el contraste y la transformación afín, mejoró significativamente la precisión de un modelo ResNet50, alcanzando un 97.8% en la clasificación de enfermedades en hojas de mango [9]. En otro estudio, se utilizó la técnica de CLAHE para mejorar el contraste de las imágenes de hojas de mango, lo que resultó en una precisión de segmentación del 99.2% al identificar áreas afectadas por enfermedades [16].Un tercer ejemplo mostró que la técnica de aumento de datos combinada con modelos CNN pre-entrenados, como ResNet50, permitió la clasificación efectiva de imágenes de hojas de mango, logrando una precisión de hasta el 98% [17].

Transfer Learning con CNN: La utilización de técnicas de transfer learning con modelos como DenseNet201 y ResNet50 ha permitido obtener precisiones superiores al 98% en la detección de enfermedades en hojas de mango, destacando la eficiencia de estas arquitecturas en la clasificación precisa de enfermedades [18].Otro caso de uso de transfer learning mostró que un modelo CNN personalizado alcanzó una precisión del 91.52% en la clasificación de imágenes de frutos de mango, utilizando imágenes de rayos X para detectar defectos internos (Ashok et al., 2023). Un tercer estudio aplicó transfer learning con ResNet50 para la clasificación de imágenes de hojas de mango, logrando una precisión del 97.7%, lo que valida la efectividad de este enfoque en la detección de enfermedades en mango [19].

Modelos Híbridos CNN-SVM: Un modelo híbrido que combina CNN y SVM fue desarrollado para clasificar la severidad de la enfermedad de la mancha foliar en mango, logrando una precisión del 95.68%, lo que demuestra la efectividad de combinar técnicas de ML para mejorar la clasificación de enfermedades [20]. En otro estudio, se utilizó un modelo CNN-SVM para la detección de la severidad de la enfermedad de oídio en mango, alcanzando una precisión global del 89.29% en la clasificación en cuatro niveles de severidad [21]. Un tercer ejemplo implementó un modelo híbrido CNN-SVM para la clasificación de múltiples enfermedades en hojas de mango, logrando una precisión del 81.13%, demostrando la utilidad de este enfoque en el diagnóstico agrícola [22].

Detección de Enfermedades en Frutos: Un modelo basado en CNN para la evaluación no destructiva de la calidad interna y externa de los frutos de mango utilizando imágenes en color y rayos X demostró altas precisiones de clasificación, mejorando significativamente los métodos tradicionales de evaluación [2]. En otro caso, se utilizó una red CapsNet para la detección de enfermedades como antracnosis y oídio en hojas de mango, alcanzando una precisión del 98.5%, superando a otros algoritmos de clasificación como SVM y CNN tradicionales [23]. Un tercer estudio aplicó técnicas de aprendizaje profundo para la clasificación de enfermedades en hojas y frutos de mango, utilizando LSTM mejorado y CNN, logrando una alta precisión en la clasificación de múltiples enfermedades [24].

IV. Evaluación de la Calidad

La evaluación no destructiva de la calidad de los mangos es esencial para garantizar la seguridad y calidad de los productos destinados al mercado. Las técnicas basadas en visión por computadora, espectroscopía y ML permiten analizar tanto las características externas como internas de los mangos sin dañarlos.

Espectroscopía en el Infrarrojo Cercano (NIR): La espectroscopía NIR se ha utilizado para evaluar la calidad interna de los mangos, como el contenido de sólidos solubles, acidez titulable y firmeza de la pulpa. Un estudio utilizó un espectrómetro de mano para predecir estos parámetros en mangos 'Tommy Atkins', logrando altos niveles de precisión con coeficientes de determinación superiores a 0.9 para sólidos solubles y firmeza [25]. Un análisis similar utilizó espectroscopía NIR para predecir la calidad interna de mangos en diferentes condiciones de almacenamiento y maduración. Este estudio destacó la robustez de los modelos NIR al considerar factores pre y postcosecha, lo que resultó en predicciones precisas de la calidad de los mangos [26]. Otro estudio evaluó la calidad interna de mangos utilizando espectroscopía visible e infrarrojo cercano, combinada con análisis de regresión parcial de mínimos cuadrados (PLS), demostrando que esta técnica es efectiva para predecir la madurez y calidad interna de los mangos [27].

