

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Visión Artificial para el Futuro del Limón Tahití: Diseño de un Prototipo Inteligente
para la Clasificación Automática en la Agroindustria

Laura Alejandra Contreras Castro y Neil Sebastian Quiroga Vela

Trabajo de grado en modalidad de práctica empresarial para obtención del título de
ingeniería química

Director

Helver Crispiniano Álvarez Castro, PhD

Tutor:

MSc. Camilo Santos

Universidad industrial de Santander
Facultad de Ingenierías Fisicoquímicas
Escuela de Ingeniería Química
Bucaramanga
2026

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Dedicatoria

A Dios y a mi familia, por ser mis cimientos. Les agradezco por cada mercado y cada oración que me brindaron en cada regreso a clases.

A mi mamá Nubia, a mis hermanas Milena y Camila, y a mi papá Nelson: gracias por su apoyo incondicional y por ser la fuerza que me impidió rendirme.

A mis amigos y compañeros presentes y pasados, por cada conocimiento, alegría y revolución compartida; en especial a Felipe, Andrew, Dolan y Jan, por darme los mejores performances de cumpleaños de mi vida.

A Harold Andrés, por ser esa palabra de amor constante que me dio el impulso para continuar y por creer en mis capacidades incluso cuando yo dudaba.

A mi compañero Neil, por aceptar este reto juntos aquella mañana de lunes.

Finalmente, gracias a la universidad pública por darme el privilegio de ser la primera ingeniera de mi familia.

Laura Alejandra Contreras Castro

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

A mi familia por todo el amor y apoyo en todos estos años de carrera.

*A mis abuelos Miriam y Miguel por acogerme en su seno y ser capaces de soportarme
en todo el transcurso de mi infancia y la carrera.*

*A mi mamá Jeilher, mi hermana Mariángel y a mi papá Rey por ser las personas
incondicionales a las cuales me apoyaron y dieron las fuerzas para continuar.*

*A mis compañeros de la universidad con los cuales logre tener experiencias únicas y
gran compañerismo.*

*A mis mejores amigas Valentina y Dana con las cuales juntos pudimos continuar
todos hasta el final de esta travesía en donde celebramos victorias y nos apoyamos en las
desgracias.*

A mi compañera de tesis Laura por su buena energía y motivación.

Neil Sebastian Quiroga Vela

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Agradecimiento

A nuestro director Helver Crispiniano Álvarez Castro, por su acompañamiento y guía durante este proceso.

A Oscar y a nuestro tutor Camilo por ayudarnos en la corroboración de los códigos y enseñanza de aplicativos fundamentales para la continuación del prototipo.

Al aserradero del parque de Floridablanca por ayudar en la cortadura de las piezas necesarias para armar la parte estructural del prototipo.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Tabla de contenido

Introducción	13
1. Objetivos	14
1.1 Objetivo general	14
1.2 Objetivos Específicos	14
2. Marco teórico	14
2.1 Marco conceptual	15
2.2 Estado del Arte	17
3. Metodología	20
3.1 Estructura mecánica y flujo de transporte	20
3.2. Arquitectura de control e integración electrónica	22
3.3 Adquisición de datos y preprocesamiento	27
3.4 Entrenamiento del modelo predictivo (YOLOv8)	29
3.5 Lógica de inferencia y control en tiempo real	31
4. Resultados y Discusiones	33
4.1. Rendimiento computacional del modelo (YOLOv8)	33
4.2. Resultados Prácticos (Prueba Piloto en Tiempo Real)	36
4.3. Validación de la arquitectura de control anticipatorio	38
4.4. Análisis de la confianza del modelo y limitaciones	39
4.5. Impacto frente al estado del arte y aplicabilidad agroindustrial	40
5. Conclusiones	41
Referencias Bibliográficas	43

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Lista de tablas

Tabla 1	Especificaciones técnicas de los subsistemas y componentes de hardware implementados en el prototipo de clasificación automatizada.	24
Tabla 2	Distribución del conjunto de datos visuales de frutos en subconjuntos de partición (entrenamiento, validación y prueba) estratificados según su categoría de calidad.	29
Tabla 3	Evaluación manual del lote de control (25 limones Tahití), contrastando los tiempos de operación y la variabilidad en el criterio de clasificación (Apto/No Apto) entre dos operarios independientes.	36
Tabla 4	Evaluación de repetibilidad y desempeño del prototipo automatizado (YOLOv8) sobre un lote estandarizado durante tres ciclos continuos, reportando tiempos de operación, resultados de clasificación y el nivel predictivo de confianza.	38

Lista de figuras

- Figura 1 Partes del prototipo del sistema de clasificación de limones (a) Vista lateral; (b) Vista superior. 21
- Figura 2 Comparación estructural entre el diseño virtual y la implementación física del sistema clasificador. (a) Representación tridimensional del modelo base señalando sus componentes principales (1-6); (b) Fotografía del prototipo electromecánico ensamblado señalando sus componentes principales (1-6). 22
- Figura 3 Disposición física e integración de hardware del actuador electromecánico en la estación de descarte. 25
- Figura 4 Diagrama de bloques de la arquitectura de control anticipatorio (feedforward) aplicada al sistema automatizado de clasificación de frutos. 26
- Figura 5 Muestras representativas del conjunto de datos capturado por el sistema de visión, detallando la clasificación binaria de los frutos en las categorías "Aptos" y "No Aptos". 28
- Figura 6 Curvas de aprendizaje del modelo de visión artificial a lo largo de 200 épocas. Se detalla la convergencia de las funciones de pérdida (box, cls, dfl) y la evolución de las métricas de rendimiento (Precisión, Exhaustividad y mAP) para los subconjuntos de entrenamiento y validación. 30
- Figura 7 Mosaico de imágenes de entrenamiento con técnicas de aumento de datos (data augmentation): (a) Variaciones de brillo, (b) saturación cromática y (c) recortes geométricos (cropping). Se observa la correcta recalibración de las cajas delimitadoras (bounding boxes) para las clases Apto y No Apto tras las transformaciones. 31
- Figura 8 Diagrama de flujo de la secuencia operativa del prototipo de clasificación, detallando desde la alimentación manual de la materia prima hasta la toma de decisiones físicas (eyección o continuidad) basada en la inferencia en tiempo real del modelo YOLO. 31
- Figura 9 Matriz de confusión del modelo de visión artificial, evaluando el desempeño de clasificación cruzada entre las predicciones del algoritmo y las etiquetas reales para las categorías de frutos aptos ("buenos"), no aptos ("malos") y el fondo ambiental (background). 34

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Glosario

Algoritmo: Conjunto de instrucciones definidas para resolver un problema o realizar una tarea específica, como la clasificación de imágenes.

Aprendizaje Automático (Machine Learning): Rama de la IA que permite a los sistemas aprender patrones a partir de datos sin programación explícita.

Aprendizaje Supervisado: Tipo de aprendizaje automático donde el modelo se entrena con datos etiquetados para predecir resultados.

Buenas Prácticas de Manufactura (BPM): Normas que garantizan la higiene y calidad en la producción de alimentos.

Clasificación por Calidad: Proceso de segmentación de productos según parámetros físicos, químicos y sensoriales.

Codex Alimentarios: Conjunto de normas internacionales para alimentos, promovido por FAO y OMS.

Control de Procesos: Conjunto de técnicas para monitorear y ajustar variables en la producción, asegurando calidad y eficiencia.

Convolución: Operación matemática utilizada en redes neuronales para extraer características de imágenes.

Deep Learning (Aprendizaje Profundo): Subcampo del aprendizaje automático que utiliza redes neuronales con múltiples capas para tareas complejas.

Índice de Madurez: Parámetro que indica el estado de desarrollo del fruto, determinado por color, tamaño y firmeza.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Inteligencia Artificial (IA): Tecnología que permite a sistemas realizar tareas que requieren inteligencia humana, como clasificación y predicción.

Limón Tahití: Variedad de cítrico caracterizada por su color verde, forma ovalada y ausencia de semillas.

Normas Internacionales de Calidad: Regulaciones establecidas por organismos globales para garantizar la inocuidad y calidad de alimentos.

Red Neuronal Convolutiva (CNN): Arquitectura de aprendizaje profundo utilizada para análisis y clasificación de imágenes.

Segmentación de Imagen: Proceso de dividir una imagen en regiones para identificar objetos o características específicas.

Validación del Modelo: Proceso para evaluar el rendimiento de un modelo predictivo con datos no vistos durante el entrenamiento.

Variables Críticas de Proceso (VCP): Parámetros que deben controlarse para garantizar la calidad del producto final.

Visión Artificial: Aplicación de técnicas computacionales para interpretar imágenes y tomar decisiones basadas en ellas.

Lista de apéndices

Apéndice A. Planos prototipo	46
Apéndice B. Códigos operativos	47
Apéndice C. Composición de la Inteligencia Artificial.	53

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Resumen

Título: Visión Artificial Para El Futuro Del Limón Tahití: Diseño De Un Prototipo Inteligente Para La Clasificación Automática En La Agroindustria¹

Autor: Laura Alejandra Contreras Castro y Neil Sebastián Quiroga Vela^{2**}

Palabras clave: Limón Tahití, Visión artificial, YOLOv8, Control anticipatorio, Agroindustria, Automatización.

Descripción: La exportación del limón Tahití exige el cumplimiento de estrictos estándares internacionales de calidad; sin embargo, la clasificación visual manual genera variabilidad, subjetividad y cuellos de botella en la agroindustria. Este trabajo presenta el diseño y validación de un prototipo electromecánico basado en visión artificial para la selección automática de este cítrico. Se implementó una arquitectura de control anticipatorio (feedforward) que sincroniza el procesamiento de imágenes en tiempo real con la actuación física. El sistema integra un modelo de detección de objetos YOLOv8, ejecutado en un procesador central, que se comunica con un microcontrolador para accionar un pistón clasificador de baja latencia. El algoritmo fue entrenado utilizando un conjunto de datos propio, curado y balanceado de 2748 imágenes de limones, categorizados en dos clases (Apto y No Apto) según sus características superficiales. Las pruebas en la banda transportadora demostraron que el modelo alcanzó una precisión media (mAP50) del 95.7% y un tiempo de inferencia de 33 milisegundos por fotograma. Físicamente, el sistema logró una efectividad de separación del 80.0% a una velocidad de procesamiento constante de 9 frutos por minuto. La integración de arquitecturas de aprendizaje profundo con hardware de control de bajo costo demuestra ser una solución viable y escalable para optimizar líneas de poscosecha, garantizando consistencia y competitividad en el mercado global.

¹* Trabajo de grado

^{2**} Facultad de Ingenierías Físicoquímicas. Escuela de Ingeniería Química. Director: Ph. D.

Helver Crispiniano Álvarez Castro, Codirector: Ing. Camilo Santos.

