

CLASIFICACIÓN DEL NIVEL DE FERMENTACIÓN DE GRANOS DE CACAO SECOS
ABIERTOS Y CERRADOS MEDIANTE EL PROCESAMIENTO DE IMÁGENES
ESPECTRALES Y APRENDIZAJE PROFUNDO.

JUAN SEBASTIAN ESPINOSA ESPINOSA
JUAN DANIEL SUAREZ JAIMES

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA

2026

CLASIFICACIÓN DEL NIVEL DE FERMENTACIÓN DE GRANOS DE CACAO SECOS
ABIERTOS Y CERRADOS MEDIANTE EL PROCESAMIENTO DE IMÁGENES
ESPECTRALES Y APRENDIZAJE PROFUNDO.

JUAN SEBASTIAN ESPINOSA ESPINOSA
JUAN DANIEL SUAREZ JAIMES

Trabajo de grado para optar al título de Ingeniero de sistemas

Directora:

Laura Viviana Galvis Carreño
Doctora en Ingeniería eléctrica y computación

Codirector

Kebin Andrés Contreras
Magíster en Bioingeniería, Universidad Industrial de Santander

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA

2026

DEDICATORIA

La ciencia no es solo un conjunto de conocimientos; es una manera de pensar, una forma de interrogar al universo con humildad. En cada algoritmo vive la chispa de curiosidad que alguna vez nos llevó a mirar las estrellas. No hay contradicción entre la razón y la emoción, porque comprender es también una forma de amar. Somos el medio por el cual el cosmos se conoce a sí mismo, los ingenieros y soñadores que traducen el infinito en lenguaje comprensible para todos.

- Carl Sagan, Cosmo.

AGRADECIMIENTOS

Queremos expresar nuestro más sincero agradecimiento a nuestras familias, cuyo apoyo incondicional, comprensión y motivación hicieron posible cada etapa de este trabajo. Su confianza y acompañamiento fueron el pilar que nos permitió avanzar y alcanzar esta meta.

Agradecemos especialmente a nuestros asesores, Jorge Luis Bacca Quintero y Laura Viviana Galvis Carreño, por su guía, dedicación y exigencia académica a lo largo del proyecto. De igual manera, extendemos nuestro agradecimiento a nuestro codirector, Kebin Andrés Contreras, por su constante orientación, sus recomendaciones técnicas y su disposición para acompañar cada avance. Nuestro reconocimiento también para los profesores que nos formaron y acompañaron durante la carrera y el desarrollo de esta investigación; sus clases, consejos y observaciones enriquecieron significativamente este trabajo. Finalmente, agradecemos a nuestros amigos, por su compañía, paciencia y aliento permanente, que nos impulsaron a seguir adelante incluso en los momentos más retadores.

CONTENIDO

	pág.
INTRODUCCIÓN	12
1. PLANTEAMIENTO Y JUSTIFICACIÓN DEL PROBLEMA	17
2. OBJETIVOS	21
2.1 OBJETIVO GENERAL	21
2.2 OBJETIVOS ESPECÍFICOS	21
3. MARCO CONCEPTUAL.....	22
3.1 GRANO DE CACAO	22
3.2 IMÁGENES ESPECTRALES	24
3.3 LENGUAJE DE PROGRAMACIÓN PYTHON.....	26
3.4 MODELO DE DETECCIÓN YOLO.....	26
3.4.1 Función objetivo del modelo YOLO.....	27
3.4.2 Componentes de la función de pérdida YOLO.....	28
3.4.2.1 Pérdida de localización.....	28
3.4.2.2 Pérdida de confianza.....	29
3.4.2.3 Pérdida de clasificación.....	29
3.4.2.4 Función de pérdida total:.....	29
3.5 PLATAFORMA DE ETIQUETADO MANUAL CVAT	30
3.6 ENTORNO DE DESARROLLO DE APK: ANDROID STUDIO	31
4. METODOLOGÍA PROPUESTA.....	32
4.1 ETAPA 1.....	32
4.1.1 Captura y modalidades de imagen.....	34
4.1.2 Preprocesamiento y organización del conjunto	37
4.1.3 Transformación de datos hiperespectrales a representación RGB mediante PCA	38

4.1.4 División del conjunto de datos.....	38
4.2 ETAPA 2.....	39
4.2.1 Configuración del entrenamiento del modelo	39
4.2.2 Métricas.....	41
4.2.3 Proceso de inferencia del modelo	41
4.2.4 Configuración experimental.....	43
4.2.5 Resultados.	44
4.2.5.1 Entrenamiento con imágenes RGB	45
4.2.5.2 Entrenamiento con imágenes espectrales con granos abiertos.	46
4.2.5.3 Entrenamiento con imágenes espectrales con granos cerrados.	47
4.2.5.4 Resultados del mejor modelo durante el entrenamiento con granos abiertos. ...	49
4.3 ETAPA 3.....	51
5. CONCLUSIONES.....	54
6. TRABAJO FUTURO.....	56
BIBLIOGRAFÍA	57

LISTA DE CUADROS

pág.

Cuadro 1. Resultados comparativos entre versiones YOLO utilizando la variante medium (modelos “m”) utilizando imágenes RGB.....	45
Cuadro 2. Resultados comparativos entre versiones YOLOv8 utilizando imágenes RGB.	46
Cuadro 3. Resultados del entrenamiento con PCA (granos abiertos).....	47
Cuadro 4. Resultados del entrenamiento con PCA (granos cerrados).....	47
Cuadro 5. Resumen comparativo de los mejores modelos por escenario experimental.	48

LISTA DE FIGURAS

	pág.
Figura 1. Calidad de granos de cacao secos.	23
Figura 2. Cubo hiperespectral y firma espectral.	25
Figura 3. Etiquetado por clases de granos de cacao.	31
Figura 4. Muestras de granos de cacao recolectadas.	33
Figura 5. Proceso de poscosecha del cacao.	34
Figura 6. Guillotina para prueba de corte de cacao.	35
Figura 7. Ejemplos del conjunto de datos y anotaciones.	37
Figura 8. Diagrama del proceso de clasificación con YOLO.	42
Figura 9. Detección del modelo sobre granos de cacao.	43
Figura 10. Curvas de aprendizaje PCA con granos abiertos.	49
Figura 11. Curvas de aprendizaje PCA con granos cerrados.	50
Figura 12. Pantalla de selección del tipo de grano.	52
Figura 13. Resultado de detección y clasificación en granos.	53

LISTA DE ANEXOS

Los anexos están adjuntos.

Anexo A. Artículo científico derivado del proyecto presentado en el XXV Symposium of Image, Signal Processing and Artificial Vision (STSIVA 2025), Armenia, Colombia. DOI: 10.1109/STSIVA66383.2025.11156348.

RESUMEN

TÍTULO: CLASIFICACIÓN DEL NIVEL DE FERMENTACIÓN DE GRANOS DE CACAO SECOS ABIERTOS Y CERRADOS MEDIANTE PROCESAMIENTO DE IMÁGENES HIPERESPECTRALES Y APRENDIZAJE PROFUNDO *

AUTORES: JUAN DANIEL SUÁREZ JAIMES, JUAN SEBASTIÁN ESPINOSA ESPINOSA **

PALABRAS CLAVE: IMÁGENES HIPERESPECTRALES, CALIDAD DEL CACAO, APRENDIZAJE PROFUNDO, TRANSFERENCIA ESPECTRAL, INFERENCIA MÓVIL.

DESCRIPCIÓN:

El proceso de fermentación del cacao es clave para el sabor y el aroma del chocolate; sin embargo, los métodos actuales de evaluación son manuales y altamente subjetivos. Este trabajo propone una alternativa estandarizada basada en aprendizaje profundo e imágenes hiperespectrales para determinar el nivel de fermentación, a partir de una base de datos de granos de cacao etiquetados conforme a la norma colombiana (NTC 1252:2021) en tres categorías: bien fermentados, parcialmente fermentados y mal fermentados.

Para ello, se empleó un enfoque de transferencia de conocimiento entre dominios, en el que el modelo fue entrenado con imágenes RGB e información hiperespectral durante la fase de entrenamiento, mientras que en la inferencia utiliza únicamente imágenes RGB, permitiendo su implementación en entornos reales. Además, se desarrolló un protocolo de adquisición y etiquetado de imágenes que garantiza la consistencia de los datos utilizados durante el entrenamiento y la evaluación del modelo.

En las pruebas realizadas, el sistema alcanzó una precisión superior al 95% y mantuvo un desempeño consistente ante variaciones controladas de iluminación y cámara. El modelo fue integrado en una aplicación móvil que clasifica cada grano de cacao de manera automática.

Esta investigación contribuye a la automatización del control de calidad del cacao, ofreciendo una herramienta rápida, confiable y asequible para productores y cooperativas. Como trabajo futuro, se plantea ampliar el modelo para detectar defectos físicos e integrarlo en sistemas de monitoreo agrícola basados en inteligencia artificial para una producción sostenible de cacao.

* Trabajo de grado

** Facultad de ingenierías fisicomecánicas. Escuela de ingeniería de sistemas. Directora: Laura Viviana Galvis Carreño. Doctora en Ingeniería eléctrica y computación. Codirector: Kebin Andrés Contreras. Magíster en bioingeniería.

ABSTRACT

TITLE: CLASSIFICATION OF THE FERMENTATION LEVEL OF DRY OPEN AND CLOSED COCOA BEANS THROUGH HYPERSPECTRAL IMAGE PROCESSING AND DEEP LEARNING *

AUTHORS: JUAN DANIEL SUÁREZ JAIMES, JUAN SEBASTIÁN ESPINOSA ESPINOSA **

KEY WORDS: Hyperspectral imaging, cocoa quality, deep learning, spectral transfer, mobile inference.

DESCRIPTION:

The cocoa fermentation process is essential for the flavor and aroma of chocolate; however, current evaluation methods are manual and highly subjective. This work proposes a standardized alternative based on deep learning and hyperspectral imaging to determine the fermentation level, using a dataset of cocoa beans labeled according to the Colombian standard (NTC 1252:2021) into three categories: well-fermented, partially fermented, and poorly fermented.

To achieve this, a cross-domain knowledge transfer approach was employed, in which the model was trained using RGB images and hyperspectral information during the training phase, while during inference it uses only RGB images, enabling its implementation in real-world environments. In addition, an image acquisition and labeling protocol was developed to ensure the consistency of the data used during model training and evaluation.

In the conducted experiments, the system achieved an accuracy above 95% and maintained consistent performance under controlled variations in lighting and camera conditions. The model was integrated into a mobile application that automatically classifies each cocoa bean.

This research contributes to the automation of cocoa quality control by providing a fast, reliable, and affordable tool for producers and cooperatives. As future work, the model will be extended to detect physical defects and integrated into artificial intelligence-based agricultural monitoring systems for sustainable cocoa production.

* Degree work

** Faculty of physical-mechanical engineering. School of systems engineering. Advisor: Laura Viviana Galvis Carreño, Ph.D. in electrical and computer engineering. Co-advisor: Kebin Andrés Contreras, M.Sc. in bioengineering.

INTRODUCCIÓN

El cacao es un cultivo emblemático de América Latina y una pieza clave de la economía agrícola de Colombia¹. El cacao colombiano es reconocido por su calidad y características sensoriales que constituyen una ventaja competitiva en mercados internacionales². Este posicionamiento impulsa programas de promoción orientados a nichos especializados y refuerza la imagen de productor premium³. La expansión del cultivo responde a oportunidades de mercado y cumple un papel estratégico en el desarrollo rural, la sustitución de cultivos ilícitos y la construcción de paz, como alternativa económica sostenible para comunidades campesinas⁴.

