

Desarrollo de un sistema de visión artificial con redes neuronales convolucionales (yolov8) para la gestión de calidad de paltas

Ryan A LEÓN LEÓN

Docente de Ingeniería industrial, Universidad Privada del Norte
Trujillo, 13006, Perú

Bradley R ESPEJO PÓCITO

Ingeniería industrial, Universidad Privada del Norte
Trujillo, 13006, Perú

Edgardo F GUZMÁN CÓRDOVA

Ingeniería industrial, Universidad Privada del Norte
Trujillo, 13006, Perú

Flavio A HUAMANCHUMO CORTEZ

Ingeniería industrial, Universidad Privada del Norte
Trujillo, 13006, Perú

Harold A MORALES RODRIGUEZ

Ingeniería industrial, Universidad Privada del Norte
Trujillo, 13006, Perú

Pamela C NUÑEZ FLORES

Ingeniería industrial, Universidad Privada del Norte
Trujillo, 13006, Perú

RESUMEN: El proyecto se centra en el desarrollo de un sistema de visión artificial basado en redes neuronales convolucionales (YOLOv8) para la gestión de calidad de paltas. Los objetivos principales son mejorar la precisión y eficiencia en la inspección de las paltas, optimizar la selección y reducir el desperdicio de productos. Se utilizaron 700 imágenes de paltas capturadas con una cámara de alta resolución, variando condiciones de iluminación y ángulos. Se etiquetaron según su madurez en Roboflow, y se aplicaron técnicas de aumentación de datos. El modelo YOLOv8 se entrenó en Google Colab con una GPU Tesla T4, ajustando parámetros como tamaño de batch y tasa de aprendizaje durante 150 ciclos. Se evaluó con un conjunto de datos de prueba y se implementó un algoritmo en Python en PyCharm para evaluar la madurez de las paltas, utilizando Google Drive para almacenar datos y modelos. Los resultados obtenidos mostraron que el modelo YOLOv8 tiene alta precisión en la clasificación de paltas. La precisión del modelo osciló entre 86% y 95% para la categoría "bueno" y entre 86% y 90% para la categoría "malo".

Palabras Claves: Visión artificial, redes neuronales convolucionales (YOLOv8), Roboflow.

Development of an artificial vision system with convolutional neural networks (YOLOv8) for quality management of avocados

ABSTRACT: The project focuses on the development of an artificial vision system based on convolutional neural networks (YOLOv8) for the quality management of avocados. The main objectives are to improve accuracy and efficiency in avocado inspection, optimize selection and reduce product waste. 700 images of avocados captured with a high-resolution camera were used, varying lighting conditions and angles. They were labeled according to their maturity in Roboflow, and data augmentation techniques were applied. The YOLOv8 model was trained on Google Colab with a Tesla T4 GPU, adjusting parameters such as batch size and learning rate for 150 cycles. It was evaluated

with a test data set and a Python algorithm was implemented in PyCharm to evaluate the maturity of the avocados, using Google Drive to store data and models. The results obtained show that the YOLOv8 model has high accuracy in avocado classification. Model accuracy ranged from 86% to 95% for the "good" category and 86% to 90% for the "bad" category.

Keywords: Artificial vision, convolutional neural networks (YOLOv8), Roboflow.

1. INTRODUCCIÓN

La gestión de calidad de las paltas enfrenta desafíos significativos debido a la necesidad de evaluar múltiples aspectos de cada fruta, como su tamaño, forma, color, textura y madurez, de manera precisa y eficiente. El proceso actual de inspección y clasificación manual de paltas es propenso a errores humanos, lo que puede resultar en la selección incorrecta de frutas de baja calidad para la comercialización. Esto conduce a pérdidas económicas tanto para los productores como para los consumidores finales. Además, la detección temprana de defectos en la fruta es fundamental para garantizar la calidad y la competitividad del producto en el mercado. Sin embargo, este proceso manual puede ser lento y costoso, especialmente al manipular grandes volúmenes de frutas. El desarrollo de un sistema de visión artificial con redes neuronales convolucionales, como YOLOv8, para la gestión de calidad de paltas es esencial para abordar estos desafíos. Este sistema permitirá una inspección automatizada y precisa de cada palta, optimizando la selección y reduciendo el desperdicio de productos. Además, facilitará la identificación rápida de defectos y características de calidad, agilizando el proceso de clasificación y garantizando que solo las paltas de la más alta calidad lleguen al mercado, mejorando así la rentabilidad y la satisfacción del cliente. Los sistemas de visión artificial son capaces de medir con precisión el tamaño y la forma de las paltas para determinar si cumplen con las especificaciones de comercialización [1].