Visión por Computadora y Clasificación de Imágenes: Un estudio desarrolló un modelo basado en redes neuronales profundas (CNN) para clasificar la calidad externa e interna de los mangos utilizando imágenes en color y rayos X, logrando precisiones de hasta 97.5% para defectos internos y 95.1% para defectos externos [2]. En otro estudio, se utilizaron técnicas de visión por computadora para evaluar la calidad del mango, prediciendo parámetros como el contenido de sólidos solubles y la firmeza. Utilizando modelos como Random Forest y SVM, se logró una precisión del 98.1% en la clasificación de los mangos en diferentes grados de calidad [28]. Un tercer estudio utilizó la visión por computadora para clasificar la calidad de mangos utilizando un enfoque de minería de datos. Este método predijo atributos de calidad como los sólidos solubles totales (TSS), la acidez y la firmeza, mostrando una mejora significativa en la conservación poscosecha [29].

Combinación de Técnicas No Destructivas: La combinación de técnicas no destructivas, como la espectroscopía NIR y sensores acústicos, ha mejorado la precisión en la evaluación de la madurez y calidad de los mangos. Un estudio utilizó la fusión de datos de espectroscopía y sensores acústicos para discriminar mejor los niveles de madurez y calidad en mangos 'Harumanis' [30]. Otro estudio desarrolló un sensor integrado en un robot gripper que combina propiedades mecánicas y ópticas para medir la firmeza y las propiedades espectrales de los mangos simultáneamente. Este enfoque mejoró la precisión de la evaluación de la calidad durante las operaciones de recolección [27]. Un tercer estudio mostró la eficacia de combinar espectroscopía visible y NIR con aprendizaje automático para predecir la madurez y la calidad de los mangos. Utilizando PLS y ANN, el estudio logró clasificaciones precisas de mangos en diferentes etapas de madurez [31].

El uso de técnicas de aprendizaje automático ha permitido desarrollar sistemas que no solo predicen la calidad de los mangos, sino que también garantizan la seguridad de los productos destinados al mercado. Estos sistemas permiten una clasificación más precisa y rápida de los frutos, lo que reduce el desperdicio y asegura que solo los mangos de la más alta calidad lleguen a los consumidores. Además, el ML ha sido fundamental para integrar múltiples fuentes de datos, lo que mejora la robustez y precisión de los modelos predictivos [26].

V. Desafíos en la Implementación

La producción de mango, una de las frutas más importantes en términos económicos a nivel global, enfrenta numerosos desafíos que limitan la eficiencia y la productividad. La implementación de tecnologías avanzadas como el Machine Learning tiene el potencial de transformar esta industria, mejorando la precisión en la clasificación de frutos, la detección de enfermedades y la predicción de rendimientos. Sin embargo, a pesar de sus beneficios potenciales, la adopción de ML en la producción de mango no está exenta de desafíos.

Limitaciones en la Disponibilidad y Calidad de Datos: Uno de los principales desafíos en la implementación de ML en la producción de mango es la disponibilidad limitada de datos de alta calidad, que son esenciales para entrenar modelos precisos. La escasez de datos etiquetados, especialmente en lo que respecta a la clasificación de enfermedades de las hojas de mango, representa un obstáculo significativo. Por ejemplo, Faye et al. (2023) señalan que la falta de conjuntos de datos grandes y etiquetados reduce la efectividad de los modelos de ML en la identificación de enfermedades, lo que resulta en un rendimiento subóptimo de los sistemas de clasificación automática. Para mitigar este problema, se han propuesto técnicas de aumento de datos, como la transformación de imágenes, que pueden mejorar la cantidad y diversidad de datos disponibles para el entrenamiento de modelos [9].

