



UNIVERSIDAD TÉCNICA DEL NORTE
Facultad de Ingeniería en Ciencias Aplicadas
Carrera de Ingeniería en Mecatrónica

TEMA:

**DETECCIÓN AUTOMÁTICA DE DEFECTOS EN AGUACATES USANDO
TÉCNICAS DE APRENDIZAJE DE MÁQUINA**

Trabajo de grado previo a la obtención de título de Ingeniero en Mecatrónica

Autor:

Kirmar Damián Farinango Maldonado

Director:

Ing. Carlos Xavier Rosero Chandi PhD

Ibarra - Ecuador

2026



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

| DATOS DE CONTACTO | | | |
|-----------------------------|-----------------------------------------------------|------------------------|------------|
| CÉDULA DE IDENTIDAD: | 175518772 - 9 | | |
| APELLIDOS Y NOMBRES: | Farinango Maldonado Kirmar Damián | | |
| DIRECCIÓN: | Robles y Benalcázar S11-46 Cayambe | | |
| EMAIL: | kdfarinangom@utn.edu.ec – kirmarfarinango@gmail.com | | |
| TELÉFONO FIJO: | (02) 2362050 | TELÉFONO MÓVIL: | 0983947181 |

| DATOS DE LA OBRA | |
|--------------------------------|----------------------------------------------------------------------------------------------|
| TÍTULO: | Detección Automática de Defectos en Aguacates Usando Técnicas de Aprendizaje de Máquina |
| AUTOR (ES): | Kirmar Damián Farinango Maldonado |
| FECHA: DD/MM/AAAA | 18/02/2026 |
| PROGRAMA: | <input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO |
| TITULO POR EL QUE OPTA: | Ingeniero en Mecatrónica |
| ASESOR /DIRECTOR: | Ing Cosme Damián Mejía Echeveria, MSc Ing. Carlos Xavier Rosero Chandi PhD. |

2. CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 18 días del mes de febrero de 2026.

EL AUTOR:

(Firma).....

Nombre: Kirmar Damián Farinango Maldonado



Universidad Técnica del Norte
Facultad de Ingeniería en Ciencias Aplicadas
CERTIFICACIÓN DEL DIRECTOR DEL TRABAJO DE
INTEGRACIÓN CURRICULAR

En mi calidad de director del trabajo de grado “DETECCIÓN AUTOMÁTICA DE DEFECTOS EN AGUACATES USANDO TÉCNICAS DE APRENDIZAJE DE MÁQUINA”, presentado por el egresado Kirmar Damián Farinango Maldonado, que opta por el título de ingeniero en Mecatrónica, certifico que el mencionado proyecto fue realizado bajo mi dirección.

Ibarra, 18 de febrero de 2026

Ing. Carlos Xavier Rosero Chandi PhD.
Director de Tesis



Universidad Técnica del Norte
Facultad de Ingeniería en Ciencias Aplicadas
APROBACIÓN DEL COMITÉ CALIFICADOR

El Tribunal Examinador del trabajo de titulación, Detección Automática de Defectos en Aguacates Usando Técnicas de Aprendizaje de Máquina. Elaborado por Kirmar Damián Farinango Maldonado, previo a la obtención del título de Ingeniero en Mecatrónica, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte:

Ing. Carlos Xavier Rosero Chandi PhD.
Director de Tesis

Ing Cosme Damián Mejía Echeveria, MSc
Asesor de Tesis

Dedicatorias

Dedico este trabajo de grado, con profundo amor y gratitud, a mi familia, quienes han sido mi mayor fortaleza a lo largo de este camino. Sin su apoyo incondicional, nada de esto habría sido posible. A mi padre, Vinicio, y a mi madre, Mabel, gracias por sus consejos, enseñanzas, paciencia, sabiduría y amor; por guiarme siempre y por no dejarme rendir en los momentos más difíciles.

A mis hermanos, Digyan y Sidek, gracias por su apoyo constante y por estar presentes de una u otra manera, brindándome ánimo y confianza en cada etapa. De manera muy especial, dedico este logro a mi segunda madre, mi abuelita Laura, “Mamaita”, quien ha sido un pilar fundamental en mi vida y una fuente inagotable de inspiración.

Este triunfo no es solo mío, sino de todos ustedes, que con cada gesto, palabra y sacrificio aportaron su granito de arena para formarme y ayudarme a alcanzar este tan anhelado título. Este logro es para ustedes, con todo mi corazón.

Los amo mucho.

Agradecimientos

A mis padres, por su amor infinito, su apoyo incondicional y por creer en mí incluso en los momentos más difíciles; a mi padre, por caminar a mi lado en cada etapa de este proceso, y a mi abuelita, por estar siempre presente con su cariño, sus palabras de aliento y su fortaleza, siendo un pilar fundamental en mi vida.

A mi director de trabajo de grado, el Ingeniero Xavier Rosero, expreso mi más sincero agradecimiento por su guía, enseñanza y sabiduría, así como por su apoyo y amistad a lo largo del desarrollo de este proyecto. De igual manera, agradezco a todos los docentes de la carrera de Ingeniería en Mecatrónica, quienes con sus conocimientos, dedicación y compromiso contribuyeron de manera significativa a mi formación profesional y personal.

Finalmente, agradezco de corazón a mis amigos, compañeros y personas especiales que formaron parte de este camino, por su compañía, apoyo y palabras de ánimo, y por ayudarme a superar los retos, problemas y dificultades que surgieron durante mi formación universitaria.

Índice general

| | |
|--------------------------------------------------------------------------------|-------------|
| Cesión de derechos de autor a favor de la Universidad Técnica del Norte | II |
| Certificación del director del trabajo de integración curricular | III |
| Aprobación del comité calificador | IV |
| Dedicatorias | V |
| Agradecimientos | VI |
| Índice general | VII |
| Índice de figuras | XI |
| Índice de tablas | XIII |
| Resumen | XV |

| | |
|--------------------------------------------------------------------|-----------|
| I. INTRODUCCIÓN | 1 |
| 1.1. Objetivos | 2 |
| 1.1.1. Objetivo general | 2 |
| 1.1.2. Objetivos específicos | 3 |
| 1.2. Justificación | 3 |
| 1.3. Alcance | 4 |
| II. MARCO TEÓRICO | 5 |
| 2.1. Método de clasificación en mora, fresa y uvillas | 5 |
| 2.2. Método de clasificación de frutas | 7 |
| 2.3. Método de clasificación en mango variedad Tommy | 8 |
| 2.4. Método de clasificación en naranjillas | 9 |
| 2.5. Método de clasificación en rosas | 10 |
| 2.6. Método de clasificación en fresas | 11 |
| 2.7. Métodos de clasificación en aguacates variedad Hass | 11 |
| III. MARCO METODOLÓGICO | 13 |
| 3.1. Enfoque de investigación | 13 |

| | | |
|--------|-----------------------------------------------------------------------|----|
| 3.2. | Tipo de investigación | 14 |
| 3.3. | Diseño metodológico por fases | 14 |
| 3.3.1. | Fase 1: Investigación y Definición | 14 |
| 3.3.2. | Fase 2: Diseño y arquitectura | 15 |
| 3.3.3. | Fase 3: Implementación | 16 |
| 3.3.4. | Fase 4: Validación y análisis | 17 |
| 3.4. | Metodología para la selección de dispositivos | 17 |
| 3.5. | Escena | 20 |
| 3.6. | Adquisición de imágenes | 21 |
| 3.6.1. | Base de datos de imágenes | 21 |
| 3.6.2. | Definición de clases | 22 |
| 3.6.3. | Origen y adquisición del dataset | 23 |
| 3.6.4. | Estructura del conjunto de datos (train/val/test) | 24 |
| 3.6.5. | Diagrama de flujo de adquisición y organización del dataset | 26 |
| 3.7. | Procesamiento digital de imágenes | 27 |
| 3.7.1. | Representación matemática y tamaño de entrada | 27 |
| 3.7.2. | Redimensionamiento | 27 |
| 3.7.3. | Normalización y escalado | 28 |

| | | |
|------------|---------------------------------------------|-----------|
| 3.7.4. | Convoluciones (núcleo CNN) | 28 |
| 3.7.5. | Activación normalización y salida | 29 |
| 3.7.6. | Preprocesamiento e inferencia | 31 |
| 3.8. | Entrenamiento | 32 |
| 3.8.1. | Arquitectura y transferencia de aprendizaje | 32 |
| 3.8.2. | Configuración del entrenamiento | 32 |
| 3.8.3. | Función de pérdida y actualización | 33 |
| 3.8.4. | Flujo del entrenamiento | 34 |
| 3.9. | Clasificación e implementación del sistema | 35 |
| 3.9.1. | Inferencia en tiempo real | 35 |
| 3.9.2. | Regla de decisión BUENO / MALO | 36 |
| 3.9.3. | Métrica FPS | 36 |
| 3.9.4. | Funcionamiento general del sistema | 37 |
| IV. | RESULTADOS | 38 |
| 4.1. | Implementación y funcionamiento del sistema | 39 |
| 4.1.1. | Escenario experimental | 39 |
| 4.1.2. | Resultados del entrenamiento | 40 |

| | | |
|---------------|--------------------------------------------------------|-----------|
| 4.1.2.1. | Análisis de la función de pérdida | 40 |
| 4.1.2.2. | Análisis de exactitud | 41 |
| 4.1.3. | Evaluación mediante matrices de confusión | 42 |
| 4.1.3.1. | Matriz de confusión absoluta | 42 |
| 4.1.3.2. | Matriz de confusión normalizada | 44 |
| 4.1.4. | Resumen cuantitativo del desempeño | 45 |
| 4.2. | Ejecución operativa del sistema | 46 |
| 4.3. | Pruebas del sistema en operación | 47 |
| 4.3.1. | Desempeño temporal y latencia | 47 |
| 4.3.2. | Errores de clasificación y casos límites | 47 |
| 4.3.3. | Análisis cualitativo del desempeño por clase | 48 |
| 4.4. | Análisis visual de resultados | 48 |
| V. | CONCLUSIONES Y RECOMENDACIONES | 51 |
| 5.1. | Conclusiones | 51 |
| 5.2. | Recomendaciones | 53 |
| 5.3. | Trabajo a futuro | 54 |
| Anexos | | 65 |