A pesar de este potencial, el sector cacaotero enfrenta importantes desafíos relacionados con su productividad, estandarización de procesos y adopción tecnológica⁵. La mayor parte de los cultivos está en manos de pequeños productores que salvaguardan prácticas tradicionales y biodiversidad, tienen acceso limitado a asistencia técnica, investigación e infraestructura⁶. Esta realidad se refleja en la calidad del grano, que a menudo presenta variabilidad debido a procesos de fermentación y secado poco uniformes⁷. La clasificación manual de los granos, un paso esencial para garantizar calidad en la cadena productiva sigue siendo artesanal y dependiente del juicio subjetivo, lo que dificulta alcanzar estándares homogéneos y competitivos frente a países líderes como Ecuador,

¹ CONTRERAS PEDRAZA, Análisis de la cadena de valor del cacao en Colombia.

² SWISSCO, *Cocoa facts and figures*.

³ LALIBERTÉ et al., Guía para la evaluación de la calidad y el sabor del cacao.

⁴ CAVIEDES RUBIO et al., Impactos ecológicos, económicos y sociales del sector cacaotero colombiano.

⁵ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

⁶ CONTRERAS PEDRAZA, Análisis de la cadena de valor del cacao en Colombia.

⁷ LALIBERTÉ et al., Guía para la evaluación de la calidad y el sabor del cacao.

Perú, entre otros⁸. Paralelamente, la lenta adopción de tecnologías digitales y de agricultura 4.0 limita la mejora de la eficiencia y la trazabilidad a lo largo de la cadena⁹.

El cacao colombiano se caracteriza por pertenecer, en gran parte, a variedades finas de aroma como el Criollo y Trinitario, que representan alrededor del 95 % de la producción nacional¹⁰. Estas variedades son reconocidas internacionalmente por sus notas sensoriales diferenciadas, desde florales hasta frutales y a nuez, lo que las convierte en un producto altamente demandado por la industria chocolatera gourmet¹¹. Sin embargo, alcanzar y sostener estos perfiles de sabor depende directamente de procesos de poscosecha cuidadosamente controlados, especialmente de la fermentación y el secado¹². Estudios y reportes técnicos advierten que, cuando existen fallas de control en estas etapas, las mermas en calidad y rendimiento pueden ser sustanciales, lo que refuerza la necesidad de fortalecer el conocimiento técnico de los productores.

Colombia ha ocupado un lugar destacado en la producción de cacao¹³. Sin embargo, su participación global sigue siendo limitada en comparación con países africanos y asiáticos que dominan el mercado de volumen¹⁴. El país apuesta a la diferenciación por calidad, con el cacao fino de aroma como sello distintivo que ha abierto oportunidades en mercados europeos y norteamericanos¹⁵.

⁸ BIOVERSITY INTERNATIONAL, Protocolo B: Análisis externo y prueba de corte de granos de cacao.

⁹ WANDEL MARROQUÍN, Nuevas tecnologías y agricultura 4.0: impacto en los recursos humanos de la industria agrícola en Centroamérica.

¹⁰ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

¹¹ LALIBERTÉ et al., Guía para la evaluación de la calidad y el sabor del cacao.

¹² BIOVERSITY INTERNATIONAL, Protocolo B: Análisis externo y prueba de corte de granos de cacao.

¹³ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

¹⁴ SWISSCO, Cocoa facts and figures.

¹⁵ LALIBERTÉ et al., Guía para la evaluación de la calidad y el sabor del cacao.

Este enfoque estratégico exige una cadena de valor sólida, desde el manejo agronómico hasta el control riguroso de la calidad de la poscosecha¹⁶. La estandarización de procesos y la innovación tecnológica son cruciales para cumplir con las demandas internacionales, donde los consumidores valoran atributos como el origen, el sabor y la sostenibilidad ambiental¹⁷.

Uno de los principales retos de la industria cacaotera en Colombia es la fermentación, etapa determinante para el desarrollo de compuestos de aroma y sabor¹⁸. En muchas regiones, este proceso se realiza de manera empírica, generando resultados heterogéneos que afectan directamente la percepción del producto final. La falta de herramientas tecnológicas que permitan evaluar con precisión el grado de fermentación y clasificar el grano genera pérdidas económicas, reduce la competitividad y limita el acceso a mercados especializados¹⁹. Este problema no se restringe a Colombia, sino que es un desafío global en el sector, aunque en países productores a gran escala existen mayores inversiones en tecnología y control de calidad²⁰.

En este contexto, la investigación científica desempeña un papel estratégico²¹. Instituciones como Agrosavia, Fedecacao y diversas universidades colombianas han avanzado en el análisis físico-químico del cacao, evaluando parámetros como el índice de fermentación, la acidez y la concentración de compuestos volátiles. Estos estudios han permitido identificar correlaciones entre la calidad sensorial del grano y las variables del proceso de poscosecha, estableciendo una base científica sólida para desarrollar

¹⁶ CONTRERAS PEDRAZA, Análisis de la cadena de valor del cacao en Colombia.

¹⁷ LALIBERTÉ et al., Guía para la evaluación de la calidad y el sabor del cacao.

¹⁸ *Ibíd.*

¹⁹ SÁNCHEZ et al., Classification of Cocoa Beans Based on their Level of Fermentation using Spectral Information.

²⁰ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

²¹ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

tecnologías de clasificación más confiables²². Sin embargo, la mayoría de estas metodologías requieren laboratorios especializados, lo que limita su acceso a pequeños productores²³. Esto resalta la importancia de explorar soluciones innovadoras que trasciendan las barreras logísticas y económicas²⁴.

Además, la digitalización del sector agrícola es una tendencia global que cobra especial relevancia en Colombia, donde la agricultura sigue siendo uno de los principales motores económicos y sociales. Iniciativas de innovación tecnológica, impulsadas por universidades, centros de investigación y empresas privadas, buscan cerrar la brecha entre el conocimiento científico y las necesidades del productor²⁵. Sin embargo, gran parte de estas soluciones se concentra en cultivos de mayor escala como café, banano o palma, lo que deja al cacao con menos recursos y desarrollos tecnológicos específicos²⁶.

La creciente demanda internacional de cacao premium exige soluciones innovadoras que permitan optimizar la producción y garantizar calidad constante²⁷. La investigación científica en Colombia ha avanzado en áreas como genética, desarrollo de clones resistentes y prácticas de cultivo sostenibles, pero la integración de tecnologías emergentes en la poscosecha sigue siendo incipiente²⁸. Esto abre una ventana de oportunidad para aplicar herramientas de inteligencia artificial (IA) y visión por

²² QUINTANA FUENTES y GARCÍA JEREZ, Evaluación integral de la calidad sensorial del cacao.

²³ MUNDACA CUEVA, Análisis de la calidad del grano de cacao mediante imágenes hiperespectrales usando técnicas de visión artificial.

²⁴ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

²⁵ WANDEL MARROQUÍN, Nuevas tecnologías y agricultura 4.0: impacto en los recursos humanos de la industria agrícola en Centroamérica.

²⁶ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

²⁷ SWISSCO, Cocoa facts and figures.

²⁸ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

computadora, capaces de transformar procesos manuales en sistemas automatizados que apoyen la toma de decisiones en tiempo real²⁹.

La investigación presentada en esta tesis busca cerrar ese vacío con una solución accesible y útil en campo. Se definió un protocolo de adquisición y etiquetado alineado con la NTC 1252:2021 (Norma técnica colombiana 1252:2021) y se ajustó mediante transferencia de conocimiento un modelo YOLO para la clasificación del nivel de fermentación en granos de cacao. Se entrena el modelo con información espectral y en la práctica la clasificación se realiza sobre imágenes en color compuestas por tres canales: rojo, verde y azul (RGB). La aplicación desarrollada para sistema operativo Android realiza la inferencia directamente en el dispositivo y registra los resultados para un lote de 50 granos de cacao. Con este enfoque se reduce la dependencia de laboratorios, se agiliza la clasificación en poscosecha y se mejora la estandarización del proceso, fortaleciendo la competitividad del cacao colombiano en términos de calidad.

Adicionalmente, los resultados obtenidos en esta investigación dieron lugar a la elaboración de un artículo científico presentado en el Congreso STSIVA 2025, realizado en Armenia, Colombia y posteriormente publicado en IEEE Xplore³⁰.

²⁹ SÁNCHEZ et al., Classification of Cocoa Beans Based on their Level of Fermentation using Spectral Information.

³⁰ SUÁREZ et al., Automated Classification of Cocoa Bean Fermentation Levels Using Computer Vision.

1. PLANTEAMIENTO Y JUSTIFICACIÓN DEL PROBLEMA

La calidad del cacao está determinada principalmente por las condiciones del proceso de fermentación, etapa en la que ocurren transformaciones bioquímicas y microbiológicas esenciales para el desarrollo del sabor, el aroma y la textura característicos del chocolate. Un proceso de fermentación adecuado garantiza la eliminación de compuestos amargos y astringentes, así como la formación de precursores aromáticos que inciden directamente en la aceptación del producto en el mercado nacional e internacional³¹. En consecuencia, el grado de fermentación se ha convertido en un indicador clave de la calidad y del valor comercial del cacao, influyendo de manera decisiva en su clasificación y precio³². En Colombia, la evaluación del nivel de fermentación se rige por la NTC 1252:2021, que establece parámetros de calidad y procedimientos para la clasificación del cacao³³. De acuerdo con dicha norma, el método más utilizado para determinar el grado de fermentación es la prueba de corte con guillotina, mediante la cual se realiza una inspección visual del color y la apariencia interna del grano³⁴. Este procedimiento, aunque ampliamente aceptado, presenta limitaciones evidentes: es destructivo, consume tiempo, requiere personal capacitado y depende del juicio subjetivo del evaluador, lo que genera inconsistencias entre diferentes lotes o laboratorios³⁵. Otro aspecto crítico es que el método manual se realiza generalmente sobre una muestra reducida que no siempre representa fielmente las condiciones del lote completo³⁶. Esto es especialmente problemático cuando se trata de granos cerrados, en los que el estado de fermentación no es visible externamente³⁷. Como resultado, pueden presentarse errores de clasificación que afectan la homogeneidad del producto y ocasionan pérdidas

³¹ LALIBERTÉ et al., Guía para la evaluación de la calidad y el sabor del cacao.

³² QUINTANA FUENTES y GARCÍA JEREZ, Evaluación integral de la calidad sensorial del cacao.

³³ COLOMBIAMIDE, Nuevas normas o estándares disponibles para las cadenas de cacao y aguacate Hass.

³⁴ BIOVERSITY INTERNATIONAL, Protocolo B: Análisis externo y prueba de corte de granos de cacao.

³⁵ REGALADO, ¿Qué es la prueba de corte del cacao y cuándo puede ser útil?

³⁶ BIOVERSITY INTERNATIONAL, Protocolo B: Análisis externo y prueba de corte de granos de cacao.

³⁷ REGALADO, ¿Qué es la prueba de corte del cacao y cuándo puede ser útil?

económicas tanto para productores como para compradores³⁸. Estas limitaciones ponen de manifiesto la necesidad de desarrollar métodos de evaluación no destructivos, objetivos y estandarizados que permitan determinar el nivel de fermentación de manera precisa y reproducible³⁹. En este contexto, las técnicas de visión por computadora y el análisis de imágenes espectrales surgen como herramientas prometedoras⁴⁰. Estas técnicas permiten capturar información asociada a propiedades físicas y químicas del grano, como contenido de humedad, estructura interna y variaciones de pigmentos invisibles al ojo humano, que están directamente relacionadas con su grado de fermentación⁴¹.