Condiciones de Campo Heterogéneas: Otro desafío clave es la heterogeneidad en las condiciones de los campos donde se cultivan los mangos. La variabilidad en factores como la estructura del árbol, la exposición a la luz, y las diferencias en el tamaño y color del fruto pueden afectar significativamente la precisión de los modelos de ML. Un estudio realizado por Sarron y otros [32] destaca cómo los modelos de detección de frutos entrenados en condiciones homogéneas mostraron una caída notable en su rendimiento cuando se aplicaron en escenarios más diversos. Este descenso en la precisión pone de relieve la necesidad de desarrollar modelos más robustos que puedan generalizarse eficazmente en diferentes condiciones de campo [32].

Dificultades en la Generalización de Modelos: La capacidad de un modelo de ML para generalizar más allá del conjunto de datos de entrenamiento es crucial para su aplicabilidad en la producción real de mango. Sin embargo, muchos modelos desarrollados en entornos controlados no logran mantener su precisión cuando se implementan en el campo. Wu y otros [33] subrayan este problema en su estudio sobre la clasificación de la calidad del mango. En su trabajo, descubrieron que los modelos entrenados con datos específicos no podían generalizar adecuadamente cuando se les aplicaba a frutas cultivadas en condiciones distintas. Esta falta de generalización limita la utilidad de estos modelos en escenarios de producción real, donde las condiciones pueden variar ampliamente [33].

Necesidad de Procesos de Preprocesamiento Complejos: El preprocesamiento de datos es una etapa crítica en la implementación de ML, y en el contexto de la producción de mango, este proceso puede ser particularmente complejo y costoso. La calidad de los datos crudos, como las imágenes y las lecturas espectrales, a menudo no es suficiente para entrenar modelos precisos sin un preprocesamiento intensivo. Tan y Chia [34] demostraron que la aplicación de métodos de preprocesamiento como la transformación de Savitzky-Golay puede mejorar significativamente la precisión de los modelos en la predicción de la calidad interna del mango, pero también incrementa la complejidad del sistema, lo que puede ser un obstáculo para su adopción generalizada [34].

Adaptación a Condiciones Operacionales del Mundo Real: Finalmente, la adaptación de los modelos de ML a las condiciones operacionales del mundo real representa un desafío considerable. Los modelos desarrollados en laboratorio a menudo no tienen en cuenta las variaciones climáticas, las limitaciones tecnológicas, y otros factores que afectan la producción de mango en el campo. Kusrini et al. [35] subrayan la importancia de adaptar los modelos de ML a las condiciones operacionales, destacando la necesidad de técnicas avanzadas de aumento de datos para simular mejor las condiciones encontradas por los agricultores en sus operaciones diarias. Este tipo de adaptación es crucial para garantizar que los modelos sean útiles y eficaces en el contexto de la producción agrícola [35].

Conclusiones

Las técnicas de Machine Learning y Deep Learning han demostrado ser herramientas fundamentales para la identificación automática y la clasificación de variedades de mango, abordando de manera efectiva muchos de los desafíos tradicionales asociados con estos procesos en la agricultura. En particular, las CNN se destacan por su capacidad para manejar tareas complejas de clasificación de imágenes, proporcionando una alta precisión en la identificación de variedades de mango y en la detección de defectos en los frutos [7]. Además, el uso del aprendizaje de transferencia ha permitido mejorar la precisión de los modelos incluso en contextos donde los datos etiquetados son limitados, lo que es crucial para aplicaciones agrícolas en regiones con menos recursos [8]. Asimismo, los

métodos basados en la extracción de características físicas y texturales han mostrado ser efectivos en la clasificación de la calidad del mango, superando las limitaciones de los métodos manuales y reduciendo la subjetividad en el proceso [10]. Finalmente, la combinación de algoritmos clásicos de ML con técnicas avanzadas de preprocesamiento y selección de características ha demostrado ser una solución práctica y eficiente para la clasificación de estados de madurez y variedades de mango, contribuyendo significativamente a mejorar la calidad y consistencia en la producción [1].