Abstract

Title: Computer Vision For The Future Of Tahiti Lime: Design Of An Intelligent Prototype For Automatic Sorting In The Agro-Industry^{3*}

Author: Laura Alejandra Contreras Castro and Neil Sebastián Quiroga Vela^{4**}

Keywords: Tahiti Lime, Computer Vision, YOLOv8, Feedforward Control, Agro-industry, Automation.

Description: The export of Tahiti lime requires compliance with strict international quality standards; however, manual visual sorting leads to variability, subjectivity, and bottlenecks within the agro-industry. This paper presents the design and validation of an electromechanical prototype based on computer vision for the automatic selection of this citrus fruit. A feedforward control architecture was implemented to synchronize real-time image processing with physical actuation. The system integrates a YOLOv8 object detection model, executed on a central processor, which communicates with a microcontroller to trigger a low-latency sorting piston. The algorithm was trained using a custom, curated, and balanced dataset of 2,748 lime images, categorized into two classes (Suitable and Unsuitable) based on surface characteristics. Conveyor belt testing demonstrated that the model achieved a mean Average Precision (mAP50) of 95.7% and an inference time of 33 milliseconds per frame. Physically, the system reached a separation effectiveness of 80.0% at a constant processing speed of 9 fruits per minute. The integration of deep learning architectures with low-cost control hardware proves to be a viable and scalable solution for optimizing post-harvest lines, ensuring consistency and competitiveness in the global market.

^{3*} Bachelor thesis.

^{4**} Faculty of Physical-Chemical Engineering. School of Chemical Engineering. Director: Ph. D. Helver Crispiniano Álvarez Castro, Co-director: Ing. Camilo Santos.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Introducción

El sector agroindustrial constituye un pilar estructural para la economía, la seguridad alimentaria y el desarrollo rural a nivel global, siendo el cultivo y procesamiento de frutos cítricos uno de los renglones más dinámicos en el comercio internacional. En Colombia, el limón Tahití (*Citrus latifolia*) se ha consolidado como un producto de excepcionales proyecciones, reportando exportaciones valoradas en 47.9 millones de dólares únicamente en el primer cuatrimestre del año 2025. Este dinamismo abre oportunidades estratégicas invaluable; no obstante, la inserción competitiva exige el cumplimiento irrestricto de normativas como las establecidas por el Codex Alimentarius.

A pesar de la evolución en las líneas de empaque, la fase de selección poscosecha en una gran mayoría de las plantas regionales continúa fundamentándose en la inspección visual manual. Este enfoque es inherentemente subjetivo y desencadena una rápida fatiga cognitiva en los operarios, incrementando las tasas de error. Estos fallos impactan directamente en la rentabilidad de las empresas debido a penalizaciones y rechazos aduaneros en los puertos de destino. Frente a esta coyuntura, surge la necesidad de aplicar la automatización industrial, particularmente mediante herramientas de visión artificial.

El desarrollo de este trabajo de grado se enmarca en la modalidad de práctica empresarial y se articula con los objetivos de innovación de AC Ingeniería Virtual. Esta entidad, con sede en Bucaramanga, Santander, es una empresa de base tecnológica enfocada en la ingeniería 4.0, especializada en el diseño de software de simulación, integración de hardware para automatización y la creación de sistemas de visión e inteligencia artificial para el sector industrial. El respaldo de esta compañía facilitó el entorno tecnológico necesario para conceptualizar una solución mecatrónica orientada al sector agrícola local.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Considerando que la maquinaria comercial internacional posee costos prohibitivos que marginan a los pequeños productores, se plantea la siguiente pregunta de investigación: ¿Es viable técnica y operativamente desarrollar un prototipo electromecánico de bajo costo, fundamentado en algoritmos de aprendizaje profundo y control anticipatorio, que garantice la clasificación automatizada del limón Tahití bajo estándares de calidad exportable?

1. Objetivos

1.1 Objetivo general

Implementar un prototipo (TRL4/5) basado en visión artificial para la clasificación de limón Tahití, con el fin de mejorar el proceso de selección y aportar valor al sector agroindustrial.

1.2 Objetivos Específicos

Diseñar un sistema de visión artificial para la clasificación automática de limones Tahití, utilizando técnicas de procesamiento de imágenes que permitan evaluar su calidad según parámetros físicos y visuales.

Desarrollar un prototipo funcional (TRL 4/5) que integre hardware y software, aplicando algoritmos de procesamiento de imágenes que clasifiquen el limón Tahití en función de variables definidas para defectos superficiales.

Evaluar el impacto del prototipo desarrollado en la eficiencia del proceso de selección de limones Tahití en una línea de producción, mediante la comparación de tiempos de operación y reducción de errores en la clasificación en comparación con métodos tradicionales.

2. Marco teórico

2.1 Marco conceptual

El limón Tahití (*Citrus latifolia*) es una variedad de cítrico ampliamente cultivada en Colombia, reconocida por su color verde intenso, forma elíptica, textura lisa y ausencia de semillas, características que lo hacen altamente demandado en mercados internacionales. Su aceptación comercial depende de parámetros fisicoquímicos específicos, entre los que se destacan el color uniforme de la cáscara, el tamaño y la forma homogénea, la textura superficial sin rugosidades y la ausencia de defectos visibles como manchas, cicatrices, plagas o daños mecánicos. Estos atributos son esenciales para garantizar la conservación durante el transporte, la presentación estética y la estandarización comercial, factores que determinan el precio y la competitividad del producto en el mercado global.

En la agroindustria, la clasificación del limón Tahití se basa en criterios como el calibre, que define el tamaño del fruto; el grado de madurez, determinado por el color y la firmeza; la tolerancia mínima a defectos, establecida por normativas internacionales como el Codex Alimentarius y estándares ISO relacionados con calidad e inocuidad alimentaria. Cumplir con estos requisitos es fundamental para evitar rechazos en procesos de exportación, reducir pérdidas económicas y asegurar la trazabilidad del producto. Desde la perspectiva de la Ingeniería Química, esta etapa se vincula directamente con el control de calidad y con operaciones unitarias posteriores como lavado, empaque y almacenamiento, influyendo en la eficiencia global del proceso productivo.

Tradicionalmente, la clasificación se realiza mediante inspección visual manual, donde operarios evalúan color, tamaño y defectos. Aunque este método es flexible, presenta limitaciones significativas: la subjetividad en la percepción, la fatiga que disminuye la precisión con el tiempo y la baja reproducibilidad, lo que genera variabilidad en los resultados. Estas limitaciones afectan indicadores clave como la exactitud, el porcentaje de error y el nivel

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

de rechazo, reduciendo la eficiencia operativa y la productividad del sistema. En términos de ingeniería, la variabilidad del proceso y la falta de estandarización son factores críticos que impactan la competitividad del sector.

Ante estas limitaciones, la automatización surge como una solución estratégica. La automatización industrial consiste en integrar sensores y sistemas de control para ejecutar tareas sin intervención humana directa, lo que en la agroindustria se traduce en beneficios como mayor precisión, velocidad, trazabilidad y reducción de costos. Sin embargo, también implica retos como la inversión inicial, la capacitación técnica y la adaptación cultural. Este enfoque se alinea con los principios de la Industria 4.0, que promueve la digitalización, la conectividad y el análisis de datos para optimizar procesos productivos. Automatizar la clasificación del limón Tahití no solo responde a la necesidad de cumplir estándares internacionales, sino que también fortalece la competitividad y la sostenibilidad del sector.

En este contexto, la visión artificial se posiciona como una herramienta clave. Se define como la capacidad de un sistema computacional para interpretar imágenes y tomar decisiones basadas en ellas, diferenciándose de la visión humana por su objetividad y reproducibilidad. Un sistema de visión artificial comprende varias etapas: adquisición de imágenes mediante cámaras, preprocesamiento para corregir iluminación y reducir ruido, segmentación para separar el objeto del fondo, extracción de características como color, forma y textura, y finalmente la clasificación, que puede basarse en reglas predefinidas o en algoritmos de aprendizaje automático.

El procesamiento digital de imágenes es el núcleo técnico de estos sistemas. Las imágenes digitales se representan por píxeles organizados en canales de color como RGB o HSV, y se someten a técnicas como filtrado para eliminar ruido, umbralización para separar regiones por intensidad y detección de bordes para identificar contornos. En el caso del limón

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Tahití, las características visuales más relevantes son el color verde uniforme, el área y la forma que determinan el calibre, y la textura superficial que indica ausencia de defectos. Estas propiedades permiten correlacionar la calidad visual con los estándares internacionales exigidos para la exportación.

Finalmente, los sistemas inteligentes de clasificación integran estos principios mediante algoritmos que toman decisiones basadas en datos. Existen enfoques basados en reglas y otros que emplean aprendizaje automático, como las redes neuronales convolucionales (CNN), que aplican operaciones de convolución para extraer patrones complejos y lograr altos niveles de precisión. Los indicadores de desempeño más utilizados son la precisión, la exactitud y el error de clasificación, que permiten evaluar la efectividad del sistema frente al método manual. Desde la Ingeniería Química, la implementación de estos sistemas impacta en la eficiencia del proceso, la consistencia del producto y la escalabilidad industrial, contribuyendo a la competitividad y sostenibilidad del sector agroindustrial colombiano.

2.2 Estado del Arte

La literatura científica documenta ampliamente la migración de la agroindustria hacia métodos no destructivos de inspección basados en inteligencia artificial, evidenciando un desarrollo tecnológico a nivel internacional, regional y nacional.

A nivel global, el estado del arte comercial se encuentra dominado por grandes corporaciones que desarrollan infraestructuras de altísimo rendimiento. Compañías como Tomra Food han implementado plataformas de vanguardia como Spectrim, equipadas con el módulo de aprendizaje profundo LUCAi, el cual es capaz de procesar hasta 40.000 imágenes por segundo para identificar más de 20 tipos de defectos superficiales en cítricos con extrema precisión. De manera análoga, plataformas como Globalscan 7 de la corporación Maf Roda

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

integran cámaras multispectrales con inteligencia artificial para obtener la huella espectral de las patologías del fruto. En el ámbito investigativo global, la literatura reciente reporta el uso de arquitecturas ligeras de la familia YOLO para la identificación de enfermedades y quemaduras solares en cítricos (Cong et al., 2025). Asimismo, revisiones sistemáticas recientes ratifican que las Redes Neuronales Convolucionales (CNN) se han posicionado indiscutiblemente como el estándar global para la detección de enfermedades en este tipo de frutos. Otras investigaciones orientadas a la robótica han fusionado detectores convolucionales con redes de memoria a corto y largo plazo (LSTM) para predecir trayectorias en bandas transportadoras continuas, logrando eficacias de detección superiores al 94.1 % a velocidades de procesamiento entre 28 y 62 fotogramas por segundo (Yu et al., 2024). No obstante, el inmenso requerimiento de capital para adquirir estas maquinarias genera una barrera infranqueable para los ecosistemas agrícolas de economías en desarrollo.

