



REVISTA INGENIO

Desarrollo de un Sistema de Visión Artificial para la Detección no Destructiva de Plátanos

Development of a Computer Vision System for the Non-Destructive Detection of Bananas

Miguel Ángel Durán Fonseca | Universidad de Colima, Facultad de Ingeniería Electromecánica (México)
Jesús Alejandro Padilla Ayala | Universidad de Colima, Facultad de Ingeniería Electromecánica (México)
Jorge Gudiño Lau | Universidad de Colima, Facultad de Ingeniería Electromecánica (México)
Saida Miriam Charre Ibarra | Universidad de Colima, Facultad de Ingeniería Electromecánica (México)
Janeth Aurelia Alcalá Rodríguez | Universidad de Colima, Facultad de Ingeniería Electromecánica (México)

Recibido: 2/6/2025
Recibido tras revisión: 23/9/2025
Aceptado: 15/10/2025
Publicado: 28/1/2026

PALABRAS CLAVE

Visión artificial, Clasificación de frutas, Inteligencia artificial, Inspección no destructiva.

RESUMEN

La evaluación de la calidad en frutas frescas es esencial para garantizar su valor comercial y reducir pérdidas en la cadena de suministro. Este artículo presenta el desarrollo de un sistema basado en visión artificial para la detección no destructiva de plátanos, con el fin de automatizar el proceso de clasificación según su madurez. Se utilizó el algoritmo YOLOv11 entrenado con un conjunto de datos que consta de 824 imágenes de plátanos en diferentes estados (verde, maduro y pasado). El sistema fue implementado sobre una banda transportadora, incorporando componentes impresos en 3D y un mecanismo de segregación automática. Las pruebas realizadas demostraron una precisión del 97.2% en la clasificación, validando su aplicabilidad en entornos agroindustriales.

KEY WORDS

Computer vision, Fruit classification, Artificial intelligence, Non-destructive inspection.

ABSTRACT

Quality assessment in fresh fruits is essential to ensure their commercial value and reduce losses throughout the supply chain. This paper presents the development of a computer vision-based system for the non-destructive detection of bananas, aiming to automate the classification process according to ripeness. The YOLOv11 algorithm was trained with a dataset consisting of 824 banana images in different states (green, ripe, and overripe). The system was implemented on a conveyor belt, incorporating 3D-printed components and an automatic segregation mechanism. Experimental tests achieved a classification accuracy of 97.2%, validating the applicability of the proposed system in agro-industrial environments.

1. INTRODUCCIÓN

La calidad de los productos agrícolas frescos, como el plátano, es un factor crítico en la cadena de valor agroalimentaria, influyendo directamente en la satisfacción del consumidor y en la competitividad de los productores. La evaluación adecuada del estado de madurez y la detección temprana de defectos visuales son fundamentales para garantizar que los productos que lleguen al consumidor final cumplan con los estándares establecidos [1].

El problema a resolver en este trabajo radica en contar con un método automatizado, confiable y eficiente para la clasificación de plátanos según su estado de madurez y condiciones de calidad. Tradicionalmente, este proceso ha sido realizado mediante inspección visual manual, llevada a cabo por operarios en líneas de empaque. Si bien este método es funcional, presenta múltiples desventajas: es subjetivo, dependiente del criterio del operario, propenso a errores y difícil de escalar en contextos de

producción masiva. Además, implica altos costos asociados a la mano de obra, presenta limitaciones en la detección de defectos sutiles y carece de trazabilidad objetiva de los datos evaluados [2].

La visión artificial ha emergido como una tecnología disruptiva en este ámbito, permitiendo automatizar tareas de inspección visual mediante sistemas capaces de adquirir, procesar y analizar imágenes de forma precisa, rápida y consistente. Combinada con algoritmos de aprendizaje automático, particularmente aquellos basados en Redes Neuronales Convolucionales (CNN, por sus siglas en inglés *Convolutional Neural Network*), la visión artificial puede alcanzar niveles de precisión superiores a los del ojo humano en la clasificación de frutas según su madurez, coloración, textura y presencia de defectos [3].

En el caso específico del plátano, fruta de alta rotación y relevancia económica en múltiples regiones del mundo, la determinación de su estado de madurez es esencial para decidir su destino comercial: exportación, consumo inmediato o descarte. La clasificación entre plátanos verdes, maduros y pasados tiene implicaciones directas en la logística, el precio y la aceptación del consumidor. Un sistema automatizado de detección no destructiva, basado en visión artificial, representa una alternativa tecnológica que puede mejorar sustancialmente este proceso [4].