Índice de figuras

| | |
|-------------------------------------------------------------------------------------------|----|
| 3.1. Diagrama de flujo del sistema propuesto. | 19 |
| 3.2. Imágenes de entrenamiento. | 24 |
| 3.3. Diagrama de flujo del proceso de preparación del conjunto de datos. | 26 |
| 3.4. Diagrama de flujo del proceso de inferencia del modelo de clasificación. | 31 |
| 3.5. Configuración de entrenamiento del modelo YOLOv8-cls. | 32 |
| 3.6. Diagrama de flujo del proceso de entrenamiento y selección del mejor modelo. | 34 |
| 3.7. Diagrama de flujo del funcionamiento general del sistema de clasificación. | 37 |
| 4.1. Evolución de la función de pérdida. | 40 |
| 4.2. Exactitud (Top-1 / Top-5). | 41 |
| 4.3. Matriz de confusión absoluta. | 43 |
| 4.4. Matriz de confusión normalizada. | 44 |

4.5. Análisis visual de resultados de inferencia del sistema de clasificación. (a) Etiquetas reales del conjunto de validación (lote 0). (b) Predicciones del modelo (lote 0). (c) Etiquetas reales del conjunto de validación (lote 1). (d) Predicciones del modelo (lote 1). 49

Índice de tablas

| | |
|-----------------------------------------------------------------------|----|
| 3.1. Componentes de la cabina de adquisición de imágenes. | 21 |
| 3.2. Códigos de clasificación y rasgos visuales asociados. | 23 |
| 3.3. Parámetros de entrenamiento del modelo de clasificación. | 33 |
| 4.1. Resumen de métricas de desempeño del modelo. | 45 |
| 4.2. Desempeño del modelo por clase. | 48 |

Resumen

La creciente demanda de aguacate, especialmente de la variedad Fuerte, ha generado la necesidad de mejorar los procesos de clasificación poscosecha para garantizar la calidad del producto. En Ecuador, este proceso aún se realiza de manera manual, lo que lo vuelve propenso a errores humanos, lentitud e inconsistencias. En este contexto, el presente trabajo propone el desarrollo de un sistema inteligente para la detección automática de defectos en aguacates mediante técnicas de aprendizaje de máquina y visión artificial. El sistema se implementa sobre la plataforma Jetson Nano, incorporando una cámara usb para capturar imágenes de los frutos en tiempo real. A través del preprocesamiento y análisis de características visuales como color, textura y tamaño, el algoritmo clasifica los aguacates según los criterios establecidos en la norma ecuatoriana NTE INEN 1755. Se emplearon redes neuronales convolucionales (CNN) entrenadas con conjuntos de datos etiquetados, logrando una precisión superior al 90 % en la identificación de defectos. La metodología utilizada fue experimental, con enfoques descriptivo y documental. Las pruebas se realizaron sobre muestras reales, obteniendo resultados favora-

bles en cuanto a precisión, portabilidad y bajo consumo energético. El sistema desarrollado permite una clasificación consistente, autónoma y de bajo costo, representando una solución viable para pequeños y medianos productores agrícolas. En conclusión, este proyecto demuestra que la aplicación de técnicas de inteligencia artificial puede optimizar significativamente la clasificación de aguacates, reduciendo errores humanos y mejorando la eficiencia del proceso poscosecha.

Palabras clave: Aprendizaje de máquina, visión artificial, clasificación de frutas, aguacate, redes neuronales, Jetson Nano, defectos visuales.

Abstract

The growing demand for avocados, especially the Fuerte variety, has generated the need to improve postharvest sorting processes to guarantee product quality. In Ecuador, this process is still carried out manually, which makes it prone to human error, slowness and inconsistencies. In this context, the present work proposes the development of an intelligent system for the automatic detection of defects in avocados using machine learning and artificial vision techniques. The system is implemented on the Jetson Nano platform, incorporating a CSI camera to capture images of the fruit in real time. Through preprocessing and analysis of visual characteristics such as color, texture and size, the algorithm classifies avocados according to the criteria established in the Ecuadorian standard NTE INEN 1755. Convolutional neural networks (CNN) trained with labeled data sets were used, achieving an accuracy of over 90 % in the identification of defects. The methodology used was experimental, with descriptive and documentary approaches. The tests were performed on real samples, obtaining favorable results in terms of accuracy, portability and low energy consumption. The system developed allows a consistent,

autonomous and low-cost classification, representing a viable solution for small and medium agricultural producers. In conclusion, this project demonstrates that the application of artificial intelligence techniques can significantly optimize avocado grading, reducing human errors and improving the efficiency of the postharvest process.

Keywords: Machine learning, artificial vision, fruit classification, avocado, neural networks, Jetson Nano, visual defects.

Capítulo I

INTRODUCCIÓN

La zona 1 del país abarca las provincias de Esmeraldas, Carchi, Imbabura, Sucumbíos y el norte de Pichincha, donde la agricultura representa una de las principales actividades económicas. En los últimos años, los cultivos tradicionales como maíz, frejol y tomate riñón han sido reemplazados progresivamente por frutales perennes, debido a la baja rentabilidad y la inestabilidad de sus precios. Entre los cultivos más destacados se des en se encuentra el aguacate, mango, naranja, mandarina, durazno, entre otros [1].

La demanda del aguacate ecuatoriano ha crecido considerablemente en el mercado internacional, gracias a su delicioso sabor, suave textura y múltiples usos que lo hacen muy apreciado [2]. En Ecuador se cultivan principalmente las variedades Fuerte y Hass; el aguacate Fuerte se

distribuye tanto en el mercado local como en las exportaciones hacia Colombia.

Antes de ser comercializado, el aguacate pasa por las etapas de cosecha, poscosecha y clasificación [3]. Este último proceso se realiza de forma manual por personal capacitado, encargado de seleccionar los frutos conforme a las exigencias del mercado. Sin embargo, esta tarea es repetitiva, lenta y susceptible a errores ocasionados por el cansancio de los trabajadores, lo que puede derivar en una menor aceptación del producto y pérdidas económicas al no cumplir con los estándares de calidad esperados.

El desarrollo de un algoritmo de visión por computadora permitiría clasificar los aguacates de acuerdo con los estándares establecidos en la norma NTE INEN 1755 [4]. La automatización de este proceso optimizaría el control de calidad, garantizando un producto que cumpla con las especificaciones requeridas.

1.1. Objetivos

1.1.1. Objetivo general

Desarrollar un sistema inteligente para la detección automática de defectos en aguacates basado en aprendizaje de máquina.

1.1.2. Objetivos específicos

- Revisar las técnicas usadas para detección de defectos en frutas y, en particular, en aguacates, para la selección de las técnicas más apegadas a la realidad.
- Proponer un algoritmo que permita identificar problemas en aguacates a través de aprendizaje de máquina.
- Implementar el algoritmo en software para evaluar su desempeño en comparación con otros algoritmos presentes.

1.2. Justificación

El aguacate ha ganado popularidad de manera gradual debido a sus numerosos beneficios para la salud y su gran valor en la gastronomía [2]. La creciente demanda tanto a nivel nacional como internacional requiere un producto de alta calidad y procesos de postcosecha y clasificación más rápidos y eficientes.

La adopción de nuevas tecnologías es esencial para garantizar altos estándares de calidad en grandes volúmenes de producción y ante una demanda creciente. Por ello, resulta clave emplear algoritmos de entrenamiento de máquina para clasificar los aguacates según sus características específicas. Este tipo de sistema podría integrarse en una plataforma de clasificación, mejorando

la calidad del producto, automatizando el proceso manual y reduciendo la carga de trabajo para los operarios.

Como estudiante de Ingeniería en Mecatrónica he adquirido conocimientos en áreas como la automatización, el procesamiento de datos y el uso de algoritmos avanzados lo cual me permitirá consolidar y poner en práctica las habilidades técnicas que he desarrollado, incluyendo el uso de herramientas de aprendizaje de máquinas y software matemático, para abordar un desafío que tiene implicaciones tanto en el ámbito tecnológico como en el sector agrícola.

1.3. Alcance

Se propone desarrollar un sistema basado en técnicas de aprendizaje de máquina para la detección automática de defectos en aguacates, utilizando imágenes obtenidas de repositorios públicos y fuentes reales. Abarcará la implementación de diversos algoritmos en el software matemático y la evaluación de su desempeño mediante métricas diseñadas específicamente para diferenciar aguacates según la severidad de sus defectos. Se busca ofrecer un análisis comparativo de los modelos utilizados, identificando la solución más eficiente y precisa dentro del contexto del problema planteado.

Capítulo II

MARCO TEÓRICO

Existe una amplia variedad de frutas, verduras y flores, las cuales presentan características propias que las diferencian entre sí. En este contexto, diversos estudios aplican técnicas de visión por computadora para automatizar los procesos de clasificación, tomando en consideración atributos como la forma, el tamaño, el color, la textura, la presencia de imperfecciones y el estado de maduración.