Frente a las barreras económicas, en la región latinoamericana los esfuerzos científicos se han inclinado hacia la adaptación de estas tecnologías a las variabilidades fenotípicas del trópico mediante el desarrollo de soluciones asequibles. En Brasil, investigaciones han explorado el uso de redes neuronales profundas como ResNet combinadas con técnicas de aumento de datos (SMOTE) para clasificar el estado de madurez y los defectos en el limón persa, buscando mitigar la alta variabilidad morfológica que presenta el cultivo en dicho país (Giacometti, 2024). En México, instituciones académicas como la Universidad Autónoma de Tamaulipas (UAT) han desarrollado sistemas basados en inteligencia artificial enfocados específicamente en la detección temprana de plagas endémicas que afectan severamente a los cítricos de la región. En ecosistemas andinos como Perú, se documentan avances significativos en el diseño de sistemas automáticos de clasificación por visión artificial orientados a optimizar la cadena productiva de frutos de exportación. Por su parte, en Ecuador, investigadores como Pilco et al. (2024) han propuesto sistemas inteligentes fundamentados en placas

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

microcontroladoras para la clasificación de frutos, partiendo de la premisa de que las infraestructuras de grado corporativo resultan financieramente inviables para los campesinos locales.

Particularmente en Colombia, la investigación en visión artificial aplicada a la agroindustria ha experimentado un crecimiento notable, generando literatura técnica sumamente pertinente para este proyecto. A nivel país, se han documentado esfuerzos rigurosos para la creación de bases de datos autóctonas de frutas cítricas colombianas orientadas exclusivamente al entrenamiento de redes neuronales profundas y la implementación de sistemas de reconocimiento automático para frutas tropicales apoyados en Redes Neuronales Convolucionales (CNN) y aprendizaje por transferencia (Álvarez-Canchila et al., 2020) , y el desarrollo de sistemas de visión basados en lenguajes de código abierto para procesos integrados de manufactura (Amaya-Zapata et al., 2016). En investigaciones avanzadas a nivel nacional, se ha validado incluso el uso de técnicas de clasificación espectral compresiva de extremo a extremo (End-to-End Compressive Spectral Classification) mediante aprendizaje profundo, logrando precisiones de hasta el 99 % en la evaluación de calidad del limón Tahití en condiciones controladas de laboratorio. A nivel departamental, Santander se ha consolidado como un clúster líder en investigación agrotecnológica. Como antecedente directo e inspiración fundamental de este trabajo de grado, destacan las investigaciones de la Universidad Industrial de Santander, donde Imbaña y López (2021) demostraron la viabilidad técnica de determinar la calidad del limón Tahití empleando arquitecturas ligeras como MobileNet sobre plataformas de hardware embebido de bajo costo, tales como Raspberry Pi y Maix Bit. Posteriormente, autores de la región como Aristizábal et al. (2023) continuaron esta línea explorando la identificación de limones aptos para exportación utilizando visión computacional en sistemas embebidos. El presente trabajo de grado se construye sobre este robusto estado del arte, escalando las investigaciones previas al sustituir los algoritmos y hardware tradicionales por la

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

avanzada arquitectura YOLOv8, y trasladando el núcleo de la innovación hacia la integración electromecánica en tiempo real mediante teoría de control anticipatorio.

3. Metodología

La metodología utilizada para este proyecto consta de las siguientes fases las cuales se detallan en subsecciones: **(1)** diseño de la estructura mecánica y flujo de transporte (Sección 3.1); **(2)** arquitectura de control e integración del hardware electrónico (Sección 3.2); **(3)** recolección y curaduría del conjunto de datos o *dataset* (Sección 3.3); **(4)** entrenamiento del modelo de inteligencia artificial (Sección 3.4); y **(5)** integración algorítmica y control anticipatorio en tiempo real (Sección 3.5).

3.1 Estructura mecánica y flujo de transporte

El diseño electromecánico se desarrolló para garantizar la firmeza y estabilidad necesaria para el sistema de visión artificial (compuesto por la cámara Logitech C920 y el anillo de iluminación LED) y la precisión del actuador de descarte. Como se ilustra en la **Figura 1a**, el sistema integra cinco componentes para el flujo de operación: la banda transportadora (1), que permite el desplazamiento lineal de los frutos; la caja de análisis (2), diseñada para el aislamiento lumínico; las estaciones de soporte y descarte (3), donde se ubica el producto final; el motor síncrono (4), encargado de la tracción constante; y el conjunto de cámara web y aro de luz (5), responsable de la adquisición de imágenes.

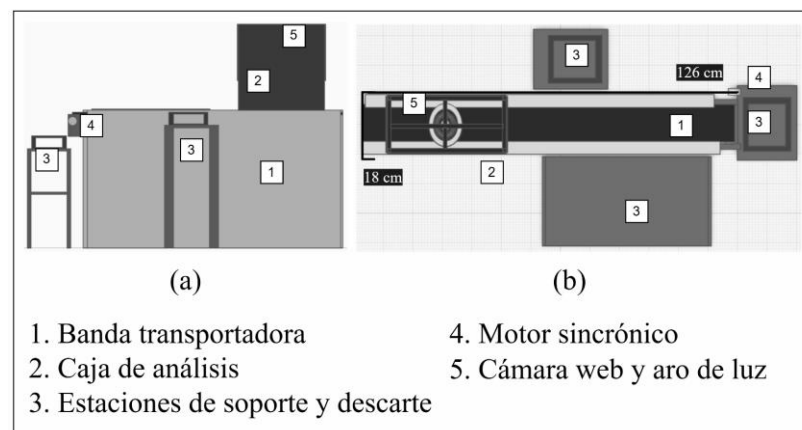
La banda transportadora tiene una longitud de 126 cm y un ancho de 18 cm esto se puede visualizar en la **Figura 1b**. Para asegurar las diferencias del fruto y permitir el análisis individual por parte del modelo computacional, la cinta está provista de separadores espaciados por cada 10 cm. El movimiento de la banda es impulsado por un motor síncrono TYC-50 (110

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

V, 30 RPM) acoplado a ejes cilíndricos de 4 cm de diámetro, lo que proporciona una velocidad constante y el tiempo de exposición adecuado para la captura de imágenes.

Figura 1

Partes del prototipo del sistema de clasificación de limones (a) Vista lateral; (b) Vista superior.

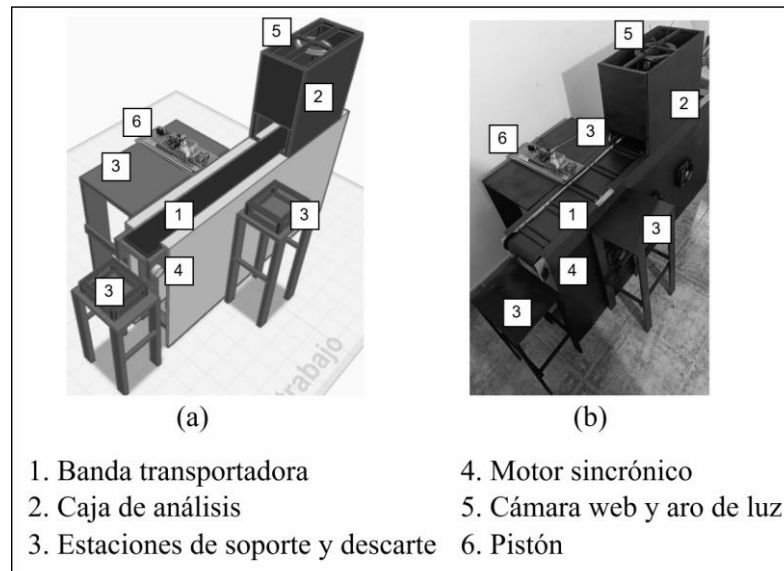


A continuación, se detallan en la **Figura 2** las seis partes fundamentales del prototipo, evidenciando la correspondencia entre el modelo virtual 3D **Figura 2a** y el sistema físico finalmente construido **Figura 2b**. El flujo de selección inicia sobre la banda transportadora (1), cuyo avance continuo y estable es garantizado por la tracción de un motor sincrónico (4). En la sección intermedia se ubica el módulo de inspección o caja de análisis (2), una cabina de 40x40x18 cm diseñada con tapas laterales para aislar la luz ambiental. Dentro de este entorno controlado opera el sistema de visión, compuesto por una cámara web y un aro de luz (5) encargados de capturar y homogeneizar la imagen de cada fruto. Por último, en la etapa posterior se encuentra la zona de acopio y estaciones de soporte (3), la cual incorpora un pistón (6) que actúa como mecanismo de eyección transversal para desviar físicamente los frutos clasificados como "No Aptos" aprovechando la inercia del movimiento.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Figura 2

Comparación estructural entre el diseño virtual y la implementación física del sistema clasificador. (a) Representación tridimensional del modelo base señalando sus componentes principales (1-6); (b) Fotografía del prototipo electromecánico ensamblado señalando sus componentes principales (1-6).



Como se puede observar en la comparativa de la **Figura 2**, el prototipo físico **Figura 2b** se construyó y validó fielmente a base del diseño y las especificaciones técnicas del modelo 3D inicial **Figura 2a**. Se mantuvo la misma distribución y funcionalidad de los componentes numerados (1 al 5), garantizando la integridad del diseño electromecánico durante la fase de implementación física.

3.2. Arquitectura de control e integración electrónica

La integración del hardware electrónico opera en un esquema de control anticipatorio (*feedforward*) diseñado para sistemas de eventos discretos, es decir que el sistema trata a cada limón individualmente como un 'evento' aislado gracias a los separadores de la banda. El control es anticipatorio porque la cámara (sensor) evalúa la calidad del fruto en aspectos físicos

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

y detecta los defectos mucho antes de que este alcance el elemento final de control (el pistón). Esto permite que la inteligencia artificial calcule y transmita la orden de rechazo con antelación para desviar el fruto defectuoso en el momento preciso.

Los componentes tecnológicos y de hardware necesarios para la operación del prototipo se encuentran detallados en la **Tabla 1**, donde se puede visualizar en la estación de trabajo central, está provista de un procesador Intel Core i5, 16 GB de RAM y una unidad de procesamiento gráfico (GPU) dedicada NVIDIA GeForce GTX 1650, responde a los requerimientos de cómputo del sistema. Los requerimientos de la arquitectura YOLOv8 para analizar el flujo de video a 23,64 fotogramas por segundo. El uso de esta GPU específica permite ejecutar el razonamiento algorítmico de manera local y en tiempo real disminuyendo el esfuerzo de procesamiento y de red que supondría procesar las imágenes en la nube o utilizando únicamente la CPU, garantizando así la sincronización estricta de la señal con el microcontrolador.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Tabla 1

Especificaciones técnicas de los subsistemas y componentes de hardware implementados en el prototipo de clasificación automatizada.