El presente trabajo tiene como objetivo el diseño e implementación de un sistema de visión artificial para la detección no destructiva de plátanos, basado en técnicas de aprendizaje profundo. El sistema de visión artificial propuesto es capaz de superar las limitaciones inherentes a la inspección visual humana, al ofrecer mayor objetividad, consistencia y eficiencia en la clasificación de los frutos. El sistema propuesto integra una banda transportadora, una cámara digital convencional y un mecanismo de segregación automática, todos controlados mediante software especializado. El modelo de inteligencia artificial (IA) utilizado está basado en la arquitectura YOLOv11 (por sus siglas en inglés *You Only Look Once*, versión 11), la cual fue entrenada con un conjunto de datos propio, compuesto por imágenes etiquetadas de plátanos en diferentes estados de madurez.

Con base en la revisión de literatura reciente, se seleccionó el modelo YOLOv11 debido a su amplio uso y desempeño en aplicaciones agrícolas. Este modelo demuestra un rendimiento sobresaliente en diversas aplicaciones agrícolas, con estudios que reportan altas tasas de precisión y capacidades de detección en tiempo real para el monitoreo de cultivos, la detección de enfermedades y la evaluación de calidad.

La evidencia abarca múltiples dominios agrícolas con métricas de desempeño sólidas. En la detección de defectos en frutas, YOLOv11 fue empleado en la detección de enfermedades en guayabas considerando cinco tipos de afecciones [5]. Los estudios sobre detección de enfermedades en plantas para veinte tipos de enfermedades [6] y para enfermedades en hojas de tomate [7]. En

aplicaciones de evaluación de calidad, se utilizó en la clasificación de fresas [8], así como en la detección del grado de madurez de tomates [9]. Otras aplicaciones incluyen la detección de malezas en agricultura de precisión [10] y el monitoreo acuícola para la detección de estanques de camarón [11]. El modelo demuestra de manera consistente capacidades de procesamiento en tiempo real adecuadas para sistemas agrícolas automatizados.


A lo largo del artículo se describe el proceso de diseño del sistema, la metodología de entrenamiento del modelo, los criterios de evaluación utilizados, así como los resultados obtenidos en entornos de prueba controlados. El enfoque propuesto busca contribuir al desarrollo de soluciones tecnológicas accesibles y escalables para la industria agroalimentaria, fomentando la transición hacia sistemas inteligentes de inspección que permitan reducir pérdidas, optimizar recursos y garantizar productos de mayor calidad para el consumidor final.

2. MÉTODO

El sistema propuesto fue desarrollado con el objetivo de realizar una detección no destructiva del estado de madurez de plátanos mediante visión artificial y técnicas de aprendizaje profundo. La arquitectura general está compuesta por una banda transportadora, una cámara digital para la adquisición de imágenes, un sistema de segregación automatizado y un modelo de inteligencia artificial entrenado con un conjunto específico de imágenes de plátanos. En la Fig. 1 se muestra un diagrama de los elementos que conforman el sistema.

Fig. 1.

Componentes físicos del sistema propuesto



A continuación, en la Tabla. 1, se presenta un resumen de los principales componentes que integran el sistema de visión artificial desarrollado para la detección no destructiva de plátanos. Cada elemento cumple una función específica dentro del proceso automatizado, desde la adquisición de imágenes hasta la clasificación y segregación del fruto. El diseño se ha enfocado en mantener una arquitectura modular, de bajo costo y fácilmente replicable para aplicaciones en entornos académicos e industriales.

TABLA I.

Componentes del sistema de visión artificial

Componente	Descripción
Computadora portátil	Ejecuta el modelo YOLOv11 y procesa las imágenes en tiempo real.
Cámara USB	Captura las imágenes de los plátanos sobre la banda transportadora.
Banda transportadora	Sistema mecánico que traslada los plátanos frente a la cámara.
Mecanismo de segregación	Compuerta accionada por servomotor que separa los plátanos “malos”.
Servomotor	Motor de precisión encargado del movimiento de la compuerta.
Estructura impresa en 3D	Soportes personalizados para cámara y elementos mecánicos.
Fuente de alimentación	Suministra energía a los motores y a los componentes electrónicos.

2.1. ADQUISICIÓN DE IMÁGENES Y BASE DE DATOS

Para entrenar el modelo de detección, se creó un conjunto de datos propio compuesto por imágenes de plátanos en tres etapas de maduración: inmaduro (verde), maduro (amarillo) y pasado (con manchas marrones). Las imágenes fueron capturadas en condiciones controladas de iluminación con el fin de minimizar variaciones por sombras o reflejos.