Sin embargo, la aplicación práctica de estas tecnologías enfrenta un obstáculo importante: los equipos hiperespectrales necesarios para capturar este tipo de información son costosos y requieren condiciones controladas de operación, lo que limita su uso a entornos de laboratorio o investigación⁴². Esto contrasta con la realidad de la producción cacaotera colombiana, compuesta en su mayoría por pequeños y medianos productores que carecen de infraestructura tecnológica avanzada⁴³. Ante este panorama, se plantea un enfoque alternativo que combine la precisión de los métodos espectrales con la accesibilidad de las imágenes RGB convencionales⁴⁴. La propuesta consiste en emplear imágenes hiperespectrales durante la fase de entrenamiento de modelos de inteligencia artificial, con el objetivo de que el modelo aprenda las relaciones entre las

³⁸ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

³⁹ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

⁴⁰ ITCL, Tecnología de imagen hiperespectral en la industria alimentaria.

⁴¹ NGUYEN et al., A method for non-destructive determination of cocoa bean fermentation levels based on terahertz hyperspectral imaging.

⁴² BAYONA et al., Cocoa bean quality assessment using closed range hyperspectral images.

⁴³ ABBOTT et al., Análisis de la cadena productiva de cacao en Colombia.

⁴⁴ OMAS-AS et al., Machine Learning as a Strategic Tool: A Comprehensive Literature Review for Advancing Agricultural Analysis, with Emphasis on the Cocoa Bean Quality Assessment.

características espectrales y las visuales del cacao⁴⁵. Posteriormente, el sistema podrá realizar la clasificación del nivel de fermentación usando únicamente imágenes RGB capturadas con cámaras comunes o dispositivos móviles. Este esquema de transferencia de conocimiento entre dominios, del espectral al visible, permite desarrollar una herramienta práctica y de bajo costo, capaz de operar fuera del laboratorio, con potencial de implementación en campo⁴⁶. La relevancia de esta investigación radica en varios niveles. En primer lugar, tecnológicamente introduce un método de clasificación basado en aprendizaje profundo y visión por computadora que automatiza y estandariza un proceso tradicionalmente manual⁴⁷. En segundo lugar, económicamente contribuye a mejorar la eficiencia en la cadena de valor del cacao al reducir los tiempos de inspección y minimizar errores humanos que pueden afectar el precio de venta⁴⁸. En tercer lugar, socialmente democratiza el acceso a la tecnología, brindando a los pequeños productores una herramienta accesible que les permite garantizar la calidad de su producto sin depender de equipos de laboratorio⁴⁹. Además, el desarrollo de un sistema de clasificación no destructivo tiene implicaciones directas en la sostenibilidad y la trazabilidad de la producción cacaotera⁵⁰. Al reducir el desperdicio de muestras y permitir evaluaciones más frecuentes y precisas, se promueve una gestión más eficiente del recurso y se fortalecen los procesos de certificación de calidad⁵¹. Estos elementos son clave para la competitividad del cacao colombiano en mercados especializados⁵². Este estudio aporta al campo de la agricultura de precisión y al uso de inteligencia artificial en la agroindustria, demostrando la viabilidad de combinar datos espectrales y RGB para

⁴⁵ NGUYEN et al., A method for non-destructive determination of cocoa bean fermentation levels based on terahertz hyperspectral imaging.

⁴⁶ ITCL, Tecnología de imagen hiperespectral en la industria alimentaria.

⁴⁷ OMAS-AS et al., Machine Learning as a Strategic Tool: A Comprehensive Literature Review for Advancing Agricultural Analysis, with Emphasis on the Cocoa Bean Quality Assessment.

⁴⁸ GARCÍA-CÁCERES et al., Characterization of the supply and value chains of Colombian cocoa.

⁴⁹ CAVIEDES RUBIO et al., Impactos ecológicos, económicos y sociales del sector cacaotero colombiano.

⁵⁰ BIOVERSITY INTERNATIONAL, Protocolo B: Análisis externo y prueba de corte de granos de cacao.

⁵¹ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

⁵² SWISSCO, Cocoa facts and figures.

resolver problemas complejos de clasificación visual⁵³. La metodología propuesta es replicable y escalable, lo que abre la posibilidad de adaptarla a otros productos agrícolas que requieren inspección visual para determinar su calidad. No obstante, la revisión del estado del arte evidencia que, aunque se han reportado aplicaciones de visión por computadora e imágenes hiperespectrales para la caracterización de distintos productos agrícolas, no se encontraron trabajos que utilicen información espectral de granos secos de cacao para el entrenamiento de modelos de inteligencia artificial y que, a partir de ello, implementen un sistema automático basado únicamente en imágenes RGB capturadas con dispositivos móviles para clasificar su nivel de fermentación. Esta ausencia de sistemas automáticos que combinen explícitamente dominios espectrales y visibles en una solución portátil y de bajo costo pone de relieve el carácter novedoso de la propuesta y la necesidad de avanzar hacia herramientas que acerquen estas tecnologías al uso cotidiano de productores y evaluadores. En síntesis, este trabajo busca responder a la siguiente pregunta de investigación: ¿Cómo desarrollar un sistema automático basado en imágenes espectrales e inteligencia artificial que permita clasificar el nivel de fermentación de granos secos de cacao, tanto abiertos como cerrados, que pueda ser implementado en dispositivos móviles para apoyar a los productores y evaluadores en la mejora de la eficiencia, la trazabilidad y la competitividad del sector cacaotero colombiano?

⁵³ CONTRERAS et al., A Multimodal Hyperspectral Dataset of Cocoa Beans with Physicochemical Annotation.

2. OBJETIVOS

2.1 OBJETIVO GENERAL

Desarrollar un sistema de visión por computadora para la clasificación de granos secos de cacao abiertos y cerrados según su nivel de fermentación mediante imágenes espectrales e imágenes RGB usando aprendizaje profundo.

2.2 OBJETIVOS ESPECÍFICOS

1. Construir y recopilar una base de datos de imágenes espectrales y RGB de granos secos de cacao abiertos y cerrados, etiquetadas según su nivel de fermentación (bien fermentado, mal fermentado, parcialmente fermentado).
2. Implementar y entrenar una arquitectura de visión por computadora basada en aprendizaje profundo para identificar el nivel de fermentación de los granos de cacao a partir de imágenes espectrales y de imágenes RGB.
3. Implementar y validar el sistema de clasificación de granos secos de cacao en una herramienta de visualización en dispositivos móviles que brinde resultados a partir de solo datos RGB.

3. MARCO CONCEPTUAL

3.1 GRANO DE CACAO

El cacao es una especie tropical cuyo grano constituye la base para la elaboración de chocolate y otros derivados. Cada mazorca contiene entre 30 y 50 granos cubiertos por una pulpa rica en azúcares, los cuales, tras los procesos de fermentación y secado, adquieren las propiedades que determinan su calidad final⁵⁴. Durante la fermentación se producen transformaciones bioquímicas que influyen en el color, aroma y sabor del grano. La acción de microorganismos como levaduras y bacterias provoca la degradación de los azúcares, favoreciendo el desarrollo de compuestos precursores del sabor característico del chocolate⁵⁵. Una fermentación deficiente genera granos con notas amargas o astringentes, mientras que un proceso controlado mejora el aroma y la aceptabilidad comercial⁵⁶. El grano seco se clasifica visualmente según su coloración interna, estructura y grado de apertura⁵⁷. De acuerdo con la Norma Técnica Colombiana NTC 1252:2021, esta norma fue empleada como referencia para la creación del conjunto de datos y la definición de las categorías de clasificación en este proyecto⁵⁸. Los granos pueden ser:

- Bien fermentados: presentan color marrón uniforme y estructura interna suelta.
- Parcialmente fermentados: muestran mezcla de tonos marrones y púrpuras, con textura compacta.
- Mal fermentados: poseen color violeta oscuro o pizarroso y estructura dura, indicativa de una fermentación incompleta.

⁵⁴ QUINTANA FUENTES y GARCÍA JEREZ, Evaluación integral de la calidad sensorial del cacao.

⁵⁵ GONZÁLEZ ORJUELA, Revisión de métodos para la fermentación de cacao.

⁵⁶ RUIZ ESPITIA, Análisis de la calidad del grano de cacao modelo araucano.

⁵⁷ BIOVERSITY INTERNATIONAL, Protocolo B: Análisis externo y prueba de corte de granos de cacao.

⁵⁸ COLOMBIAMIDE, Nuevas normas o estándares disponibles para las cadenas de cacao y aguacate Hass.

Los granos de cacao se clasifican en tres categorías según su nivel de fermentación (bien fermentado, parcialmente fermentado y mal fermentado). En la Figura 1, los granos en A y B son considerados buenos, ya que presentan un color marrón uniforme y una estructura interna bien definida; los granos en C son malos, pues su tonalidad morado oscuro sugiere una fermentación incompleta o deficiente; y los granos en D son parciales, ya que muestran una fermentación irregular con zonas bien procesadas y otras con tonos morados, lo que puede comprometer la calidad final del producto.

Figura 1. Calidad de granos de cacao secos.



Fuente: elaboración propia con base en Bioversity International (2020). A y B: buenos (marrón uniforme); C: malos (morado oscuro, fermentación incompleta); D: parciales (fermentación irregular).

3.2 IMÁGENES ESPECTRALES

Las imágenes espectrales registran la intensidad de la radiación electromagnética en múltiples longitudes de onda, abarcando el espectro visible y regiones del infrarrojo o ultravioleta⁵⁹. A diferencia de las imágenes RGB, que se limitan a tres canales (rojo, verde y azul), las imágenes espectrales pueden contener decenas o incluso cientos de bandas, lo que permite analizar con mayor precisión las propiedades físicas y químicas de los materiales⁶⁰. Cada píxel de una imagen espectral representa un vector de valores que describe la respuesta espectral del objeto a lo largo de diferentes longitudes de onda⁶¹. Como se ilustra en la Figura 2, esta información permite identificar variaciones sutiles en composición, textura o humedad que no son perceptibles en imágenes RGB convencionales. Por esta razón, las imágenes espectrales son ampliamente utilizadas en aplicaciones como agricultura de precisión, control de calidad y teledetección⁶².

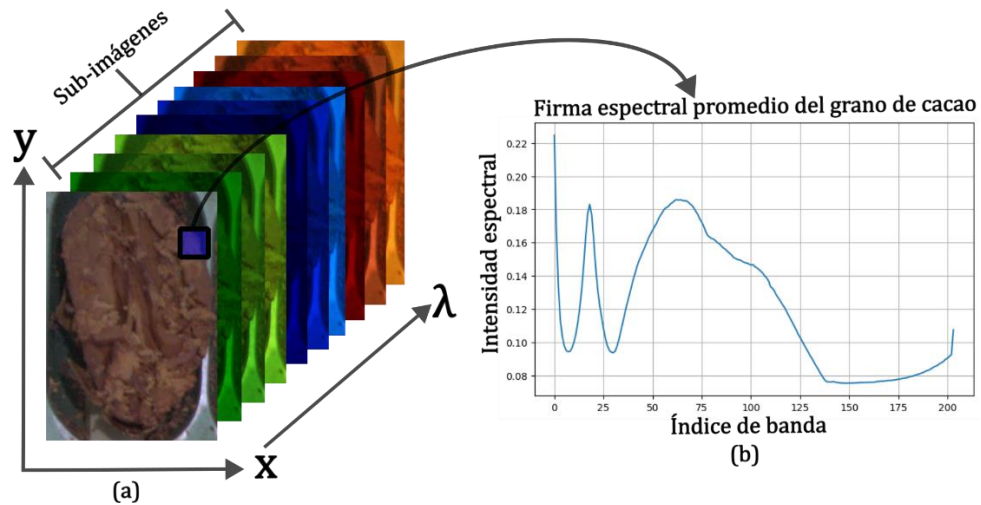
⁵⁹ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

⁶⁰ ITCL, Tecnología de imagen hiperespectral en la industria alimentaria.