2.1. Método de clasificación en mora, fresa y uvillas

Se presenta un sistema de visión artificial basado en redes neuronales profundas para la clasificación de frutas como fresas, moras y uvillas, destinadas a la industria alimentaria, siguiendo

la tendencia actual de emplear CNN y detectores de objetos (como Faster R-CNN, Yolo o EfficientNet) para clasificación de frutas y evaluación de calidad en aplicaciones agrícolas automatizada [5], [6]. Utilizando librerías de open CV implementadas en Visual C++ Express 2010, el sistema analiza imágenes capturadas con una cámara web de alta definición, identifica características como forma, tamaño y estado de maduración bajo condiciones variables de iluminación y orientación, de forma coherente con sistemas de clasificación y “grading” de frutas que utilizan atributos de color, textura, tamaño y forma como variables de entrada para los modelos de aprendizaje de máquina . A través de comandos de detección de bordes y localización de regiones de interés (ROI), las imágenes se procesan para entrenar la red neuronal, siguiendo el flujo típico de procesamiento, segmentación y extracción de características descrito en la literatura de sistemas de visión por computador para frutas y detección de defectos [7], [8]. Probado en tiempo real, el sistema automatiza la clasificación con alta precisión, en línea con sistemas de inspección visual no destructivos que alcanzan precisiones cercanas o superiores al 95 - 99 % en la detección de madurez, frescura o defectos superficiales en frutas como manzanas, bananas, mangos y tomates [9], [10]. De manera específica para aguacates, se desarrollan modelos basados en CNN que realizan identificación de defectos externos y detección de madurez a partir de imágenes RGB con altas tasas de acierto [11], así como sistemas de segmentación semántica profunda sobre imágenes de rayos X para detectar podredumbre interna en aguacate Hass con

una exactitud cercana al 98 %.

2.2. Método de clasificación de frutas

El proyecto implementa un módulo didáctico basado en visión estereoscópica para identificar las coordenadas (x y z) de objetos sólidos y calificarlos según su forma y color mediante un brazo robótico comercial, en línea con sistemas de reconstrucción 3D y posicionamiento de brazos robóticos guiados por cámaras estéreo para tareas de manipulación y desactivación de artefactos, donde la visión estereoscópica se utiliza para obtener la posición 3D del objeto y guiar el efector final del robot [12], [13]. Se utilizan algoritmos en LabVIEW para la adquisición de imágenes y el control del brazo y MATLAB para resolver la visión estereoscópica, siguiendo enfoques de reconstrucción 3D basados en correspondencia estéreo y cálculo de profundidad que logran errores de reconstrucción del orden de milímetros en aplicaciones de navegación quirúrgica y robótica [14], [15]. Además, se desarrolla una aplicación basada en redes neuronales para identificar frutas como limones, manzanas, naranjas, mandarinas y tomates usando características de color y textura, de forma coherente con sistemas de clasificación automática de frutas que emplean CNN y otros modelos de aprendizaje profundo sobre imágenes RGB para reconocer múltiples tipos de frutas con precisiones cercanas al 99 % utilizando rasgos de color,

forma y textura como entradas del clasificador [16], [17]. Las pruebas del sistema muestran un error máximo del 2 % en la reconstrucción de la escena y del 10 % en el posicionamiento del brazo robótico, resultados comparables a los errores de reconstrucción 3D reportados en plataformas robóticas con visión estéreo y reconstrucción basada en aprendizaje profundo, donde se alcanzan errores submilimétricos a pocos milímetros según las condiciones experimentales [18], lo que respalda la viabilidad de integrar visión 3D y robótica en módulos didácticos aplicables posteriormente a sistemas de inspección y manipulación en agroindustria, como los requeridos para la detección automática [19], [20].

2.3. Método de clasificación en mango variedad Tommy

Se desarrolla una aplicación de visión artificial con Image Processing Toolbox de Matlab para clasificar mangos de variedad tome según su color y tamaño, lo que coincide con múltiples sistemas de clasificación y “grading” de mangos que utilizan características de color, tamaño, forma y textura extraídas de imágenes RGB para evaluar la calidad del fruto [21], [22]. Se utiliza una cámara web para capturar imágenes en un área de trabajo de hasta tres mangos, enfoque similar a dispositivos de clasificación automática que emplean cámaras CCD o webcams y procesamiento en Matlab/Arduino para determinar color, tamaño y defecto superficiales y decidir

si el mango es apto para exportación o no [23]. Además, se explica la programación en M-file, método de segmentación y reconocimiento para procesar imágenes, en línea con esquemas que segmentan el mango del fondo mediante umbralización, k-means u Otsu, extraen rasgos geométricos y de color, y alimentan clasificadores basados en redes neuronales o árboles de decisión para asignar la clase de calidad [24], [25]. Finalmente, se obtienen gráficos y resultados que describen la clasificación mediante una red de decisión, análogo al uso de clasificadores como Random Forest, redes neuronales probabilísticas o árboles de decisión para separar mangos en categorías (bueno, promedio, defectuoso) a partir de sus atributos físicos y visuales [26], [27]. Este tipo de metodología es directamente exportable a otros frutos como el aguacate, donde sistemas basados en CNN y redes neuronales utilizan color, forma, textura y defectos de la cáscara para clasificar madurez y determinar daños [28], [29].

2.4. Método de clasificación en naranjillas

En el artículo [30] se presenta el diseño e implementación de un módulo robótico para clasificar lulos, combinando control, visión artificial y robótica. Se utiliza un brazo robótico de 5 GDL para seleccionar lulos según características como tamaño, color e imperfecciones, establecidas por el usuario. El desarrollo incluye un diseño CAD para definir propiedades físicas,

materiales, fabricación y movimientos de los mecanismos involucrados. Se implementan algoritmos de control, cinemática y visión artificial. El resultado es un módulo académico funcional para la clasificación de lulos.

2.5. Método de clasificación en rosas

El proyecto en [31] desarrolla un sistema de clasificación de rosas basado en la longitud del tallo y el tamaño del botón, utilizando una cámara, sensores infrarrojos, un PLC Delta y Visual Studio .NET. El sistema opera en tres etapas: recepción de las flores en cadena, adquisición de los datos mediante visión artificial y sensores, y clasificación automática en cinco ranuras según los parámetros obtenidos. La interfaz, desarrollada en Visual C++, permite visualizar datos, controlar el PC y gestionar usuarios, con información almacenada en una base de datos MS Access. Programado en ISPsoft, el módulo se controla de forma local y remota, logrando un funcionamiento en tiempo real con un 80 % de confiabilidad, cumpliendo con los objetivos de clasificación eficiente e interacción de un HMI amigable.

2.6. Método de clasificación en fresas

En el texto [32] se aborda los avances en la clasificación automatizada de frutas, especialmente fresas, mediante visión artificial y procesamiento de imágenes. Estas tecnologías permiten evaluar atributos como tamaño, forma, color, madurez y defectos en tiempo real de manera no destructiva. Se mencionan diversos sistemas desarrollados para frutas como tomates, manzanas, melocotones y papas, empleando modelos de redes neuronales, análisis de color y procesamiento de bordes para mejorar su precisión. En el caso de las fresas, el color de la superficie es un índice clave para determinar la calidad interna, mientras que su forma presenta desafíos debido a su diversidad (cónica, cuadrada y redondeada). Estudios previos utilizan redes neuronales con múltiples entradas para clasificar formas, aunque existen largos tiempos de entrenamiento. Por ello, el objetivo del estudio es desarrollar un sistema más eficiente para clasificar fresas considerando índices de forma, color y tamaño.

2.7. Métodos de clasificación en aguacates variedad Hass

El estudio en [33] analiza la maduración del aguacate Hass mediante procesamiento de imágenes, evaluando cambios en color, textura, firmeza y pérdida de masa. Se utilizan 10 muestras para análisis visual y 16 para medir firmeza y masa, estableciendo tres etapas de madurez me-

dian­te análisis de componentes principales y k-NN. La firmeza disminuye de 75.43 a 2.63 N en 12 días, mientras que el parámetro de color verde (a^*) resulta clave para clasificar con el más del 80 % de precisión de niveles de madurez. Los resultados destacan que el procesamiento de imágenes es una herramienta eficaz para evaluar la maduración del aguacate en el laboratorio. Según [34], el cultivo de aguacate Hass es clave para la economía agrícola colombiana, tanto para el mercado local como la exportación. Sin embargo, se requieren mejoras en procesos como cosecha, transporte y almacenamiento. La clasificación manual del aguacate consume tiempo que puede dedicarse a otras tareas. Se propone un sistema automatizado basado en imágenes para clasificar aguacates mediante un algoritmo que opera en computadoras conectadas a cámaras inalámbricas. Esto optimiza su distribución en cintas transportadoras según su categoría. El algoritmo alcanza un 88 % de coincidencia con expertos y una precisión del 82.22 % en las pruebas. En [35], se presentan máquinas semiautomáticas que utilizan cámaras de visión artificial para capturar imágenes de piezas en diferentes ángulos, almacenando mediciones en una base de datos para realizar análisis estadísticos del control de procesos.

Capítulo III

MARCO METODOLÓGICO

Este capítulo describió la metodología empleada para el desarrollo del sistema de clasificación automática de aguacates basado en técnicas de aprendizaje de máquina y visión artificial. La metodología siguió un enfoque ingenieril que permitió comprender el funcionamiento del sistema desde el entorno físico hasta el proceso final de clasificación.

3.1. Enfoque de investigación

El trabajo de titulación se enmarcó dentro de un enfoque aplicado, debido a que estuvo orientada al desarrollo de una solución tecnológica funcional para la identificación de defectos en aguacates. El enfoque aplicado permitió utilizar conocimientos teóricos existentes y adaptarlos a un problema real, mediante la implementación de algoritmos de aprendizaje de máquina y técnicas de visión artificial.

3.2. Tipo de investigación

- **Investigación documental:** Enfocada en la revisión y análisis de artículos científicos, papers y trabajos de titulación relacionados con la detección de defectos en frutas y el uso de técnicas de aprendizaje de máquina.
- **Investigación experimental:** Orientada al diseño, implementación y validación del algoritmo propuesto, mediante pruebas realizadas con datos de entrenamiento, datos de prueba y muestras reales de aguacates.