La calidad de las imágenes fue un factor determinante para el entrenamiento exitoso del modelo. Por ello, se estableció como criterio de inclusión la nitidez y claridad de las muestras. Estudios previos han demostrado que el éxito del aprendizaje profundo en visión artificial depende en gran medida de la calidad y representatividad de los datos de entrada [3], [12].

Las imágenes fueron etiquetadas en dos categorías:

- Plátanos buenos: incluyen los estados verde e intermedio (maduro), considerados comercializables.
- Plátanos malos: incluyen ejemplares con deterioro avanzado, no aptos para la venta.

Esta categorización binaria permite simplificar el proceso de clasificación y facilitar la toma de decisiones automatizada en entornos industriales, como sugieren [2], [4].

2.2. MODELO DE DETECCIÓN Y ENTRENAMIENTO

Se utilizó el modelo YOLOv11, un algoritmo de detección de objetos basado en CNN, conocido por su alta precisión y velocidad de inferencia en tiempo real [13]. YOLO permite realizar detección y clasificación simultáneamente

con gran eficiencia computacional, lo que lo hace ideal para aplicaciones en líneas de producción [14].

Se tomaron un total de 410 imágenes de plátanos capturadas en condiciones controladas de iluminación y fondo neutro. Las imágenes fueron tomadas utilizando una cámara USB de alta resolución, instalada a una altura aproximada de 20 cm sobre la banda transportadora y con un ángulo de inclinación de entre 37° y 45° respecto al plano horizontal, lo que permitió obtener una vista oblicua del fruto para reducir las oclusiones parciales.

Las imágenes se adquirieron bajo iluminación artificial difusa, con una resolución de 1920 × 1080 píxeles, evitando reflejos o sombras que pudieran afectar la detección de contornos y texturas. La banda transportadora operó a una velocidad constante de 0.5 m/s, permitiendo un flujo uniforme de los frutos en el área de escaneo y facilitando la adquisición continua de cuadros para el análisis en tiempo real.

Cada imagen fue procesada mediante técnicas de *data augmentation* para mejorar la robustez del modelo frente a cambios de iluminación, rotación o escala, tal como se recomienda en [15]. Estas técnicas consisten en la modificación artificial de las imágenes originales, generando variaciones plausibles que permiten simular diferentes escenarios de captura sin necesidad de aumentar físicamente el volumen de datos.

Las técnicas de *data augmentation* que se utilizaron fueron las siguientes:

- Flip horizontal, que invierte la imagen en modo espejo, permitiendo que el modelo reconozca los frutos independientemente de su orientación lateral.
- Crop, consistente en un recorte o *zoom* del 15% sobre el área original de la imagen, lo que simula variaciones en la distancia de captura.
- Rotación, mediante giros de $\pm 15^\circ$ hacia la izquierda y hacia la derecha, para reproducir cambios en la orientación del fruto sobre la banda.

Gracias a la aplicación combinada de estas técnicas, el conjunto de datos aumentó de 410 a 824 imágenes, mejorando así la representación de distintas condiciones visuales.

Estas transformaciones se aplicaron de manera aleatoria y combinada durante el proceso de entrenamiento. Según Goodfellow et al. [15], estas técnicas son fundamentales para evitar el sobreajuste (*overfitting*) y aumentar la capacidad del modelo para generalizar a nuevos escenarios no vistos durante el entrenamiento.

Una vez aplicadas las técnicas de *data augmentation*, el conjunto de datos utilizado para el entrenamiento y validación del modelo YOLOv11 estuvo conformado por un total de 824 imágenes.

El conjunto de datos se dividió de la siguiente manera: 621 imágenes (75%) para entrenamiento, 122 imágenes (15%) para validación y 81 imágenes (10%)

para prueba, manteniendo el equilibrio entre clases y garantizando una adecuada generalización del modelo. El entrenamiento se llevó a cabo durante 100 épocas, con un tamaño de lote de 16 imágenes y una tasa de aprendizaje inicial de 0.001. Cada sesión de entrenamiento tuvo una duración aproximada de 40 minutos.


2.3. HARDWARE Y COMPONENTES FÍSICOS

El sistema físico fue montado sobre una banda transportadora comercial, sobre la cual se dispuso la fruta para ser inspeccionada por la cámara. La estructura fue complementada con soportes impresos en 3D para alojar tanto la cámara como el sistema de accionamiento del mecanismo de segregación.

