

PROTOTIPO PARA LA CLASIFICACIÓN DE MUCÍLAGO DE CACAO UTILIZANDO TICS EN EL EMPALME, ECUADOR

PROTOTYPE FOR COCOA MUCILAGE CLASSIFICATION USING ICTS IN EL EMPALME, ECUADOR

Mishelle Mosquera Rizzo¹, Jorge Piguave Rodríguez¹, Charles M. Pérez-Espinoza¹, Teresa Samaniego Cobo^{1*}

¹Universidad Agraria del Ecuador, Guayaquil, 090601, Ecuador

*Autor de Correspondencia: tsamaniego@uagraria.edu.ec

Historial del artículo:

Recibido: 02.05.2025

Revisado: 20.06.2025

Aceptado: 05.07.2025

En línea: 15.07.2025

Palabras clave:

Mucílago de cacao

Raspberry Pi

ESP8266

Redes neuronales

Teachable machine

Keywords:

Cocoa mucilage

Raspberry Pi

ESP8266

Neural networks

Teachable machine

Cómo citar:

M. Mosquera Rizzo, J. Piguave Rodríguez, C. M. Pérez-Espinoza, y T. Samaniego, «Prototipo para la clasificación de mucílago de cacao utilizando TICS en El Empalme, Ecuador», *International Journal of Computational Innovations, Intelligent Systems and AI*, vol. 1, n.º 1, pp. 45–61, jul. 2025. doi: [10.64439/cisai.v1i1.4](https://doi.org/10.64439/cisai.v1i1.4)

Este es un artículo de acceso abierto bajo licencia CC-BY-NC-ND



Resumen:

La clasificación de la calidad del mucílago de cacao es un proceso importante para garantizar la aceptación del producto en los mercados nacionales e internacionales. Sin embargo, la presencia de impurezas provoca con frecuencia el rechazo del producto y la pérdida de confianza entre los compradores. En El Empalme, Ecuador, esta problemática impulsó el desarrollo de un prototipo automatizado capaz de separar impurezas, ofreciendo un producto más limpio y fortaleciendo la confianza en las transacciones comerciales. Este sistema incorpora una banda transportadora para clasificar el mucílago y una aplicación móvil que registra la cantidad de baldes recolectados y el peso total de la producción. También, cuenta con una cámara web para capturar imágenes del mucílago y procesarlas en un Raspberry Pi que aplica el algoritmo de redes convolucionales utilizado en Teachable Machine para catalogar los dos tipos de clases, al final se usa un servomotor que lo deposita en el recipiente adecuado. Como resultado, el prototipo creado logró clasificar el mucílago automáticamente, optimizando el proceso, reduciendo pérdidas y generando mayor confianza en los compradores. Asimismo, toda la información se almacena en el sistema y puede visualizarse desde la aplicación móvil. En conclusión, el prototipo desarrollado cubre satisfactoriamente las necesidades de la finca.

Abstract:

The quality classification of cocoa mucilage is an important process to ensure product acceptance in national and international markets. However, the presence of impurities often leads to product rejection and loss of trust among buyers. In El Empalme, Ecuador, this challenge motivated the development of an automated prototype capable of separating impurities, delivering a cleaner product, and strengthening trust in commercial transactions. The system incorporates a conveyor belt for mucilage classification and a mobile application that records the number of buckets collected and the total production weight. It also includes a webcam to capture images of the mucilage, which are processed by a Raspberry Pi running a convolutional neural network algorithm trained with Teachable Machine to classify the two categories. Finally, a servomotor deposits the product into the appropriate container. As a result, the prototype successfully classified mucilage automatically, optimizing the process, reducing losses, and increasing buyer confidence. Furthermore, all information is stored in the system and can be accessed through the mobile application. In conclusion, the developed prototype satisfactorily meets the needs of the farm.

I. INTRODUCCIÓN

El cacao es uno de los cultivos más importantes de Ecuador, destacándose por su impacto económico y social en el país. Esta planta produce una mazorca que, en su interior, alberga almendras utilizadas en la fabricación de chocolate y otros derivados, como el polvo de cacao. Actualmente, los cultivos de cacao representan el 12% de la superficie agrícola del país y generan empleo para una gran parte de la población. Ecuador, además, es uno de los principales exportadores de cacao a nivel mundial, enviando aproximadamente 297,067 toneladas de este producto para su transformación en chocolate y otros artículos derivados [1].

Dentro de la cadena de producción del cacao, la etapa de postcosecha es fundamental para garantizar la calidad del producto final. En este proceso, los agricultores seleccionan las mejores mazorcas, las cuales deben abrirse con sumo cuidado para extraer las semillas sin dañarlas. Para ello, se emplean herramientas manuales, como machetes o cuchillos, lo que requiere precisión y destreza. Un aspecto crucial en esta fase es la recolección del mucílago, que debe caer directamente en los recipientes adecuados, evitando el contacto con el suelo para prevenir su contaminación con impurezas. La presencia de residuos en el mucílago puede afectar la calidad de las semillas, por lo que, en caso de contaminación, es necesario lavarlas para eliminar cualquier suciedad o materia inorgánica [2] [3].

El adecuado manejo del mucílago y las semillas es determinante en el desarrollo del sabor del cacao. Es esencial que los granos sean tratados con cuidado y que se evite su fermentación prematura si no se cumplen las condiciones adecuadas [4]. La calidad del cacao puede verse comprometida si el mucílago se mezcla con impurezas, ya que en muchos casos los trabajadores no realizan un lavado previo antes de almacenarlo junto a las semillas limpias. En la Figura 1 se muestra cuando el mucílago viene con impurezas y cuando está limpio. Este descuido puede generar problemas durante el proceso de fermentación, afectando directamente la calidad del producto final. Por lo tanto, garantizar buenas prácticas en la postcosecha del cacao es clave para obtener un producto de alto valor en el mercado internacional, asegurando así la competitividad del sector y el reconocimiento de Ecuador como un referente en la producción de cacao de calidad.



Figura 1. Cultivo de cacao en la finca y el mucílago de cacao con impurezas y limpio

1.1 Problemática

En los últimos años se ha evidenciado diversas problemáticas en la producción y comercialización del mucílago de cacao, siendo una de las más relevantes la desconfianza de los compradores. La presencia de impurezas, como tierra y residuos, en el mucílago almacenado en los baldes representa un obstáculo para concretar futuras ventas [5]. Los compradores enfatizan que el mucílago debe mantenerse limpio, ya que la contaminación con elementos externos no solo compromete su calidad, sino que también puede atraer insectos que afecten procesos fundamentales como la fermentación, etapa crucial para el desarrollo del sabor del cacao [6]. En las diferentes fincas dedicadas a la producción y venta de mucílago de cacao, se ha identificado que este suele mezclarse con materiales inorgánicos del entorno, como piedras, hojas secas y polvo. Este problema surge durante la extracción manual del mucílago de las mazorcas, un procedimiento en el que, con frecuencia, parte del producto cae fuera de los recipientes. Ante esta situación, los trabajadores suelen recogerlo sin realizar una limpieza adecuada, lo que genera rechazo por parte de los compradores, quienes desconfían del peso real del mucílago al sospechar que podría contener piedras u otros materiales añadidos involuntariamente.