3.3. Diseño metodológico por fases

El diseño metodológico se dividió en cuatro fases principales que integraron los pasos clave del proyecto, asegurando un desarrollo lógico y una validación rigurosa del sistema de clasificación automática de aguacates mediante técnicas de aprendizaje de máquina.

3.3.1. Fase 1: Investigación y Definición

Esta fase se centró en la revisión teórica, la toma de decisiones tecnológicas preliminares y la definición del alcance del sistema.

1. **Revisión de técnicas de detección de defectos en frutas:** Se realizó la investigación y

análisis de artículos científicos, papers y trabajos de titulación relacionados con la detección de defectos en frutas, con énfasis en aguacates, considerando técnicas tradicionales y enfoques basados en aprendizaje de máquina.

2. **Análisis de algoritmos de aprendizaje de máquina:** Se llevó a cabo la revisión del estado del arte en modelos de clasificación y detección de defectos, evaluando su precisión, complejidad computacional y aplicabilidad en entornos reales.
3. **Definición de requisitos operacionales:** Se establecieron las variables de salida del sistema, los criterios de clasificación, las métricas de desempeño y los requerimientos funcionales necesarios para el desarrollo del algoritmo propuesto.

3.3.2. Fase 2: Diseño y arquitectura

Esta fase estableció la estructura lógica del sistema previa a su implementación, garantizando la coherencia entre los componentes de procesamiento, clasificación y visualización de resultados.

1. **Diseño del algoritmo de clasificación:** Se definió la estructura del algoritmo seleccionado para la identificación de defectos en aguacates, considerando las técnicas previamente analizadas y los requisitos establecidos.

2. **Arquitectura del sistema:** Se diseñó el flujo general del sistema, desde la adquisición de imágenes hasta la obtención del resultado de clasificación, definiendo la interacción entre los módulos de procesamiento, clasificación y visualización.
3. **Preparación del conjunto de datos:** Se organizó y preparó el conjunto de datos utilizado para el entrenamiento y prueba del modelo, considerando criterios de representatividad y calidad de las muestras.

3.3.3. Fase 3: Implementación

Esta fase se enfocó en la implementación del sistema y la integración de los componentes definidos en las etapas anteriores.

1. **Implementación del algoritmo en software:** Se desarrolló el algoritmo de clasificación utilizando herramientas de programación adecuadas, adaptando el modelo diseñado para su correcta ejecución.
2. **Integración del sistema:** Se integraron los módulos de adquisición, procesamiento y clasificación, asegurando el funcionamiento conjunto del sistema.
3. **Pruebas funcionales iniciales:** Se ejecutaron pruebas preliminares para verificar el correcto funcionamiento del sistema y la estabilidad del proceso de clasificación.

3.3.4. Fase 4: Validación y análisis

La fase final se dedicó a la evaluación del desempeño del sistema mediante pruebas experimentales.

1. **Validación con datos de prueba:** Se evaluó el sistema utilizando datos reales y simulados, analizando su capacidad para identificar defectos en aguacates.
2. **Análisis de resultados:** Se analizaron los resultados obtenidos a partir de las pruebas realizadas, considerando métricas de desempeño como precisión y confiabilidad del sistema.
3. **Comparación con enfoques existentes:** Se comparó el desempeño del sistema propuesto con otros métodos reportados en la literatura.

3.4. Metodología para la selección de dispositivos

Para la selección de los dispositivos utilizados en el desarrollo del sistema de clasificación automática de aguacates, se realizó una investigación del mercado con el objetivo de identificar opciones viables, accesibles y compatibles con los requerimientos técnicos del proyecto. La selección se fundamentó en criterios técnicos y operativos que permitieron garantizar el correcto funcionamiento del sistema.

Uno de los criterios principales considerados fue la compatibilidad, priorizando dispositivos que contaran con interfaces adecuadas para la interconexión entre los distintos componentes del sistema, tales como cámaras, dispositivos de procesamiento y periféricos de adquisición de datos, facilitando la comunicación y la integración del sistema en su conjunto.

Asimismo, se evaluó la capacidad de procesamiento de los dispositivos seleccionados, considerando los requerimientos necesarios para la ejecución de algoritmos de aprendizaje de máquina y procesamiento de imágenes en tiempo real. Este criterio permitió asegurar que el sistema fuera capaz de realizar la clasificación de aguacates de manera eficiente y estable.

Otro criterio relevante fue la disponibilidad y el costo, tomando en cuenta dispositivos comercialmente accesibles en el mercado local, con el fin de evitar costos excesivos y garantizar la replicabilidad del sistema. Se priorizó el uso de componentes de fácil adquisición y con una adecuada relación costo–beneficio.

Adicionalmente, se consideró la confiabilidad de los dispositivos, apoyándose en referencias de trabajos previos y en el reconocimiento de marcas ampliamente utilizadas en aplicaciones similares. Este criterio permitió seleccionar componentes con un historial comprobado de funcionamiento estable y compatibilidad con entornos de desarrollo existentes.

Finalmente, se priorizó el uso de dispositivos previamente disponibles, con el objetivo de optimizar los recursos económicos del proyecto y evitar adquisiciones innecesarias, manteniendo

do un enfoque práctico y eficiente en el desarrollo del sistema.

La estructura metodológica se compuso de las etapas que se observaron a manera de ilustración en la Figura 3.1.

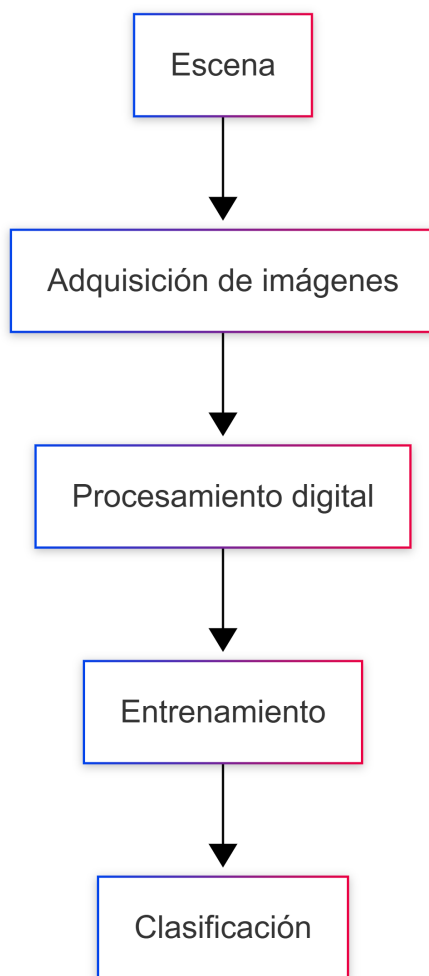


Figura 3.1: Diagrama de flujo del sistema propuesto.

A continuación, a través de la sección 3.1 a la sección 3.5 se explicó de manera detallada la aplicación de este algoritmo.

3.5. Escena

La escena de adquisición de imágenes se definió como un entorno de inspección visual controlado, concebido para asegurar condiciones constantes de captura y minimizar la influencia de factores externos. Para este propósito, se utilizó una cabina de iluminación cuya función principal fue mantener la estabilidad del entorno visual y mejorar la repetibilidad del sistema [36].

Desde la perspectiva de la visión artificial el uso de la iluminación controlada contribuyó a una mayor estabilidad de las características visuales y a un aumento en la robustez del sistema de clasificación [36]. En consecuencia, el diseño de la cabina de iluminación se basó en los siguientes criterios:

- Iluminación uniforme mediante fuentes LED.
- Disminución de sombras y reflejos especulares.
- Empleo de un fondo de color neutro para maximizar el contraste con el aguacate.

Como se mostró en la Tabla 3.1 se describieron los componentes principales de la cabina de adquisición de imágenes y la función específica que desempeñó cada uno dentro del sistema.

Tabla 3.1: Componentes de la cabina de adquisición de imágenes.

| Componente | Función |
|-------------------|-----------------------------------------|
| Estructura física | Aislar el entorno y soportar el sistema |
| Iluminación LED | Proveer luz constante y uniforme |
| Difusores | Minimizar sombras y puntos brillantes |
| Fondo neutro | Facilitar el análisis visual del objeto |

3.6. Adquisición de imágenes

3.6.1. Base de datos de imágenes

El rendimiento de un sistema de clasificación basado en aprendizaje profundo estuvo directamente condicionado por la calidad, representatividad y correcta organización del conjunto de datos empleado durante las etapas de entrenamiento y validación del modelo. En el ámbito de la visión por computador, el dataset no sólo proporcionó ejemplos de aprendizaje, sino que también definió el espacio estadístico sobre el cual el modelo construyó su conocimiento; por esta razón, una base de datos mal estructurada pudo provocar sobreajuste y disminuir la capacidad de generalización del clasificador frente a condiciones reales de operación [36], [37].

En el presente proyecto, el problema se abordó como una tarea de clasificación supervisada multiclase de imágenes de aguacate, en la cual cada imagen se asoció a una etiqueta que representó una condición específica del fruto. El propósito del conjunto de datos fue permitir que el modelo aprendiera una función de mapeo definida

$$f_{\theta}(\mathbf{X}) = \hat{\mathbf{y}}, \quad (3.1)$$

donde \mathbf{X} correspondió a la imagen de entrada representada como una matriz de píxeles, e $\hat{\mathbf{y}}$ fue el vector de probabilidades estimado por el modelo por cada clase. El parámetro θ representó el conjunto de pesos entrenables de la red neuronal, que incluyó las capas convolucionales, las capas de clasificación y los procesos de normalización [37], [38].