Subsistema	Componente	Especificaciones Técnicas
Procesamiento Central	Estación de trabajo (PC)	Procesador Intel Core i5-12450H (2.00 GHz), 16 GB RAM. GPU: NVIDIA GeForce GTX 1650. Arquitectura x64.
Visión Artificial	Cámara Web de Inspección	Resolución de captura HD (1080p/720p) a 30/60 fps*. Conexión USB.
Iluminación	Aro de Luz LED	Iluminación difusa continua, temperatura de color fría para maximizar el contraste del fruto.
Unidad de Control	Placa Microcontroladora	Arduino Uno R3. Microcontrolador ATmega328P, 5V de operación lógica, comunicación Serial (USB).
Detección de Presencia	Sensor Ultrasonido	de Módulo HC-SR04. Rango de medición: 2 cm a 400 cm. Precisión de 3 mm. Ángulo de medición < 15°.
Actuación y Potencia	Driver de Motor	Módulo L298N / Relé de potencia. Soporte para modulación por ancho de pulsos (PWM) y control de giro.
Actuación Física	Pistón Electromecánico	Motor de corriente continua (DC) acoplado a mecanismo de piñón y cremallera. Respuesta de accionamiento rápido.


CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

El sistema de visión, alojado en la cabina de inspección, consta de una cámara web de resolución HD y un aro de luz LED. Esta configuración garantiza una iluminación difusa y constante, aumentando el contraste del cítrico y minimizando los falsos positivos derivados de sombras o reflejos.

El actuador del proceso consiste en un pistón electromecánico impulsado por un motor de corriente continua (DC) mediante un mecanismo de piñón y cremallera. La **Figura 3** detalla la disposición física de este conjunto, donde se observa la instalación de un sensor de ultrasonido (HC-SR04) perpendicular al flujo de la banda. Todo el conjunto de potencia y actuación es gobernado por una placa microcontroladora Arduino Uno a través de un *driver* L298N, cuyas conexiones y disposición física se aprecian en la misma figura. Esta unidad periférica se comunica vía serial con la estación de trabajo central (equipada con una GPU NVIDIA GeForce GTX 1650), la cual procesa la carga algorítmica pesada.

Figura 3

Disposición física e integración de hardware del actuador electromecánico en la estación de descarte.



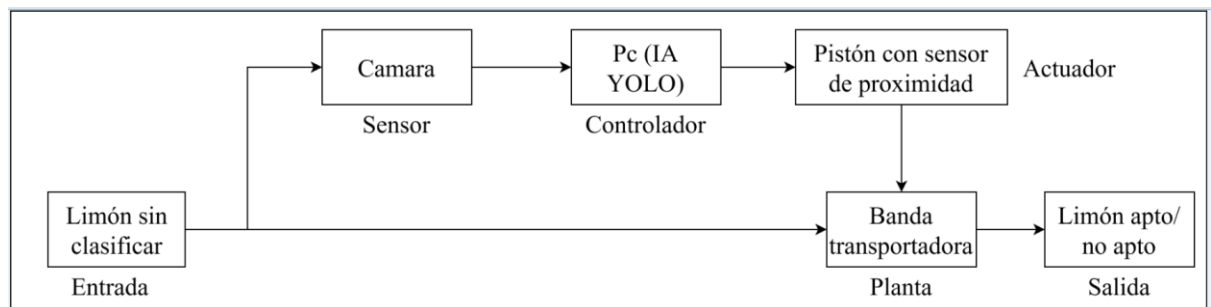
La interacción entre los componentes de hardware y software se modeló bajo una arquitectura de control anticipatorio (*feedforward*). La **Figura 4** ilustra el diagrama de bloques que define esta arquitectura, estructurando la jerarquía de toma de decisiones del sistema; en

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

ella se evidencia cómo la cámara (sensor) evalúa la entrada (limón sin clasificar) permitiendo que el controlador (PC con IA YOLO) anticipe la perturbación y comande al actuador (pistón con sensor de proximidad). De este modo la acción de control se ejecuta sobre la planta (banda transportadora) para determinar la salida final del fruto como apto o no apto.

Figura 4

Diagrama de bloques de la arquitectura de control anticipatorio (feedforward) aplicada al sistema automatizado de clasificación de frutos.



Como se detalla en el diagrama, el flujo del proceso y la toma de decisiones se dividen en las siguientes etapas funcionales:

- **Entrada y Perturbación:** Corresponde al ingreso físico de los limones a la banda transportadora. Al contar con separadores cada 10 cm, el sistema garantiza un flujo discreto e individualizado tratando a cada limón como un evento independiente.
- **Etapas de Medición (Sensores):** El sistema de visión artificial (cámara) adquiere las características únicas del fruto bajo condiciones de iluminación controlada.
- **Controlador Principal:** El procesamiento de la señal se divide en dos niveles. El cálculo intensivo y la toma de decisión (inferencia) son ejecutados por el computador mediante el modelo de redes neuronales (YOLO), el cual clasifica el limón como "Apto" o "No Apto". Esta decisión lógica es transmitida a la placa

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

microcontroladora (Arduino Uno), la cual se encarga de traducir la orden digital en una señal eléctrica de potencia.

- **Elemento Final de Control (Actuador):** Compuesto por el *driver* de potencia y el pistón electromecánico. La acción de control se ejecuta de forma binaria (encendido/apagado).
- **Planta (Proceso):** Es la zona de descarte sobre la banda transportadora. Si el controlador decide que el fruto es "No Apto", el pistón se activa, alterando la trayectoria del limón y desviándose hacia la caja de rechazo.

El controlador calcula un tiempo de retardo (*delay*) exacto entre el momento en que la cámara captura la imagen y el momento en que el pistón debe golpear. Este cálculo se parametriza asumiendo una velocidad constante en la banda transportadora, garantizando que el actuador intervenga únicamente sobre el fruto previamente analizado, sin afectar a las unidades anteriores o posteriores a éste.

3.3 Adquisición de datos y preprocesamiento

El desarrollo de los componentes del prototipo se estructuró en tres fases secuenciales: la consolidación del conjunto de datos (*dataset*), el entrenamiento del modelo predictivo y la integración de códigos de respuesta con el hardware de actuación.

Para el entrenamiento del modelo, se requirió la construcción de un conjunto de datos específico para el limón Tahití, capturado bajo las condiciones operativas del prototipo. La adquisición visual se realizó mediante la grabación continua de los frutos pasando por la cabina de inspección bajo iluminación constante, simulando así una línea de clasificación real. Para ello, se introdujeron aleatoriamente sobre la banda transportadora, de forma discontinua e irregular, frutos de dos clases: Aptos (frutos con coloración verde uniforme, textura lisa y sin daños aparentes) y No Aptos (frutos que presentan patologías o defectos físicos no permitidos


CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

para la exportación, tales como oleocelosis, melanosis, sarna cítrica, daños mecánicos o marcas por plagas como trips).

Esta categorización se fundamentó en los parámetros morfológicos de calidad y tolerancia a defectos establecidos en el manual técnico de producción nacional (Murcia Riaño et al., 2020) y las directrices internacionales actualizadas para frutos cítricos (Codex Alimentarius, 2023). El video resultante del proceso tuvo una duración de 2 minutos, capturado a una resolución de 1920×1080 píxeles con una frecuencia de 23,64 fotogramas por segundo (fps). Posteriormente, mediante un algoritmo desarrollado en Python, se procesó este archivo para la extracción secuencial de los cuadros, obteniendo así un espacio de 2.748 imágenes. Un ejemplo visual del resultado de esta categorización entre frutos aptos y no aptos se detalla en la **Figura 5**.

Figura 5

Muestras representativas del conjunto de datos capturado por el sistema de visión, detallando la clasificación binaria de los frutos en las categorías "Aptos" y "No Aptos".



A partir de las secuencias de video, se aplicó un muestreo selectivo de fotogramas (*frames*) para asegurar la variabilidad espacial del fruto y eliminar la redundancia de datos. Este procedimiento permitió consolidar un *dataset* final de 2.748 imágenes óptimas para el

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

entrenamiento. Para evitar sesgos predictivos, la muestra se balanceó estrictamente: 50% (1.374 imágenes) correspondientes a frutos aptos y 50% a frutos no aptos. El etiquetado de las cajas delimitadoras (*bounding boxes*) se ejecutó en la plataforma Roboflow, dividiendo el conjunto en subconjuntos de entrenamiento (70%), validación (20%) y prueba (10%), como se detalla en la Tabla 2.

Tabla 2

Distribución del conjunto de datos visuales de frutos en subconjuntos de partición (entrenamiento, validación y prueba) estratificados según su categoría de calidad.

Subconjunto	Porcentaje	Clase "Apto" (50%)	Clase "No Apto" (50%)	Total Imágenes
Entrenamiento (<i>Train</i>)	70 %	962	962	1924
Validación (<i>Valid</i>)	20 %	275	275	550
Prueba (<i>Test</i>)	10 %	137	137	274
Total General	100 %	1374	1374	2748

3.4 Entrenamiento del modelo predictivo (YOLOv8)

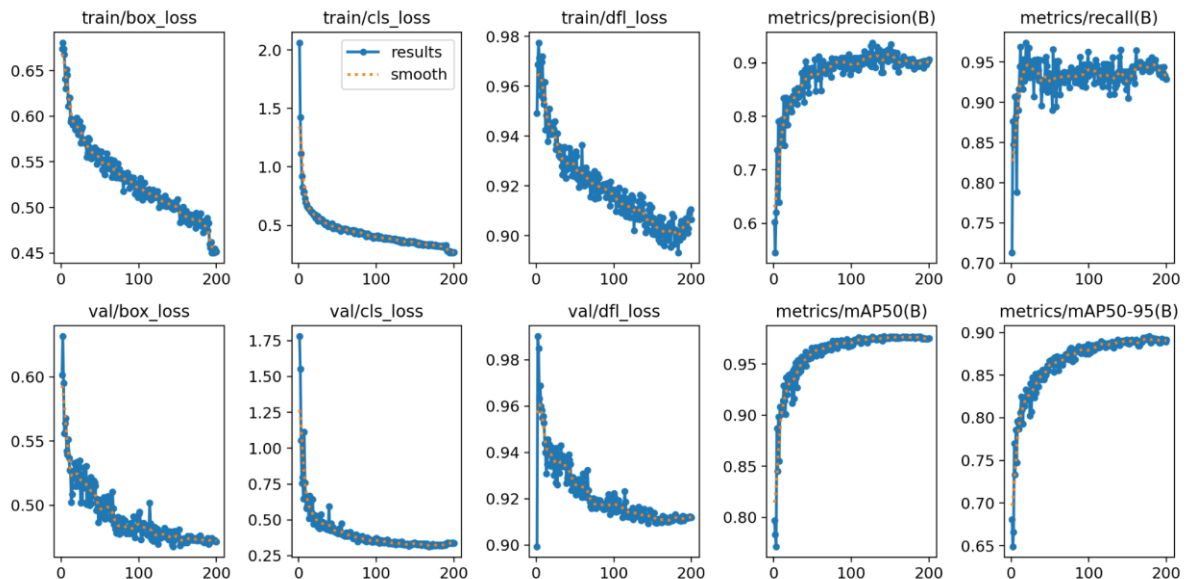
Para la tarea de detección y clasificación en tiempo real, se seleccionó la arquitectura de red neuronal convolucional YOLOv8 (Ultralytics) debido a su equilibrio entre precisión computacional y baja latencia de inferencia. Dada la exigencia del procesamiento de tensores,

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

el entrenamiento se ejecutó en un entorno de computación en la nube (Google Colab), habilitando aceleración por hardware mediante una GPU NVIDIA Tesla T4. Como se observa en la **Figura 6**, el entrenamiento se configuró para 200 épocas debido a que las curvas de precisión (*Precision*) y las métricas de pérdida (*Loss*) alcanzan una estabilización temprana (convergencia). Prolongar el entrenamiento más allá de este punto no aportaría mejoras significativas al asertividad del modelo y aumentaría el riesgo de sobreajuste (*overfitting*).