Actualmente, las fincas tienen encargados de la cosecha y extracción del mucílago, quienes realizan esta labor en un periodo de cinco horas. Posteriormente, el proceso de clasificación, donde se separa el mucílago limpio del contaminado, toma aproximadamente dos horas adicionales. Sin embargo, debido a la gran cantidad de mucílago extraído y al ritmo acelerado del trabajo, la clasificación suele realizarse de manera apresurada. Esto aumenta la carga laboral, ya que los trabajadores deben dedicar más tiempo a la limpieza del mucílago antes de su comercialización. En la Figura 2 se muestran a los trabajadores realizando la comercialización después de haber separado manualmente el mucilago limpio.



Figura 2. Trabajadores con los recipientes de mucilago para la venta

Los compradores buscan un producto completamente limpio y de alta calidad, por lo que la presencia de impurezas en el mucílago genera un rechazo considerable, provocando pérdidas económicas para la finca. A pesar de que el mucílago pasa por un proceso de lavado antes de la venta, garantizar su pureza desde la etapa de extracción es fundamental para mejorar su aceptación en el mercado y optimizar la eficiencia del proceso productivo.

1.2 Trabajos relacionados

La clasificación de productos agrícolas mediante técnicas de visión por computador y algoritmos de aprendizaje profundo ha demostrado ser una estrategia efectiva para mejorar la calidad y optimizar los procesos en la cadena de valor agroindustrial. Mukhiddinov et al. [7] abordaron un sistema de clasificación para frutas y verduras basado en un modelo YOLOv4 optimizado, capaz de identificar el tipo de producto en una imagen y clasificarlo en dos categorías, fresco o deteriorado. El modelo incorpora la función de activación Mish para aumentar la precisión y velocidad de detección, logrando un promedio de precisión superior al de versiones anteriores como YOLOv3 y YOLOv4 estándar. Este tipo de aproximaciones permite implementar sistemas autónomos y en tiempo real que pueden ser aplicados en entornos de producción, comercialización y apoyo a personas con discapacidad visual.

De forma complementaria, Garcés-Cadena et al. [8] desarrollaron una herramienta para la clasificación de calidad de manzanas con fines de monitoreo de cosechabilidad, utilizando visión por computador y redes neuronales profundas. El sistema integra detección de tipo de manzana mediante SSD-MobileNet y segmentación de calidad a nivel de píxel con FCN-ResNet 18. Entrenado con bases de datos en entornos controlados y agrícolas reales, el modelo alcanza precisiones del 86,7% al 92,6% en detección y del $94,7 \pm 2,5\%$ en segmentación, superando resultados de trabajos previos. Este enfoque demuestra que la combinación de técnicas de detección y segmentación puede proporcionar un alto nivel de exactitud en la evaluación de calidad de productos agrícolas, lo que resulta especialmente relevante para el desarrollo de prototipos orientados a la clasificación del mucílago de cacao, donde las variaciones visuales y de textura requieren modelos robustos y adaptativos.

En el ámbito específico del cacao, Lopes et al. [9] propusieron un sistema de visión profunda para clasificar granos en diferentes variedades, comparando un Deep Computer Vision System (DCVS) basado en arquitecturas ResNet18 y ResNet50 con un sistema tradicional de visión por computador que utiliza algoritmos como Support Vector Machine y Random Forest. El estudio empleó un conjunto de datos de 1.239 imágenes de granos de cacao, evaluando el rendimiento de ambos enfoques. Los resultados muestran que el DCVS con ResNet18 alcanzó una precisión del 96,82%, superando ampliamente el 85,71% obtenido por el sistema tradicional. Este hallazgo evidencia la superioridad de las redes neuronales convolucionales en la identificación de características visuales complejas y sutiles en productos agrícolas, lo que las convierte en una herramienta prometedora para aplicaciones de clasificación en la industria cacaotera.

Asimismo, Pal et al. [10] proponen el modelo Cocoa-Net para clasificar granos de cacao en cuatro categorías (grande, mediano, pequeño y rechazado) utilizando características estructurales extraídas de imágenes y comparando métodos de *machine learning* tradicionales (KNN, SVM, Random Forest) con CNN. El modelo Cocoa-Net, optimizado con Adam y evaluado mediante K-fold, obtuvo la mayor precisión con un 85%, destacando la importancia del preprocesamiento y optimización de características para mejorar el rendimiento en *datasets* agrícolas limitados. Este trabajo subraya que la combinación de técnicas avanzadas con procesos de selección de características permite lograr modelos más eficientes, especialmente en aplicaciones donde la variabilidad visual y las condiciones de captura pueden afectar la clasificación. Por su parte, Das et al. [11] desarrollaron una solución de visión por computador que clasifica granos de cacao en cuatro categorías empleando exclusivamente características estructurales (forma y tamaño) y algoritmos clásicos de *machine learning*. Tras optimizar las características con *Univariate Selection* y *Feature Importance*, evaluaron los modelos mediante validación cruzada estratificada, encontrando que Random Forest alcanzó la mayor precisión (75%). Este resultado, aunque menor que el de las CNN, evidencia que técnicas tradicionales siguen siendo útiles en contextos con recursos computacionales limitados. Además, el estudio demuestra que, en escenarios con bases de datos pequeñas y hardware básico, la implementación de algoritmos de menor complejidad sigue siendo una estrategia viable para alcanzar un desempeño aceptable.

Jean et al. [12] presentaron un enfoque híbrido CNN-SVM y PCA-SVM para clasificar granos de cacao fermentados. La CNN actúa como extractor de características, mientras que el SVM realiza la clasificación. El modelo híbrido CNN-SVM alcanzó un 98,32% de precisión, superando tanto a las CNN puras como a los SVM convencionales. La incorporación de PCA-SVM permitió reducir el tamaño de imagen manteniendo las características clave, logrando un 97,65% de precisión. Estos resultados demuestran que las combinaciones de métodos pueden superar a los modelos individuales, mejorando la robustez y reduciendo el costo computacional. Adicionalmente, la comparación de múltiples configuraciones de kernels y optimizadores aporta evidencia sobre la flexibilidad de los modelos híbridos para adaptarse a distintas condiciones de procesamiento y complejidad visual.

En este contexto, la evidencia recopilada confirma que las CNN, tecnología disponible en plataformas como Teachable Machine, pueden aplicarse con éxito a la clasificación de productos agrícolas, incluido el cacao y sus derivados. Las experiencias en frutas, manzanas y granos de cacao constituyen una base sólida para un prototipo orientado al mucílago de cacao, donde la capacidad de generalización de estos modelos resulta esencial para lograr un desempeño consistente y replicable en entornos reales.