En la fig. 2, se presenta una fotografía del prototipo físico del sistema de visión artificial para la detección no destructiva de plátanos. Se observa una computadora portátil encargada de ejecutar el modelo de detección YOLOv11, una cámara utilizada para capturar las imágenes de los plátanos, y una banda transportadora. Este montaje permite la adquisición de datos en tiempo real y la activación del sistema de clasificación automatizada.

Fig. 2.

Prototipo físico del sistema



La integración entre el software de visión artificial y el sistema físico de segregación se realizó mediante una conexión directa entre Python y Arduino, utilizando como interfaz de comunicación la computadora portátil donde se ejecuta el modelo YOLOv11. La cámara captura imágenes en tiempo real y las envía al sistema en Python, que procesa cada cuadro y determina el estado del plátano con base en la predicción del modelo.


Cuando el algoritmo identifica un plátano en mal estado, se genera una señal digital a través del puerto serial USB que comunica a la computadora con el microcontrolador Arduino UNO. Este actúa como intermediario entre la inteligencia artificial y el mecanismo físico, activando el servomotor encargado de accionar la compuerta del sistema de segregación. De esta forma, la decisión computacional derivada del modelo de detección se traduce en una respuesta mecánica inmediata, lo

que permite la clasificación automatizada de los plátanos sin intervención humana.

El diseño en CAD del mecanismo de segregación del sistema de clasificación de plátanos se presenta en la Fig. 3. Se muestra una compuerta accionada mediante un servomotor, la cual tiene como función desviar los plátanos clasificados como “malos” fuera de la línea principal de transporte. El diseño permite una respuesta rápida y precisa, integrándose directamente al sistema de visión artificial mediante control electrónico sincronizado. La arquitectura de control se diseñó para ser modular y de bajo costo, siguiendo lineamientos similares a los propuestos en [1].

Fig. 3.

Diseño en CAD del mecanismo de segregación



El sistema fue evaluado mediante pruebas con plátanos individuales y en racimos (“manos”), simulando condiciones operativas reales. Se verificó la capacidad del modelo para identificar correctamente las clases objetivo con una tasa de acierto superior al 90% en condiciones controladas. La validación se alineó con metodologías recomendadas por la literatura para sistemas de inspección automatizada [16].

3. RESULTADOS Y DISCUSIÓN

3.1. DESEMPEÑO DEL MODELO YOLOV11 EN CONDICIONES CONTROLADAS

El modelo YOLOv11 fue entrenado a lo largo de 100 épocas utilizando un conjunto de datos exclusivo de imágenes de plátanos divididas en dos clases: “buenos” (etapas verde y madura) y “malos” (etapa pasada o deteriorada).

Para garantizar una evaluación objetiva y confiable del desempeño del modelo de visión artificial, el conjunto de 824 imágenes fue dividido en tres subconjuntos con funciones específicas: entrenamiento, validación y prueba. Esta práctica es estándar en el desarrollo de modelos de aprendizaje automático, ya que permite medir la capacidad de generalización del sistema y prevenir el sobreajuste (overfitting) [15].

- Conjunto de entrenamiento (75%): Incluye la mayoría de las imágenes disponibles. Su función

principal es permitir al modelo aprender los patrones característicos de las clases objetivo (en este caso, plátanos buenos y malos). Durante esta etapa, los pesos de la red neuronal son ajustados mediante un proceso iterativo de retropropagación.

- Conjunto de validación (15%): Se utiliza durante el proceso de entrenamiento, pero no forma parte directa de los datos que el modelo ve para aprender. Su propósito es evaluar el rendimiento del modelo en datos distintos a los de entrenamiento en cada época, lo cual permite detectar signos de sobreajuste y ajustar hiperparámetros como la tasa de aprendizaje, número de épocas, funciones de pérdida, etc.
- Conjunto de prueba (10%): Este subconjunto es completamente independiente y se reserva para una evaluación final del modelo una vez concluido el entrenamiento. Sirve para simular cómo se comportará el sistema frente a nuevos datos no vistos, proporcionando métricas objetivas de desempeño (precisión, recall, F1-score, etc.).

Esta división garantiza que el modelo no solo funcione bien con los datos que conoce (entrenamiento), sino también con casos nuevos y reales, lo cual es esencial para aplicaciones prácticas como la clasificación de frutas en tiempo real.