Los modelos basados en CNN han demostrado ser altamente efectivos en la detección temprana de enfermedades en cultivos de mango, especialmente cuando se combinan con otras técnicas de aprendizaje automático como el aprendizaje federado y los modelos híbridos de CNN-SVM. El uso de técnicas de aprendizaje federado no solo mejora la precisión en la detección de enfermedades, sino que también protege la privacidad de los datos de los agricultores, lo que resulta en un manejo más efectivo y sostenible de las enfermedades en los cultivos [14]. Las técnicas de aumento de datos, como el contraste y la transformación afín, han sido esenciales para mejorar la precisión de los modelos CNN en la clasificación de enfermedades, alcanzando precisiones de hasta el 97.8% en algunos estudios [9]. Además, la aplicación de transfer learning con modelos como DenseNet201 y ResNet50 ha permitido alcanzar una precisión superior al 98% en la detección de enfermedades en hojas de mango, destacando la eficiencia de estas arquitecturas [18]. Los modelos híbridos que combinan CNN con SVM han mostrado ser particularmente útiles para clasificar la severidad de las enfermedades en hojas de mango, logrando precisiones significativas en la clasificación de múltiples niveles de severidad de la enfermedad, lo que podría ayudar en la implementación de medidas más precisas de manejo agrícola [20]. La detección temprana y no destructiva de enfermedades en los frutos de mango a través de técnicas de aprendizaje profundo y visión por computadora ha demostrado mejorar la precisión y eficiencia de los métodos tradicionales de evaluación, lo que es crucial para mantener la calidad del producto en el mercado global [2].

Los métodos no destructivos basados en NIR han demostrado ser altamente efectivos para evaluar la calidad interna de los mangos, como el contenido de sólidos solubles, la acidez titulable y la firmeza de la pulpa. La precisión de estos métodos ha sido validada en diferentes estudios, destacando su utilidad en la predicción de la calidad del mango, incluso bajo condiciones variables de almacenamiento y maduración [25], [26]. La visión por computadora combinada con el aprendizaje automático ha permitido desarrollar sistemas robustos para la clasificación de la calidad externa e interna de los mangos, logrando altas precisiones en la identificación de defectos y en la clasificación de la madurez. Estos sistemas no solo han mejorado la eficiencia en la clasificación, sino que también han demostrado ser herramientas valiosas para la conservación poscosecha y la reducción de pérdidas [2], [29]. La combinación de técnicas no destructivas, como la espectroscopía NIR y los sensores acústicos, ha permitido una evaluación más precisa y completa de la calidad del mango, mejorando la discriminación de los niveles de madurez y calidad. Estas combinaciones, junto con la integración de sensores en sistemas automatizados, ofrecen una gran promesa para la mejora de la calidad en la cadena de suministro de mangos [27], [30].

La implementación de Machine Learning en la producción de mango presenta una serie de desafíos complejos que van desde la recopilación de datos hasta la adaptación de los modelos a las condiciones del campo. Para superar estos desafíos, es esencial un enfoque multidisciplinario que incluya avances en la recopilación y preprocesamiento de datos, así como el desarrollo de modelos más robustos y adaptativos. La superación de estos obstáculos permitirá aprovechar plenamente el potencial de ML para transformar la producción de mango, mejorando tanto la eficiencia como la calidad del producto final [9], [32], [33], [34], [35].

REFERENCIAS

[1] D. Worasawate, P. Sakunasinha, y S. Chiangga, «Automatic Classification of the Ripeness Stage of Mango Fruit Using a Machine Learning Approach», *AgriEngineering*, vol. 4, n.º 1, Art. n.º 1, mar. 2022, doi: 10.3390/agriengineering4010003.