1.3 Motivación y contribución

El mucílago de cacao, un subproducto resultante de la fermentación del grano, posee un alto valor agregado por sus propiedades organolépticas y su potencial de aprovechamiento en la industria agroalimentaria. Sin embargo, su clasificación representa todavía un desafío técnico y operativo en la cadena de valor del cacao, especialmente en regiones productoras como Empalme, Ecuador, donde las prácticas de selección se realizan de manera manual y dependen en gran medida de la experiencia empírica de los productores. Este método no solo implica un alto consumo de tiempo y mano de obra, sino que también presenta limitaciones en la precisión y consistencia de los resultados, lo que puede afectar la calidad final del producto y su competitividad en mercados especializados. La creciente demanda de cacao de calidad y el impulso hacia procesos agrícolas más tecnificados y sostenibles han puesto en evidencia la necesidad de soluciones innovadoras que permitan optimizar la etapa de postcosecha, garantizando criterios objetivos de evaluación y reduciendo la dependencia de procedimientos subjetivos. En este escenario, las tecnologías basadas en Inteligencia Artificial y el uso de hardware libre surgen como alternativas viables, asequibles y escalables para enfrentar este desafío, facilitando la implementación de herramientas de automatización y control de calidad en entornos agrícolas de pequeña y mediana escala.

La presente investigación propone como contribución principal el diseño y desarrollo de un prototipo robótico automatizado capaz de clasificar el mucílago de cacao de forma precisa y eficiente mediante un sistema de captura y procesamiento de imágenes en tiempo real, soportado por redes neuronales convolucionales entrenadas con un conjunto de datos elaborado a partir de características físico-químicas y visuales del producto. Este prototipo, construido con hardware libre, integra sensores ópticos y cámaras de alta resolución que permiten una evaluación objetiva y rápida de la calidad del mucílago, reduciendo el margen de error humano. Además, incorpora una aplicación móvil que brinda la posibilidad de monitorizar el proceso de clasificación de manera remota, proporcionando a los productores una interfaz intuitiva para la toma de decisiones y la gestión del proceso postcosecha. Con ello, se busca no solo mejorar el rendimiento y la estandarización de la calidad, sino también contribuir a la digitalización de los procesos agrícolas, impulsando la adopción de tecnologías inteligentes en el sector cacaotero. La replicabilidad del sistema, gracias al empleo de hardware libre y a la documentación técnica generada, abre la puerta a su implementación en otras zonas productoras y en diferentes eslabones de la cadena agroalimentaria, consolidando un aporte tecnológico y metodológico que vincula innovación, sostenibilidad y desarrollo internacional.

II. MÉTODOS

La metodología del proyecto se organizó en cinco fases consecutivas que abarcaron desde la recopilación de requerimientos hasta la construcción del prototipo y la fase de pruebas. La Figura 3 presenta el flujo de trabajo correspondiente a cada fase, acompañado de un resumen de las tareas realizadas para la obtención del prototipo final.

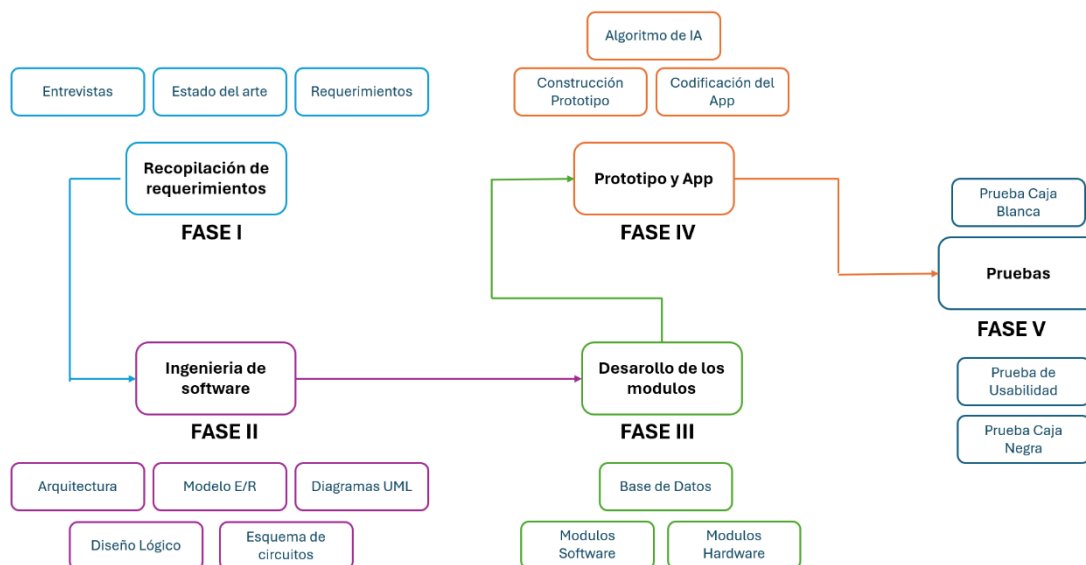


Figura 3. Flujo del trabajo de la metodología.

En la Fase 1 se efectuaron visitas a la finca con el propósito de observar y analizar de manera directa los procesos tradicionales de manipulación del mucílago. Asimismo, se realizaron entrevistas estructuradas (Figura 4) para recopilar información clave, delimitar con precisión la problemática y determinar los requerimientos del sistema, lo que permitió formular la propuesta de solución alineada con las necesidades reales del sector.



Figura 4. Recopilación de requerimientos

En la segunda fase, denominada Ingeniería de Software, se diseñó la arquitectura del prototipo y del sistema, incorporando la selección de los lenguajes de programación y la elaboración de diagramas de Entidad/Relación, diagramas de flujo de datos y diagramas de componentes. Este paso resultó fundamental para definir la estructura tanto del software como del hardware involucrado en el prototipo. La Figura 5 presenta la arquitectura del prototipo.

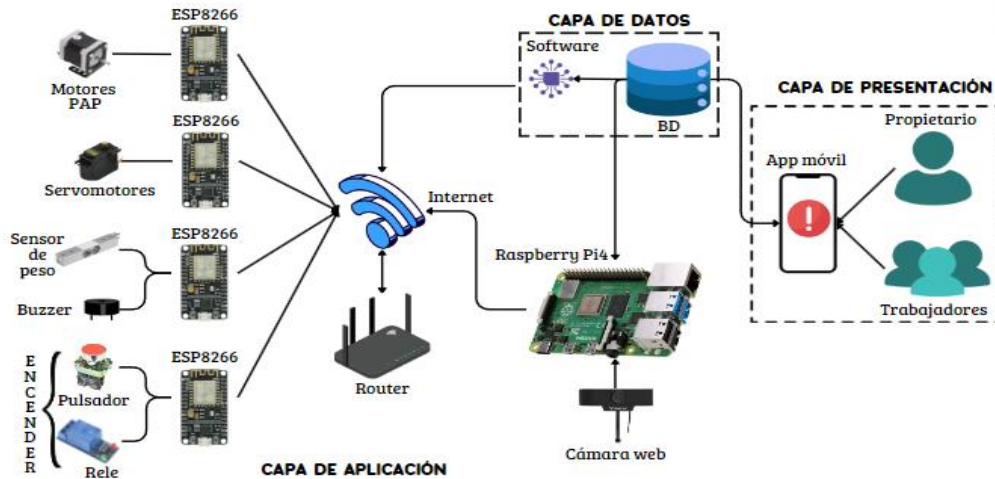


Figura 5. Arquitectura del prototipo

La tercera fase contempló el desarrollo de los módulos del prototipo mediante una aplicación móvil, integrando tanto el componente mecánico como la programación. Este proceso incluyó cinco módulos esenciales para el correcto funcionamiento del prototipo y la gestión eficiente de la información. A continuación, se detallan cada uno de los módulos:

- **Módulo de transporte:** Incorporó motores paso a paso y una banda transportadora para mover el mucílago.
- **Módulo de detección y clasificación:** Utilizó una cámara web para capturar imágenes, y un raspberry pi que sirvió como servidor en donde por medio una codificación en lenguaje Python contenía un modelo de aprendizaje profundo con Teachable Machine para clasificar el mucílago como limpio o con impurezas.
- **Módulo de llenado y pesado:** Aplicó un servomotor y sensores de peso para automatizar la distribución del mucílago en recipientes según su clasificación.
- **Módulo de alerta:** Activó una alarma sonora cuando los recipientes alcanzaban el peso determinado (22 kg aproximadamente).
- **Módulo de usuario:** Este es otro módulo de software en donde se desarrolló una aplicación en Android Studio para la monitorización del proceso como el encendido del prototipo, el conteo de recipientes para generación de reportes.