Para evaluar el rendimiento del modelo de visión artificial, se emplearon métricas estándar ampliamente utilizadas en el ámbito del aprendizaje automático y la visión por computadora. Estas métricas permiten cuantificar la capacidad del sistema para clasificar correctamente los objetos en las categorías definidas (en este caso, plátano “bueno” o “malo”). A continuación, se describen las principales métricas utilizadas:

- Precisión (*Precision*): Mide la proporción de verdaderos positivos entre todas las predicciones positivas realizadas por el modelo. Indica qué tan confiables son las predicciones positivas. La precisión se calcula de la siguiente forma:

$$Precision = \frac{VP}{VP + FP} \quad (1)$$

donde:

VP = Verdaderos positivos,
FP = Falsos positivos.

- Exhaustividad o Sensibilidad (*Recall*): Evalúa la capacidad del modelo para identificar correctamente todos los casos positivos reales. Es decir, cuántos de los plátanos “buenos” fueron

correctamente detectados. Para calcular esta métrica se utiliza la siguiente ecuación:

$$Recall = \frac{VP}{VP + FN} \quad (2)$$

donde:

FN = Falsos negativos.

- Exactitud (*Accuracy*): Representa el porcentaje total de predicciones correctas (positivas y negativas) respecto al total de casos. La fórmula para calcular la exactitud se presente en la ec. (3).

$$Accuracy = \frac{VP + VN}{TOTAL} \quad (3)$$

donde:

VN = Verdaderos negativos,

TOTAL = Total de predicciones.

- Puntuación F1 (*F1-Score*): Es la media armónica entre la precisión y la exhaustividad. Es una métrica equilibrada que resulta útil especialmente cuando existe un desbalance entre clases, y se calcula de la siguiente forma:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Estas métricas proporcionan una visión integral del desempeño del modelo, permitiendo identificar fortalezas y debilidades específicas. En este trabajo, se reportan todas ellas para ofrecer una evaluación completa de la efectividad del sistema propuesto en condiciones reales de operación. Las métricas obtenidas tras finalizar el entrenamiento son las siguientes:


- Precisión (*Precision*): 97.2%
- Exhaustividad (*Recall*): 96.8%
- Exactitud (*Accuracy*): 96.9%
- Puntuación F1 (*F1 Score*): 97.0%

Estas métricas demuestran un desempeño sobresaliente, lo cual valida la hipótesis de que una red neuronal convolucional moderna como YOLOv11, correctamente entrenada con un conjunto de datos específico y representativo, puede clasificar con alta fiabilidad el estado de madurez de frutas como el plátano. Las cifras obtenidas son comparables con resultados de investigaciones similares que aplicaron modelos CNN para clasificación de frutas [17].

Además, se observó que el modelo convergió de manera estable, sin sobreajuste evidente, lo cual se atribuye tanto al equilibrio en las clases del conjunto de datos como al uso adecuado del conjunto de validación. Las curvas de pérdida y precisión durante el entrenamiento mostraron una mejora sostenida, con estabilización hacia la época 85 (ver. Fig. 4).

Fig. 4.

Curvas de pérdida y precisión durante el entrenamiento del modelo



La función de pérdida mide la diferencia entre las predicciones del modelo y las etiquetas reales del conjunto de entrenamiento, y es el parámetro que se minimiza mediante retropropagación en cada iteración. En el caso de YOLOv11, la pérdida es una combinación de varios términos que incluyen errores de localización (*bounding boxes*), clasificación y confianza del objeto detectado [13].

Estos resultados refuerzan la validez del modelo propuesto, evidenciando su eficacia en la clasificación no destructiva de frutos y su potencial de aplicación en líneas de selección automatizadas.

3.2. EVALUACIÓN FUNCIONAL DEL SISTEMA CON ENTRADAS INDIVIDUALES Y AGRUPADAS

Durante las pruebas experimentales se evaluó la capacidad del sistema para identificar correctamente el estado de madurez en dos escenarios:

1. **Pruebas con plátanos individuales:** En esta etapa inicial, los frutos fueron colocados uno a uno sobre la banda transportadora. El sistema demostró una alta sensibilidad para reconocer características visuales como la tonalidad del color, textura y manchas, discriminando con precisión los estados “verde”, “maduro” y “pasado”.

En la fig. 5 se muestra el resultado de la detección automática de plátanos en estado de descomposición. La imagen muestra tres frutos clasificados como “plátanos malos” con una confianza del 100%, evidenciando la capacidad del

sistema para identificar características visuales asociadas a deterioro avanzado, como manchas oscuras, textura irregular y cambios de coloración. Las cajas delimitadoras verdes indican la segmentación precisa realizada por la red neuronal durante la inferencia.

Fig. 5.