[2] V. Ashok, B. R. K, y S. N, «An Automatic Non-Destructive External and Internal Quality Evaluation of Mango Fruits based on Color and X-ray Imaging using Computer Vision Techniques», *Intel. Artif.*, vol. 26, n.º 72, Art. n.º 72, sep. 2023, doi: 10.4114/intartif.vol26iss72pp223-243.

[3] K. Sawant *et al.*, *Fruit Identification using YOLO v8 and Faster R- CNN -A Commparative Study*. 2024. doi: 10.1109/ICDCOT61034.2024.10515677.

[4] P. P. Singh, D. Kumar, A. Srivastava, M. Basumatary, y S. Prasad, «A CNN Model Based Approach for Disease Detection in Mango Plant Leaves», en *Proceedings of the 12th International Conference on Soft Computing for Problem Solving*, M. Pant, K. Deep, y A. Nagar, Eds., Singapore: Springer Nature, 2024, pp. 389-399. doi: 10.1007/978-981-97-3292-0_27.

[5] V. Ashok, B. R. K, y P. Shivakumara, «Building a Medium Scale Dataset for Non-destructive Disease Classification in Mango Fruits Using Machine Learning and Deep Learning Models», *Int. J. Image Graph. Signal Process.*, vol. 15, n.º 4, p. 83, ene. 2024, Accedido: 12 de junio de 2024. [En línea]. Disponible en: https://www.mecs-press.org/ijigsp/ijigsp-v15-n4/v15n4-7.html

[6] N. Nafi'iyah y J. Maknun, «CNN Architecture for Classifying Types of Mango Based on Leaf Images», *Telematika*, vol. 14, n.º 2, Art. n.º 2, ago. 2021, doi: 10.35671/telematika.v14i2.1262.

[7] R. Nithya, B. Santhi, R. Manikandan, M. Rahimi, y A. H. Gandomi, «Computer Vision System for Mango Fruit Defect Detection Using Deep Convolutional Neural Network», *Foods*, vol. 11, n.º 21, Art. n.º 21, ene. 2022, doi: 10.3390/foods11213483.

[8] M. R. Mustaffa, A. A. Idris, L. N. Abdullah, y N. A. Nasharuddin, «Deep learning mango fruits recognition based on tensorflow lite», *Int. J. Adv. Intell. Inform.*, vol. 9, n.º 3, Art. n.º 3, nov. 2023, doi: 10.26555/ijain.v9i3.1368.

[9] D. Faye, I. Diop, N. Mbaye, y D. Dione, «A Combination of Data Augmentation Techniques for Mango Leaf Diseases Classification», *Glob. J. Comput. Sci. Technol.*, pp. 1-10, abr. 2023, doi: 10.34257/GJCSTGVOL23IS1PG1.

[10] N. Kumari, A. Kr. Bhatt, R. Kr. Dwivedi, y R. Belwal, «Hybridized approach of image segmentation in classification of fruit mango using BPNN and discriminant analyzer», *Multimed. Tools Appl.*, vol. 80, n.º 4, pp. 4943-4973, feb. 2021, doi: 10.1007/s11042-020-09747-z.

[11] F. Thaib, G. Tomasila, G. V. Nivaan, y A. J. Santoso, «Radial Basis Function Neural Network in Identifying The Types of Mangoes», en *2020 8th International Conference on Information and Communication Technology (ICoICT)*, jun. 2020, pp. 1-6. doi: 10.1109/ICoICT49345.2020.9166271.

[12] T. Aslam *et al.*, «Machine learning approach for classification of mangifera indica leaves using digital image analysis», *Int. J. Food Prop.*, dic. 2022, Accedido: 16 de agosto de 2024. [En línea]. Disponible en: https://www.tandfonline.com/doi/abs/10.1080/10942912.2022.2117822

[13] S. Mehta, V. Kukreja, y S. Vats, «Advancing Agricultural Practices: Federated Learning-based CNN for Mango Leaf Disease Detection», en *2023 3rd International Conference on Intelligent Technologies (CONIT)*, jun. 2023, pp. 1-6. doi: 10.1109/CONIT59222.2023.10205850.