3.6.2. Definición de clases

El conjunto de datos fue estructurado en seis clases codificadas, cada una asociada a un estado visual específico del aguacate. Dichas clases se definieron a partir de criterios observables mediante inspección visual, tales como el color, la textura y la presencia de defectos. En el contexto del aprendizaje supervisado, una definición precisa de las clases contribuyó a disminuir la ambigüedad semántica y a mejorar la coherencia del proceso de etiquetado, lo que reflejó en un entrenamiento más estable y en una reducción del ruido en las etiquetas [36], [37].

La Tabla 3.2 presentó los códigos utilizados para la clasificación visual de los aguacates en el sistema propuesto, junto con su significado operacional y los rasgos visuales típicos asociados a cada clase. Estos códigos permitieron estandarizar la identificación de las condiciones del

fruto, abarcando desde estados óptimos hasta diferentes tipos de defectos o anomalías visibles.

La definición clara de cada clase facilitó el entrenamiento y la evaluación del modelo de clasificación basado en redes neuronales convolucionales.

Tabla 3.2: Códigos de clasificación y rasgos visuales asociados.

| Código | Significado operacional | Rasgos visuales típicos |
|---------------|--------------------------------|--------------------------------|
| AN | Anomalías visibles | irregularidades, manchas |
| DM | Daño mecánico | golpes, hundimientos |
| LR | Lesiones externas | zonas afectadas |
| OK | Óptimo | color y textura esperados |
| RO | Sobremaduro | cambios marcados de color |
| TR | Defecto superficial | trazas o defectos leves |

Desde la perspectiva matemática, el proceso de etiquetado permite definir el conjunto de datos como se expresó mediante

$$\mathcal{D} = \{(\mathbf{X}_i, y_i)\}_{i=1}^N, \quad y_i \in \{1, 2, 3, 4, 5, 6\}, \quad (3.2)$$

donde N representó el número total de imágenes y y_i correspondió a la etiqueta de clase asociada a la imagen \mathbf{X}_i [37].

3.6.3. Origen y adquisición del dataset

Las imágenes empleadas se obtuvieron a partir de un repositorio digital, con el objetivo de minimizar la variabilidad. En la aplicación de visión artificial, las variaciones en la iluminación

constituyeron una de las principales causas de degradación del desempeño, ya que modificaron la distribución de intensidades y colores captados por el sensor, influyendo directamente en las características aprendidas por el modelo [36].

Por ello, se utilizó una cabina de iluminación que permitió mantener la estabilidad del entorno visual y aumentar la repetitividad el sistema.

3.6.4. Estructura del conjunto de datos (train/val/test)

Con el fin de asegurar un entrenamiento y una evaluación adecuados, el conjunto de datos se estructuró conforme al esquema estándar de la clasificación supervisada. Para ello se establecieron tres subconjuntos como se mostró en la ilustración de la Figura 3.2 entrenamiento (train), validación (val) y prueba (test).




Figura 3.2: Imágenes de entrenamiento.

Esta disposición facilitó el control del sobreajuste y permitió obtener una estimación imparcial del desempeño del modelo.

De manera formal, el conjunto de datos total se definió como la unión de los subconjuntos

de entrenamiento validación y prueba tal como

$$\mathcal{D} = \mathcal{D}_{\text{train}} \cup \mathcal{D}_{\text{val}} \cup \mathcal{D}_{\text{test}}, \quad (3.3)$$

cumpléndose que dichos subconjuntos fueron mutuamente excluyentes. Esto se expresó matemáticamente mediante

$$\mathcal{D}_{\text{train}} \cap \mathcal{D}_{\text{val}} = \emptyset, \quad \mathcal{D}_{\text{train}} \cap \mathcal{D}_{\text{test}} = \emptyset, \quad \mathcal{D}_{\text{val}} \cap \mathcal{D}_{\text{test}} = \emptyset, \quad (3.4)$$

Esta separación previno la fuga de información (data leakage) [37], [39].

3.6.5. Diagrama de flujo de adquisición y organización del dataset




Figura 3.3: Diagrama de flujo del proceso de preparación del conjunto de datos.

En la Figura 3.3 el diagrama resumió las etapas necesarias para obtener un dataset estructurado y listo para el entrenamiento del modelo de clasificación.

3.7. Procesamiento digital de imágenes

3.7.1. Representación matemática y tamaño de entrada

Una imagen digital pudo modelarse como un tensor tridimensional definido por

$$\mathbf{X} \in \mathbb{R}^{H \times W \times C}, \quad (3.5)$$

donde H representó la altura, W el ancho y C el número de canales de color (RGB). En este trabajo se utilizó un tamaño de entrada fijo como se observó en

$$\mathbf{X} \in \mathbb{R}^{224 \times 224 \times 3}, \quad (3.6)$$

el cual fue ampliamente empleado en arquitecturas preentrenadas [36], [37].

3.7.2. Redimensionamiento

Con el propósito de garantizar uniformidad en la entrada del modelo, las imágenes se redimensionaron de la siguiente manera

$$\mathbf{X}' = \text{Resize}(\mathbf{X}, 224, 224), \quad (3.7)$$

Este procedimiento aseguró entradas homogéneas, mini-lotes conscientes y compatibilidad con técnicas de transferencia de aprendizaje [36], [37].

3.7.3. Normalización y escalado

Posteriormente, los valores de intensidad se normalizaron dividiéndolos por 255. Esto se expresa

$$\mathbf{X}_n = \frac{\mathbf{X}'}{255}, \quad (3.8)$$

De forma opcional, se aplicó una estandarización adicional definida

$$\mathbf{X}_{\text{std}} = \frac{\mathbf{X}_n - \mu}{\sigma}, \quad (3.9)$$

La finalidad de este proceso fue reducir variaciones de escala y facilitar la optimización del modelo mediante métodos de descenso por gradiente [37].

3.7.4. Convoluciones (núcleo CNN)

La operación de convolución se definió matemáticamente

$$S(x, y) = (I * K)(x, y) = \sum_i \sum_j I(x + i, y + j) K(i, j), \quad (3.10)$$

donde los núcleos convolucionales permitieron extraer patrones locales relevantes, tales como bordes, texturas y manchas [36], [37], [38].

3.7.5. Activación normalización y salida

El procesamiento posterior incluyó funciones de activación y normalización. En primer lugar, se empleó la función ReLU. Esto se expresó

$$\text{ReLU}(z) = \text{máx}(0, z), \quad (3.11)$$

seguida de Batch Normalization, definida mediante la ecuación (3.12):

$$\hat{x} = \frac{x - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}, \quad (3.12)$$

Finalmente, la capa de salida utilizó la función Softmax para estimar la probabilidad de pertenencia a cada clase definida matemáticamente

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}, \quad (3.13)$$

Este conjunto de operaciones permitió obtener una salida probabilística adecuada para tareas de clasificación multiclase [40], [41].

3.7.6. Preprocesamiento e inferencia




Figura 3.4: Diagrama de flujo del proceso de inferencia del modelo de clasificación.

En la Figura 3.4 se presentó el diagrama de flujo correspondiente al proceso de inferencia, desde la captura del frame hasta la obtención de la clase predicha y su nivel de confianza.

3.8. Entrenamiento

3.8.1. Arquitectura y transferencia de aprendizaje

$$\theta = \theta_{\text{preentrenado}} + \Delta\theta \quad (3.14)$$

Se utilizó el modelo YOLOv8-cls, el cual se encontró optimizado para tareas de clasificación en tiempo real, tal como se expresó en la ecuación (3.14) [42].

3.8.2. Configuración del entrenamiento

En la Figura 3.5 se mostrarán los parámetros de empleados durante el entrenamiento del modelo de clasificación, incluyendo el modelo base, el conjunto de datos, el tamaño de imagen, y el número de épocas y tamaño de lote.

```
yolo classify train model=yolov8n-cls.pt data=dataset_cls imgsz=224 epochs=30 batch=32
```

Figura 3.5: Configuración de entrenamiento del modelo YOLOv8-cls.

La Tabla 3.3 mostró los hiperparámetros que permitieron un entrenamiento estable del modelo, evitando el sobreajuste y manteniendo tiempos de entrenamiento adecuados para el hardware disponible.

Tabla 3.3: Parámetros de entrenamiento del modelo de clasificación.

| Parámetro | Valor |
|--------------------------|----------------|
| Modelo | yolov8n-cls.pt |
| Conjunto de datos | dataset_cls |
| Tamaño de imagen (imgsz) | 224 |
| Épocas | 30 |
| Tamaño de lote (batch) | 32 |

3.8.3. Función de pérdida y actualización

El proceso de entrenamiento del modelo se basó en la minimización de una función de pérdida, la cual midió la discrepancia entre las etiquetas reales y las predicciones del modelo.

En este trabajo se empleó la función de entropía cruzada categórica, definida en

$$\mathcal{L} = - \sum_{i=1}^C y_i \log(\hat{y}_i). \quad (3.15)$$

La actualización de los parámetros del modelo se realizó mediante el algoritmo de descenso por gradiente, tal como se expresa en

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} \mathcal{L}(\theta). \quad (3.16)$$

3.8.4. Flujo del entrenamiento




Figura 3.6: Diagrama de flujo del proceso de entrenamiento y selección del mejor modelo.

En la Figura 3.6 se presentó el diagrama de flujo correspondiente al proceso de entrenamiento, validación y selección del mejor modelo, destacando el carácter iterativo del ajuste de parámetros y la evaluación continua del desempeño.