También pueden evaluar el estado de madurez basándose en el color y la textura de la piel, lo cual es crucial para el sabor y la durabilidad de la fruta [2, 3]. Así mismo, pueden detectar defectos visibles como magulladuras, manchas, grietas o daños en la piel, permitiendo separar las frutas de calidad inferior antes de su distribución al mercado. [4, 5]. La visión artificial utiliza redes neuronales para reconocer imágenes como lo hacen los humanos, dentro del campo del machine learning (ML). El ML busca desarrollar sistemas que aprendan automáticamente y predigan comportamientos a partir de datos, utilizando herramientas como las redes neuronales artificiales (ANNs) y el aprendizaje profundo (DL) [6]. Las redes neuronales convolucionales (CNN) son especialmente útiles en el análisis de calidad para el procesamiento de imágenes y la visión por computadora [7, 8]. Es así, que, en la actualidad, se utilizan diversas técnicas de visión por computadora y aprendizaje profundo para analizar imágenes de paltas y evaluar su calidad [9]. Se destaca el uso de YOLO (You Only Look Once) para la detección de calidad, un framework que aborda la detección de objetos como un problema de regresión única [10].

Para la implementación del software de detección de calidad, se utiliza Python, un lenguaje de programación versátil y popular conocido por su simplicidad y su sintaxis intuitiva [11, 12]. Investigaciones previas han validado la eficacia de las redes neuronales convolucionales en la detección y clasificación de objetos en imágenes, incluyendo frutas y vegetales. Modelos como YOLO se destacan por su habilidad para identificar características específicas de las paltas, como tamaño, forma, color y madurez, con alta precisión y eficiencia computacional [13]. Además, la visión artificial ha sido aplicada exitosamente en la gestión de calidad de productos agrícolas, permitiendo la detección temprana de defectos, la clasificación automática según estándares de calidad y la optimización de procesos de selección y empaquetado [14]. Por ejemplo, en un estudio reciente se diseñó un sistema automatizado para la clasificación precisa de paltas Hass maduras, inmaduras y sobremaduras, utilizando una red neuronal entrenada con YOLO V5, con simulación incluida en Factory Portal IO. Esta propuesta permitió un reconocimiento del 100% de los aguacates, facilitando la clasificación automática y el conteo [15]. Por otro lado, otro estudio se enfocó en desarrollar un sistema de clasificación de madurez de paltas utilizando Graph Neural Network, un algoritmo de aprendizaje profundo, similar a Convolutional Neural Network. Se creó un conjunto de datos de 400 imágenes de aguacates para entrenar y verificar el modelo, logrando con éxito clasificar la madurez con una precisión del 97.75% [16]. Estos enfoques demuestran la potencialidad de diversas técnicas de aprendizaje automático aplicadas a la agricultura, abriendo nuevas posibilidades para mejorar la gestión y calidad de los cultivos a través de la inteligencia artificial. La visión artificial ofrece una herramienta poderosa para automatizar y mejorar la evaluación de la calidad de las paltas, permitiendo una selección más precisa y eficiente de la fruta en diferentes etapas de producción y comercialización. La aplicación de redes neuronales convolucionales abre nuevas posibilidades para mejorar la eficiencia y la calidad en la cadena de suministro de paltas, beneficiando a productores, distribuidores y consumidores.

En esta investigación se busca desarrollar un sistema de visión artificial con redes neuronales convolucionales (yolov8) para la gestión de calidad de paltas. Así como también, entrenar un modelo de red neuronal convolucional basado en YOLOv8 e implementar data set con imágenes de alta resolución de paltas en diferentes estados de madurez y calidad.

2. MATERIALES Y MÉTODOS

Para la etapa inicial del proyecto se utilizó la plataforma Roboflow, que se centró en recopilar y etiquetar imágenes de paltas para gestionar su calidad. Se capturaron 466 imágenes de paltas utilizando una cámara de alta resolución, asegurando la diversidad del conjunto de datos mediante la variación de condiciones de iluminación y ángulos de captura. La metodología empleada se basa en una investigación previa sobre la clasificación de la calidad de frutas, la cual utilizó 700 imágenes como referencia [17]. Se decidió entrenar el modelo con imágenes de alta calidad y nitidez para obtener resultados más favorables y eficientes. Esta decisión se basa en la evolución significativa de las redes neuronales en los últimos años, las cuales han mejorado su capacidad para aprender rápidamente. En la selección de imágenes, se eliminaron aquellas que no cumplían con los estándares de calidad o que estaban duplicadas. En la etapa de etiquetado, se utilizaron herramientas gráficas para identificar el estado de madurez de las paltas mediante Roboflow (Figura. 1) del total de las imágenes para el entrenamiento se dividieron en 85% para el entrenamiento, 10% para la validación y 5% para el testeo. El color y la textura de las paltas son fundamentales para la clasificación, ya que el software detecta y marca las paltas en las imágenes, asignándoles etiquetas como "madura", "inmadura" y "sobremadura". Esta clasificación visual permite al modelo aprender a diferenciar con precisión entre los distintos estados de madurez de las paltas, tal como indican estudios recientes [18,19]. Adicionalmente, se implementaron técnicas de aumentación de datos, incluyendo rotación y ajuste de brillo y contraste, para aumentar la variabilidad y robustez del conjunto de datos. Las características recopiladas se basaron en criterios visuales y morfológicos como el color, tamaño y textura de las paltas. Un rasgo distintivo para identificar una palta madura es su color uniforme y su textura suave, mientras que las paltas inmaduras suelen presentar un color más claro y una textura más firme, y las paltas sobre maduras pueden mostrar manchas y una textura blanda. Esta información es fundamental para el entrenamiento de la red neuronal.