La Figura 6 presenta el esquema modular de la aplicación móvil diseñada para la gestión y control del prototipo de clasificación del mucílago de cacao. El sistema se estructura en distintos niveles. El módulo de presentación, que incluye la interfaz de usuario para el inicio de sesión y el menú de opciones; el servicio de interfaz, encargado de la administración de empleados (agregar, eliminar y listar) y la generación de reportes de producción; el módulo de procesos, que permite encender o apagar la clasificadora de forma remota; y el módulo de acceso, donde se gestionan las entidades de datos y la conexión a la base de datos MySQL. También, se contempla un módulo de datos, con una base de datos local para almacenamiento temporal, y un módulo de servicios, responsable de la sincronización con el servidor mediante servicios móviles. La arquitectura permite que tanto el propietario como los trabajadores interactúen con el prototipo, asegurando el flujo bidireccional de información y un control eficiente de las operaciones.

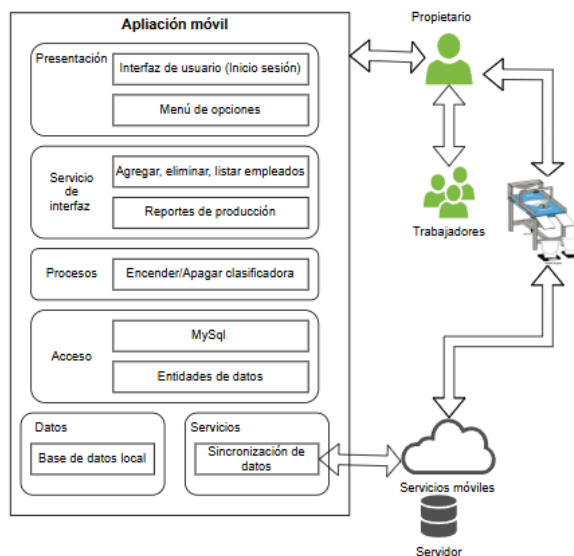


Figura 6. Esquema modular de la aplicación

Para el desarrollo de la aplicación móvil, se emplearon herramientas de software libre, destacando Android Studio, el cual es compatible con dispositivos que ejecuten Android 6.0 o versiones posteriores. Esta elección garantiza una gestión eficiente de los recursos del teléfono móvil. La aplicación incorpora diversas funcionalidades, como un sistema de inicio de sesión destinado al acceso del administrador y los empleados de la finca. El administrador tiene la capacidad de gestionar la información del personal, permitiéndole registrar, modificar y reactivar cuentas de empleados. De igual manera, incorpora la funcionalidad de supervisar la activación del prototipo destinado a la clasificación del mucílago de cacao, así como la posibilidad de consultar reportes detallados de la producción. Paralelamente, el propietario de la finca cuenta con una plataforma web que le brinda acceso directo a dichos informes. A través de esta interfaz, el usuario puede consultar el volumen procesado diariamente, efectuar búsquedas por fecha y, además, analizar estadísticas de producción correspondientes a periodos específicos. De esta manera, el sistema posibilita un análisis más preciso de la información, lo que a su vez facilita la toma de decisiones y asegura un control eficiente de la producción. Asimismo, incorpora un sistema de notificaciones automáticas que alerta cuando es necesario reemplazar un recipiente lleno.

En la cuarta y penúltima fase se integraron todos los componentes, durante la cual se recolectaron imágenes para conformar un dataset y se entrenó el modelo de aprendizaje profundo destinado a la clasificación efectiva del mucílago. Posteriormente, se llevaron a cabo pruebas del algoritmo y validaciones del funcionamiento general del prototipo. En la Figura 7 se ilustra el proceso de clasificación del mucílago a través de la cámara.



Figura 7. Prueba del servidor para la clasificación del mucílago

En la Figura 8 se presenta el diseño tridimensional con las dimensiones de la máquina, donde se emplearon recursos tecnológicos para la construcción del prototipo, su puesta en marcha y la demostración de su correcto funcionamiento. Para ello, se consideraron los recursos detallados en la Tabla 1.




Figura 8. Prototipo en 3D con sus medidas respectivas para su construcción

Tabla 1. Recursos tecnológicos de hardware

Nombre del recurso	Descripción
Raspberry Pi 4	La Raspberry Pi 4 es una computadora de placa única y tamaño reducido, desarrollada por la Raspberry Pi Foundation en el Reino Unido. Está diseñada para fomentar la enseñanza de conceptos básicos de informática en escuelas y países en desarrollo, pero su bajo costo y flexibilidad la han hecho popular entre aficionados y diseñadores de dispositivos en todo el mundo [13] [14].
Cámara Web	Son dispositivos de entrada utilizados para la captura de videos, fotos y videollamadas, teniendo en cuenta que ofrezcan una buena resolución. De igual manera, estas cámaras capturan imágenes en tiempo real, permitiendo compartir contenido de forma interactiva [15].
Motor PAP 17PM-K342B	Son mecanismos síncronos que transforman la energía eléctrica en mecánica.
Sensor de peso/fuerza celda carga 50kg y la tarjeta HX-711	Creado para realizar la medición de masa. Este tipo de componentes son ideales para diseñar sistemas de pesaje completos, los cuales pueden incluir desde básculas industriales hasta equipos de medición más sofisticados [16].
Servomotor MG995 5Kg	Es un actuador eléctrico giratorio y autónomo de corriente continua. Este dispositivo efectúa desplazamientos angulares a una velocidad específica [17].
Buzzer pasivo KY-006	Este dispositivo mejora la interacción con el usuario y permite realizar una programación de alarmas y recordatorios para actividades futuras [18].
ESP8266 NodeMCU V. 1.0	Es un microcontrolador con capacidades Wi-Fi integrado, es un dispositivo útil para el envío de datos, además permite adaptar diferentes componentes electrónicos. Además, permite el control de flujo de paquetes de una red mediante diferentes protocolos para el envío de información, y de operar con múltiples plataformas con los protocolos [19].
Módulo Relé de 2 canales	Es un módulo que contiene dos relés electromecánicos, permitiendo controlar de manera independiente dos circuitos eléctricos separados con una señal de control pequeña y es ideal para uso con Arduino y otros sistemas [20].