⁶¹ MUNDACA CUEVA, Análisis de la calidad del grano de cacao mediante imágenes hiperespectrales usando técnicas de visión artificial.

⁶² CETINA CÁCERES, Generación de curvas espectrales.

Figura 2. Cubo hiperespectral y firma espectral.



Fuente: elaboración propia con base en Wieme et al. (2022). (a) Representación tridimensional de un cubo hiperespectral compuesto por múltiples bandas en diferentes longitudes de onda; (b) firma espectral correspondiente a un píxel específico.

Debido a la alta dimensionalidad de los cubos espectrales, su visualización directa resulta compleja. Para representar estos datos en formato RGB, se emplean técnicas de reducción de dimensionalidad, siendo el Análisis de Componentes Principales (PCA, por sus siglas en inglés) una de las más comunes⁶³. Este método transforma las bandas originales en componentes ortogonales que concentran la mayor parte de la información en las primeras dimensiones. Al asignar las tres primeras componentes principales a los canales rojo, verde y azul, se obtiene una representación pseudo-RGB que conserva las características espectrales más relevantes⁶⁴.

En este proyecto, el PCA se utilizó para convertir los cubos hiperespectrales de los granos de cacao en imágenes RGB representativas, facilitando su análisis visual y su uso en el entrenamiento de modelos de aprendizaje profundo.

⁶³ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

⁶⁴ ITCL, Tecnología de imagen hiperespectral en la industria alimentaria.

3.3 LENGUAJE DE PROGRAMACIÓN PYTHON

Python es un lenguaje de programación de alto nivel, claro y fácil de usar, ampliamente empleado en visión por computadora y aprendizaje profundo gracias a su sintaxis simple y a un ecosistema maduro que permite un prototipado rápido⁶⁵. Su entorno científico incluye librerías clave como NumPy y pandas, utilizadas para el manejo eficiente de arreglos y datos tabulares, lo que facilita el preprocesamiento y análisis de información. El entrenamiento y la inferencia del modelo se realizan mediante PyTorch, una biblioteca de aprendizaje profundo basada en tensores con aceleración por GPU y una API dinámica que simplifica la depuración y experimentación durante el desarrollo. Asimismo, la familia de modelos YOLO cuenta con implementaciones en Python, como Ultralytics, que integran en un mismo flujo de trabajo las etapas de entrenamiento, validación y exportación de modelos, optimizando el proceso de desarrollo en aplicaciones de visión por computadora

3.4 MODELO DE DETECCIÓN YOLO

You Only Look Once (YOLO) es una arquitectura de detección de objetos en tiempo real basada en redes neuronales convolucionales profundas (CNN), diseñada para realizar simultáneamente la localización y clasificación de objetos dentro de una imagen. A diferencia de los métodos tradicionales de detección por etapas, como R-CNN o Faster R-CNN, YOLO procesa la imagen completa en una única pasada hacia adelante (forward pass), lo que le permite alcanzar altas velocidades de inferencia manteniendo un buen nivel de precisión. La arquitectura de YOLO divide la imagen de entrada en una cuadrícula. Cada celda de la cuadrícula es responsable de predecir uno o varios cuadros delimitadores (bounding boxes), junto con una puntuación de confianza y las probabilidades asociadas a cada clase⁶⁶. Cada cuadro delimitador se representa

⁶⁵ PYTHON SOFTWARE FOUNDATION, Python Documentation.

⁶⁶ REDMON et al., You Only Look Once: Unified, Real-Time Object Detection, p. 780.

mediante las coordenadas del centro (x, y) , el ancho w y la altura h . La puntuación de confianza indica la probabilidad de que exista un objeto dentro de la región predicha y qué tan precisa es la localización del cuadro respecto al objeto real. La arquitectura está compuesta principalmente por tres bloques: backbone, neck y head. El backbone se encarga de extraer características espaciales relevantes de la imagen mediante capas convolucionales profundas. Posteriormente, el neck combina información de diferentes escalas para mejorar la detección de objetos pequeños y grandes. Finalmente, el head genera las predicciones finales correspondientes a la localización de los objetos, la confianza y las probabilidades de clasificación. En este trabajo se emplean modelos YOLO para procesar imágenes de granos de cacao y predecir su categoría según el nivel de fermentación (Arboleda, 2024). Durante el entrenamiento se optimiza una función de pérdida total compuesta por tres términos: pérdida de localización (L_{loc}), pérdida de confianza (L_{conf}) y pérdida de clasificación (L_{cls}); la combinación de estos componentes permite equilibrar precisión y velocidad en escenarios de control de calidad con visión por computadora.

3.4.1 Función objetivo del modelo YOLO. Matemáticamente, cada celda i predice B cuadros delimitadores (bounding boxes) y para cada uno de ellos se calcula un puntaje de confianza mediante la siguiente ecuación:

$$Confidence_i = Pr(Object_i) \cdot IoU_{pred,i}^{truth} \quad (1)$$

Donde $Pr(Object_i)$ representa la probabilidad de que exista un objeto en la celda i y $IoU_{pred,i}^{truth}$ corresponde a la intersección sobre unión (Intersection over Union) entre el cuadro predicho y el cuadro real.

Además, YOLO predice las probabilidades condicionales por clase $Pr(Class_c|Object_i)$ para cada clase c . De este modo, el puntaje final específico por clase se calcula como:

$$Score_{i,c} = Pr(Class_c|Object_i) \cdot Confidence_i \quad (2)$$

Donde $\Pr(Class_c|Object_i)$ indica la probabilidad condicional de que el objeto detectado en la celda i pertenezca a la clase c . Esta formulación permite que YOLO detecte y clasifique múltiples objetos en una sola pasada hacia adelante (forward pass), optimizando la eficiencia del modelo en aplicaciones en tiempo real.

3.4.2 Componentes de la función de pérdida YOLO. La función de pérdida total de YOLO se compone de tres términos principales que permiten entrenar simultáneamente la detección y clasificación de objetos en una única red neuronal. Esta formulación integra la localización espacial de los objetos, la estimación de la confianza de las detecciones y la asignación de categorías. La descomposición de la pérdida en diferentes componentes facilita regular la contribución de cada objetivo y mejorar la estabilidad del aprendizaje. A continuación, se presentan las expresiones matemáticas asociadas a cada componente de la función de pérdida utilizada para ajustar los parámetros del modelo.

3.4.2.1 Pérdida de localización. La pérdida de localización cuantifica la precisión con la que las cajas delimitadoras predichas se ajustan a las cajas reales. Evalúa el error en las coordenadas del centro (x, y) y en las dimensiones (w, h) de cada cuadro. Se define como:

$$L_{loc} = \lambda_{coord} \sum_{t=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{tj}^{obj} [(x_t - \hat{x}_t)^2 + (y_t - \hat{y}_t)^2] \\ + \lambda_{coord} \sum_{t=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{tj}^{obj} \left[(\sqrt{w_t} - \sqrt{\hat{w}_t})^2 + (\sqrt{h_t} - \sqrt{\hat{h}_t})^2 \right]$$

donde λ_{coord} es un factor de ponderación que enfatiza la precisión de la localización y $\mathbb{1}_{tj}^{obj}$ es una función indicadora que vale 1 si existe un objeto en la celda y cuadro correspondiente y 0 en caso contrario.

3.4.2.2 Pérdida de confianza. La pérdida de confianza mide el grado de certeza del modelo respecto a la presencia o ausencia de un objeto en una celda y cuadro determinados. Penaliza tanto las falsas detecciones como las omisiones. Su expresión es:

$$L_{conf} = \sum_{t=0}^{S^2} \sum_{j=0}^B I_{tj}^{obj} (C_t - \hat{C}_t)^2 + \lambda_{noobj} \sum_{t=0}^{S^2} \sum_{j=0}^B I_{tj}^{noobj} (C_t - \hat{C}_t)^2$$

donde C_t representa la puntuación de confianza predicha, \hat{C}_t la puntuación real y λ_{noobj} reduce el impacto de las celdas donde no se detecta ningún objeto.

3.4.2.3 Pérdida de clasificación. La pérdida de clasificación evalúa la diferencia entre las probabilidades de clase predichas y las etiquetas reales, considerando únicamente las celdas que contienen objetos. Se calcula mediante:

$$L_{cls} = \sum_{t=0}^{S^2} I_t^{obj} \sum_{c \in \text{classes}} (p_{t(c)} - \hat{p}_{t(c)})^2$$

donde $p_{t(c)}$ y $\hat{p}_{t(c)}$ corresponden a las probabilidades de clase predichas y verdaderas, respectivamente, para la clase c en la celda t .

3.4.2.4 Función de pérdida total. La función de pérdida total L_{total} se define como la suma de los tres componentes anteriores:

$$L_{total} = L_{loc} + L_{conf} + L_{cls}$$


Esta formulación compuesta permite a YOLO optimizar simultáneamente la localización de objetos, la estimación de confianza y la clasificación, logrando un equilibrio entre precisión y velocidad durante el entrenamiento.

3.5 PLATAFORMA DE ETIQUETADO MANUAL CVAT

El Computer Vision Annotation Tool (CVAT) es una herramienta de anotación desarrollada por Intel para la creación de datasets en proyectos de visión por computadora. Se trata de una plataforma web que permite realizar el etiquetado manual o semiautomático de imágenes y videos, ofreciendo soporte para distintos formatos de salida, entre ellos el formato YOLO, ampliamente utilizado en el entrenamiento de modelos de detección de objetos⁶⁷. En este proyecto, CVAT se utilizó para etiquetar manualmente los granos de cacao, delimitando cada grano individual dentro de las imágenes capturadas y asignándole una clase según su nivel de fermentación conforme a la norma NTC 1252:2021, con tres categorías principales: bien fermentado, parcialmente fermentado y mal fermentado, como se muestra en la Figura 3. El proceso de etiquetado fue realizado manualmente por los autores del proyecto utilizando la plataforma CVAT. Previamente, expertos agricultores y evaluadores de calidad de cacao brindaron acompañamiento en la clasificación de las muestras, indicando la categoría correspondiente de cada grano de acuerdo con los criterios establecidos por la norma técnica. Las anotaciones se exportaron en formato YOLO y posteriormente se revisaron manualmente como parte del control de calidad, garantizando la consistencia y compatibilidad de los datos utilizados durante el entrenamiento y evaluación del sistema de clasificación automática.

⁶⁷ CVAT.AI, CVAT Documentation.

Figura 3. Etiquetado por clases de granos de cacao.



Fuente: elaboración propia. Ejemplo de etiquetado por clases donde se observan las tres categorías definidas según el nivel de fermentación: malo (rojo), parcial (azul) y bueno (verde).