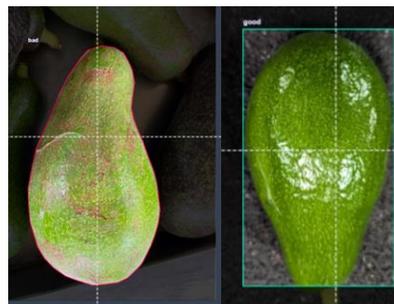


Figura 1: Etiquetado de paltas mediante el software Roboflow, destacando características como el color, tamaño y textura para identificar la calidad de las paltas.

YOLO (You Only Look Once) es una serie de modelos de redes neuronales convolucionales (CNN) empleada para la detección de objetos en imágenes y videos en tiempo real [20]. En este proyecto, se utilizó la versión YOLOv8, la iteración más reciente de esta tecnología, reconocida por su alta precisión y eficiencia. YOLOv8 se basa en una arquitectura de red neuronal convolucional, que permite la detección de objetos con una sola pasada a través de la red, en lugar de realizar múltiples etapas de procesamiento como en otros métodos. Esta elección se justifica en una investigación reciente donde se usó YOLOv8,

demostrando su superioridad en términos de precisión y velocidad en comparación con versiones anteriores y otros modelos de detección de objetos [20]. Dicha arquitectura se caracteriza por:
 Convoluciones: Estas capas extraen características importantes de las imágenes mediante el uso de filtros que detectan bordes, texturas y patrones. Capas de Anclaje: YOLOv8 utiliza cajas de anclaje predefinidas para predecir la ubicación y el tamaño de los objetos en la imagen [20]. Las coordenadas predichas para una caja de anclaje.

La identificación del punto óptimo de maduración b_x (Ec. 1) se realiza ajustando la coordenada x del centro de la región de interés mediante la aplicación de una función de activación sigmooidal (σ) a la predicción de madurez (tx) obtenida de la red neuronal, sumando luego la posición relativa a la celda de la cuadrícula (cx), lo que facilita la localización precisa del punto óptimo de maduración en la dimensión horizontal. Para la evaluación vertical de la maduración b_y (Ec. 2), se determina la coordenada y del punto de interés aplicando la función de activación sigmooidal (σ) a la predicción vertical (ty) de maduración y ajustando la posición vertical respecto a la celda de la cuadrícula (cy), asegurando así una evaluación precisa de la maduración en la dimensión vertical. El ajuste dinámico del grosor b_w (Ec. 3) se calcula mediante una función exponencial aplicada a la predicción de grosor (tw), que es multiplicada por el grosor estándar predefinido, permitiendo adaptar dinámicamente el grosor de la región de interés según la predicción de la red. De manera análoga, la evaluación dinámica de la calidad b_h (Ec. 4) determina la altura de la región de interés mediante una función exponencial aplicada a la predicción de altura (th), multiplicada por la altura estándar predefinida, logrando así una evaluación dinámica de la calidad basada en la predicción de la red neuronal.

$$b_x = \sigma(tx) + cx \quad (1)$$

$$b_y = \sigma(ty) + cy \quad (2)$$

$$b_w = pw e^{tw} \quad (3)$$

$$b_h = ph e^{th} \quad (4)$$

Predicción Simultánea: A diferencia de otros métodos que primero generan propuestas de regiones y luego clasifican, YOLOv8 realiza la predicción de las clases y las ubicaciones de los objetos simultáneamente, lo que mejora la velocidad y la eficiencia.

Función de Pérdida (Ec.5). La función de pérdida de YOLOv8 combina la precisión de la clasificación y la precisión de la localización en un único valor escalar, optimizando así ambos aspectos durante el entrenamiento. La pérdida total L se define como:

$$L = L_{loc} + L_{conf} + L_{cls} \quad (5)$$

L_{loc} es la pérdida de localización, que mide el error en las predicciones de las coordenadas de las cajas. L_{conf} es la pérdida de confianza, que mide el error en las predicciones de la confianza de que una caja contiene un objeto y L_{cls} es la pérdida de clasificación, que mide el error en las predicciones de las clases de los objetos.