Figura 6

Curvas de aprendizaje del modelo de visión artificial a lo largo de 200 épocas. Se detalla la convergencia de las funciones de pérdida (box, cls, dfl) y la evolución de las métricas de rendimiento (Precisión, Exhaustividad y mAP) para los subconjuntos de entrenamiento y validación.




Durante la fase de entrenamiento el algoritmo aplica internamente diversas transformaciones de aumento de datos (*data augmentation*), como se evidencia en la **Figura 7** estas técnicas pueden incluir la generación de mosaicos (combinación aleatoria de varias fotografías) y alteraciones dinámicas de saturación y exposición lumínica. Estas

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

transformaciones ayudan a robustecer al modelo frente a los cambios de iluminación reales de la banda transportadora.

Figura 7

Mosaico de imágenes de entrenamiento con técnicas de aumento de datos (data augmentation): (a) Variaciones de brillo, (b) saturación cromática y (c) recortes geométricos (cropping). Se observa la correcta recalibración de las cajas delimitadoras (bounding boxes) para las clases Apto y No Apto tras las transformaciones.



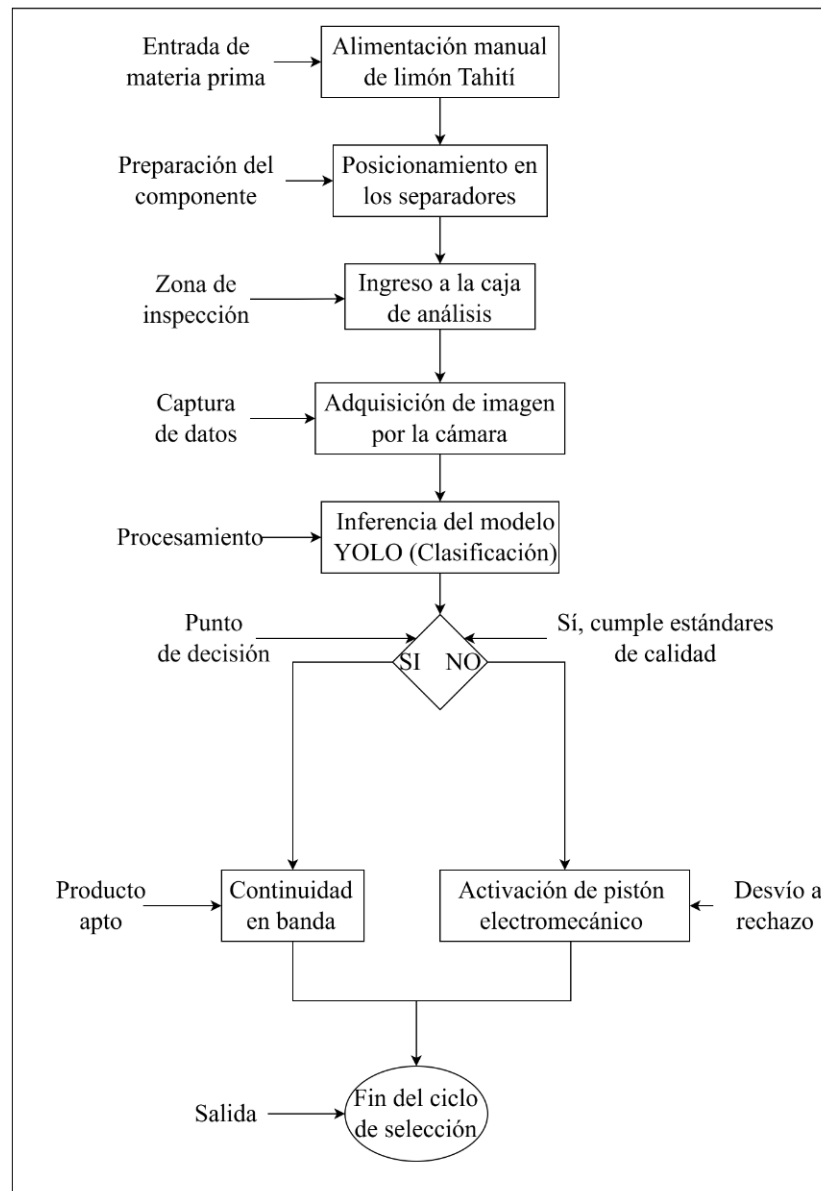
3.5 Lógica de inferencia y control en tiempo real

El acoplamiento del modelo computacional con la estación física de descarte se rige por el flujo metodológico que se puede ver en la **Figura 8**.

Figura 8

Diagrama de flujo de la secuencia operativa del prototipo de clasificación, detallando desde la alimentación manual de la materia prima hasta la toma de decisiones físicas (eyección o continuidad) basada en la inferencia en tiempo real del modelo YOLO.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ



La arquitectura de software se diseñó de manera distribuida para garantizar tiempos de respuesta predecibles.

La estación de trabajo central ejecuta un *script* en Python que decodifica el video en vivo y realiza la inferencia continua mediante el modelo YOLOv8. Al clasificar un fruto con la etiqueta "No Apto", el PC transmite instantáneamente una bandera digital mediante comunicación serial hacia la placa microcontroladora (Arduino Uno).

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

El microcontrolador actúa como una unidad periférica de control de actuadores. Al recibir la bandera inicia una rutina de lectura de alta frecuencia en el sensor ultrasónico HC-SR04, el cual monitorea perpendicularmente la zona de rechazo. Cuando el fruto interrumpe el haz ultrasónico el sistema confirma la alineación física exacta y envía una señal de potencia al controlador del motor (driver L298N). Esto desencadena la extensión rápida del pistón electromecánico (piñón-cremallera) para expulsar el limón defectuoso, invirtiendo la polaridad en milisegundos para retornar a su posición de reposo y quedar disponible para el siguiente ciclo de evaluación.

4. Resultados y Discusiones

Para validar la eficacia del sistema automatizado de selección de limón Tahití, el análisis de resultados se estructura en dos fases: una evaluación computacional (teórica) y una validación física (práctica). La primera fase analiza el rendimiento del modelo de inteligencia artificial entrenado con el dataset propio, evaluando sus métricas de precisión para la detección y clasificación del fruto. La segunda fase somete al prototipo electromecánico a un entorno de operación continuo, donde el sistema procesa y descarta limones ingresados de forma aleatoria en la banda transportadora. Posteriormente se encuentran tres secciones de discusión para analizar la metodología que permite constatar no solo la exactitud predictiva del algoritmo, sino también la fidelidad, sincronización y viabilidad del equipo físico en su conjunto.

4.1. Rendimiento computacional del modelo (YOLOv8)

El entrenamiento del modelo converge en 50 épocas, punto en el cual las curvas de pérdida se estabilizaron (como se evidenció previamente en la **Figura 6**), mitigando el riesgo de sobreajuste (*overfitting*). El algoritmo alcanzó una Precisión Media (mAP50) del 95.7%, demostrando una alta robustez en la detección bajo condiciones controladas. El modelo registró

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

una Precisión de 0.90 y una sensibilidad (*Recall*) de 0.95. Estos valores se pueden entender en una minimización de falsos positivos (evitando el rechazo y desperdicio de limones aptos) y una reducción drástica de falsos negativos (garantizando que los frutos con patologías no superen el control de calidad). El análisis de la matriz de confusión confirma este desempeño, evidenciando que los márgenes de error se limitaron a confusiones menores con el fondo de la banda transportadora (*background*), con apenas 42 y 26 instancias de clasificación errónea sobre el conjunto de validación, confirmando la viabilidad del algoritmo para la toma de decisiones en tiempo real. Como se puede ver anteriormente en la **Figura 7**, el modelo YOLOv8 logra una correcta delimitación espacial (*bounding boxes*) de los frutos sobre la cinta transportadora, demostrando una adaptación a las condiciones de iluminación difusa de la cabina sin confundir el fruto con los topes separadores.

Para cuantificar esta capacidad de discriminación, se analizó la matriz de confusión en la **Figura 9**. Los resultados demuestran una buena fiabilidad del algoritmo: El análisis de la matriz de confusión revela que el modelo identificó de manera correcta el **92.1 %** de los limones en estado óptimo ('Aptos') y el **84.4 %** de los frutos defectuosos ('No Aptos'). Las tasas de error cruzado entre clases directas son sobresalientes, destacando un **0.0 %** de falsos negativos (ningún limón apto fue clasificado como defectuoso) y apenas un **0.3 %** de falsos positivos (frutos defectuosos clasificados como aptos). La minoría de las confusiones del modelo (7.9 % y 15.3 % respectivamente) se generaron contra el fondo de la imagen (*background*), un margen de error técnicamente seguro, ya que previene la activación del actuador electromecánico en falsos descartes, garantizando la rentabilidad en la línea de producción.

Figura 9

Matriz de confusión del modelo de visión artificial, evaluando el desempeño de clasificación

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

cruzada entre las predicciones del algoritmo y las etiquetas reales para las categorías de frutos aptos ("buenos"), no aptos ("malos") y el fondo ambiental (background).

		Confusion Matrix		
		buenos	malos	background
Predicted	buenos	92%		8%
	malos	0,30%	84%	15,30%
	background	25,00%	75%	
		buenos	malos	background
		True		

(Nota: Para fines de programación y etiquetado en el software, las clases se definieron internamente como "buenos" y "malos", correspondiendo directamente a las categorías "Aptos" y "No Aptos" analizadas en este estudio)

Las curvas de pérdida de clasificación (*cls_loss*) y delimitación (*box_loss*) mostraron una convergencia sostenida, descartando fenómenos de sobreajuste (*overfitting*). El modelo YOLOv8 alcanzó métricas aceptables para la automatización en tiempo real, logrando una Precisión Media (mAP50) del 95.7 %, una Precisión (*Precision*) del 90 % y una Exhaustividad (*Recall*) del 95 %.