3.6 ENTORNO DE DESARROLLO DE APK: ANDROID STUDIO

Android Studio es el entorno de desarrollo integrado (IDE) oficial para crear aplicaciones en Android. Es una herramienta gratuita, compatible con Windows, macOS y Linux, basada en IntelliJ IDEA⁶⁸. Incluye emulador, depuración en tiempo real, perfiladores y el sistema de compilación Gradle para generar archivos APK o AAB. Se eligió por facilitar la integración de bibliotecas de inteligencia artificial, como PyTorch Mobile y TensorFlow Lite, permitiendo la ejecución del modelo sin conexión a internet. El proyecto se desarrolló en Kotlin, utilizando un minSdk compatible y un targetSdk vigente. Las dependencias de captura de imágenes, preprocesamiento e inferencia se gestionaron mediante Gradle y el modelo entrenado se empaquetó en la carpeta assets junto con etiquetas y parámetros de normalización para su ejecución offline.

El flujo de la aplicación consiste en cargar una imagen, realizar su preprocesamiento, ejecutar la inferencia en el dispositivo y mostrar la clasificación de cada grano de cacao en las categorías definidas.

⁶⁸ ANDROID DEVELOPERS. Android Studio Overview. 2025.

4. METODOLOGÍA PROPUESTA

La metodología propuesta para este trabajo de grado se basa en el desarrollo de un sistema de visión por computadora capaz de clasificar el nivel de fermentación del grano de cacao mediante un modelo de aprendizaje profundo entrenado con imágenes hiperespectrales y RGB. El proceso metodológico se dividió en etapas secuenciales que garantizan la trazabilidad, reproducibilidad y validación de los resultados obtenidos, definidas a partir de los objetivos del proyecto.

- Etapa 1: Adquisición y conformación de la base de datos de imágenes espectrales y RGB.
- Etapa 2: Entrenamiento y validación del modelo de clasificación basado en aprendizaje profundo.
- Etapa 3: Implementación del modelo en una aplicación móvil para inferencia en campo.

Cada etapa se desarrolla de forma independiente, pero mantiene coherencia en los parámetros de captura, etiquetado, preprocesamiento y evaluación.

4.1 ETAPA 1

El conjunto de datos empleado en este trabajo se construyó a partir de la integración de información visual y espectral de granos de cacao recolectados en diferentes etapas del proceso de fermentación. La construcción del conjunto de datos se fundamentó en los lineamientos de la Norma Técnica Colombiana NTC 1252:2021, la cual define los parámetros de clasificación del cacao según su nivel de fermentación en tres categorías principales: bien fermentado, parcialmente fermentado y mal fermentado. El propósito de la recopilación de estos datos fue generar una base sólida para el desarrollo de modelos de aprendizaje profundo capaces de estimar de forma no destructiva el grado de fermentación a partir de imágenes RGB, aprovechando información del dominio espectral durante la fase de entrenamiento. De esta manera, se busca establecer un puente entre

la evaluación tradicional basada en la prueba de corte y un enfoque moderno sustentado en visión por computadora e inteligencia artificial. Las muestras fueron recolectadas en una finca de cacao ubicada en el municipio de El Carmen de Chucurí, departamento de Santander (Colombia), zona reconocida por su alta producción y calidad del grano. Se emplearon tres variedades de cacao de interés comercial: CCN-51, ICS-95 y TCS-01.

En la Figura 4 se presentan muestras representativas de los granos de cacao recolectados en la finca utilizada durante la fase de adquisición de datos.

Figura 4. Muestras de granos de cacao recolectadas.



Fuente: elaboración propia. Granos recolectados en El Carmen de Chucurí, Santander, durante la fase de adquisición de datos. La imagen corresponde a un lote representativo dentro del conjunto total de muestras recolectadas.

El proceso de poscosecha del cacao se llevó a cabo en cajas de madera cubiertas con hojas de plátano, replicando las condiciones tradicionales de los pequeños productores; el flujo completo se muestra en la Figura 5, donde se ilustran las etapas de cosecha, extracción de las semillas, fermentación y secado. Cada lote fue fermentado entre cinco

y siete días, con mezclas diarias para favorecer la aireación. Posteriormente, los granos se secaron al sol hasta alcanzar un contenido de humedad inferior al 10 % (NTC 1252:2021). Las muestras fueron clasificadas visualmente por agricultores con más de 15 años de experiencia en procesos de fermentación y evaluación de calidad del cacao, considerando características como color, textura interna y olor, de acuerdo con los criterios establecidos en la NTC 1252:2021.

Figura 5. Proceso de poscosecha del cacao.



Fuente: Contreras et al. (2025). Proceso de poscosecha de las mazorcas de cacao que incluye cosecha, extracción de semillas, fermentación y secado.


4.1.1 Captura y modalidades de imagen. Las imágenes fueron adquiridas bajo condiciones controladas de iluminación en una cabina diseñada para minimizar las variaciones de luz ambiental. Se emplearon fuentes LED de espectro neutro, difusores homogéneos y fondo no reflectante de color gris neutro. Los granos se dispusieron sobre bandejas uniformes y fueron fotografiados a una distancia constante de la cámara, con el objetivo de garantizar consistencia entre las tomas. Se utilizaron cuatro cámaras con diferentes capacidades espectrales, cada una destinada a capturar una modalidad específica de información:

- Canon EOS M50: cámara RGB de alta resolución (6000 × 4000 píxeles) con sensor CMOS APS-C, empleada para la captura de imágenes visibles.
- Toucan Multispectral: cámara de tipo snapshot con 10 bandas espectrales distribuidas entre 420 y 870 nm.
- Ultris SR5 (Cubert): cámara hiperespectral snapshot con 51 bandas entre 450 y 850 nm, utilizada para capturas rápidas sin necesidad de escaneo.

- Specim IQ: cámara hiperspectral de tipo push-broom, con 204 bandas distribuidas entre 350 y 1000 nm y resolución espacial de 512 × 512 píxeles.

Cada lote de cacao fue fotografiado en dos condiciones distintas: con los granos cerrados (vista externa) y con los granos abiertos mediante corte longitudinal usando una guillotina cortadora para granos de cacao, lo cual permitió observar el interior y correlacionar el estado visual con los parámetros fisicoquímicos. El dispositivo empleado para la prueba de corte se presenta en la Figura 6. En total, se obtuvieron 19 escenas, cada una compuesta por 50 granos, las cuales fueron organizadas por fecha y lote, lo que equivale a más de 900 granos por modalidad de captura, individualmente registrados y etiquetados. La distribución de las categorías no se estableció mediante un muestreo balanceado, sino que correspondió a la variabilidad observada en las muestras reales recolectadas en campo.

Figura 6. Guillotina para prueba de corte de cacao.



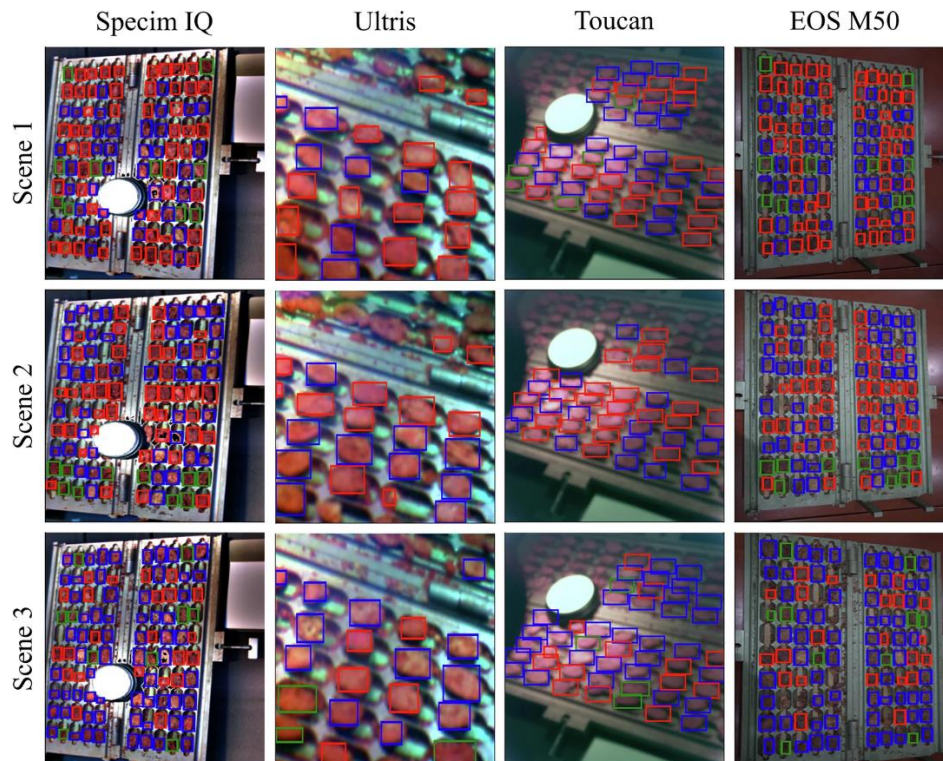
Fuente: elaboración propia. Dispositivo de corte utilizado para exponer el interior del grano durante la evaluación del nivel de fermentación.

La adquisición de datos se realizó bajo condiciones controladas y siguiendo un protocolo estandarizado de captura y etiquetado de las muestras.

- Condiciones de captura: Las muestras se fotografiaron en una cabina de iluminación controlada, con fondo neutro y fuente de luz uniforme, garantizando condiciones constantes para todas las imágenes.
- Muestras: Se recolectaron granos de cacao en diferentes etapas de fermentación, obtenidos de distintos lotes y orígenes.
- Etiquetado: Cada grano fue clasificado por expertos certificados, con más de 20 años de experiencia en calidad de cacao, siguiendo los criterios de la Norma Técnica Colombiana NTC 1252:2021, que define tres categorías principales: cacao bien fermentado, parcialmente fermentado y mal fermentado.

En la Figura 7 se muestra un ejemplo visual del proceso de anotación. La imagen de la izquierda corresponde a las muestras originales sin etiquetas, mientras que la de la derecha presenta las anotaciones manuales realizadas, donde los recuadros de colores representan las distintas clases: verde para Bien fermentado, azul para Parcialmente fermentado y rojo para Mal fermentado.

Figura 7. Ejemplos del conjunto de datos y anotaciones.



Fuente: elaboración propia. Muestras representativas del conjunto de datos con cajas delimitadoras y clases asignadas para cada grano de cacao. Las cajas de color verde corresponden a granos bien fermentados, las de color azul a granos parcialmente fermentados y las de color rojo a granos mal fermentados.

4.1.2 Preprocesamiento y organización del conjunto. Antes del entrenamiento, todas las imágenes fueron sometidas a una serie de procesos de normalización y limpieza de datos:

- Corrección radiométrica: compensación de campo oscuro y campo plano para cada banda.
- Normalización de imágenes: procesamiento aplicado para mantener consistencia visual entre las muestras capturadas bajo distintas condiciones de iluminación.
- Segmentación de regiones de interés: recorte individual de cada grano para aislar las muestras dentro de la imagen.

- Aumento de datos: rotación, volteo, traslación y ajuste de brillo para incrementar la variabilidad del conjunto y mejorar la generalización del modelo.

4.1.3 Transformación de datos hiperespectrales a representación RGB mediante PCA. Adicionalmente, para el procesamiento de los datos hiperespectrales se aplicó una técnica de reducción de dimensionalidad basada en Análisis de Componentes Principales (PCA), con el objetivo de generar representaciones compatibles con modelos de visión por computadora. Cada cubo hiperespectral con dimensiones $h \times w \times b$ fue reorganizado en una matriz bidimensional de tamaño $(h \cdot w) \times b$, donde cada fila representa un píxel y cada columna una banda espectral. Posteriormente, los datos fueron normalizados mediante un escalado Min-Max para llevar los valores al rango $[0, 1]$, evitando sesgos debido a diferencias de escala entre las bandas. Se aplicó PCA seleccionando las tres primeras componentes principales ($n = 3$), las cuales concentran la mayor varianza del conjunto de datos. Estas componentes fueron reorganizadas nuevamente a la forma espacial original, generando una imagen de dimensiones $h \times w \times 3$.