La arquitectura YOLOv8 ver (Figura. 2), ejecuta un proceso preciso para categorizar la calidad de las paltas en niveles como excelente, aceptable y no apta, con una alta exactitud y eficiencia. Comienza con el Backbone, una fase inicial de la red que analiza la imagen de las paltas para extraer características visuales clave, como color y textura. Durante este paso, los filtros

convolucionales del Backbone detectan rasgos específicos relacionados con la calidad de las paltas, como la coloración dorada para las de alta calidad y la presencia de irregularidades para las de baja calidad. Estas características son posteriormente refinadas en el Neck, donde se fusionan y combinan para formar representaciones más elaboradas y detalladas de la calidad.

En la etapa de Predicción, estas representaciones se utilizan para generar resultados específicos sobre la calidad de las paltas en la imagen. La red examina las características extraídas en busca de señales distintivas de calidad, como uniformidad en el color y ausencia de defectos para las paltas de alta calidad. Estos criterios son aprendidos y codificados por los filtros de la red durante el entrenamiento. Como resultado, YOLOv8 puede identificar de manera precisa las paltas de alta calidad en la imagen, proporcionando información detallada sobre su ubicación y clasificación. Este enfoque metódico y detallado garantiza una evaluación precisa y confiable de la calidad de las paltas, lo que puede ser crucial en aplicaciones agrícolas para mejorar la selección y manejo de la fruta. La convolución es un proceso matemático que fusiona dos conjuntos de datos. En el ámbito de las redes neuronales convolucionales (CNN), implica aplicar un filtro (o kernel) a una imagen para extraer características esenciales [21]. Este filtro se desplaza sobre la imagen de entrada y, en cada posición, genera un valor de salida mediante una suma ponderada de los valores de la imagen y los del filtro. Durante el entrenamiento de YOLOv8, las capas convolucionales se emplean para extraer características visuales clave de las imágenes de paltas. Estas características pueden abarcar bordes, texturas, colores y formas que indican los diferentes estados de madurez.

Las funciones de activación son esenciales para que el modelo aprenda y realice predicciones precisas. La función Sigmoid es especialmente útil en la última capa de la red neuronal para la tarea de clasificación binaria, ya que transforma las salidas en probabilidades entre 0 y 1. Esto permite que el modelo determine la probabilidad de que una palta sea "buena" o "mala". La función Tanh, que transforma las salidas a un rango entre -1 y 1, es beneficiosa en las capas ocultas al centrar los datos en torno a cero, lo cual facilita la convergencia del modelo durante el entrenamiento. Esto ayuda a la red a aprender mejor las diferencias sutiles entre paltas buenas y malas. La función ReLU (Rectified Linear Unit) es ampliamente utilizada en YOLOv8 para mitigar el problema del desvanecimiento del gradiente. Establece los valores negativos en 0 y deja los valores positivos sin cambios, lo que permite una propagación de gradientes más eficiente y activa las neuronas de manera efectiva. Esto es crucial para detectar características complejas y variadas en las imágenes de paltas. La función Leaky ReLU, una variación de la ReLU, permite un pequeño gradiente cuando la entrada es negativa, evitando que las neuronas queden completamente inactivas. Esto es importante para mantener la capacidad de la red de aprender características relevantes de las paltas en diferentes condiciones y estados de calidad.

Los filtros de convolución representan matrices pequeñas que se aplican a las imágenes. Cada filtro es entrenado para reconocer rasgos particulares. Investigaciones anteriores han evidenciado su efectividad en la identificación y detección de distintos atributos en paltas, resaltando su utilidad [22]. En el ámbito de las paltas, algunos filtros pueden ser entrenados para reconocer el color uniforme de una palta, mientras que otros pueden ser capacitados para identificar texturas o manchas de las paltas. Con el fin de adiestrar el modelo YOLOv8, se hizo uso de la capacidad de

cómputo proporcionada por Google Colab, que brinda recursos especializados para el adiestramiento de redes neuronales, incluyendo GPUs. Concretamente, se empleó una GPU Tesla T4 con 15 GB de memoria, que es compatible con CUDA, lo que posibilitó una notable aceleración del proceso de adiestramiento. La potencia de procesamiento de esta GPU garantizó una pronta convergencia del modelo y tiempos de adiestramiento eficaces. Para el entrenamiento se llevó a cabo el siguiente proceso, en el cual se requirió llegar a más del 98% de precisión. Al establecer el entorno en Google Colab, se importaron las bibliotecas necesarias como torch y yolov8 para el desarrollo y entrenamiento del modelo [23]. PyTorch, importado como torch, es una biblioteca de código abierto muy popular para el aprendizaje profundo. Es especialmente conocida por su facilidad de uso y flexibilidad, lo que la hace ideal para la investigación y el desarrollo de modelos de redes neuronales.