Para el diseño de la estructura del prototipo de clasificadora de mucílago de cacao, se desarrolló un modelo detallado con dimensiones de 0,80 m de alto y 0,85 m de ancho. Esta estructura se fabricó utilizando dos tubos metálicos EMT cuadrados galvanizados de 1/2 x 2 mm y 45 cm de largo, seleccionados por su resistencia y durabilidad en entornos agrícolas. El diseño contempla dos salidas independientes que permiten depositar, de forma separada, el mucílago limpio y aquel que contiene impurezas en recipientes diferenciados, optimizando así el proceso de clasificación. En la Figura 9 se ilustra la construcción del prototipo, evidenciando la disposición de los componentes y la accesibilidad para su mantenimiento. De esta manera, en la última fase del proyecto se verificó la usabilidad y funcionalidad del sistema mediante pruebas de caja blanca y caja negra, garantizando la correcta integración de todos los módulos y la operatividad del aplicativo móvil.



Figura 9. Construcción del prototipo

III. RESULTADOS

Concluidas las fases de diseño, construcción e integración del sistema, se procedió a la etapa de validación y evaluación del prototipo, con el objetivo de determinar su desempeño en condiciones reales de operación. Este proceso abarcó la verificación del ensamblaje físico, la calibración de los sensores, la ejecución del algoritmo de clasificación y la interacción con la aplicación móvil. La evaluación se planteó como un paso esencial para confirmar que la solución propuesta cumpliera con los requerimientos definidos en las etapas iniciales, asegurando así su viabilidad técnica y funcional. En este contexto, los resultados del prototipo se evaluaron considerando tres aspectos principales: el funcionamiento de la estructura física, la efectividad del algoritmo de clasificación y el manejo del software. Era fundamental verificar que el diseño arquitectónico permitiera una interacción adecuada entre los distintos componentes y la aplicación móvil, asegurando una conexión eficiente para el intercambio de datos. Para ello, se implementó una estructura modular que facilitó la ejecución de los procesos definidos y la comprensión del modelo relacional de la base de datos.

En una primera etapa, se analizaron los resultados de las pruebas sobre la estructura. El sistema puede iniciarse de forma manual o mediante la aplicación móvil. El proceso comienza con el depósito del mucílago en una tolva, desde donde es transportado por una banda hasta la cámara de clasificación. Allí, el algoritmo categoriza el producto en dos grupos: limpio o con impurezas. Luego, el mucílago clasificado se distribuye en recipientes separados, cada uno monitorizado por sensores de peso. Cuando la carga alcanza los 22 kg, un buzzer emite una alerta para indicar el reemplazo del recipiente. Simultáneamente, la aplicación móvil registra la cantidad de recipientes llenos. Este flujo automatizado optimiza la clasificación, reduciendo el tiempo de procesamiento de 2 horas a tan solo 45 minutos y garantizando un control preciso de la carga. En la Figura 10 se observa cómo el mucílago limpio cae en un recipiente, mientras que el producto con impurezas se dirige a otro contenedor.



Figura 10. Clasificación del mucílago en los recipientes respectivos.

La segunda parte de los resultados se centró en la evaluación de la precisión del algoritmo basado en redes neuronales convolucionales, implementado en la plataforma Teachable Machine. Este análisis se sustentó en métricas obtenidas a través de la matriz de confusión, la gráfica de pérdida y la gráfica de ganancia de efectividad. Se establecieron tres clases para el entrenamiento: limpia, impurezas y vacío, siendo esta última la ausencia total de producto en la banda transportadora. Para el conjunto de datos, se recopilieron 490 imágenes correspondientes a la clase vacío, 750 imágenes para la categoría limpia y 820 imágenes para la categoría impurezas. El entrenamiento se ejecutó con un total de 50 épocas, un tamaño de lote de 16 y una tasa de aprendizaje de 0,001, lo que permitió alcanzar una efectividad del 98 % en la clasificación. Este alto porcentaje refleja la capacidad del modelo para identificar con precisión cada categoría, minimizando falsos positivos y falsos negativos. Dicho rendimiento es especialmente relevante, ya que garantiza un proceso de selección más confiable y consistente, incluso ante variaciones en la iluminación o la posición del mucílago en la banda. En la Figura 11 se ilustra el procedimiento de clasificación implementado en Teachable Machine, así como la interfaz utilizada para la visualización de los resultados.

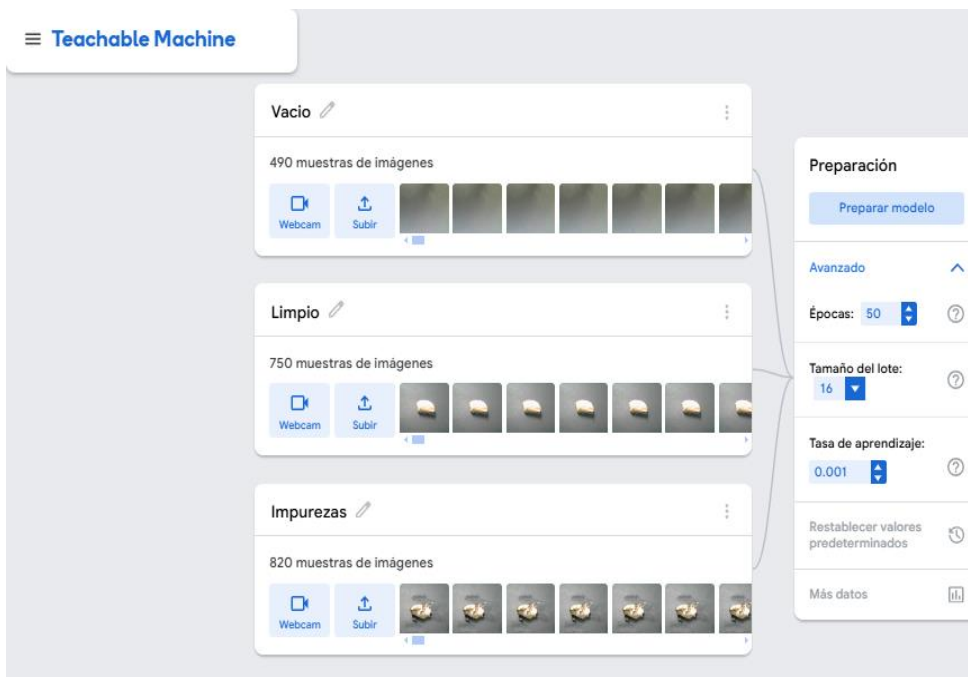


Figura 11. Clasificación en teachable machine

En la Figura 12 se presenta la matriz de confusión correspondiente a las tres categorías previamente definidas (vacío, limpio e impurezas), utilizando el conjunto de imágenes capturadas por la cámara web implementada en el prototipo. Los resultados evidencian un desempeño altamente satisfactorio del modelo. Para la clase vacío, se alcanzó una precisión del 100 %, con 74 aciertos y ninguna clasificación errónea. En la categoría limpio también se obtuvo un 100 % de precisión, con 113 aciertos sobre 113 muestras. La clase impurezas mostró un rendimiento ligeramente inferior, con un 98 % de precisión, registrando 121 aciertos y 2 clasificaciones incorrectas como vacío.