Resultado de pruebas con plátanos individuales



En la fig. 6 del anexo, se presentan los resultados de la detección de plátanos clasificados como “buenos” por el modelo YOLOv11. Se observa que ambos frutos fueron identificados correctamente con una confianza del 100%, lo que evidencia la capacidad del sistema para reconocer características visuales asociadas al estado óptimo de madurez, tales como color homogéneo y ausencia de manchas significativas. Este resultado confirma la robustez del modelo en escenarios de iluminación controlada y con objetos aislados, reforzando la validez de su aplicación en la clasificación automática durante el proceso de empaque.

Al comparar los resultados obtenidos en las pruebas con plátanos clasificados como “malos” (Fig. 5) y aquellos identificados como “buenos” (Fig. 6), se confirma la capacidad del modelo YOLOv11 para discriminar entre diferentes estados de maduración con altos niveles de confianza. En ambos casos, el sistema alcanzó un 100% de certeza en la predicción, lo que indica una correcta extracción de características visuales relevantes como la coloración, presencia de manchas oscuras y textura superficial.

Mientras que en los plátanos en buen estado se destacan tonalidades verdes o amarillas uniformes, en los plátanos deteriorados predominan áreas con oscurecimiento irregular y pérdida de firmeza, factores que el modelo logra identificar consistentemente. Este contraste en los resultados evidencia la eficacia del sistema para diferenciar condiciones extremas de madurez, aunque se mantiene la necesidad de refinar la clasificación en estados intermedios, donde la frontera entre categorías no siempre es visualmente evidente.

2. **Pruebas con racimos (“manos”) de plátanos:** Esta segunda etapa simuló condiciones más

cercanas a un entorno productivo real, donde los plátanos llegan agrupados. A pesar del mayor nivel de complejidad visual, el sistema logró identificar correctamente la mayoría de los frutos en el racimo. Las métricas se mantuvieron dentro del rango de error esperado, con una leve reducción del recall ($\approx 94.7\%$), atribuida a la oclusión parcial de algunos plátanos.

El resultado de la clasificación simultánea de plátanos con diferente grado de madurez se muestra en la Fig. 7 del anexo. El sistema identifica correctamente un plátano bueno (verde) y un plátano malo (pasado) con una confianza del 100% en ambos casos. Esta imagen demuestra la capacidad del modelo para realizar detecciones múltiples dentro del mismo encuadre, discriminando entre clases incluso cuando los objetos están parcialmente superpuestos.

En ambas configuraciones, la activación del mecanismo de segregación se sincronizó adecuadamente con las predicciones de la IA, lo que indica que la comunicación entre el modelo y el actuador fue estable y eficiente.

3.3. ROBUSTEZ FRENTE A VARIACIONES EN CONDICIONES

En una serie de pruebas controladas se evaluó la sensibilidad del sistema ante variaciones en la iluminación ambiental, ángulos de cámara y distancias de visualización. Se identificó que:

- Bajo condiciones óptimas de iluminación (luz difusa y estable), la detección se mantuvo precisa y veloz.
- En condiciones de contraluz o sombra marcada, la precisión disminuyó hasta en un 8%, especialmente en plátanos parcialmente maduros.
- Cambios bruscos en la distancia o enfoque afectaron la nitidez de la imagen, lo que ocasionó errores puntuales de clasificación.

Estos hallazgos concuerdan con lo reportado por Saragih et al. [18], quienes resaltaron la importancia de mantener condiciones controladas de iluminación y enfoque en sistemas de visión artificial aplicados a clasificación de frutas en movimiento.

3.4. ANÁLISIS DE ERRORES Y POSIBLES MEJORAS

Se identificaron errores de clasificación en menos del 4% de los casos. Estos errores se concentraron en:

- Frutas parcialmente cubiertas o en posiciones anguladas.

- Plátanos con estados intermedios difíciles de clasificar visualmente (verde-maduro o maduro-pasado).

Estos errores se consideran justificados debido a que las **oclusiones parciales** y los **ángulos de observación no frontales** reducen la cantidad de información visual disponible para el modelo, dificultando la correcta identificación de características relevantes como color, textura o contorno. Asimismo, los **estados intermedios de maduración** presentan transiciones graduales en la apariencia del fruto, lo que genera ambigüedad incluso para un observador humano. En consecuencia, es esperable que un sistema de visión artificial registre cierto margen de error en estos escenarios límite, los cuales constituyen casos particularmente complejos dentro de la clasificación automática de plátanos.