Su eficacia y versatilidad han sido respaldadas por numerosas revisiones [23,24]. Además, se montó Google Drive para facilitar el almacenamiento y acceso a los conjuntos de datos y modelos. La fase de adiestramiento se realizó en Google Colab, donde se obtuvieron los datos etiquetados desde Roboflow y se

incorporaron al entorno de trabajo. Luego, se ajustó el modelo YOLOv8 configurando parámetros tales como el tamaño del grupo, la tasa de aprendizaje y el número de ciclos, estableciendo este último en un total de 150. Esta elección se basó en investigaciones previas que validaron la eficacia de este número de ciclos para optimizar el rendimiento del modelo. A lo largo del adiestramiento, se supervisaron medidas como la pérdida de entrenamiento y la precisión en el conjunto de validación, lo que permitió realizar ajustes en los hiperparámetros según fuera necesario para mejorar el desempeño del modelo.

Una vez concluido el proceso de entrenamiento, se sometió el modelo a una evaluación utilizando un conjunto de datos de prueba independiente. Esto se hizo con el fin de evitar el sobreajuste y confirmar la capacidad del modelo para generalizar a datos no vistos previamente. Este enfoque aseguró la robustez y precisión del modelo en la detección de la calidad de las paltas. Para poner en práctica el algoritmo de evaluación de la madurez de las paltas, se optó por Python en el marco de desarrollo PyCharm. Se preparó PyCharm con un entorno virtual y se procedió a instalar los componentes necesarios, entre ellos opencv-python y pytorch [23].

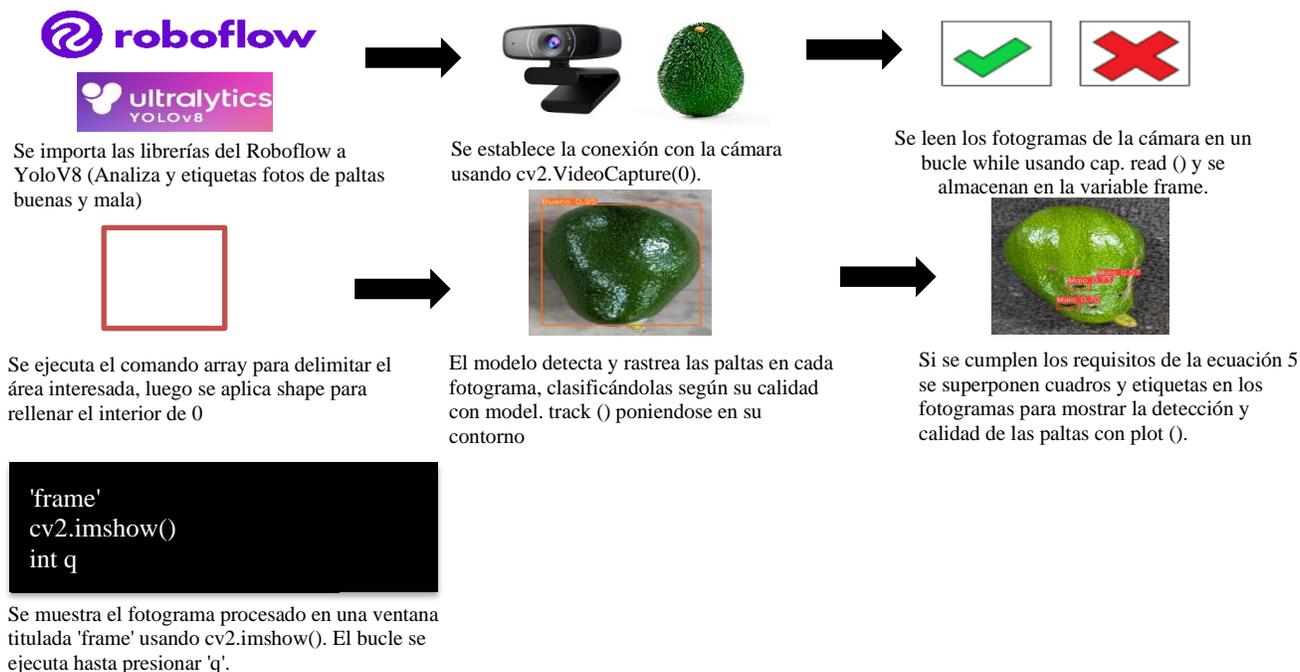


Figura 2: Diagrama de bloques de cada etapa del algoritmo principal de YOLOv8. Describe paso a paso el proceso de detección, seguimiento y visualización de paltas mediante el uso de un modelo YOLOv8, desde la inicialización del modelo y la cámara hasta la visualización en tiempo real de los resultados

Para utilizar el algoritmo principal de YOLOv8 y visualizar los resultados de la detección de paltas en tiempo real, se implementó un proceso estructurado que abarcó una serie de pasos meticulosamente definidos, los cuales se presentan en la Figura 2. Estos pasos fueron establecidos luego del exhaustivo entrenamiento y programación del modelo YOLOv8, asegurando un rendimiento óptimo. El proceso comenzó con la inicialización del modelo, donde se cargaron los pesos entrenados de YOLOv8 y se configuraron los parámetros necesarios para la detección. Posteriormente, se procedió a la configuración de la cámara o la

carga de imágenes desde el sistema de archivos, dependiendo de la fuente de datos elegida para el análisis.