La capacidad de discriminación del algoritmo se corroboró mediante la matriz de confusión. El sistema demostró una sensibilidad industrial al identificar correctamente 253 frutos defectuosos ('No Aptos') y 271 frutos en estado óptimo ('Aptos'). Las tasas de error se mantuvieron en márgenes mínimos, con solo 42 falsos positivos y 26 falsos negativos, lo que garantiza que la señal lógica enviada al actuador electromecánico posea la fiabilidad necesaria para minimizar el desperdicio de producto en la línea de empaque.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

4.2. Resultados Prácticos (Prueba Piloto en Tiempo Real)

Se midió el tiempo que tardaron dos operarios en clasificar los 25 frutos. Los resultados de esta prueba se pueden evidenciar en la **Tabla 3** donde se presentan las deficiencias de la inspección visual tradicional.

A. Evaluación del Método Tradicional (Manual)

Para establecer una línea base de comparación, se evaluó el rendimiento de la inspección visual humana tradicional. Se midió el tiempo y la precisión de dos operarios independientes al clasificar un lote de control estandarizado de 25 limones Tahití. Los resultados de esta prueba piloto, detallados en la **Tabla 3**, exponen claramente los problemas de este enfoque. Como se observa en los datos, existe una discrepancia significativa entre los evaluadores tanto en el tiempo total de operación invertido (65 s frente a 75 s) como en el criterio de selección final para la misma muestra. Esta disparidad en el conteo de frutos aptos y no aptos evidencia la alta subjetividad y la inconsistencia inherentes a la inspección manual, justificando la necesidad de implementar un sistema automatizado.

Tabla 3

Evaluación manual del lote de control (25 limones Tahití), contrastando los tiempos de operación y la variabilidad en el criterio de clasificación (Apto/No Apto) entre dos operarios independientes.

Evaluador Humano	Tiempo de Operación (s)	Limones "Aptos" (Buenos)	Limones "No Aptos" (Malos)
Operario 1	65.00	12	13

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Operario 2	75.00	9	16
------------	-------	---	----

El método manual es rápido al inicio, logrando un tiempo promedio de 70 segundos por lote. Sin embargo, el dato más crítico expuesto en la **Tabla 3** es la diferencia de criterio entre ambas personas: frente a los mismos 25 limones exactos, un operario aceptó 12 y el otro solo 9. Esta subjetividad genera un margen de desacuerdo inaceptable a escala industrial, el cual representaría cientos de kilos de fruta mal clasificada o rechazada indebidamente por un error de percepción. Además, la velocidad física del humano decae naturalmente después de unas horas debido a la fatiga visual.

B. Evaluación del Prototipo Automatizado

El mismo lote de 25 limones fue alimentado a través de la banda transportadora en tres corridas experimentales distintas para evaluar el sincronismo cámara-procesador-pistón y el comportamiento probabilístico de la red neuronal en movimiento.

Los resultados en la **Tabla 4** evidencian un comportamiento mecatrónico radicalmente distinto. Aunque el tiempo promedio del prototipo (158.89 segundos) es superior al del operario descansado, su ventaja competitiva radica en la varianza nula de su capacidad de atención. La máquina establece un flujo determinista de 9.4 frutos por minuto (aproximadamente 566 frutos ininterrumpidos por hora) que no padece pausas fisiológicas.

Respecto a la métrica de Confianza Promedio IA, los registros del sistema revelaron que, durante el flujo dinámico, la certeza de la red descendió a un promedio del 66.82% (frente al 94% in-silico). Sin embargo, el umbral de activación binaria de YOLOv8 se mantuvo lo suficientemente resiliente para tomar decisiones acertadas a tiempo, permitiendo que la placa Arduino accionara el pistón con una efectividad física que rondó el 80%.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Respecto a la métrica de Confianza Promedio IA, los registros del sistema revelaron que, durante el flujo dinámico, la certeza de la red descendió a un promedio del 66.82% (frente al 94% in-silico). Sin embargo, el umbral de activación binaria de YOLOv8 se mantuvo lo suficientemente resiliente para tomar decisiones acertadas a tiempo, permitiendo que la placa Arduino accionara el pistón con una efectividad física que rondó el 80%.

Tabla 4

Evaluación de repetibilidad y desempeño del prototipo automatizado (YOLOv8) sobre un lote estandarizado durante tres ciclos continuos, reportando tiempos de operación, resultados de clasificación y el nivel predictivo de confianza.

Prueba Práctica (IA)	Tiempo de Operación (s)	Limones "Aptos" (Buenos)	Limones "No Aptos" (Malos)	Confianza Promedio IA (%)
Práctica 1	162.14	11	14	69.42 %
Práctica 2	130.38	14	11	67.37 %
Práctica 3	184.16	12	13	63.66 %
Promedio Automatizado	158.89	12	13	66.82 %

4.3. Validación de la arquitectura de control anticipatorio

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Los resultados de la prueba piloto en estado continuo demuestran la viabilidad técnica de la arquitectura distribuida (PC-Arduino) implementada. El procesamiento ininterrumpido de 71 muestras evidenció que el esquema de control *feedforward* logró mitigar el cuello de botella tradicional asociado a la latencia de comunicación. El hecho de que el actuador electromecánico ejecutará el rechazo físico de 41 frutos defectuosos sin interrumpir la secuencia de la banda transportadora confirma que separar la carga algorítmica pesada (GPU) de la ejecución de hardware (microcontrolador) es una estrategia funcional y de bajo costo para mantener altas tasas de procesamiento en líneas de poscosecha.

4.4. Análisis de la confianza del modelo y limitaciones

Durante el análisis teórico en entornos aislados, el modelo YOLOv8 demostró un rendimiento algorítmico sobresaliente con una asertividad superior al 95 % (mAP50). No obstante, durante las pruebas dinámicas en tiempo real, la confianza probabilística promedio de la red experimentó una caída al 66.82 % (con varianzas entre 40.38 % y 92.99 %). Esta caída de confianza en vivo no obedece a una deficiencia de la Inteligencia Artificial, sino que evidencia de forma explícita un cuello de botella derivado del hardware de captura. La cámara web comercial empleada presenta limitaciones ópticas en entornos dinámicos, sufriendo pérdida de auto-enfoque (desenfoque por movimiento rápido) y saturación lumínica (*glare*) al interactuar la luz con la superficie porosa y brillante del cítrico. Estas anomalías visuales enmascaran la textura real del fruto, forzando a la red neuronal a operar con datos distorsionados en milisegundos. Se concluye que el modelo predictivo es robusto, pero para transferir el 100 % de su capacidad teórica a la línea de producción física, la transición mecatrónica exige el reemplazo del sensor actual por cámaras industriales de visión artificial (tipo *Global Shutter*) acopladas a esquemas de iluminación estrictamente difusa.

4.5. Impacto frente al estado del arte y aplicabilidad agroindustrial

En contraste con estudios internacionales recientes que alcanzan precisiones superiores al 95 % utilizando sensores multiespectrales o cámaras 3D de alto costo, este prototipo demuestra que es posible obtener un rendimiento competitivo para la agroindustria utilizando hardware RGB estándar y algoritmos de código abierto. Para el contexto exportador colombiano del limón Tahití, esta solución automatizada representa un avance significativo frente a la inspección manual. Permite estandarizar la clasificación bajo las normativas del *Codex Alimentarius*, reduciendo la subjetividad del operario y asegurando la consistencia exigida por los mercados internacionales.

En contraste con investigaciones previas en la agroindustria de cítricos, los resultados obtenidos respaldan la evolución tecnológica hacia arquitecturas de detección en una sola etapa (*One-Stage Detectors*). Mientras que estudios como los de Chen et al. (2021) abordaron el desafío de la clasificación en tiempo real combinando detectores convolucionales con algoritmos de seguimiento (SORT) que pueden exigir altos costos computacionales, la implementación directa de YOLOv8 en este prototipo demuestra una mejora significativa en los tiempos de inferencia (milisegundos) y un excelente manejo algorítmico frente a la iluminación dinámica de la cabina. Asimismo, aunque autores como Giacometti (2024) han documentado la alta complejidad algorítmica de categorizar el limón Tahití debido a las sutilezas morfológicas de sus patologías sobre la cáscara verde, este trabajo evidencia que la arquitectura YOLOv8 logra superar dicha barrera analítica, trasladando el desafío de la etapa de *software* a la etapa de adquisición óptica (*hardware*).

5. Conclusiones

Se diseñó con éxito un sistema de visión artificial para la clasificación automática de limones Tahití estructurado sobre la arquitectura de aprendizaje profundo YOLOv8. Utilizando técnicas de procesamiento de imágenes con un conjunto de datos propio, curado y balanceado de 2748 imágenes, el modelo demostró una capacidad analítica excepcional para evaluar la calidad del fruto según sus parámetros físicos y visuales. Las validaciones teóricas comprobaron que el software alcanzó una exactitud media promedio (mAP0.5) superior al 95.7% en la segmentación y detección de defectos, asegurando latencias de inferencia ultrabajas de apenas 33 milisegundos por fotograma.

Se desarrolló un prototipo funcional de bajo costo que integra sinérgicamente hardware y software, logrando aplicar los algoritmos de procesamiento de imágenes en un entorno mecánico en tiempo real para clasificar el limón Tahití en función de variables definidas para defectos superficiales. La arquitectura logró acoplar de manera eficiente la inferencia computacional de la estación de trabajo con el determinismo temporal de una placa microcontroladora periférica (Arduino), orquestando la captura de la cámara web y el accionamiento físico del pistón de descarte bajo una estrategia de control anticipatorio (feedforward) sobre una banda transportadora continua.

Finalmente, se evaluó el impacto del prototipo desarrollado en la eficiencia del proceso de selección mediante la comparación de tiempos de operación y la reducción de errores frente a métodos tradicionales (operarios). Se comprobó que, aunque la inspección manual ofrece una velocidad pico inicial (70 segundos por lote de 25 frutos), padece de una alta variabilidad y subjetividad (12% de discrepancia entre operarios) así como vulnerabilidad a la fatiga. En contraste, el sistema automatizado estabilizó una velocidad ininterrumpida de 9.4 frutos por minuto. A pesar de que las limitaciones ópticas de la cámara comercial restringieron la

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

confianza de la IA al 66.82% en movimiento, el prototipo logró aislar la toma de decisiones del error humano, reduciendo las inconsistencias de clasificación y demostrando que la visión artificial es una herramienta altamente eficaz para optimizar las líneas de producción postcosecha.