Para mitigar estos errores, se propone:

- Ampliar el conjunto de datos con más ejemplos en condiciones adversas. Por ejemplo: recopilar imágenes con oclusiones parciales, ángulos extremos y fondos variados.
- Incorporar técnicas de *data augmentation* específicas para simular rotaciones, sombras o reflejos.
- Optimizar el ángulo y posición de la cámara para mejorar la visibilidad constante de los objetos.
- Iluminación controlada: difusores, túnel negro y filtros polarizadores para minimizar brillos/sombras.
- Cámara: fijar exposición/balance de blancos; aumentar resolución útil para texturas finas.
- Multivista: 2 cámaras a 90° (o espejo perimetral) para reducir oclusiones sin mover la fruta.

4. CONCLUSIONES

La presente investigación ha demostrado la viabilidad técnica y funcional de un sistema de visión artificial basado en inteligencia artificial, específicamente mediante el uso del modelo YOLOv11, para la detección no destructiva del estado de madurez de plátanos. La combinación de técnicas avanzadas de aprendizaje profundo, un conjunto de datos bien estructurado y una implementación física eficiente permitió desarrollar un prototipo capaz de operar con alta precisión en condiciones controladas.

Los resultados obtenidos, con métricas superiores al 96% en precisión, exactitud y puntuación F1, validan la hipótesis inicial: una inteligencia artificial bien entrenada puede superar las limitaciones de la inspección visual manual, reduciendo errores, mejorando la consistencia de la clasificación y aumentando la velocidad de procesamiento. La implementación del sistema sobre una banda transportadora, junto con mecanismos de

segregación automatizados, confirma su aplicabilidad práctica en entornos industriales reales.

Asimismo, se comprobó que el modelo mantiene un buen desempeño frente a variaciones en la presentación del objeto, aunque se identificaron ciertas limitaciones bajo condiciones de iluminación desfavorable o en la presencia de oclusión parcial de los frutos. Estas observaciones abren la puerta a mejoras futuras mediante el enriquecimiento del *dataset*, técnicas de *data augmentation* y el ajuste de parámetros de adquisición de imágenes.

Desde una perspectiva aplicada, este desarrollo representa un avance hacia la automatización inteligente del control de calidad en la agroindustria, contribuyendo a la reducción de pérdidas postcosecha y al aseguramiento de la calidad en productos perecederos. Su enfoque modular y de bajo costo lo convierte en una alternativa escalable, adaptable a otros tipos de frutas y productos hortofrutícolas, así como a sistemas más complejos integrados con robótica e IoT.

El sistema propuesto no solo demuestra un alto grado de precisión técnica, sino que también sienta las bases para futuras implementaciones industriales orientadas a la sostenibilidad, eficiencia operativa y mejora continua en la cadena de valor agroalimentaria.