Una vez configurada la entrada de datos, se inició la captura y procesamiento de las imágenes en tiempo real. Aquí, el modelo YOLOv8 realizó la detección y clasificación de las paltas en cada cuadro, identificando su calidad según las categorías predeterminadas ("Apto para exportar" y "No apto para exportar"). Finalmente, los resultados de la detección fueron visualizados sobre las imágenes originales, utilizando cuadros delimitadores y etiquetas que indicaban la calidad de cada palta

detectada. Esta visualización en tiempo real permitió una evaluación inmediata y precisa de la clasificación, facilitando la toma de decisiones basadas en la calidad de las paltas analizadas. Se importó el modelo entrenado de YOLOv8 y se diseñó un script en Python específicamente para analizar imágenes de paltas, ya fueran capturadas en tiempo real desde una cámara o cargadas desde el sistema de archivos. El proceso de análisis comenzó con la aplicación del modelo YOLOv8, que se encargó de detectar y clasificar las paltas en las imágenes basándose en su calidad. Las categorías establecidas fueron: "Apto para exportar" y "No apto para exportar". Los resultados del análisis se presentaron de manera visual, utilizando cuadros delimitadores que enmarcaron las paltas identificadas, junto con etiquetas que indicaban la clasificación correspondiente. Estos resultados se superpusieron a las imágenes originales, proporcionando una representación clara y directa de las detecciones realizadas, como se puede apreciar en la (Figura 3), que muestra la prueba de precisión de la red neuronal.



Figura 3: Evaluación de la precisión de la red neuronal en la clasificación de paltas en buenas y malas utilizando un conjunto de datos de prueba como parte de la gestión de la calidad.

Después de desarrollar un sistema de visión artificial con redes neuronales convolucionales (YOLOv8) para la gestión de calidad de paltas, se implementó un ambiente controlado para mejorar la visualización de las paltas (Figura 4). Esto permitió identificar defectos de manera más clara y eficiente, aumentando así la efectividad del sistema.

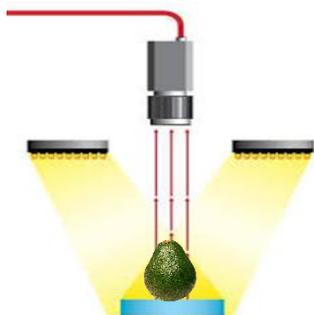


Figura 4: El espacio controlado está representado por una superficie cúbica con dimensiones de 50 cm por lado.

3. RESULTADOS

Se observa que 154 instancias de "Bueno", 161 de "Malo" y 0 de "Falsos Positivos" fueron correctamente clasificadas. Sin embargo, se cometieron errores: 0 instancias de "Bueno" fueron

etiquetadas como "Malo", 151 como "Falsos Positivos"; 0 instancias de "Malo" como "Bueno", 15 como "Falsos Positivos"; y 15 instancias de "Falsos Positivos" como "Bueno", 97 como "Malo". Estos resultados indican que, aunque el modelo tiene alta precisión en la clase "Bueno", hay margen de mejora en la distinción entre "Malo" y "bueno".

En la (Tabla), se muestran Los resultados obtenidos en este estudio de investigación sobre la clasificación de la calidad de paltas utilizando un sistema de visión artificial basado en YOLOv8, la precisión y el F1-score proporcionan una evaluación detallada del rendimiento del modelo. Los valores de precisión, que reflejan la proporción de predicciones correctas realizadas por el modelo, oscilaron entre 86% y 95% para la categoría "bueno" y entre 86% y 90% para la categoría "malo". Por su parte, el F1-score, que combina precisión y recall para evaluar la capacidad del modelo de identificar correctamente los casos positivos, varió entre 87% y 96% para "bueno" y entre 87% y 91% para "malo". Estos resultados resaltan la solidez del sistema en la distinción precisa entre paltas de diferentes calidades, consolidando su utilidad potencial para optimizar los procesos agrícolas mediante la automatización de la evaluación de la fruta.