Finalmente, las componentes obtenidas se normalizaron al rango $[0, 1]$ y se interpretaron como una representación RGB, donde cada componente principal corresponde a un canal de color (rojo, verde y azul). Esta transformación permitió utilizar modelos de visión por computadora diseñados para imágenes RGB convencionales, manteniendo la información espectral relevante.

4.1.4 División del conjunto de datos. Finalmente, el conjunto total fue dividido en tres subconjuntos de acuerdo con las prácticas estándar en aprendizaje profundo:

- 70 % Conjunto de entrenamiento
- 15 % Conjunto de validación
- 15 % Conjunto de prueba

Cada subconjunto fue conformado manteniendo representatividad de las diferentes variedades y condiciones presentes en las muestras recolectadas. Este enfoque permitió evaluar la capacidad de generalización del modelo propuesto bajo escenarios reales de variabilidad. El conjunto de datos empleado constituye una de las primeras bases de información multimodal orientadas al análisis de cacao colombiano. La integración de imágenes RGB, multiespectrales e hiperespectrales, ofrece una herramienta de alto valor para el desarrollo de modelos de clasificación y estimación de calidad basados en visión artificial e inteligencia artificial. Además, al combinar técnicas de laboratorio con metodologías accesibles de captura RGB, se sientan las bases para soluciones prácticas y asequibles que puedan ser implementadas directamente en campo por asociaciones de productores.

4.2 ETAPA 2

Se implementó un modelo basado en la arquitectura YOLO, adaptado mediante transferencia de conocimiento para el aprendizaje conjunto espectral–RGB.

- Las imágenes hiperespectrales se usaron para guiar la adaptación inicial del modelo al dominio espectral y posteriormente, se efectuó ajuste fino en el dominio RGB para la clasificación del nivel de fermentación.
- Se compararon variantes de YOLO y configuraciones de ajuste fino para seleccionar el mejor compromiso entre precisión y latencia.
- Las métricas de evaluación incluyeron: precisión, recall, F1-score y matriz de confusión.

4.2.1 Configuración del entrenamiento del modelo. El entrenamiento de los modelos se realizó utilizando la implementación de YOLO junto con la herramienta de monitoreo de experimentos Weights & Biases (wandb), la cual permitió registrar de manera automática los hiperparámetros, métricas y evolución del proceso de aprendizaje, garantizando la reproducibilidad de los resultados.

Los principales hiperparámetros utilizados durante el entrenamiento del modelo seleccionado se describen a continuación:

- Tamaño de imagen (*imgsz*): 640 × 640 píxeles.
- Tamaño de lote (*batch size*): 16.
- Número de épocas: 1000.
- Tasa de aprendizaje inicial (*lr0*): 0,01.
- Tasa de aprendizaje final (*lrf*): 0,01.
- Estrategia de ajuste de la tasa de aprendizaje: coseno (*cos_lr = true*).
- *Momentum*: 0,937.
- Decaimiento de pesos (*weight decay*): 0,0005.
- Épocas de calentamiento (*warmup epochs*): 3.
- Paciencia para detención temprana (*early stopping*): 80.

Adicionalmente, se aplicaron técnicas de aumento de datos para mejorar la capacidad de generalización del modelo:

- Volteo horizontal (*flip_lr*): 0,7.
- Matiz (*hsv_h*): 0,02.
- Saturación (*hsv_s*): 0,5.
- Valor (*hsv_v*): 0,3.
- *Mosaic augmentation*: 0,8.
- *MixUp*: 0,2.

Estas configuraciones permitieron entrenar un modelo robusto frente a variaciones de iluminación, orientación y condiciones de captura, lo cual es fundamental para su aplicación en entornos reales. Además, se definió un número elevado de épocas en conjunto con un criterio de detención temprana, permitiendo finalizar el entrenamiento automáticamente cuando el modelo deja de mejorar, evitando así el sobreajuste.

4.2.2 Métricas. Para evaluar el rendimiento de los modelos de detección y clasificación desarrollados, se emplearon las siguientes métricas de desempeño:

- **Precisión (Precision Score):** mide la proporción de predicciones correctas respecto al total de detecciones realizadas por el modelo.
- **Recall (Sensibilidad):** indica la capacidad del modelo para identificar correctamente todos los objetos pertenecientes a una clase determinada.
- **F1-Score:** representa el equilibrio entre la precisión y el recall, calculado como la media armónica de ambas métricas.
- **Intersección sobre Unión (Intersection over Union, IoU):** evalúa el grado de superposición entre la caja delimitadora predicha y la caja real de referencia. Esta métrica se define como:

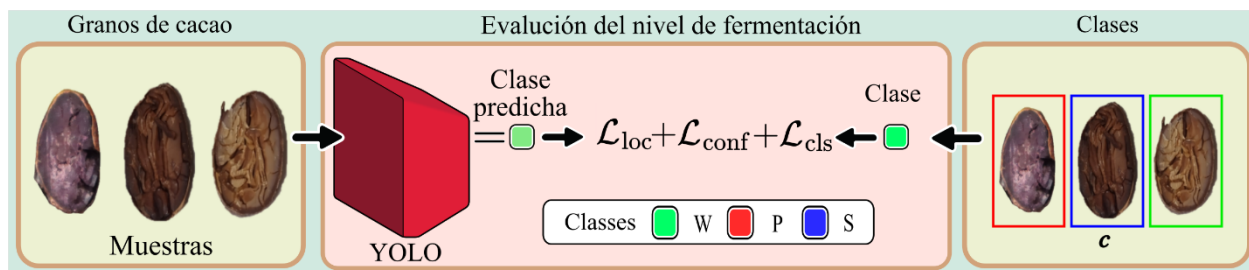
$$IoU = \frac{\text{Área}(B_{pred} \cap B_{gt})}{\text{Área}(B_{pred} \cup B_{gt})}$$

donde B_{pred} corresponde al bounding box predicho por el modelo y B_{gt} al ground truth o caja real. También se consideró el tiempo de inferencia por imagen, medido en milisegundos (ms), como indicador de la eficiencia del modelo en aplicaciones en tiempo real.

4.2.3 Proceso de inferencia del modelo. La figura 8 ilustra el flujo de inferencia del modelo basado en YOLO para la clasificación del nivel de fermentación del cacao. A partir de una imagen RGB, la red neuronal detecta los granos presentes y asigna una clase a cada uno de ellos, correspondiente a bien fermentado, parcialmente fermentado o mal fermentado.

Asimismo, se incluyen los componentes de la función de pérdida utilizados durante el entrenamiento, los cuales consideran términos de localización, confianza y clasificación, fundamentales para optimizar el desempeño del modelo.

Figura 8. Diagrama del proceso de clasificación con YOLO.




Fuente: elaboración propia. Esquema del proceso de inferencia y de los componentes de la función de pérdida para la clasificación del nivel de fermentación del cacao.

El modelo final, basado en la arquitectura YOLO e implementado en PyTorch, fue optimizado para su ejecución en una aplicación móvil, lo que permitió reducir su tamaño y mejorar el rendimiento computacional sin afectar su precisión. La aplicación permite al usuario capturar una fotografía de los granos de cacao o seleccionar una imagen directamente desde la galería del dispositivo, para posteriormente obtener una predicción inmediata del nivel de fermentación. La interfaz fue diseñada de forma sencilla e intuitiva, facilitando la visualización de los resultados. La inferencia se realiza de manera local en el dispositivo, sin requerir conexión a internet.

La validación del sistema se llevó a cabo evaluando el desempeño del modelo de clasificación de granos de cacao directamente en la aplicación móvil desarrollada en Android Studio. Para ello, se emplearon imágenes pertenecientes al conjunto de prueba del dataset, con el fin de comprobar la capacidad del modelo para generalizar bajo condiciones reales de iluminación y captura.

Las predicciones obtenidas fueron comparadas con la clasificación manual realizada por expertos en el proceso de fermentación del cacao, permitiendo medir el grado de coincidencia entre ambos métodos. Asimismo, se analizó la precisión por clase correspondiente a los niveles de fermentación: bien fermentado, parcialmente fermentado y mal fermentado.

Figura 9. Detección del modelo sobre granos de cacao.



Fuente: elaboración propia. Detección realizada por el modelo después del entrenamiento. Cada recuadro representa un grano de cacao clasificado en una de las tres categorías: bien fermentado (verde), mal fermentado (rojo) o parcialmente fermentado (azul).

Como se observa en la Figura 9, el modelo genera cajas delimitadoras y asigna una categoría de fermentación a cada grano detectado dentro de la imagen, permitiendo su clasificación automática en las tres clases definidas.

4.2.4 Configuración experimental. Los experimentos se desarrollaron en un entorno de cómputo con aceleración por GPU, utilizando el conjunto de datos previamente descrito. Las anotaciones fueron gestionadas en formato YOLO, garantizando compatibilidad directa con las arquitecturas evaluadas.

El objetivo principal fue analizar el desempeño de diferentes variantes de la familia YOLO en la tarea de detección y clasificación del nivel de fermentación del cacao, considerando métricas de precisión y eficiencia computacional.

El proceso experimental se estructuró en dos etapas: (i) entrenamiento y validación utilizando imágenes RGB convencionales y (ii) entrenamiento con imágenes espectrales transformadas mediante Análisis de Componentes Principales (PCA) a representaciones pseudo-RGB de tres canales.

Esta segunda modalidad permitió incorporar información espectral relevante en el proceso de aprendizaje, facilitando la transferencia de conocimiento desde el dominio hiperespectral hacia el dominio visible. De esta manera, se evaluó el impacto de la información espectral en el desempeño del modelo, manteniendo la posibilidad de realizar inferencia únicamente con imágenes RGB en entornos reales.

4.2.5 Resultados. En esta sección se presentan los resultados obtenidos durante el proceso de entrenamiento y evaluación de los modelos desarrollados para la detección y clasificación del nivel de fermentación en granos de cacao. Se analizaron diferentes versiones de la arquitectura YOLO empleando tanto imágenes RGB como imágenes espectrales procesadas mediante Análisis de Componentes Principales. La comparación entre modelos se realizó utilizando métricas de desempeño como IoU, precisión, recall y F1-Score, con el fin de identificar la configuración más adecuada para cada escenario experimental.

4.2.5.1 Entrenamiento con imágenes RGB. En la primera etapa se entrenaron y compararon distintos modelos de la familia YOLO utilizando exclusivamente las imágenes RGB del conjunto de datos. Todos los modelos se entrenaron con los mismos hiperparámetros para garantizar una comparación justa del desempeño. Para mantener condiciones equivalentes entre arquitecturas, se seleccionó la variante m (medium) de cada versión de YOLO, correspondiente a un tamaño intermedio del modelo que ofrece un balance entre complejidad computacional y capacidad de representación. Los resultados se muestran en el cuadro 1, donde puede observarse que, para el escenario con imágenes RGB, el modelo YOLOv8m presentó el mejor equilibrio entre precisión y tiempo de inferencia, destacándose como el más adecuado para esta tarea.

Cuadro 1. Resultados comparativos entre versiones YOLO utilizando la variante medium (modelos “m”) utilizando imágenes RGB.

Modelo	IoU@0.5	Precisión	Recall	F1-Score	Tiempo [ms]
YOLOv5m	0.8314	0.8189	0.8262	0.8225	61.42
YOLOv8m	0.9021	0.8613	0.9157	0.8880	96.32
YOLOv9m	0.8526	0.8413	0.8580	0.8496	72.18
YOLOv10m	0.8719	0.8621	0.8742	0.8681	64.33
YOLOv11m	0.8327	0.8275	0.9102	0.8987	59.74

Fuente: elaboración propia.