Referencias Bibliográficas

- Álvarez-Canchila, O. I., Arroyo-Pérez, D. E., Patiño-Saucedo, A., Rostro González, H., & Patiño-Vanegas, A. (2020). Colombian fruit and vegetables recognition using convolutional neural networks and transfer learning. *Journal of Physics. Conference Series*, 1547(1), 12020. <https://doi.org/10.1088/1742-6596/1547/1/012020>
- Amaya-Zapata, S., Pulgarín-Velásquez, D., & Torres-Pardo, Í. D. (2016). Desarrollo e Implementación de un Sistema de Visión Artificial Basado en Lenguajes de Uso Libre para un Sistema Seleccionador de Productos de un Centro Integrado de Manufactura (CIM). *Lampsakos*, (15), 43. <https://doi.org/10.21501/21454086.1702>
- AnalDEX. (2025). Limón Tahití le saca el jugo a sus exportaciones: crecimiento de más de 8% a abril. Asociación Nacional de Comercio Exterior. <https://analdex.org/2025/06/18/limon-tahiti-le-saca-el-jugo-a-sus-exportaciones-crecimiento-de-mas-de-8-a-abril/>
- Arifin, K. N., Rupa, S. A., Anwar, M. M., & Jahan, I. (2024). Lemon and Orange Disease Classification using CNN-Extracted Features and Machine Learning Classifier. arXiv preprint arXiv:2408.14206. <https://arxiv.org/pdf/2408.14206>
- Aristizábal, M., Gómez, R., & Rueda, S. (2023). Identificación de limones Tahití aptos para exportación con visión computacional en sistemas embebidos. Universidad Autónoma de Bucaramanga UNAB.
- Chen, Y., An, X., Gao, S., Li, S., & Kang, H. (2021). A Deep Learning-Based Vision System Combining Detection and Tracking for Fast On-Line Citrus Sorting. *Frontiers in Plant Science*, 12, 622062. <https://doi.org/10.3389/fpls.2021.622062>

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

- Cong, G., Chen, X., Bing, Z., Liu, W., Chen, X., Wu, Q., Guo, Z., & Zheng, Y. (2025). YOLOv8-Scm: an improved model for citrus fruit sunburn identification and classification in complex natural scenes. *Frontiers in Plant Science*, *16*, 1591989. <https://doi.org/10.3389/fpls.2025.1591989>
- FAO & OMS. (2011). Norma para la lima-limón (CXS 213-1999). Codex Alimentarius. Organización de las Naciones Unidas para la Alimentación y la Agricultura; Organización Mundial de la Salud. (https://www.fao.org/fao-who-codexalimentarius/sh-proxy/es/?lnk=1&url=https%253A%252F%252Fworkspace.fao.org%252Fsites%252Fcodex%252Fstandards%252FCXS%2B213-1999%252FCXS_213e.pdf)
- Giacometti, E. M. (2024). Towards an automatic classification of Tahiti lime (Tesis de maestría). Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ), Río de Janeiro, Brasil. https://dippg.cefet-rj.br/ppeel/attachments/article/81/Disserta%C3%A7%C3%A3o_Final_Ellen.pdf
- Imbaña, D., & López, W. (2021). Diseño e implementación de un sistema de procesamiento de imágenes para determinar la calidad del Limón Tahití (Tesis de grado). Universidad Industrial de Santander.
- Injante, R., & Sánchez-Isuiza, S. (2025). Detection of citrus diseases using artificial intelligence: A systematic review. *LatIA*, *3*, 122. <https://doi.org/10.62486/latia2025122>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). YOLO by Ultralytics (Version 8.0.0). Ultralytics.
- Maf Roda. (2024). IA para la clasificación de cítricos y robótica para el encajado. [Poscosecha.com](https://www.poscosecha.com).

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

- Murcia Riaño, N., Martínez, M. F., Orduz-Rodríguez, J. O., et al. (2020). Modelo productivo de lima ácida Tahití (*Citrus latifolia* Tanaka ex Q. Jiménez) para Colombia. Corporación Colombiana de Investigación Agropecuaria (AGROSAVIA). <https://doi.org/10.21930/agrosavia.model.7403435>
- Pilco, A., Moya, V., Quito, A., Vásconez, J. P., & Limaico, M. (2024). Image processing-based system for apple sorting. *Journal of Image and Graphics*, 12(4), 362-371. <https://doi.org/10.18178/joig.12.4.362-371>
- Tomra. (2024). Citrus sorting and packing solutions. TOMRA Food. <https://www.tomra.com/food/categories/fruit/citrus-fruit>
- Universidad Autónoma de Tamaulipas (UAT). (2025). Desarrolla la UAT aplicación para detectar plagas en los cítricos. Prensa UAT. <https://www.uat.edu.mx/noticias/Paginas/Noticia.aspx?nid=914>
- Yu, Y., An, X., Lin, J., Li, S., & Chen, Y. (2024). A vision system based on CNN-LSTM for robotic citrus sorting. *Information Processing in Agriculture*, 11(1), 14–25. <https://doi.org/10.1016/j.inpa.2022.06.002>

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Apéndices

Apéndice A. Planos prototipo

Figura A.1

Banda transportadora

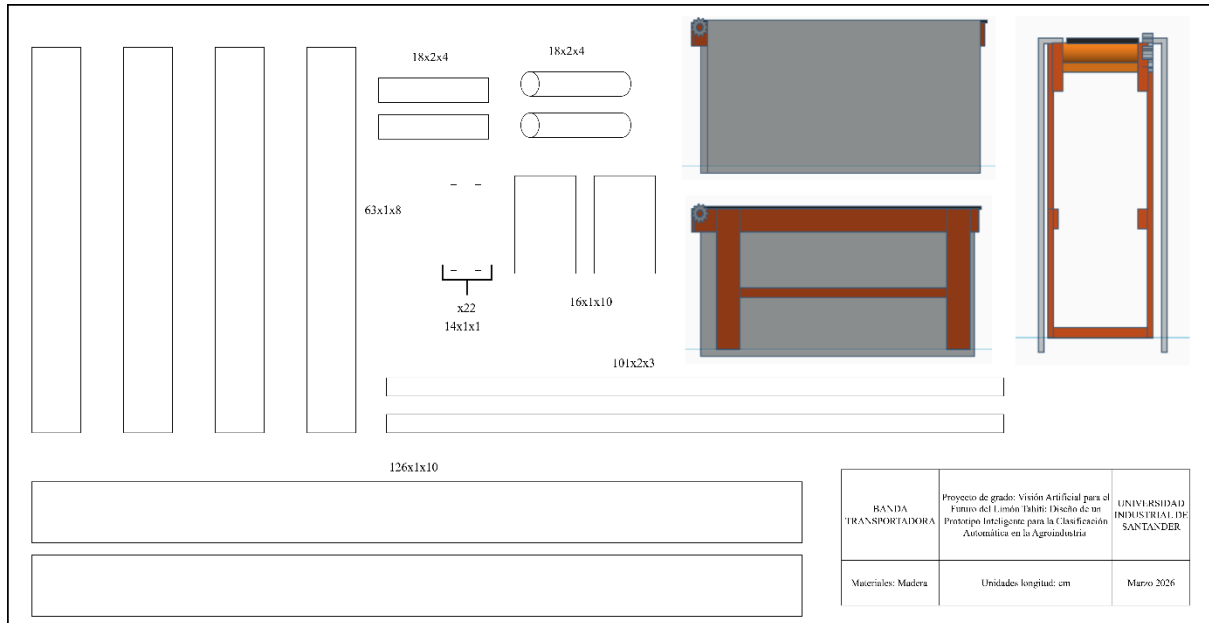


Figura A.2

Caja de selección

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ


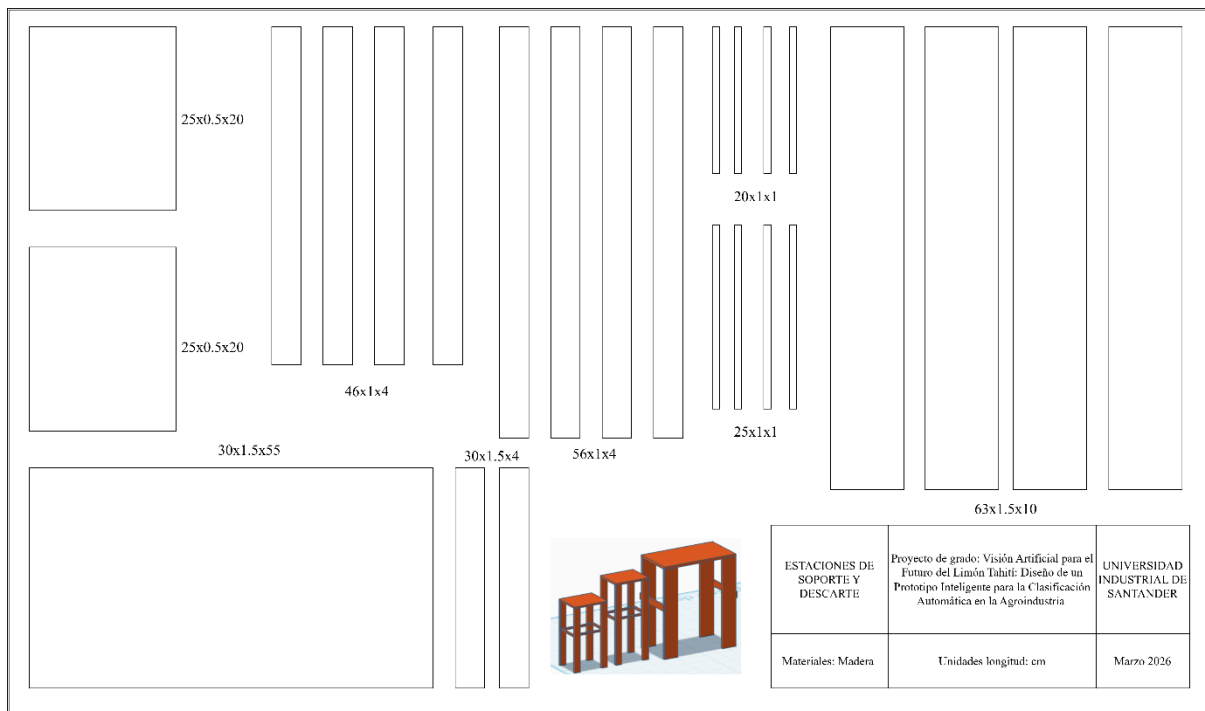


Figura A.3

Puntos finales de selección



Apéndice B. Códigos operativos

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Apéndice B. 1 Códigos funcionamiento inteligencia artificial YOLO v8

```
import cv2
import serial
import time
import csv
from datetime import datetime
from ultralytics import YOLO

# --- CONFIGURACIÓN ---
MODEL_PATH = 'best5.pt'
ARDUINO_PORT = 'COM3'
BAUD_RATE = 9600

# --- VARIABLES DEL SENSOR VIRTUAL (NUEVO) ---
# Estas líneas imaginarias en la pantalla evitarán que la IA cuente limones en
# los bordes
ZONA_INICIO = 200
ZONA_FIN = 440

# --- VARIABLES DE CONTEO Y SEGUIMIENTO (TRACKING) ---
contador_buenos = 0
contador_malos = 0
limones_procesados_ids = set()
historial_limones = []

# Inicializar Modelo
try:
    model = YOLO(MODEL_PATH)
    print("Modelo cargado exitosamente.")
except Exception as e:
    print(f"Error al cargar el modelo: {e}")
    exit()

# Inicializar Arduino
try:
    arduino = serial.Serial(ARDUINO_PORT, BAUD_RATE, timeout=0.1)
    time.sleep(2)
    print(f"Arduino conectado en {ARDUINO_PORT}.")
except:
    print("AVISO: Arduino no conectado. El sistema funcionará solo con la
cámara.")

# Forzamos el uso de DirectShow (DSHOW) para tener control profundo en Windows
cap = cv2.VideoCapture(0, cv2.CAP_DSHOW)
# ¡MAGIA! Esta línea hace que salte la ventana secreta de configuración de tu
cámara
cap.set(cv2.CAP_PROP_SETTINGS, 1)
```