Tabla: Desempeño de la red neuronal YOLOv8 para la Gestión de Calidad de Paltas

Árbol	Categoría de Calidad	Número de Imágenes	Precisión (%)	F1-Score (%)
Árbol 1	Bueno	60	93	94
	Malo	45	88	89
Árbol 2	Bueno	58	95	96
	Malo	42	90	91
Árbol 3	Bueno	59	92	93
	Malo	41	87	88
Árbol 4	Bueno	61	94	95
	Malo	39	89	90
Árbol 5	Bueno	62	91	92
	Malo	38	86	87

4. DISCUSIÓN

En el ámbito de la investigación sobre la clasificación de la calidad de paltas mediante sistemas de visión artificial, los resultados obtenidos en este estudio representan un avance significativo. Utilizando un modelo basado en YOLOv8, se evaluó la precisión y el F1-score como métricas clave para medir el rendimiento del sistema en la clasificación de paltas en categorías "bueno" y "malo". Comparando estos hallazgos con investigaciones previas, se observa que la precisión del modelo, que alcanzó valores entre el 86% y el 95% para la categoría "bueno" y entre el 86% y el 90% para la categoría "malo", se sitúa en un rango competitivo con otros estudios similares. Por ejemplo, investigaciones anteriores [24, 25] reportaron precisiones comparables en la clasificación de frutas como manzanas y peras utilizando redes neuronales convolucionales. El F1-score obtenido en este estudio, que varió entre el 87% y el 96% para "bueno" y entre el 87% y el 91% para "malo", también

refleja una evaluación robusta del rendimiento del modelo en términos de precisión y recall.

La solidez del sistema propuesto radica en su capacidad para realizar una distinción precisa entre diferentes categorías de calidad de paltas, lo cual es fundamental para optimizar los procesos agrícolas mediante la automatización de la evaluación de la fruta. Esta automatización no solo mejora la eficiencia y precisión en la clasificación de productos agrícolas, sino que también puede reducir costos operativos y minimizar el desperdicio de alimentos, contribuyendo así a la sostenibilidad en la industria agrícola.

5. CONCLUSIÓN

Se implementó un sistema de visión artificial basado en redes neuronales convolucionales, específicamente YOLOv8, para la gestión de calidad de paltas. Esta tecnología avanzada ha demostrado ser altamente efectiva en la detección precisa y rápida de defectos, mejorando significativamente los procesos de inspección. La integración de YOLOv8 no solo optimiza la eficiencia operativa, sino que también asegura estándares de calidad consistentes y elevados en la industria agrícola.