[14] S. Mehta, V. Kukreja, y R. Yadav, «Advanced Mango Leaf Disease Detection and Severity Analysis with Federated Learning and CNN», en *2023 3rd International Conference on Intelligent Technologies (CONIT)*, jun. 2023, pp. 1-6. doi: 10.1109/CONIT59222.2023.10205922.

[15] T. M. Saravanan, M. Jagadeesan, P. A. Selvaraj, M. Aravind, G. D. Raj, y P. Lokesh, «Prediction of Mango Leaf Diseases using Convolutional Neural Network», en *2023 International Conference on Computer Communication and Informatics (ICCCI)*, ene. 2023, pp. 1-4. doi: 10.1109/ICCCI56745.2023.10128578.

[16] R. Saleem, J. Shah, M. Sharif, y G. Ansari, «Mango Leaf Disease Identification Using Fully Resolution Convolutional Network», *Comput. Mater. Contin.*, vol. 69, n.º 3, pp. 3581-3601, 2021, doi: 10.32604/cmc.2021.017700.

[17] S. S, B. Ananthakrishnan, y A. K. Sivaraman, «Deep Learning and Computer Vision based Model for Detection of Diseased Mango Leaves», *Int. J. Recent Innov. Trends Comput. Commun.*, vol. 10, n.º 6, Art. n.º 6, jun. 2022, doi: 10.17762/ijritcc.v10i6.5555.

[18] A. Rajbongshi, T. Khan, M. M. Rahman, A. Pramanik, S. M. T. Siddiquee, y N. R. Chakraborty, «Recognition of mango leaf disease using convolutional neural network models: a transfer learning approach», *Indones. J. Electr. Eng. Comput. Sci.*, vol. 23, n.º 3, Art. n.º 3, sep. 2021, doi: 10.11591/ijeecs.v23.i3.pp1681-1688.

[19] S. Jain y P. Jaidka, «Mango Leaf disease Classification using deep learning Hybrid Model», en *2023 International Conference on Power, Instrumentation, Energy and Control (PIECON)*, feb. 2023, pp. 1-6. doi: 10.1109/PIECON56912.2023.10085869.

[20] D. Baresary, A. Saini, R. K. Sharma, D. Bordoloi, R. Sharma, y V. Kukreja, «MangoSpot: A Hybrid CNN-SVM Model for Multi-Classification of Mango Leaf Spot Disease Based on Seriousness Levels», en *2023 3rd International Conference on Intelligent Technologies (CONIT)*, jun. 2023, pp. 1-5. doi: 10.1109/CONIT59222.2023.10205376.

[21] D. Banerjee, V. Kukreja, S. Hariharan, y V. Jain, «Enhancing Mango Fruit Disease Severity Assessment with CNN and SVM-Based Classification», en *2023 IEEE 8th International Conference for Convergence in Technology (I2CT)*, abr. 2023, pp. 1-6. doi: 10.1109/I2CT57861.2023.10126397.

[22] D. Banerjee, V. Kukreja, S. Hariharan, V. Jain, y S. Vats, «Mango Disease Detection System Using CNN and SVM: A Comparative Study with Traditional Diagnostic Methods», en *2023 World Conference on Communication & Computing (WCONF)*, jul. 2023, pp. 1-6. doi: 10.1109/WCONF58270.2023.10235224.

[23] B. Janakiramaiah, G. Kalyani, L. V. N. Prasad, A. Karuna, y M. Krishna, «Intelligent system for leaf disease detection using capsule networks for horticulture», *J. Intell. Fuzzy Syst.*, vol. 41, n.º 6, pp. 6697-6713, ene. 2021, doi: 10.3233/JIFS-210593.