3.9. Clasificación e implementación del sistema

3.9.1. Inferencia en tiempo real

Durante la etapa de inferencia, el modelo de clasificación procesó la imagen de un entrada y genera un vector de probabilidades asociadas a cada clase. Este proceso se define mediante

$$\hat{\mathbf{y}}_t = f_{\theta}(\mathbf{X}_t), \quad (3.17)$$

$$\hat{c}_t = \arg \max_k \hat{y}_{t,k}, \quad (3.18)$$

$$\text{conf}_t = \max_k \hat{y}_{t,k}, \quad (3.19)$$

donde \mathbf{X}_t representó la imagen de entrada en el instante t , $\hat{\mathbf{y}}_t$ fue el vector de probabilidades estimado por el modelo por cada clase, $\hat{y}_{t,k}$ correspondió a la probabilidad asociada a la clase k , \hat{c}_t es la clase predicha mediante el criterio Top-1, y conf_t indica el nivel de confianza asociado a dicha predicción.

3.9.2. Regla de decisión BUENO / MALO

Con base en la clase predicha por el modelo, se definió una regla de decisión binaria que permitió clasificar el objeto como *BUENO* o *MALO*, tal como

$$d(\hat{c}_t) = \begin{cases} \text{BUENO,} & \text{si } \hat{c}_t = \text{OK,} \\ \text{MALO,} & \text{caso contrario,} \end{cases} \quad (3.20)$$

donde \hat{c}_t representó la clase predicha por el modelo en el instante t , y $d(\hat{c}_t)$ correspondió a la decisión final del sistema de clasificación.

3.9.3. Métrica FPS

El rendimiento del sistema en tiempo real se evaluó mediante la tasa de cuadros por segundo (*Frames Per Second*, FPS), la cual se calculó

$$\text{FPS} = \frac{1}{t_{\text{actual}} - t_{\text{previo}}} \quad (3.21)$$

donde t_{actual} correspondió al instante de tiempo en el que se procesó el cuadro actual y t_{previo} representó el instante de tiempo del cuadro anterior.

3.9.4. Funcionamiento general del sistema



Figura 3.7: Diagrama de flujo del funcionamiento general del sistema de clasificación.

En la Figura 3.7 se presentó el diagrama de flujo correspondiente al proceso de captura, procesamiento, inferencia, clasificación y visualización de resultados del sistema propuesto.

Capítulo IV

RESULTADOS

En este capítulo se presentaron los resultados obtenidos tras la implementación y ejecución del sistema de clasificación automática de aguacates basado en redes neuronales convolucionales. El análisis se centró en evaluar el desempeño del modelo entrenado, su comportamiento en un entorno de ejecución real y las limitaciones observadas durante las pruebas experimentales.

A diferencia del capítulo metodológico, este apartado se enfocó exclusivamente en los resultados experimentales, su interpretación desde el punto de vista ingenieril y la validación práctica del sistema desarrollado. La evaluación se apoya en métricas cuantitativas, análisis visual, matrices de confusión y pruebas operativas en tiempo real.

4.1. Implementación y funcionamiento del sistema

Esta sección presentó los resultados asociados al proceso de implementación del modelo entrenado, demostrando que el aprendizaje alcanzado es consciente y adecuado para la tarea de clasificación propuesta.

El desempeño alcanzado por el modelo entrenado confirmó que la sección de técnicas basadas en redes neuronales convolucionales resultó adecuada para la detección de defectos en frutas, y en particular en aguacates. Los resultados obtenidos evidenciaron que este tipo de modelos fue capaz de capturar características visuales relevantes como textura, color y forma, las cuales resultaron fundamentales en procesos reales de inspección postcosecha.

4.1.1. Escenario experimental

Las pruebas se realizaron utilizando el conjunto de datos de prueba, compuesto por imágenes que no participaron en las fases de entrenamiento ni validación. Este enfoque garantizó que los resultados reflejaran la capacidad real de generalización del modelo frente a datos no vistos.

Las imágenes fueron capturadas bajo condiciones controladas de iluminación mediante una cabina diseñada para minimizar variaciones lumínicas, sombras y reflejos. El modelo evaluado corresponde al archivo `best.pt`, seleccionado automáticamente como el de mejor desempeño

durante el entrenamiento.

4.1.2. Resultados del entrenamiento

4.1.2.1. Análisis de la función de pérdida

La Figura 4.1 mostró la evolución de la función de pérdida del conjunto de entrenamiento y validación a lo largo de las épocas.




Figura 4.1: Evolución de la función de pérdida.

La evolución de la función de pérdida mostró una disminución progresiva y estable a lo largo de las épocas de entrenamiento. Este comportamiento indicó que el modelo logró aprender las

características visuales relevantes sin presentar inestabilidades numéricas.

La cercanía entre las curvas de entrenamiento y validación sugirió que el modelo no presentó sobreajuste significativo, lo cual constituyó un indicador positivo de generalización.

4.1.2.2. Análisis de exactitud

Figura 4.2 mostró la evolución de la exactitud del modelo durante el entrenamiento. Se mostraron las métricas de exactitud Top-1 y Top-5 obtenidas a lo largo de las épocas de entrenamiento, evidenciando un incremento progresivo del desempeño del modelo.




Figura 4.2: Exactitud (Top-1 / Top-5).

La exactitud Top-1 alcanzó valores cercanos al 80 %, mientras que la exactitud Top-5 se aproximó al 100 %. Esto implicó que, en la mayoría de los casos, la clase correcta se encontró dentro de las cinco predicciones más probables del modelo.

Este resultado es coherente con problemas de clasificación multiclase donde existieron similitudes visuales entre categorías, especialmente en defectos superficiales del aguacate.

4.1.3. Evaluación mediante matrices de confusión

4.1.3.1. Matriz de confusión absoluta

Figura 4.3. Mostró la matriz de confusión absoluta del conjunto de prueba. La figura mostró el número de aciertos y errores del modelo para cada clase evaluada, permitiendo identificar las clases con mayor y menor desempeño.




Figura 4.3: Matriz de confusión absoluta.

La matriz de confusión absoluta evidenció una alta concentración de aciertos en la diagonal principal, lo cual confirmó un desempeño general satisfactorio del sistema. Las clases LR, RO y TR presentan un alto número de verdaderos positivos.

Las confusiones más frecuentes se observaron entre las clases AN, DM y TR, lo que puede atribuirse a similitudes visuales en textura y coloración superficial.

4.1.3.2. Matriz de confusión normalizada




Figura 4.4: Matriz de confusión normalizada.

En la Figura 4.4, la matriz normalizada permitió analizar el desempeño relativo por clase.

Se observó que:

- LR alcanzó una tasa de reconocimiento cercana al 100 %.
- TR mantiene un desempeño elevado.

- AN presentó el mayor porcentaje de confusión, evidenciando la dificultad del problema.

4.1.4. Resumen cuantitativo del desempeño

En la tabla 4.1 se mostraron las métricas obtenidas durante la evaluación del modelo, destacando la exactitud Top-1, la exactitud Top-5, las clases mejor reconocidas y aquellas con mayor nivel de confusión.

Tabla 4.1: Resumen de métricas de desempeño del modelo.

| Métrica | Resultado observado |
|-------------------------------|----------------------------|
| Exactitud Top-1 | $\approx 80\%$ |
| Exactitud Top-5 | $\approx 100\%$ |
| Clases mejor reconocidas | LR, RO, TR |
| Clases con mayor confusión | AN, DM |
| Estabilidad del entrenamiento | Alta |

Esta tabla permitió sintetizar de forma clara el desempeño global del sistema.

A partir de los resultados obtenidos durante la evaluación del modelo, se confirmó que el algoritmo propuesto es capaz de identificar de manera automática distintos problemas visuales en los aguacates. La estabilidad del entrenamiento, junto con el desempeño observado en las matrices de confusión y las métricas de exactitud, demostró que el algoritmo cumplió con el propósito de identificar defectos de forma confiable.

4.2. Ejecución operativa del sistema

Esta sección describió la ejecución operativa del modelo entrenado y su integración en un sistema funcional.

El modelo entrenado fue cargado mediante un script desarrollado en Python, el cual permitió realizar inferencias tanto sobre imágenes individuales como sobre secuencias de vídeo capturadas en tiempo real. El sistema procesó cada imagen de entrada y generó una predicción inmediata.

Los resultados se visualizaron en tiempo real a través de una interfaz gráfica, mostrada en una pantalla, donde se indicó de forma clara el estado del aguacate evaluado. La interfaz presentó una información intuitiva que permitió identificar rápidamente si el producto cumplió con los criterios de aceptación.

Aunque el modelo fue entrenado como un clasificador multiclase, la ejecución final del sistema se orienta a una decisión binaria:

- AGUACATE BUENO.

- AGUACATE MALO.

Esta estrategia simplificó la interpretación de resultados y facilitó la integración del sistema en procesos de control de calidad automatizados.

4.3. Pruebas del sistema en operación

Durante las pruebas operativas se evaluó el desempeño del sistema bajo condiciones reales de ejecución.

4.3.1. Desempeño temporal y latencia

El sistema fue ejecutado sobre una plataforma Jetson Nano, la cual presentó limitaciones inherentes, incapacidad de procesamiento y consumo energético. Durante la ejecución se observó la presencia de lag, especialmente al procesar imágenes de mayor resolución o al ejecutar múltiples tareas simultáneamente.

Este comportamiento fue atribuible a la carga computacional asociada a la indiferencia con redes neuronales profundas en hardware embebido.

4.3.2. Errores de clasificación y casos límites

Durante las pruebas se identificaron errores de clasificación en situaciones donde existieron similitudes visuales entre defectos, particularmente en textura y coloración. Estos casos correspondieron a escenarios límite, donde incluso para un observador humano resulta compleja la diferenciación.

Este comportamiento evidenció la dificultad intrínseca del problema y resaltó la necesidad de incrementar la diversidad del dataset para mejorar la discriminación entre clases similares.