6. REFERENCIAS BIBLIOGRÁFICAS

- [1] Zhang J, et al. Flexible sensing enabled intelligent manipulator system (FSIMS) for avocados (Persea Americana Mill) ripeness grading. *Journal of Cleaner Production*, 2022, vol. 363, p. 132599. <https://doi.org/10.1016/j.jclepro.2022.132599>
- [2] Melado A, et al. Postharvest ripeness assessment of 'Hass' avocado based on development of a new ripening index and Vis-NIR spectroscopy. *Postharvest Biology and Technology*, 2021, vol. 181, p. 111683. Available in: <https://www.sciencedirect.com/science/article/abs/pii/S0925521421002222>
- [3] Wieme J, et al. Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review. *biosystems engineering*, 2022, vol. 222, p. 156-176. <https://doi.org/10.1016/j.postharvbio.2021.111683>
- [4] Sucari, León Reynaldo, et al. Visión artificial en el reconocimiento de patrones para la clasificación de frutas en la agroindustria. *El Viajero*, 2020, vol. 2, núm. <https://doi.org/10.37073/puriq.2.2.76>
- [5] Garcia J, et al. Phenology of hass avocado in the Andean tropics of Caldas, Colombia. *Revista Brasileira de Fruticultura*, 2022, vol. 44, p. e-252. doi: 10.1590/0100-29452022252.
- [6] Becerra FJ, Peres H, Meza M. Development of non-destructive system for estimating avocado quality parameters. *Postharvest Biology and Technology*, 2024, vol. 212, p. 112886. <https://doi.org/10.1016/j.postharvbio.2024.112886>
- [7] Luo N, et al. Principles and applications of convolutional neural network for spectral analysis in food quality evaluation: A review. *Journal of Food Composition and Analysis*, 2024, p. 105996.
- [8] Velasquez R. "Avocado visual selection with convolutional neural networks based on Peruvian standards", Proceedings of the 2022 IEEE 29th International Conference on Electronics, Electrical Engineering and Computing, INTERCON 2022, 2022, doi: 10.1109/INTERCON55795.2022.9870148.
- [9] S. Arivazhagan, R. N. Shebiah, S. Selva Nidhyandhan, y L. Ganesan, "Journal of Computing Fruit Recognition using Color and Texture Features", *Journal of Emerging Trends in Computing and Information Sciences*, vol. 1, núm. 2, 2010, Consultado: el 18 de abril de 2024. [En línea]. Disponible en: <http://www.cisjournal.org>
- [10] Redmon J, et al. Motion Detection and Object Detection: Yolo (You Only Look Once). En *2021 7th Annual International Conference on Network and Information Systems for Computers (ICNISC)*. IEEE, 2021. p. 250-257. 2016. pág. 779-788. 10.1109/ICNISC54316.2021.00053
- [11] M. S. Prokopyev, E. Z. Vlasova, T. V. Tretyakova, M. A. Sorochinsky, y R. A. Solovyeva, "Development of a Programming Course for Students of a Teacher Training Higher Education Institution Using the Programming Language Python", *Propósitos y Representaciones*, vol. 8, núm. 3, 2020, doi: 10.20511/PYR2020.V8N3.484.
- [12] Paladino O; Fissore F; Neviani M. A low-cost monitoring system and operating database for quality control in small food processing industry. *Journal of sensor and actuator networks*, 2019, vol. 8, no 4, p. 52. <https://doi.org/10.3390/jsan8040052>
- [13] F. Moza, J. Villanueva, B. Meneses. Uso de Redes Neuronales Convolucionales (CNN) para reconocer la calidad de las naranjas en el Perú al 2023. <https://doi.org/10.56294/dm2023175>.
- [14] Tian, Hongkun, et al. Computer vision technology in agricultural automation—A review. *Information Processing in Agriculture*, 2020, vol. 7, no 1, p. 1-19. <https://doi.org/10.1016/j.inpa.2019.09.006>
- [15] Cruz, JM, et al. Automated System for Hass Avocado Grading System. En *2023 International Conference on Intelligent Computing and Control (IC&C)*. IEEE, 2023. p. 19-24. Available in: <https://www.sciencedirect.com/science/article/pii/S2214317319301751>
- [16] CDD Yu y JF Villaverde. Avocado ripeness classification using graph neural network. En *2022 14th International Conference on Computer and Automation Engineering (ICCAE)*. IEEE, 2022. p. 74-79. doi: 10.1109/ICCAE55086.2022.9762435.
- [17] Viveros L et al. Maturity Recognition and Fruit Counting for Sweet Peppers in Greenhouses Using Deep Learning Neural Networks. *Agriculture*, 2024, vol. 14, no 3, p. 331. : <https://doi.org/10.30880/eeee.2024.05.01.053>
- [18] Xavier, Pedro; Rodrigues, Pedro Miguel; Silva, Cristina LM. Shelf-Life Management and Ripening Assessment of 'Hass' Avocado (Persea americana) Using Deep Learning Approaches. *Foods*, 2024, vol. 13, no 8, p. 1150. <https://doi.org/10.3390/foods13081150>
- [19] J. E. Cruz de la Cruz and O. J. Vera Ramirez, "Convolutional neural networks for the Hass avocado classification using LabVIEW in an agro-industrial plant," *2020 IEEE XXVII International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*.2020, pp. 1-4, doi: 10.1109/INTERCON50315.2020.9220246.
- [20] Dewi, Christine, et al. Automated Fruit Classification Based on Deep Learning Utilizing Yolov8. En *2023 10th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*. IEEE, 2023. p. 801-807.. doi: 10.1109/UPCON59197.2023.10434542.
- [21] Liu, Yao; Pu, Hongbin; Sun, Da-Wen. Efficient extraction of deep image features using convolutional neural network

- (CNN) for applications in detecting and analysing complex food matrices. *Trends in Food Science & Technology*, 2021, vol. 113, p. 193-204. <https://doi.org/10.1016/j.tifs.2021.04.042>
- [22] Bongulwar, DM; Talbar, SN. Bongulwar, D. M.; Talbar, S. N. Robust Convolutional Neural Network Model for Recognition of Fruits. *Indian Journal of Science and Technology*, 2021, vol. 14, no 45, p. 3318-3334. <https://doi.org/10.17485/IJST/v14i45.1493>
- [23] Shalini, K., et al. Comparative analysis on Deep Convolution Neural Network models using Pytorch and OpenCV DNN frameworks for identifying optimum fruit detection solution on RISC-V architecture. En *2021 IEEE Mysore Sub Section International Conference (MysuruCon)*. IEEE, 2021. p. 738-743. doi: 10.1109/ICCAE55086.2022.9762435.
- [24] Dewi, Christine; Thiruvady, Dhananjay; Zaidi, Nayyar. Fruit Classification System with Deep Learning and Neural Architecture Search. arXiv preprint arXiv:2406.01869, 2024. <https://doi.org/10.48550/arXiv.2406.01869>
- [25] Ropelewska, Ewa; piecko, Jan. Discrimination of tomato seeds belonging to different cultivars using machine learning. *European Food Research and Technology*, 2022, vol. 248, no 3, p. 685-705. <https://doi.org/10.1007/s00217-021-03920-w>