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

```

print("\n--- Sistema de Clasificación y Tracking Iniciado. Presiona 'q' para
salir ---")

while True:
    ret, frame = cap.read()
    if not ret: break

    # Altura de tu cámara (para dibujar las líneas completas de arriba a
    abajo)
    h, w, _ = frame.shape

    # ¡NUEVO! Usamos bytetrack.yaml (ideal para bandas) y conf=0.40 / iou=0.4
    results = model.track(frame, persist=True, conf=0.40, iou=0.4,
    tracker="bytetrack.yaml", verbose=False)

    for r in results:
        if r.bboxes.id is not None:
            for box in r.bboxes:
                cls_id = int(box.cls[0])
                label_name = model.names[cls_id]
                confianza_porcentaje = round(float(box.conf[0]) * 100, 2)
                track_id = int(box.id[0])

                # --- LÓGICA DE CONTEO ÚNICO CON SENSOR VIRTUAL ---
                # 1. Calculamos el centro exacto del limón en el eje X
                x1, y1, x2, y2 = map(int, box.xyxy[0])
                centro_x = int((x1 + x2) / 2)
                centro_y = int((y1 + y2) / 2)

                # 2. Solo lo contamos si su centro cruzó las líneas azules
                if track_id not in limones_procesados_ids and (ZONA_INICIO <
                centro_x < ZONA_FIN):
                    limones_procesados_ids.add(track_id) # Lo anotamos

                    if label_name == 'buenos':
                        contador_buenos += 1
                        # Le avisamos al Arduino que va un limón BUENO ('G')
                    en camino

                        if 'arduino' in locals() and arduino.isOpen():
                            arduino.write(b'G')

                    elif label_name == 'malos':
                        contador_malos += 1
                        # Le avisamos al Arduino que va un limón MALO ('B') en
                    camino

                        if 'arduino' in locals() and arduino.isOpen():
                            arduino.write(b'B')

```

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

```

# Guardamos este limón en la memoria para el Excel
hora_exacta = datetime.now().strftime("%H:%M:%S")
historial_limones.append({
    "ID_Limon": track_id,
    "Hora_Deteccion": hora_exacta,
    "Clasificacion": label_name.upper(),
    "Confianza_IA_%": confianza_porcentaje
})

# --- DIBUJAR CUADROS EN PANTALLA ---
color = (0, 0, 255) if label_name == 'malos' else (0, 255, 0)
cv2.rectangle(frame, (x1, y1), (x2, y2), color, 2)
# Dibujamos un puntito en el centro del limón
cv2.circle(frame, (centro_x, centro_y), 5, (255, 255, 255), -
1)

    cv2.putText(frame, f"ID:{track_id} {label_name}
{confianza_porcentaje}%", (x1, y1 - 10), cv2.FONT_HERSHEY_SIMPLEX, 0.6, color,
2)

# --- DIBUJAR EL SENSOR VIRTUAL EN PANTALLA (Líneas Azules) ---
cv2.line(frame, (ZONA_INICIO, 0), (ZONA_INICIO, h), (255, 0, 0), 2)
cv2.line(frame, (ZONA_FIN, 0), (ZONA_FIN, h), (255, 0, 0), 2)

# --- DIBUJAR INTERFAZ (HUD) ---
cv2.rectangle(frame, (10, 10), (350, 160), (0, 0, 0), -1)
total_limones = contador_buenos + contador_malos
cv2.putText(frame, f"TOTAL: {total_limones}", (20, 50),
cv2.FONT_HERSHEY_SIMPLEX, 0.8, (255, 255, 255), 2)
    cv2.putText(frame, f"Buenos: {contador_buenos}", (20, 95),
cv2.FONT_HERSHEY_SIMPLEX, 0.8, (0, 255, 0), 2)
    cv2.putText(frame, f"Malos: {contador_malos}", (20, 140),
cv2.FONT_HERSHEY_SIMPLEX, 0.8, (0, 0, 255), 2)

    cv2.imshow('Tesis - Limon Tahiti', frame)
    if cv2.waitKey(1) & 0xFF == ord('q'):
        break

# --- LIMPIEZA Y GENERACIÓN DE REPORTE EXCEL ---
cap.release()
cv2.destroyAllWindows()
if 'arduino' in locals() and arduino.isOpen():
    arduino.close()

fecha_hoy = datetime.now().strftime("%Y-%m-%d")
nombre_archivo = f'reporte_detallado_{fecha_hoy}.csv'

try:
    with open(nombre_archivo, mode='w', newline='') as file:

```

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

```

writer = csv.writer(file)
writer.writerow(["ID_LIMON", "HORA", "TIPO_DE_LIMON",
"CONFIANZA_IA_PORCENTAJE"])
    for limon in historial_limones:
        writer.writerow([limon["ID_Limon"], limon["Hora_Deteccion"],
limon["Clasificacion"], limon["Confianza_IA_%"]])

writer.writerow([])
writer.writerow(["RESUMEN TOTAL", f"Buenos: {contador_buenos}",
f"Malos: {contador_malos}", ""])
    print(f"\n[ÉXITO] Reporte guardado en: {nombre_archivo}")
except Exception as e:
    print(f"\n[ERROR] No se pudo guardar el reporte: {e}")

```

Apéndice B.2 Códigos funcionamiento pistón

Arduino nano

```

// --- Configuración de Pines ---
int IN1 = 7;    // Dirección motor 1
int IN2 = 6;    // Dirección motor 2
int ENA = 3;    // Velocidad motor (PWM)

const int ECHO = 11; // Sensor Ultrasonido
const int TRIG = 12; // Sensor Ultrasonido

// --- VARIABLES DE CALIBRACIÓN (TUS AJUSTES ORIGINALES) ---
int distancia_disparo = 15;

// 1. EL TIEMPO DE GOLPE: ¡Restaurado a tus 800ms perfectos!
int retardo_trayectoria = 850;

int tiempo_salida_piston = 300;
int tiempo_entrada_piston = 310;

// 2. EL CRONÓMETRO DE CEGUERA: Bajado a 600ms para que no se traslape
// con el siguiente limón de la banda.
int tiempoCeguera = 600;

// --- Variables internas ---
long duracion;
int distancia;
String colaLimones = "";
bool sensorYaLeyo = false;
unsigned long tiempoUltimoLimon = 0;

void setup() {
    Serial.begin(9600); // Iniciar comunicación con Python

```

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

```

pinMode(IN1, OUTPUT);
pinMode(IN2, OUTPUT);
pinMode(ENA, OUTPUT);
digitalWrite(ENA, LOW); // Motor apagado por seguridad

pinMode(TRIG, OUTPUT);
pinMode(ECHO, INPUT);

pinMode(LED_BUILTIN, OUTPUT); // Led de alerta
}

void loop() {
  // 1. ESCUCHAR A LA IA (PYTHON)
  if (Serial.available() > 0) {
    char order = Serial.read();
    if (order == 'B' || order == 'G') {
      colaLimonos += order;
    }
  }

  // 2. LEER SENSOR DE DISTANCIA (ULTRASONIDO)
  distancia = medirDistancia();

  // 3. EL TRUCO DEL CRONÓMETRO
  if (sensorYaLeyo && (millis() - tiempoUltimoLimon > tiempoCeguera)) {
    sensorYaLeyo = false; // Ya pasó el limón, abrimos los ojos
  }

  // 4. LÓGICA DE DISPARO
  if ((distancia > 0 && distancia <= distancia_disparo) && !sensorYaLeyo) {

    sensorYaLeyo = true;
    tiempoUltimoLimon = millis();

    if (colaLimonos.length() > 0) {
      char limonActual = colaLimonos[0];
      colaLimonos.remove(0, 1);

      if (limonActual == 'B') {
        // --- SECUENCIA PARA LIMÓN MALO ---
        digitalWrite(LED_BUILTIN, HIGH);
        delay(retardo_trayectoria); // Esperamos tus 800ms exactos
        actuarPiston();
        digitalWrite(LED_BUILTIN, LOW);
      }
      else if (limonActual == 'G') {
        // --- SECUENCIA PARA LIMÓN BUENO ---

```

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

```

        // Pasa de largo, pero el sensor queda bloqueado por los 600ms de
arriba
    }
}
}

    delay(30);
}

// --- FUNCIONES AUXILIARES ---

void actuarPiston() {
    digitalWrite(IN1, HIGH);
    digitalWrite(IN2, LOW);
    analogWrite(ENA, 255);
    delay(tiempo_salida_piston);

    analogWrite(ENA, 0);
    delay(50);

    digitalWrite(IN1, LOW);
    digitalWrite(IN2, HIGH);
    analogWrite(ENA, 255);
    delay(tiempo_entrada_piston);

    analogWrite(ENA, 0);
    digitalWrite(IN1, LOW);
    digitalWrite(IN2, LOW);
}

int medirDistancia() {
    digitalWrite(TRIG, LOW);
    delayMicroseconds(2);
    digitalWrite(TRIG, HIGH);
    delayMicroseconds(10);
    digitalWrite(TRIG, LOW);

    duracion = pulseIn(ECHO, HIGH, 20000);
    if (duracion == 0) return 999;
    distancia = duracion * 0.034 / 2;
    return distancia;
}

```

Apéndice C. Composición de la Inteligencia Artificial.

Apéndice C1. Resultados del entrenamiento de la Inteligencia Artificial.

CLASIFICACIÓN AUTOMÁTICA DEL LIMÓN TAHITÍ

Link:https://drive.google.com/file/d/1udejFz9PrEcQ92cPYH4XGJxF62UJgpzd/view?usp=drive_link

[ve link](#)

Apéndice C2. Dataset.

Link:https://drive.google.com/file/d/1l_vfM_lu1b1BDau1Gb5DcbEl_hFZPMk/view?usp=drive_link

[ve link](#)