4.3.3. Análisis cualitativo del desempeño por clase

Tabla 4.2: Desempeño del modelo por clase.

| Clase | Desempeño | Observaciones |
|--------------|------------------|----------------------------------|
| AN | Medio | Confusión con defectos similares |
| DM | Bueno | Buen reconocimiento de daños |
| LR | Muy alto | Patrones bien definidos |
| OK | Bueno | Identificación estable |
| RO | Muy alto | Color y textura distintivos |
| TR | Muy alto | Defectos superficiales claros |

En la Tabla 4.2 se mostraron las observaciones principales del desempeño del modelo para cada clase, destacando aquellas con mayor precisión y las que presentaron mayores niveles de confusión.

4.4. Análisis visual de resultados

Como se observó en la Figura 4.5, el sistema presentó una alta correspondencia entre las etiquetas reales y las predicciones obtenidas, especialmente en las clases con patrones visuales bien definidos. Las discrepancias observadas se concentraron en casos límite, donde existen similitudes visuales entre defectos, lo cual coincidió con los resultados obtenidos en el análisis

cuantitativo mediante la matriz de confusión.




Figura 4.5: Análisis visual de resultados de inferencia del sistema de clasificación. (a) Etiquetas reales del conjunto de validación (lote 0). (b) Predicciones del modelo (lote 0). (c) Etiquetas reales del conjunto de validación (lote 1). (d) Predicciones del modelo (lote 1).

Las imágenes de inferencia mostraron que el sistema fue capaz de identificar correctamente la mayoría de los casos con alta confianza. Las predicciones con menor nivel de confianza correspondieron a escenarios donde el objeto presentó características intermedias entre clases.

Este análisis visual reforzó los resultados cuantitativos y permitió validar el comportamiento del sistema en situaciones reales.

Los resultados obtenidos demostraron que el sistema desarrollado presentó un desempeño adecuado para la clasificación automática de aguacates. La combinación de un entrenamiento estable, una ejecución funcional y una interfaz gráfica intuitiva confirmó la viabilidad del sistema para aplicaciones reales.

No obstante, se identificaron limitaciones asociadas al hardware embebido y a la similitud visual entre defectos, las cuales representaron oportunidades de mejora futura.

En este capítulo se presentaron y analizaron los resultados experimentales del sistema de clasificación automática de aguacates. El modelo implementado demostró una adecuada capacidad de generalización y un comportamiento consciente en tiempo real, validando el enfoque propuesto.

Los resultados confirmaron que el sistema es funcional, robusto y aplicable, construyendo una base sólida para su integración en el proceso de inspección visual automatizada.

Capítulo V

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

El desarrollo del sistema inteligente para la obtención automática de defectos en aguacates permitió demostrar que el uso de técnicas de aprendizaje de máquina basadas en redes neuronales convolucionales es una alternativa viable para la clasificación automática de la calidad del fruto. Los resultados experimentales obtenidos evidencian que el modelo implementado es capaz de identificar patrones visuales asociados a defectos externos y diferenciar entre aguacates en buen estado y mal estado, logrando una implementación funcional en un entorno de inspección visual automatizada.

El análisis de las técnicas empleadas para la detección de defectos en frutas que permitió identificar que los métodos basados en visión por computadora y aprendizaje profundo presen-

tan mayores ventajas frente a técnicas tradicionales, especialmente en términos de precisión y capacidad de generalización. En particular, el uso de redes neuronales convolucionales ha demostrado ser adecuado para el análisis visual de aguacates, ya que permite extraer automáticamente características relevantes como textura, color y forma, sin depender de reglas manuales o umbrales rígidos.

La propuesta del algoritmo basado en una arquitectura CNN tipo YOLOv8-cls permitió identificar de manera efectiva los defectos visuales presentes en los aguacates. El comportamiento del modelo durante el entrenamiento y la validación mostró una convergencia estable de la función de pérdida y un incremento progresivo de la exactitud, lo que confirma que el algoritmo propuesto es capaz de aprender las características discriminantes de cada clase, incluso en presencia de variabilidad visual entre defectos similares.

La implementación del algoritmo en un entorno de software permitió evaluar su desempeño tanto desde el punto de vista estadístico como operativo. Los resultados obtenidos mediante métricas como la exactitud Top-1, Top-5 y la matriz de confusión evidencian un desempeño satisfactorio del sistema en la clasificación de los de aguacate. Asimismo, la ejecución del modelo en una plataforma embebida permitió verificar su funcionamiento en condiciones cercanas a un escenario real, identificando fortalezas del sistema y limitaciones relacionadas con la latencia y el consumo de recursos computacionales.

5.2. Recomendaciones

Se recomienda ampliar el conjunto de datos utilizado para el entrenamiento del modelo, incorporando un mayor número de muestras por clase, especialmente en aquellas que presentan mayor nivel de confusión. Esto permitiría mejorar la capacidad de generalización del sistema y reducir errores de clasificación.

Es aconsejable mejorar las condiciones de adquisición de imágenes, manteniendo un control más estricto de la iluminación y el posicionamiento del fruto, con el fin de reducir variaciones que puedan afectar el desempeño del clasificador.

Para aplicaciones en tiempo real, se recomienda evaluar el uso de plataformas de hardware con mayor capacidad de procesamiento o la optimización del modelo, ya que durante las pruebas se evidenció la presencia de lag al ejecutar el sistema en la plataforma Jetson Nano.

Se recomienda documentar y monitorear de forma sistemática los errores de clasificación observados durante la operación del sistema, con el fin de retroalimentar el proceso de entrenamiento y mejorar continuamente el desempeño del modelo.

5.3. Trabajo a futuro

Como trabajo futuro, se plantea la implementación del sistema en dispositivos embebidos de mayor rendimiento, lo que permitiría evaluar su comportamiento en condiciones reales de operación industrial.

Se propone extender el sistema para incorporar nuevas clases de defectos y considerar variables adicionales, como el análisis interno del fruto mediante técnicas no invasivas.

Otra línea de investigación consiste en la integración del sistema con plataformas de monitoreo y control automatizado, permitiendo su uso dentro de cadenas de clasificación y empaque de productos agrícolas.

Finalmente, se sugiere explorar técnicas de aprendizaje profundo más avanzadas y estrategias de aumento de datos que permitan mejorar la capacidad de generalización del modelo frente a escenarios no contemplados durante el entrenamiento.

Bibliografía

- [1] W. Benalcázar, «Los fruticultores de Imbabura apuntan a la exportación,» *El Comercio*, 18 de febrero de 2018 [En línea]. Recuperado de: <https://www.elcomercio.com/actualidad/ecuador/imbabura-exportacion-frutas-comercio-agricultura/>.
- [2] CORPEI, «Perfil de Aguacates,» Corporación de Promoción de Exportaciones e Inversiones (CORPEI), Quito, Ecuador, Informe técnico, 2009.
- [3] MAGAP, «Buenas Prácticas Agrícolas para Aguacates,» Ministerio de Agricultura, Ganadería, Acuacultura y Pesca (MAGAP), Quito, Ecuador, Guía técnica, 2015.
- [4] *Norma Técnica Ecuatoriana para Frutas Frescas. Aguacates: Requisitos*, Norma técnica ecuatoriana, Quito: INEN, 2015.
- [5] J. Naranjo-Torres, M. Mora, R. Hernández-García, R. J. Barrientos, C. Fredes y A. Valenzuela, «A Review of Convolutional Neural Network Applied to Fruit Image Processing,» *Applied Sciences*, vol. 10, pág. 3443, mayo de 2020. DOI: [10.3390/app10103443](https://doi.org/10.3390/app10103443).

- [6] N. Ismail y O. A. Malik, «Real-time visual inspection system for grading fruits using computer vision and deep learning techniques,» *Information Processing in Agriculture*, febrero de 2021. DOI: [10.1016/j.inpa.2021.01.005](https://doi.org/10.1016/j.inpa.2021.01.005).
- [7] V. Zárate, E. González y D. Cáceres-Hernández, «Fruit Detection and Classification Using Computer Vision and Machine Learning Techniques,» págs. 1-6, junio de 2023. DOI: [10.1109/isie51358.2023.10228051](https://doi.org/10.1109/isie51358.2023.10228051).
- [8] J. F. I. Nturambirwe y U. L. Opara, «Machine learning applications to non-destructive defect detection in horticultural products,» *Biosystems Engineering*, vol. 189, págs. 60-83, enero de 2020. DOI: [10.1016/j.biosystemseng.2019.11.011](https://doi.org/10.1016/j.biosystemseng.2019.11.011).
- [9] B. Xiao, M. Nguyen y W. Q. Yan, «Fruit ripeness identification using YOLOv8 model,» *Multimedia Tools and Applications*, agosto de 2023. DOI: [10.1007/s11042-023-16570-9](https://doi.org/10.1007/s11042-023-16570-9).
- [10] T. Matsui, H. Sugimori, S. Koseki y K. Koyama, «Automated detection of internal fruit rot in Hass avocado via deep learning-based semantic segmentation of X-ray images,» *Postharvest biology and technology*, vol. 203, págs. 112 390-112 390, septiembre de 2023. DOI: [10.1016/j.postharvbio.2023.112390](https://doi.org/10.1016/j.postharvbio.2023.112390).