REFERENCIAS

- [1] D. Escobar Figueroa y E. Roa Guerrero, «Sistema de visión artificial para la identificación del estado de madurez de frutas (granadilla)», *Redes de Ingeniería*, vol. 7, n.º 1, pp. 78-86, jun. 2016, <https://doi.org/10.14483/udistrital.jour.redes.2016.1.a08>.
- [2] L. O. Villarreal Ger, «Prototipo para la detección y clasificación de productos alimenticios mediante visión artificial en base al color», *Conectividad*, vol. 5, n.º 2, pp. 46-62, feb. 2024, <https://doi.org/10.37431/conectividad.v5i2.129>.
- [3] K. Yu *et al.*, «Advances in Computer Vision and Spectroscopy Techniques for Non-Destructive Quality Assessment of Citrus Fruits: A Comprehensive Review», *Foods*, vol. 14, n.º 3, p. 386, ene. 2025, <https://doi.org/10.3390/foods14030386>.
- [4] R. Sucari León, Y. Aroquipa Durán, L. D. Quina Quina, y E. Quispe Yapó, «Visión artificial en reconocimiento de patrones para clasificación de frutas en agronegocios», *PURIQ*, vol. 2, n.º 2, abr. 2020, [En línea]. Disponible en: https://www.researchgate.net/publication/340571315_Vision_artificial_en_reconocimiento_de_patrones_para_clasificacion_de_frutas_en_agronegocios
- [5] G. Madasamy Raja, P. Selvaraju, P. Pathmanaban, y C. G. Manuvel Antony, «YOLOv11n for precision agriculture: lightweight and efficient detection of guava defects across diverse conditions», *Journal of the Science of Food and Agriculture*, vol. 105, n.º 11, pp. 6182-6195, may 2025, <https://doi.org/10.1002/jsfa.14331>.
- [6] G. Shanmugam, D. Balusamy, K. R. KavinSubash, S. Ajay, y K. Gokul, «Sustainable Agriculture with Advanced Plant Disease Detection using YOLOv11 and XAI», presentado en 2025 IEEE 14th International Conference on Communication Systems and Network Technologies (CSNT), Bhopal, India, mar. 2025, pp. 598-603. <https://doi.org/10.1109/CSNT64827.2025.10968901>.
- [7] M. Al Husaini, A. R. Raharja, V. H. C. Putra, y H. H. Lukmana, «Enhanced Plant Disease Detection Using Computer Vision YOLOv11: Pre-Trained Neural Network Model Application», *Journal of Computer Networks, Architecture and High Performance Computing*, vol. 7, n.º 1, pp. 82-95, 2025.
- [8] A. Fahriansyah, P. M. El Zaky, L. Novamizanti, y S. Sa'idah, «YOLOv11 for Classification of Strawberry Quality and Ripeness», presentado en 2025 IEEE International Conference on Artificial Intelligence for Learning and Optimization (ICoAILO), Bali, Indonesia, ago. 2025, pp. 93-99. <https://doi.org/10.1109/ICoAILO66760.2025.11156057>.
- [9] S. M. Shendkar, R. V. Shimpi, A. S. Todmal, C. Sukte, P. Futane, y M. Kodmelwa, «Utilizing YOLOv10 and YOLOv11 for Tomato Ripeness Detection in Vertical Farming», *Advances in Nonlinear Variational Inequalities*, vol. 28, n.º 5s, pp. 290-302, ene. 2025, <https://doi.org/10.52783/anvi.v28.3905>.
- [10] A. B. Shaik, A. K. Kandula, G. K. Tirumalasetti, B. Yendluri, y H. K. Kalluri, «Comparative Analysis of YOLOv11 and YOLOv12 for Automated Weed Detection in Precision Agriculture», presentado en 2025 5th International Conference on Pervasive Computing and Social Networking (ICPCSN), Salem, India, may 2025, pp. 787-793. <https://doi.org/10.1109/ICPCSN65854.2025.11036078>.
- [11] A. C. Ferreira *et al.*, «Aplicando o Modelo YOLOv11 para Detectar e Segmentar Viveiros de Camarão em Imagens Georreferenciadas», presentado en XVI Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais, Maceió, Brasil: SBC, jul. 2025, pp. 30-38. <https://doi.org/10.5753/wcama.2025.7190>.
- [12] L. Pencue-Fierro y J. León Téllez, «Detección y clasificación de defectos en frutas mediante el procesamiento digital de imágenes», *Revista Colombiana de Física*, vol. 35, n.º 1, enero de 2003. [En línea]. Disponible en: https://www.researchgate.net/publication/238095132_Deteccion_y_clasificacion_de_defectos_en_frutas_mediante_el_procesamiento_digital_de_imagenes
- [13] Ultralytics, «YOLOv11 Documentation». Accedido: 22 de mayo de 2025. [En línea]. Disponible en: <https://docs.ultralytics.com/es/models/yolo11>

- [14] J. Redmon, S. Divvala, R. Girshick, y A. Farhadi, «You Only Look Once: Unified, Real-Time Object Detection», 9 de mayo de 2016, arXiv:1506. Accedido: 22 de mayo de 2025. [En línea]. Disponible en: <https://arxiv.org/abs/1506.02640>
- [15] I. Goodfellow, Y. Bengio, y A. Courville, *Deep Learning*. en Adaptive Computation and Machine Learning series. MIT Press, 2016. [En línea]. Disponible en: <https://mitpress.mit.edu/9780262035613/deep-learning/>
- [16] E. Saldaña, R. Siche, M. Luján, y R. Quevedo, «Review: computer vision applied to the inspection and quality control of fruits and vegetables Review: computer vision applied to the inspection and quality control of fruits and vegetables», *Brazilian Journal of Food Technology*, vol. 16, n.º 4, diciembre de 2013. [En línea]. <https://doi.org/10.1590/S1981-67232013005000031>
- [17] L. Yang *et al.*, «Automatic Detection of Banana Maturity—Application of Image Recognition in Agricultural Production», *Processes*, vol. 12, n.º 4, p. 799, abril de 2024.
- [18] R. E. Saragih, A. R. Purnajaya, I. Syafrinal, Y. Fernando, y Yodi, «Mango and Banana Ripeness Detection based on Lightweight YOLOv8», *Jurnal Buana Informatika*, vol. 15, n.º 2, pp. 79-88, oct. 2024.

ANEXOS

Fig. 6.

Resultado de pruebas con plátanos individuales




Fig. 7.

Resultado de pruebas con plátanos en racimos