[24] S. S. Veling y T. B. Mohite-Patil, «Multi-Disease Classification of Mango Tree Using Meta-Heuristic-Based Weighted Feature Selection and LSTM Model», *Int. J. Image Graph.*, vol. 24, n.º 04, p. 2450039, jul. 2024, doi: 10.1142/S0219467824500396.

[25] E. J. N. Marques, S. T. de Freitas, M. F. Pimentel, y C. Pasquini, «Rapid and non-destructive determination of quality parameters in the 'Tommy Atkins' mango using a novel handheld near infrared spectrometer», *Food Chem.*, vol. 197, pp. 1207-1214, abr. 2016, doi: 10.1016/j.foodchem.2015.11.080.

[26] T. Nordey, J. Joas, F. Davrieux, M. Chillet, y M. Léchaudel, «Robust NIRS models for non-destructive prediction of mango internal quality», *Sci. Hortic.*, vol. 216, pp. 51-57, feb. 2017, doi: 10.1016/j.scienta.2016.12.023.

[27] V. Cortés *et al.*, «Integration of simultaneous tactile sensing and reflectance visible and near-infrared spectroscopy in a robot gripper for mango quality assessment», *Biosyst. Eng.*, n.º 166, pp. 112-123, 2017, doi: 10.1016/j.biosystemseng.2017.08.005.

[28] N. Truong Minh Long y N. Truong Thinh, «Using Machine Learning to Grade the Mango's Quality Based on External Features Captured by Vision System», *Appl. Sci.*, vol. 10, n.º 17, Art. n.º 17, ene. 2020, doi: 10.3390/app10175775.

[29] D. S. Reis, R. F. de O. Neto, J. D. de S. Costa, A. F. Neto, y M. de S. Costa, «A data mining approach for prediction of quality attributes in Palmer mango from images», *Rev. Bras. Comput. Apl.*, vol. 12, n.º 2, Art. n.º 2, jun. 2020, doi: 10.5335/rbca.v12i2.10866.

[30] A. Zakaria *et al.*, «Improved Maturity and Ripeness Classifications of Magnifera Indica cv. Harumanis Mangoes through Sensor Fusion of an Electronic Nose and Acoustic Sensor», *Sensors*, vol. 12, n.º 5, Art. n.º 5, may 2012, doi: 10.3390/s120506023.

[31] S. H. E. J. Gabriëls, P. Mishra, M. G. J. Mensink, P. Spoelstra, y E. J. Woltering, «Non-destructive measurement of internal browning in mangoes using visible and near-infrared spectroscopy supported by artificial neural network analysis», *Postharvest Biol. Technol.*, vol. 166, p. 111206, ago. 2020, doi: 10.1016/j.postharvbio.2020.111206.

[32] J. Sarron *et al.*, «Is machine learning efficient for mango yield estimation when used under heterogeneous field conditions?», *Acta Hortic.*, n.º 1279, pp. 201-208, jun. 2020, doi: 10.17660/ActaHortic.2020.1279.30.

[33] S.-L. Wu, H.-Y. Tung, y Y.-L. Hsu, «Deep Learning for Automatic Quality Grading of Mangoes: Methods and Insights», en *2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA)*, dic. 2020, pp. 446-453. doi: 10.1109/ICMLA51294.2020.00076.

[34] Y. P. Tan y K. S. Chia, «Effects of Pre-Processing and Principal Components for Artificial Neural Network in Non-Destructive Internal Quality Prediction of Mango across Different Harvest Periods», en *2023 IEEE 13th International Conference on Control System, Computing and Engineering (ICCSCE)*, ago. 2023, pp. 144-148. doi: 10.1109/ICCSCE58721.2023.10237167.

[35] K. Kusrini *et al.*, «Data augmentation for automated pest classification in Mango farms», *Comput. Electron. Agric.*, vol. 179, p. 105842, dic. 2020, doi: 10.1016/j.compag.2020.105842.