- [11] L. D. Valiente, K. Mhae y G. Carlo, «Non-destructive Image Processing Analysis for Defect Identification and Maturity Detection on Avocado Fruit,» octubre de 2021. DOI: [10.1109/iccis53528.2021.9645970](https://doi.org/10.1109/iccis53528.2021.9645970).
- [12] S. Lee, L. Chen, J. Wang, A. Liniger, S. Kumar y F. Yu, «Uncertainty Guided Policy for Active Robotic 3D Reconstruction Using Neural Radiance Fields,» *IEEE Robotics and Automation Letters*, vol. 7, págs. 12 070-12 077, octubre de 2022. DOI: [10.1109/lra.2022.3212668](https://doi.org/10.1109/lra.2022.3212668).
- [13] J. I. Vasquez-Gomez, L. E. Sucar y R. Murrieta-Cid, «View/state planning for three-dimensional object reconstruction under uncertainty,» *Autonomous Robots*, vol. 41, págs. 89-109, diciembre de 2015. DOI: [10.1007/s10514-015-9531-3](https://doi.org/10.1007/s10514-015-9531-3).
- [14] B. Göbel, J. Hurdeman, A. Reiterer y K. Möller, «Robot-Based Procedure for 3D Reconstruction of Abdominal Organs Using the Iterative Closest Point and Pose Graph Algorithms,» *Journal of Imaging*, vol. 11, pág. 44, febrero de 2025. DOI: [10.3390/jimaging11020044](https://doi.org/10.3390/jimaging11020044) [En línea]. Recuperado de: <https://www.mdpi.com/2313-433X/11/2/44>.

- [15] B. Göbel, A. Reiterer y K. Möller, «Image-Based 3D Reconstruction in Laparoscopy: A Review Focusing on the Quantitative Evaluation by Applying the Reconstruction Error,» *Journal of Imaging*, vol. 10, pág. 180, julio de 2024. DOI: [10.3390/jimaging10080180](https://doi.org/10.3390/jimaging10080180).
- [16] M. S. Hossain, M. Al-Hammadi y G. Muhammad, «Automatic Fruit Classification Using Deep Learning for Industrial Applications,» *IEEE Transactions on Industrial Informatics*, vol. 15, págs. 1027-1034, febrero de 2019. DOI: [10.1109/tii.2018.2875149](https://doi.org/10.1109/tii.2018.2875149).
- [17] L. T. Duong, P. T. Nguyen, C. Di Sipio y D. Di Ruscio, «Automated fruit recognition using EfficientNet and MixNet,» *Computers and Electronics in Agriculture*, vol. 171, pág. 105 326, abril de 2020. DOI: [10.1016/j.compag.2020.105326](https://doi.org/10.1016/j.compag.2020.105326).
- [18] A. Saikia et al., «Robotic Arm Platform for Multi-View Image Acquisition and 3D Reconstruction in Minimally Invasive Surgery,» *IEEE Robotics and Automation Letters*, vol. 10, págs. 3174-3181, abril de 2025. DOI: [10.1109/lra.2025.3540529](https://doi.org/10.1109/lra.2025.3540529) [En línea]. Recuperado de: <https://ieeexplore.ieee.org/document/10879583>.
- [19] S. K. Chakraborty et al., «Development of an optimally designed real-time automatic citrus fruit grading–sorting machine leveraging computer vision-based adaptive deep learning model,» *Engineering Applications of Artificial Intelligence*, vol. 120, pág. 105 826, abril de 2023. DOI: [10.1016/j.engappai.2023.105826](https://doi.org/10.1016/j.engappai.2023.105826).

- [20] M. Rizzo, M. Marcuzzo, A. Zangari, A. Gasparetto y A. Albarelli, *Fruit Ripeness Classification: a Survey*, arXiv.org, 2022 [En línea]. Recuperado de: <https://arxiv.org/abs/2212.14441>.
- [21] H. M. Rizwan Iqbal y A. Hakim, «Classification and Grading of Harvested Mangoes Using Convolutional Neural Network,» *International Journal of Fruit Science*, vol. 22, págs. 95-109, enero de 2022. DOI: [10.1080/15538362.2021.2023069](https://doi.org/10.1080/15538362.2021.2023069).
- [22] N. Gururaj, V. Vinod y K. Vijayakumar, «Deep grading of mangoes using Convolutional Neural Network and Computer Vision,» *Multimedia Tools and Applications*, julio de 2022. DOI: [10.1007/s11042-021-11616-2](https://doi.org/10.1007/s11042-021-11616-2).
- [23] *View of Carabao Mango Export Quality Checker Using MATLAB Image Processing*, Stepacademic.net, 2026 [En línea]. Recuperado de: <https://stepacademic.net/ijcsr/article/view/423/186>.
- [24] N. D. Thong, N. T. Thinh y H. T. Cong, *Mango Classification System Uses Image Processing Technology and Artificial Intelligence*, IEEE Xplore, julio de 2019. DOI: [10.1109/ICSSE.2019.8823119](https://doi.org/10.1109/ICSSE.2019.8823119) [En línea]. Recuperado de: <https://ieeexplore.ieee.org/document/8823119>.

- [25] 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, pág. 3483, noviembre de 2022. DOI: [10.3390/foods11213483](https://doi.org/10.3390/foods11213483).
- [26] 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,» *Multimedia Tools and Applications*, octubre de 2020. DOI: [10.1007/s11042-020-09747-z](https://doi.org/10.1007/s11042-020-09747-z).
- [27] R. Mardianto, S. Quinevera y S. Rochimah, «Perbandingan Metode Random Forest, Convolutional Neural Network, dan Support Vector Machine Untuk Klasifikasi Jenis Mangga,» *Journal of Applied Computer Science and Technology*, vol. 5, págs. 63-71, mayo de 2024. DOI: [10.52158/jacost.v5i1.742](https://doi.org/10.52158/jacost.v5i1.742).
- [28] J.-F. Yeh, K.-M. Lin, C. Lin y J.-C. Kang, «Intelligent Mango Fruit Grade Classification Using AlexNet-SPP With Mask R-CNN-Based Segmentation Algorithm,» *IEEE Transactions on AgriFood Electronics*, vol. 1, págs. 41-49, junio de 2023. DOI: [10.1109/tafe.2023.3267617](https://doi.org/10.1109/tafe.2023.3267617).

- [29] B. D. Peón, J. T. Gómez y A. F. Márquez, *CNN-based solution for mango classification in agricultural environments*, arXiv.org, 2025 [En línea]. Recuperado de: <https://arxiv.org/abs/2507.23174>.
- [30] P. Alexander, C. Augusto y R. Jaimes, «Módulo robótico para la clasificación de lulos (Solanum Quitoense) implementando visión artificial,» *Inge CuC*, vol. 10, págs. 51-62, 2018 [En línea]. Recuperado de: <https://revistascientificas.cuc.edu.co/ingecuc/article/view/343>.
- [31] V. Janneth, «Diseño e implementación de un sistema de control de calidad de rosas utilizando técnicas de visión artificial para la empresa Bosqueflowers,» *Epn.edu.ec*, 2026. DOI: [T-IE/3920/CD5504](https://bibdigital.epn.edu.ec/handle/15000/7355) [En línea]. Recuperado de: <https://bibdigital.epn.edu.ec/handle/15000/7355>.
- [32] X. Liming y Z. Yanchao, «Automated strawberry grading system based on image processing,» *Computers and Electronics in Agriculture*, vol. 71, S32-S39, abril de 2010. DOI: [10.1016/j.compag.2009.09.013](https://doi.org/10.1016/j.compag.2009.09.013).
- [33] I. Arzate-Vázquez et al., «Image Processing Applied to Classification of Avocado Variety Hass (Persea americana Mill.) During the Ripening Process,» *Food and Bioprocess Technology*, vol. 4, págs. 1307-1313, mayo de 2011. DOI: [10.1007/s11947-011-0595-6](https://doi.org/10.1007/s11947-011-0595-6).

- [34] E. Roa y G. Meneses, «Automated system for classifying Hass avocados based on image processing techniques,» págs. 1-6, junio de 2014. DOI: [10.1109/colcomcon.2014.6860414](https://doi.org/10.1109/colcomcon.2014.6860414) [En línea]. Recuperado de: <https://ieeexplore.ieee.org/abstract/document/6860414/references#references>.
- [35] A. Nogué, «Aplicación práctica de la visión artificial en el control de procesos industriales,» Institut la Garrotxa, Cataluña, España, abril de 2012.
- [36] R. Szeliski, *Computer Vision*. Springer International Publishing, 2022. DOI: [10.1007/978-3-030-34372-9](https://doi.org/10.1007/978-3-030-34372-9).
- [37] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*, Deeplearningbook.org, 2016 [En línea]. Recuperado de: <https://www.deeplearningbook.org/>.
- [38] A. Krizhevsky, I. Sutskever y G. E. Hinton, «ImageNet Classification with Deep Convolutional Neural Networks,» *Communications of the ACM*, vol. 60, págs. 84-90, mayo de 2012.
- [39] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.

- [40] S. Ioffe y C. Szegedy, *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift* [En línea]. Recuperado de: <https://static.googleusercontent.com/media/research.google.com/es//pubs/archive/43442.pdf>.
- [41] J. S. Bridle, «Probabilistic Interpretation of Feedforward Classification Network Outputs, with Relationships to Statistical Pattern Recognition,» *Neurocomputing*, págs. 227-236, 1990. DOI: [10.1007/978-3-642-76153-9_28](https://doi.org/10.1007/978-3-642-76153-9_28).
- [42] Ultralytics, *YOLOv8 Image Classification Documentation*, <https://docs.ultralytics.com>, 2024.
- [43] K. D. Farinango. «Sistema de detección automática de defectos en aguacates mediante redes neuronales convolucionales.» Repositorio GitHub [En línea]. Recuperado de: <https://github.com/kirmardamianfarinango/deteccion-defectos-aguacate-cnn>.

Anexos

Algoritmo de clasificación

El código fuente desarrollado para el sistema de detección automática de efectos en aguacates se encuentra disponible en un repositorio público en GitHub [43]. El repositorio contiene los scripts utilizados para el entrenamiento del modelo de clasificación basado en redes neuronales convolucionales, así como la implementación del sistema de inferencia en tiempo real mediante cámara USB.

El código se encuentra documentado y versionado con el objetivo de facilitar la reproductibilidad de los resultados y la verificación del funcionamiento del sistema que es propuesto.