Posteriormente, se analizaron las variantes de la arquitectura YOLOv8 (n, s, m, l), correspondientes a las configuraciones nano, small, medium y large. La variante nano (n) se caracteriza por ser la más ligera y rápida, con un menor número de parámetros y profundidad de red, orientada a escenarios con recursos computacionales limitados. La versión small (s) incrementa moderadamente la capacidad de representación manteniendo un bajo costo computacional. Por su parte, la variante medium (m) busca un equilibrio entre precisión y complejidad, mientras que la versión large (l) presenta una arquitectura más profunda y un mayor número de parámetros, favoreciendo el desempeño predictivo a costa de mayores tiempos de procesamiento. Estas variantes

permiten evaluar distintos compromisos entre velocidad y capacidad de aprendizaje para determinar la configuración más adecuada. Los resultados (cuadro 2) confirmaron nuevamente que la versión YOLOv8m ofrecía el mejor balance entre precisión, recall y tiempo de procesamiento.

Cuadro 2. Resultados comparativos entre versiones YOLOv8 utilizando imágenes RGB.

Modelo	IoU@0.5	Precisión	Recall	F1-Score	Tiempo [ms]
YOLOv8n	0.8123	0.8054	0.8211	0.8132	41.28
YOLOv8s	0.8479	0.8326	0.8542	0.8433	63.47
YOLOv8m	0.9021	0.8613	0.9157	0.8880	96.32
YOLOv8l	0.8845	0.8718	0.8904	0.8810	82.65

Fuente: elaboración propia.

4.2.5.2 Entrenamiento con imágenes espectrales con granos abiertos.

En la segunda etapa se emplearon cubos hiperespectrales correspondientes al mismo conjunto de granos de cacao abiertos utilizado en la fase anterior. Con el objetivo de optimizar la información para el entrenamiento, los cubos fueron transformados mediante el método de PCA, obteniendo imágenes RGB sintéticas que preservaban la mayor varianza espectral posible⁶⁹. Estas imágenes reducidas se utilizaron para repetir el proceso de entrenamiento y evaluación de distintos modelos de la familia YOLO. En este escenario con imágenes espectrales reducidas por PCA, el modelo YOLOv11x, donde la variante x (extra large) corresponde a una configuración de mayor profundidad y número de parámetros orientada a maximizar la capacidad de representación del modelo, obtuvo el mejor desempeño global en las métricas evaluadas, posicionándose como la alternativa más adecuada para esta configuración (véase cuadro 3).

⁶⁹ WIEME et al., Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review.

Cuadro 3. Resultados del entrenamiento con PCA (granos abiertos).

Modelo	IoU@0.5	Precisión	Recall	F1-Score
YOLOv11x	0.9950	0.9981	1.0000	0.9990
YOLOv10x	0.9550	0.9580	0.9520	0.9550
YOLOv9x	0.9480	0.9500	0.9440	0.9470
YOLOv8x	0.9380	0.9420	0.9360	0.9390
YOLOv8m	0.9220	0.9300	0.9200	0.9250

Fuente: elaboración propia.

4.2.5.3 Entrenamiento con imágenes espectrales con granos cerrados.

Luego se procesaron los cubos hiperespectrales del mismo conjunto utilizado previamente pero ahora con granos de cacao cerrados. Con el fin de realzar la información relevante para el aprendizaje se aplicó PCA para obtener proyecciones RGB sintéticas que conservan la mayor proporción de varianza espectral. Estas proyecciones se usaron para replicar las fases de entrenamiento y validación sobre un conjunto de variantes de YOLO. Tal como se sintetiza en el cuadro 4 se compararon varios modelos sobre las imágenes espectrales transformadas. El modelo YOLOv11x alcanzó los valores más altos en todas las métricas consideradas y se consolida como la opción con mejor rendimiento en este escenario.

Cuadro 4. Resultados del entrenamiento con PCA (granos cerrados).

Modelo	IoU@0.5	Precisión	Recall	F1-Score
YOLOv11x	0.9920	0.9961	0.9800	0.9790
YOLOv10x	0.9350	0.9380	0.9320	0.9350
YOLOv9x	0.9280	0.9300	0.9240	0.9270
YOLOv8x	0.9180	0.9220	0.9160	0.9190
YOLOv8m	0.9020	0.9100	0.9020	0.9050

Fuente: elaboración propia

En ambas etapas con imágenes espectrales reducidas mediante PCA, tanto para granos abiertos como para granos cerrados el modelo YOLOv11x se destacó por su precisión y eficiencia, consolidándose como la opción más adecuada para la detección y clasificación del nivel de fermentación en este escenario. Estos resultados validan su aplicabilidad en sistemas automatizados de control de calidad y su potencial integración en herramientas móviles de evaluación en tiempo real.

Cuadro 5. Resumen comparativo de los mejores modelos por escenario experimental.

Tipo de imagen	Granos abiertos		Granos cerrados	
	RGB	Espectral (PCA)	RGB	Espectral (PCA)
Modelo	YOLOv8m	YOLOv11x	YOLOv8m	YOLOv11x
IoU@0.5	0.9021	0.9950	0.8720	0.9920
Precisión	0.8613	0.9981	0.8605	0.9961
Recall	0.9157	1.0000	0.8780	0.9880
F1-Score	0.8880	0.9990	0.8691	0.9790


Fuente: elaboración propia.

El cuadro 5 resume los mejores resultados obtenidos en cada escenario experimental, comparando el desempeño de los modelos con imágenes RGB y espectrales procesadas mediante PCA para granos de cacao abiertos y cerrados. En el caso de las imágenes RGB, el modelo YOLOv8m presentó el mejor rendimiento general, observándose una ligera disminución en las métricas para los granos cerrados. Por su parte, el uso de imágenes espectrales permitió al modelo YOLOv11x alcanzar los valores más altos en todas las métricas evaluadas. En conjunto, la tabla evidencia que la incorporación de información espectral mejora significativamente el desempeño de detección y permite apreciar de forma directa la influencia del tipo de imagen y del estado del grano en los resultados obtenidos.

4.2.5.4 Resultados del mejor modelo durante el entrenamiento con granos abiertos.

En la Figura 10 se muestran las curvas de aprendizaje correspondientes al modelo con mejor desempeño obtenido durante el entrenamiento utilizando granos de cacao abiertos a partir de imágenes espectrales procesadas mediante Análisis de Componentes Principales (PCA). Estas curvas describen la evolución de las métricas de precisión, recall e IoU@0.5 a lo largo del proceso de entrenamiento, permitiendo analizar el comportamiento de convergencia y el desempeño alcanzado en una condición en la que la estructura interna del grano es visible, lo que aporta mayor información discriminativa al modelo.

Figura 10. Curvas de aprendizaje PCA con granos abiertos.




Fuente: elaboración propia. Los valores obtenidos para recall, IoU@0.5 y precisión durante el entrenamiento con granos abiertos fueron: IoU@0.5 = 0.9950, Precisión = 0.9981, Recall = 1.0000.

- Recall: el recall llegó a 1.0000. Esto significa que el modelo encuentra todos los granos que debe detectar, sin dejar casos fuera en el conjunto de validación. En otras palabras, no hay granos reales que el sistema pase por alto. Este resultado es importante cuando se busca evitar pérdidas de información.
- IoU@0.5: El valor fue 0.9950. Indica que las cajas que dibuja el modelo casi siempre coinciden muy bien con las cajas reales, es decir, ubica los granos con gran precisión. Esto se traduce en recortes bien ajustados alrededor de cada grano, lo que reduce errores al medir o clasificar. En práctica, la localización es estable y confiable durante todo el proceso de evaluación.

- Precisión: La precisión fue 0.9981. En la práctica, casi todas las detecciones que hace el modelo son correctas y hay muy pocos falsos positivos. Esto es útil porque evita marcar como “grano objetivo” algo que no lo es, lo que ahorra tiempo y revisiones manuales. Para una aplicación en campo, significa decisiones más seguras con menos correcciones.
- F1-Score: El F1-Score alcanzó 0.9990. Este valor resume que el modelo mantiene un recall muy alto y una precisión muy alta. Cuando ambas medidas están equilibradas, el sistema es más útil y consistente en diferentes lotes y condiciones. En conjunto, estos resultados muestran un desempeño sólido para la detección y clasificación del nivel de fermentación.

Figura 11. Curvas de aprendizaje PCA con granos cerrados.



Fuente: elaboración propia. Los valores obtenidos para recall, IoU@0.5 y precisión durante el entrenamiento con granos cerrados fueron: IoU@0.5 = 0.9920, Precisión = 0.9961, Recall = 0.9800.

- Recall: el recall fue 0.9800. En términos prácticos, el modelo recupera casi todas las instancias que deberían detectarse en validación, con muy pocos casos omitidos. Esto reduce la probabilidad de pasar por alto granos presentes en la imagen.
- IoU@0.5: el IoU@0.5 alcanzó 0.9920. Esto indica que las cajas predichas se superponen casi por completo con las cajas reales, logrando una localización muy precisa de los granos. El ajuste consistente de los recortes favorece mediciones y clasificaciones más confiables a lo largo del proceso.

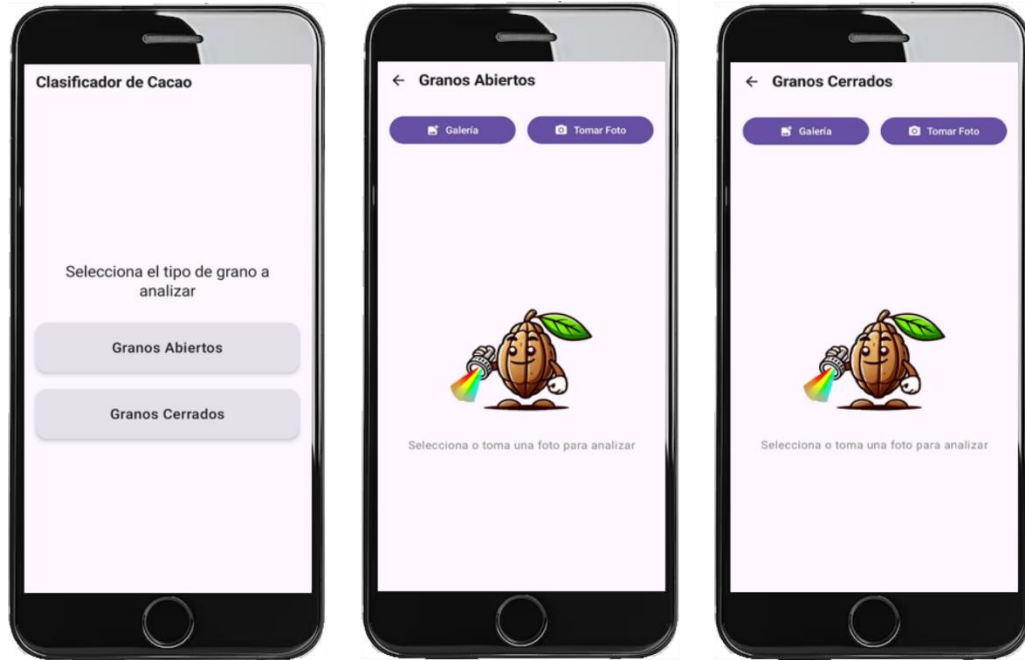
- Precisión: la precisión fue 0.9961. Es decir, la gran mayoría de las detecciones corresponden efectivamente a granos válidos, con un número mínimo de falsos positivos. En escenarios operativos, esto reduce verificaciones manuales y decisiones erróneas.
- F1-Score: el F1-Score obtuvo 0.9790. Este valor sintetiza el equilibrio entre precisión y recall alcanzado por el modelo, reflejando un comportamiento estable frente a diferentes lotes e imágenes. En conjunto, las métricas del YOLOv11x muestran un desempeño sólido para la detección y la clasificación del nivel de fermentación.