Figura 12. Resultados de la matriz de confusión y gráficas de la precisión y pérdida

En cuanto al comportamiento del entrenamiento, las gráficas de precisión por época indican que el modelo alcanzó rápidamente un valor estable cercano al 100%, manteniéndose constante durante las 50 épocas. Esto refleja que el algoritmo logró aprender las características distintivas de cada clase en las primeras iteraciones, evitando sobreajustes y garantizando una buena generalización en los datos de prueba. Por su parte, la gráfica de pérdida por época muestra una reducción abrupta en las primeras iteraciones, seguida de una estabilización en valores cercanos a cero, lo que confirma una convergencia eficiente del modelo. La interpretación conjunta de estos resultados permite concluir que el sistema de clasificación basado en redes neuronales convolucionales no solo ofrece una alta precisión global (98 %), sino que también mantiene un rendimiento consistente incluso ante variaciones leves en el aspecto del mucílago. Este nivel de exactitud asegura que el prototipo pueda ser utilizado de manera confiable en condiciones reales de postcosecha, optimizando el proceso y minimizando el riesgo de errores en la selección del producto.

Por último, se presentan los resultados de las pruebas de usabilidad de la aplicación desarrollada para dispositivos con sistema operativo Android. Estas evaluaciones permitieron validar el correcto funcionamiento de cada uno de los procesos implementados, comprobando la entrada y validación de datos en las distintas interfaces y asegurando que la aplicación ofreciera respuestas precisas y oportunas para los usuarios finales, como el propietario y los trabajadores de la finca. Durante la evaluación se registró el flujo de interacción de los usuarios, lo que permitió medir el tiempo necesario para completar cada acción y confirmar un rendimiento óptimo. Asimismo, se verificó la facilidad de navegación entre los módulos, la claridad de la información presentada y la eficiencia en la consulta de reportes. En la Figura 13 se observa la interfaz del aplicativo, desde la pantalla de inicio de sesión hasta los menús de gestión y el sistema de reportes del proyecto.

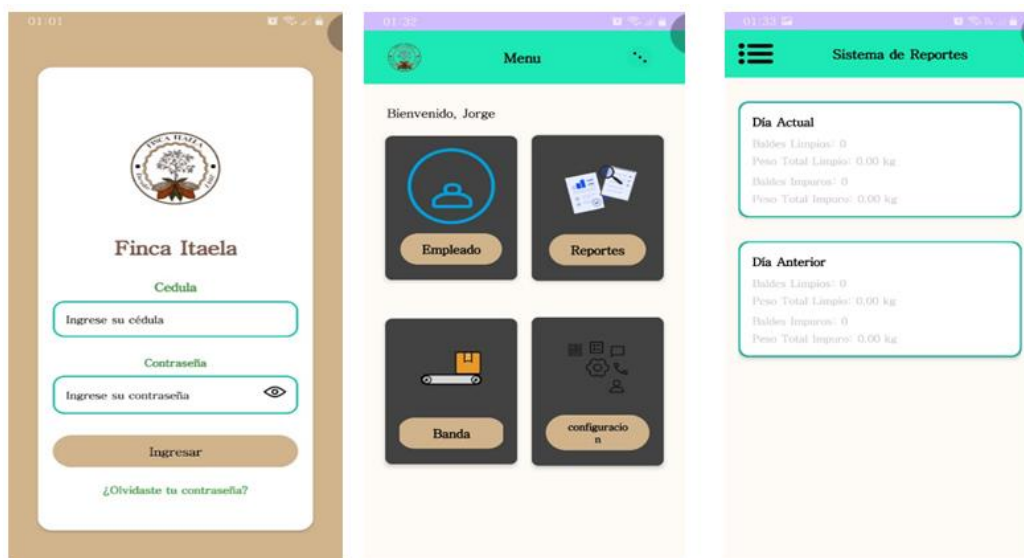


Figura 13. Aplicación Móvil con sistemas de reportes

En síntesis, los resultados obtenidos evidencian que el prototipo desarrollado cumple satisfactoriamente con los objetivos planteados, ya que integra de manera eficiente los componentes mecánicos, electrónicos y de software, alcanzando una alta precisión en el algoritmo de clasificación y reduciendo de forma significativa los tiempos de procesamiento, lo que demuestra su potencial para optimizar el manejo del mucílago en la etapa de postcosecha; asimismo, la aplicación móvil validó su usabilidad y funcionalidad al facilitar el control remoto y la gestión de datos en tiempo real, de modo que en conjunto estos hallazgos confirman la viabilidad técnica y operativa de la solución, así como su aplicabilidad en entornos agrícolas reales.

IV. DISCUSIÓN

El prototipo de clasificación de mucílago de cacao ha sido desarrollado utilizando Teachable Machine, una herramienta basada en redes neuronales convolucionales para el aprendizaje automático. Gracias a esta tecnología, ha sido posible entrenar modelos personalizados de reconocimiento de imágenes, facilitando la identificación de patrones visuales específicos. En este sentido, los hallazgos, evidencian una precisión global del 98 % empleando una red neuronal convolucional para clasificar mucílago de cacao en tres categorías (vacío, limpio, impurezas), coinciden favorablemente con trabajos previos en la literatura. Por ejemplo, Rola et al. [21] reportaron un 99 % de exactitud al detectar *Phytophthora palmivora* en granos de cacao mediante CNN. Asimismo, Lopes et al. [9] lograron una precisión de 96,82 % usando un sistema de visión profunda (ResNet-18) para clasificar variedades de cacao. Estos resultados respaldan el alto rendimiento de los métodos basados en visión artificial y refuerzan la robustez de tu modelo, incluso con un volumen moderado de imágenes.

Otra investigación que abordó este desafío fue la de Anduyan et al. [22] en la cual se demostró que la combinación de transfer learning con técnicas de ensamblado (bagging, boosting, stacking) permitió alcanzar una precisión elevada en la clasificación de enfermedades en vainas de cacao, empleando arquitecturas como VGG16, ResNet50 e InceptionV3. Aunque en el presente trabajo no se implementaron métodos de ensemble learning, el haber obtenido un 98 % de efectividad con modelos entrenados en Teachable Machine y un conjunto de datos más reducido evidencia una notable eficiencia y alta aplicabilidad práctica. Estos resultados confirman que este enfoque constituye una alternativa accesible, de bajo costo y adaptable a productores agrícolas, manteniendo un elevado nivel de precisión, una correcta operatividad tecnológica y un potencial considerable para su escalabilidad en entornos productivos diversos.

En la misma dirección el estudio de Pal et al. [10] lograron una exactitud máxima de 0,86 al emplear CNN sobre rasgos estructurales, destacando que la selección de características y la calidad del dataset influyen de forma decisiva en el rendimiento del modelo. Por su parte, Eric et al. [23] demostraron que la incorporación de información cromática y textural en redes de menor complejidad puede mejorar los resultados frente a modelos basados únicamente en forma o estructura, evidenciando que la combinación de atributos visuales incrementa la capacidad discriminativa de los algoritmos. Este conjunto de referencias confirma que, aunque el prototipo desarrollado se entrenó con un volumen de datos moderado y en un entorno de desarrollo accesible como Teachable Machine, el rendimiento alcanzado no solo es competitivo frente a arquitecturas más complejas, sino que además supera a varios métodos reportados en la etapa de poscosecha, consolidando su potencial como solución viable, escalable y de bajo costo para el sector agrícola.

De igual manera, Vera et al. [24], quienes desarrollaron un modelo de detección de enfermedades "monilia" y "black pod" en vainas de cacao utilizando el detector EfficientDet-Lite4, notablemente eficiente y ligero. El modelo, entrenado con un conjunto equilibrado de imágenes, se integró en una aplicación móvil Android con interfaz de usuario amigable, demostrando precisión suficientemente alta para ayudar a agricultores con poca experiencia. En contraste, aunque el presente estudio no aborda enfermedades de la vaina, comparte el enfoque de visión artificial aplicado al cacao y valida que soluciones ligeras e integradas en dispositivos móviles pueden ser precisas, accesibles y prácticas para contextos rurales.

El análisis comparativo con la literatura revela que el sistema desarrollado se sitúa en un nivel competitivo frente a soluciones más complejas, lo que resulta especialmente relevante considerando que se entrenó con un conjunto de datos moderado y empleando hardware libre. La precisión del 98 % obtenida en la clasificación del mucílago de cacao no solo valida la pertinencia de las redes neuronales convolucionales en procesos de poscosecha, sino que también demuestra

que la optimización de recursos y la selección adecuada de hiperparámetros pueden generar resultados equivalentes a arquitecturas más sofisticadas, como ResNet o VGG, reportadas en estudios previos. Sin embargo, esta coincidencia de métricas no implica que ambos enfoques sean intercambiables, ya que la robustez a condiciones variables de iluminación, textura o humedad requiere validaciones adicionales. En este sentido, el presente trabajo destaca por su enfoque de aplicabilidad y transferencia tecnológica directa al sector cacaotero, alineándose con tendencias de digitalización y agricultura inteligente que priorizan la eficiencia y la accesibilidad.

Si bien los resultados obtenidos son alentadores, es necesario reconocer ciertas limitaciones que condicionan la generalización del modelo. El tamaño y la procedencia del dataset podrían limitar su rendimiento en contextos con variaciones marcadas en el tipo de mucílago o en las condiciones ambientales. Asimismo, el uso de Teachable Machine, aunque facilitó el prototipado rápido, restringe el acceso a optimizaciones avanzadas y a una personalización más profunda del modelo. Futuras investigaciones deberían incorporar datasets más amplios y diversos, explorar técnicas de ensemble learning y realizar pruebas en distintas zonas productoras. En la próxima sección se presentan las conclusiones que sintetizan los hallazgos y aportes del estudio.

V. CONCLUSIONES

El propósito de este estudio fue diseñar, desarrollar y validar un prototipo robótico automatizado para la clasificación del mucílago de cacao, empleando inteligencia artificial y hardware libre, con el fin de mejorar el proceso de postcosecha y mejorar la eficiencia productiva. Los resultados demostraron que el sistema integra de forma eficiente la estructura física, el algoritmo de clasificación y el software de control, logrando una precisión global del 98 % y reduciendo significativamente los tiempos de procesamiento. Esta combinación de desempeño, accesibilidad tecnológica y bajo coste evidencia el potencial de la propuesta para mejorar la competitividad en el sector cacaotero y fomentar la innovación agrícola.

El análisis de la precisión del modelo, basado en redes neuronales convolucionales, reveló un desempeño consistente en las tres clases definidas, con una tasa del 100 % en vacío y limpio, y del 98 % en impurezas, lo que confirma su fiabilidad. La convergencia rápida y la baja pérdida durante el entrenamiento demuestran la eficacia del modelo, incluso ante variaciones en iluminación o posición del producto en la banda transportadora. Asimismo, las pruebas de usabilidad de la aplicación Android validaron la facilidad de uso, la claridad en la presentación de datos y la eficiencia en la gestión remota, asegurando su utilidad para los usuarios finales en entornos agrícolas reales y permitiendo una supervisión constante del proceso.

Si bien los resultados son alentadores, se identificaron limitaciones asociadas al tamaño y diversidad del conjunto de datos, así como a las restricciones de personalización impuestas por la plataforma de entrenamiento utilizada, lo que limita la posibilidad de aplicar ajustes avanzados. Futuras investigaciones deberían ampliar el dataset con muestras recolectadas en diferentes zonas y condiciones ambientales, incorporar técnicas más sofisticadas como ensemble learning, transfer learning o arquitecturas de última generación como Vision Transformers y EfficientNet, y realizar pruebas de campo prolongadas para validar la robustez del sistema ante escenarios de alta variabilidad. Asimismo, se recomienda explorar la aplicación de estas tecnologías en otros cultivos o productos agroindustriales, así como experimentar su implementación en distintas localidades internacionales, lo que permitiría evaluar la adaptabilidad y escalabilidad de la solución en contextos productivos diversos. Estas acciones fortalecerán la generalización del modelo, ampliarán su aplicabilidad y contribuirán de forma decisiva a la digitalización del sector agrícola.

Contribución de los autores:

La conceptualización del estudio fue realizada por M.M.R. y J.P.R.; el diseño metodológico y el análisis formal de los datos, por M.M.R. y J.P.R.; la recolección y curación de datos, por M.M.R. y J.P.R.; la redacción del borrador original estuvo a cargo de M.M.R. y J.P.R., quienes además elaboraron la visualización de los resultados. La revisión crítica y edición del manuscrito fue realizada por C.M.P.E. y T.S.C.; la supervisión general, así como la administración del proyecto, estuvieron a cargo de C.M.P.E. y T.S.C. Todos los autores han leído y aprobado la versión final del manuscrito, y se hacen responsables de su contenido.

Agradecimientos:

Se extiende un especial agradecimiento a la Universidad de Guayaquil por el respaldo institucional brindado, el cual permitió el acceso a sus plataformas y bibliotecas, recursos que fueron esenciales para el desarrollo de la presente investigación. Asimismo, se reconoce el valioso acompañamiento ofrecido por CISAI durante la etapa de revisión del manuscrito, cuya contribución resultó determinante para mejorar su calidad y fortalecer su alcance académico.

Financiamiento:

El estudio ha sido autofinanciado por los autores.

Declaración de consentimiento informado:

No aplica.

Declaración de disponibilidad de datos:

Los datos que respaldan los resultados de este estudio están disponibles previa solicitud al autor de correspondencia.

Conflictos de intereses:

No existen conflictos de intereses.

REFERENCIAS

- [1] T. P. Ramos-Ramos, D. J. Guevara-Llerena, L. B. Sarduy-Pereira, and K. Diéguez-Santana, "Producción más limpia y ecoeficiencia en el procesado del cacao: un caso de estudio en Ecuador," *I&D*, vol. 20, no. 1, pp. 135–146, Jul. 2020. <https://doi.org/10.23881/idupbo.020.1-10i>
- [2] A. Teixeira, P. Iannetta, K. Binnie, T. A. Valentine, and P. Toorop, "Myxospermous seed-mucilage quantity correlates with environmental gradients indicative of water-deficit stress: Plantago species as a model," *Plant Soil*, vol. 446, no. 1–2, pp. 343–356, Jan. 2020. <https://doi.org/10.1007/s11104-019-04335-z>
- [3] W. Deng, P. P. M. Iannetta, P. D. Hallett, P. E. Toorop, G. R. Squire, and D.-S. Jeng, "The rheological properties of the seed coat mucilage of *Capsella bursa-pastoris* L. Medik. (shepherd's purse)," *Biorheology*, vol. 50, no. 1–2, pp. 57–67, 2013. <https://doi.org/10.3233/BIR-130627>
- [4] B. Hirko, H. Mitiku, and A. Getu, "Role of fermentation and microbes in cacao fermentation and their impact on cacao quality," *Syst Microbiol and Biomanuf*, vol. 3, no. 4, pp. 509–520, Oct. 2023. <https://doi.org/10.1007/s43393-023-00160-9>
- [5] A. Figoli, J. Hoinkis, S. A. Altinkaya, and J. Bundschuh, Eds., *Application of Nanotechnology in Membranes for Water Treatment*, 1st ed. CRC Press, 2017. <https://doi.org/10.1201/9781315179070>
- [6] O. V. Zinina, A. V. Sharopatova, and J. A. Olentsova, "Management of an agricultural organization based on building a quality management system," *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 677, no. 2, p. 022029, Mar. 2021. <https://doi.org/10.1088/1755-1315/677/2/022029>

- [7] M. Mukhiddinov, A. Muminov, and J. Cho, "Improved Classification Approach for Fruits and Vegetables Freshness Based on Deep Learning," *Sensors*, vol. 22, no. 21, p. 8192, Oct. 2022. <https://doi.org/10.3390/s22218192>
- [8] A. A. Garcés-Cadena, O. A. Menéndez Granizo, E. P. Córdova, and A. J. Prado Romo, "Clasificación de calidad de manzana para monitoreo de cosechabilidad utilizando visión por computador y algoritmos de aprendizaje profundo," *Ingeniare. Rev. chil. ing.*, vol. 31, Aug. 2023. <https://doi.org/10.4067/S0718-33052023000100215>
- [9] J. F. Lopes, V. G. T. Da Costa, D. F. Barbin, L. J. P. Cruz-Tirado, V. Baeten, and S. Barbon Junior, "Deep computer vision system for cocoa classification," *Multimed Tools Appl*, vol. 81, no. 28, pp. 41059–41077, Nov. 2022. <https://doi.org/10.1007/s11042-022-13097-3>
- [10] C. Pal, S. Das, A. Akuli, S. K. Adhikari, and A. Dey, "Cocoa-Net: Performance Analysis on Classification of Cocoa Beans Using Structural Image Feature," *IJCAI*, vol. 48, no. 12, Sep. 2024. <https://doi.org/10.31449/inf.v48i12.5762>
- [11] S. Das, A. Akuli, S. Biswas, A. Dey, A. Ghosh, and R. Shaw, "Discrimination of Cocoa Beans using Structural Image Features: An Experimental Analysis," in *2022 IEEE IAS Global Conference on Emerging Technologies (GlobConET)*, Arad, Romania: IEEE, May 2022, pp. 1138–1142. <https://doi.org/10.1109/GlobConET53749.2022.9872329>
- [12] A. K. Jean, M. Diarra, B. A. Bakary, G. Pierre, and A. K. Jérôme, "Application based on Hybrid CNN-SVM and PCA-SVM Approaches for Classification of Cocoa Beans," *IJACSA*, vol. 13, no. 9, 2022. <https://doi.org/10.14569/IJACSA.2022.0130927>
- [13] T. Coughlin, "Supersize My Pi [The Art of Storage]," *IEEE Consumer Electron. Mag.*, vol. 6, no. 3, pp. 124–144, Jul. 2017. <https://doi.org/10.1109/MCE.2017.2685038>
- [14] P. D. Prasetyo Adi *et al.*, "Optimization and Development of Raspberry Pi 4 Model B for the Internet of Things," in *2023 IEEE 9th Information Technology International Seminar (ITIS)*, Batu Malang, Indonesia: IEEE, Oct. 2023, pp. 1–6. <https://doi.org/10.1109/ITIS59651.2023.10420261>
- [15] A. P. Singh and D. Agarwal, "Webcam Motion Detection in Real-Time Using Python," in *2022 International Mobile and Embedded Technology Conference (MECON)*, Noida, India: IEEE, Mar. 2022, pp. 1–4. <https://doi.org/10.1109/MECON53876.2022.9752059>
- [16] M. Islamiah and F. Fathurrahmaniah, "Praktikalitas Pembelajaran STEM dengan Arduino dan Sensor HX-711 pada Materi Impuls Berbasis Website," *jm-jpmipa*, vol. 4, no. 4, pp. 707–717, Dec. 2024. <https://doi.org/10.53299/jagomipa.v4i4.904>
- [17] S. P. Atti, H. Raj, H. K. A. N, H. R. P. N. H, and M. R. K, "Humanoid Robot," in *2024 IEEE 11th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, Lucknow, India: IEEE, Nov. 2024, pp. 1–4. <https://doi.org/10.1109/UPCON62832.2024.10982951>
- [18] J. Vazquez, A. P. Torres, F. J. L. Alcolea, E. J. M. Martinez, and P. Roncero-Sanchez, "Implementation of a sensorized home alarm prototype on an FPGA platform," in *2022 Congreso de Tecnología, Aprendizaje y Enseñanza de la Electrónica (XV Technologies Applied to Electronics Teaching Conference)*, Teruel, Spain: IEEE, Jun. 2022, pp. 1–7. <https://doi.org/10.1109/TAE54169.2022.9840636>
- [19] J. Torres Ventura, A. H. Ruelas Puente, and J. R. Herrera García, "Rendimiento para la interoperabilidad entre Rasperry pi, ESP8266 y PLC con Node-RED para el IIoT," *ings*, no. 29, pp. 90–97, Jan. 2023. <https://doi.org/10.17163/ings.n29.2023.08>
- [20] D. Ascencios, K. Meza, J. Lluen, and G. Simon, "Calibración, validación y automatización del sistema de riego por goteo subterráneo usando un microcontrolador Arduino," *Rev. investig. altoandin.*, vol. 22, no. 1, pp. 95–105, Jan. 2020. <https://doi.org/10.18271/ria.2020.540>
- [21] J. B. Rola *et al.*, "Convolutional Neural Network Model for Cacao Phytophthora Palmivora Disease Recognition," *ijacsa*, vol. 15, no. 8, 2024. <https://doi.org/10.14569/IJACSA.2024.0150897>
- [22] D. Anduyan, N. Cabillo, N. Gultiano, and M. P. Pacot, "Enhancing Cocoa Pod Disease Classification via Transfer Learning and Ensemble Methods: Toward Robust Predictive Modeling," 2025, *arXiv*. <https://doi.org/10.48550/ARXIV.2504.12992>
- [23] O. Eric, R.-M. O. M. Gyening, O. Appiah, K. Takyi, and P. Appiahene, "Cocoa beans classification using enhanced image feature extraction techniques and a regularized Artificial Neural Network model," *Engineering Applications of Artificial Intelligence*, vol. 125, p. 106736, Oct. 2023. <https://doi.org/10.1016/j.engappai.2023.106736>
- [24] D. B. Vera, B. Oviedo, W. C. Casanova, and C. Zambrano-Vega, "Deep Learning-Based Computational Model for Disease Identification in Cocoa Pods (*Theobroma cacao* L.)," 2024, *arXiv*. <https://doi.org/10.48550/ARXIV.2401.01247>