4.3 ETAPA 3

Con el fin de llevar el modelo a un entorno de uso práctico, se desarrolló una aplicación para sistema operativo Android que ejecuta la inferencia en el propio dispositivo. El flujo comienza con la selección del tipo de grano que se analizará.

La Figura 12 presenta el flujo inicial de la aplicación móvil desarrollada. En primer lugar, el usuario accede a una pantalla de selección en la que debe indicar si los granos a clasificar corresponden a la modalidad de granos abiertos o cerrados. Posteriormente, según la opción elegida, se despliega la interfaz específica de captura, desde la cual es posible tomar una fotografía directamente con la cámara del dispositivo o seleccionar una imagen almacenada en la galería. Este diseño permite adaptar el proceso de inferencia a la modalidad seleccionada, garantizando coherencia con el tipo de entrada y el modelo previamente entrenado para cada caso.

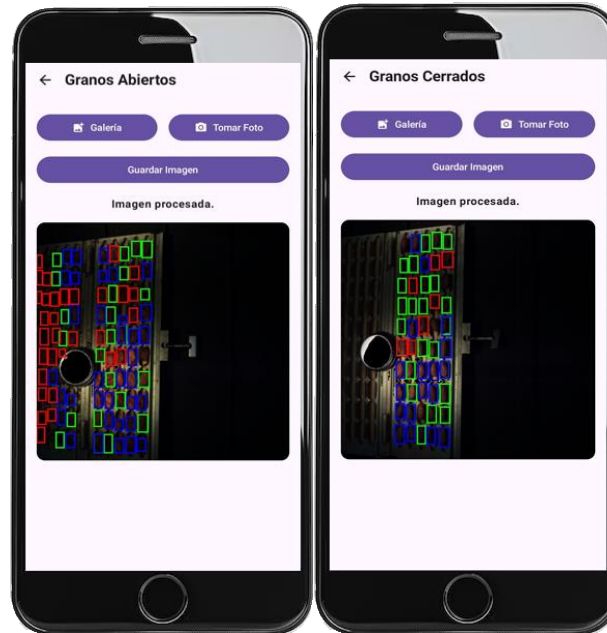
Figura 12. Pantalla de selección del tipo de grano.



Fuente: elaboración propia. Interfaz de la aplicación móvil para la selección del tipo de grano y captura o carga de imágenes.

La Figura 13 muestra el resultado del proceso de detección y clasificación de los granos de cacao. Una vez que el usuario carga o captura una imagen, la aplicación procesa automáticamente la información y genera como salida la misma imagen con las detecciones correspondientes, donde cada grano es identificado mediante un recuadro y clasificado según su nivel de fermentación. Este resultado permite visualizar de manera clara la clasificación individual de cada grano dentro de la imagen analizada, donde el color verde indica granos bien fermentados, el azul parcialmente fermentados y el rojo mal fermentados.

Figura 13. Resultado de detección y clasificación en granos.



Fuente: elaboración propia. Resultado de la detección y clasificación automática de granos de cacao en la aplicación móvil.

Igualmente, al procesar una imagen de granos cerrados se obtiene un resultado equivalente, con las detecciones y colores superpuestos (Figura 13).

En conjunto, las Figuras 12 y 13 ilustran el flujo completo del aplicativo móvil: inicialmente se presenta la interfaz para la selección y captura de la imagen y posteriormente se ejecuta la inferencia para clasificar el nivel de fermentación de cada grano presente. La implementación del modelo en el dispositivo permite realizar evaluaciones rápidas y precisas directamente en campo, sin necesidad de equipos especializados.

5. CONCLUSIONES

El desarrollo de este trabajo de grado permitió diseñar e implementar un sistema de visión por computadora basado en aprendizaje profundo capaz de determinar el nivel de fermentación del grano de cacao de forma rápida y objetiva.

A partir de la información espectral obtenida con una cámara hiperespectral, se logró entrenar un modelo que aprende la correspondencia entre los dominios espectral y visible, permitiendo aprovechar la riqueza informativa de las longitudes de onda en el rango de 400–1000 nm. Este enfoque representa un aporte innovador, ya que combina la precisión de los métodos hiperespectrales con la accesibilidad y practicidad de los sistemas RGB convencionales.

La metodología implementada, que incluyó la captura controlada de muestras, el etiquetado conforme a la NTC 1252:2021, el PCA y la optimización de un modelo YOLO, demostró resultados satisfactorios, alcanzando altos niveles de precisión en la clasificación de las tres categorías definidas: cacao bien fermentado, parcialmente fermentado y mal fermentado.

Al comparar los resultados obtenidos con granos abiertos y cerrados, se evidenció un mejor desempeño en el caso de los granos abiertos, especialmente en la métrica de recall. Este comportamiento puede atribuirse a que la visibilidad de la estructura interna del grano proporciona mayor información espectral y espacial al modelo, facilitando la discriminación entre los niveles de fermentación. En contraste, los granos cerrados constituyen una condición visual más desafiante, lo que explica la ligera disminución observada en el desempeño.

La implementación del modelo en una aplicación móvil constituye un avance significativo hacia la democratización de la tecnología de análisis de calidad del cacao, al permitir la evaluación directa en campo sin necesidad de infraestructura costosa ni conectividad permanente. Esto representa una herramienta de apoyo para los productores y

cooperativas, que podrán tomar decisiones informadas sobre la calidad del grano en las etapas iniciales del poscosecha.

En conjunto, los resultados de este trabajo contribuyen al fortalecimiento del sector cacaotero colombiano mediante la introducción de herramientas basadas en inteligencia artificial, fomentando la trazabilidad, la estandarización de la calidad y la adopción de prácticas de agricultura de precisión.

6. TRABAJO FUTURO

- Ampliación de la base de datos: Se propone recolectar un conjunto de datos más extenso y diverso que incluya distintas variedades de cacao, procedencias geográficas y condiciones de fermentación. Esta ampliación permitirá mejorar la capacidad de generalización del modelo y facilitar su aplicación a nivel nacional e internacional.
- Optimización de arquitecturas de red: Explorar arquitecturas de aprendizaje profundo más avanzadas, como Vision Transformers o modelos espectrales basados en atención, además de aplicar técnicas de transferencia de conocimiento entre los dominios espectral y visible para mejorar la eficiencia del entrenamiento.
- Evaluación en condiciones reales de campo: Realizar pruebas experimentales en ambientes no controlados, considerando factores como iluminación natural, temperatura y humedad. Estos ensayos permitirán ajustar los algoritmos de normalización y verificar la robustez del modelo en escenarios reales de producción.
- Evaluación en condiciones reales de campo: Integrar el modelo con una aplicación web o una infraestructura en la nube que permita registrar, visualizar y analizar los resultados en tiempo real. Esto facilitará la trazabilidad, la certificación de la calidad del cacao y la gestión de datos a gran escala.
- Desarrollo de una plataforma integral de monitoreo: Aplicar el enfoque espectral--RGB a otros aspectos del procesamiento del cacao, como la detección de defectos físicos, la evaluación del grado de secado o la predicción de propiedades químicas relevantes para la industria chocolatera.

En conjunto, estas líneas de trabajo futuro constituyen una base sólida para continuar el desarrollo de herramientas inteligentes orientadas al control de calidad del cacao mediante técnicas de visión por computadora y aprendizaje profundo, contribuyendo así a la innovación tecnológica y al fortalecimiento del sector agroindustrial colombiano.

BIBLIOGRAFÍA

ABBOTT, Philip C., et al. Análisis de la cadena productiva de cacao en Colombia. Cali: United States Agency for International Development (USAID), 2018. 208 p.

ANDROID DEVELOPERS. Android Studio Overview [en línea]. Mountain View, California, Estados Unidos: Google LLC, 2025. Disponible en: <https://developer.android.com/studio/intro>.

BAYONA, Oswaldo Alejandro, et al. Cocoa bean quality assessment using closed range hyperspectral images. En: 2018 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC). Honolulu, Hawái, Estados Unidos, 2018. p. 622-626. DOI: 10.23919/APSIPA.2018.8659490.

BIOVERSITY INTERNATIONAL. Protocolo B: Análisis externo y prueba de corte de granos de cacao. En: Estándares Internacionales para la Evaluación de la Calidad y el Sabor del Cacao (ISCQF). Primer borrador público. Roma: Bioversity International, 2020.

CAVIEDES RUBIO, Diego Iván; PARRA GARCÍA, Fabián Eduardo y ANDRADE VARGAS, Karla Catherine. Impactos ecológicos, económicos y sociales del sector cacaotero colombiano. En: La Granja: Revista de Ciencias de la Vida. Vol. 40, No. 2 (2024), p. 50-64. DOI: 10.17163/lgr.n40.2024.03.

CETINA CÁCERES, Nicol Andrea. Generación de curvas espectrales de vegetación, suelo y agua, a partir del análisis de imágenes multiespectrales, como herramienta indirecta de evaluación del estado del humedal “El Ocho” y Páramo de Letras. Trabajo de grado para optar al título de Ingeniera Ambiental. Manizales, Caldas: Universidad Católica de Manizales, Facultad de Ingeniería y Arquitectura, Programa de Ingeniería Ambiental, 2017.

COLOMBIAMIDE. Nuevas normas o estándares disponibles para las cadenas de cacao y aguacate Hass, aprobados por ICONTEC y gestionados por ColombiaMide [en línea]. Bogotá D.C.: Proyecto ColombiaMide, 6 ago. 2021. Disponible en: <https://colombiamide.inm.gov.co/nuevas-normas-o-estandares-disponibles-para-las-cadenas-de-cacao-y-aguacate-hass-aprobados-por-icontec-y-gestionados-por-colombiamide/>.

CONTRERAS, Kebin, et al. A Multimodal Hyperspectral Dataset of Cocoa Beans with Physicochemical Annotation. En: *Scientific Data*. Vol. 12 (2025), artículo 2043. DOI: 10.1038/s41597-025-06314-9.

CONTRERAS PEDRAZA, Carlos Alberto. Análisis de la cadena de valor del cacao en Colombia: generación de estrategias tecnológicas en operaciones de cosecha y poscosecha, organizativas, de capacidad instalada y de mercado. Tesis de maestría para optar al título de Magíster en Ingeniería – Ingeniería Agrícola. Bogotá D.C.: Universidad Nacional de Colombia, Facultad de Ingeniería, Departamento de Ingeniería Civil y Agrícola, 2017.

CVAT.AI CORPORATION. CVAT Documentation [en línea]. Palo Alto, California, Estados Unidos: CVAT.AI Corporation, 2025. Disponible en: <https://docs.cvat.ai/>. Consultado en: octubre de 2025.

GARCÍA-CÁCERES, Rafael, et al. Characterization of the supply and value chains of Colombian cocoa. En: *DYNA*. Vol. 81, No. 187 (2014). p. 30-40. DOI: 10.15446/dyna.v81n187.39555.

GONZÁLEZ ORJUELA, Santiago. Revisión de métodos para la fermentación de cacao y análisis de la fermentación combinada de cacao criollo y forastero. Trabajo de grado para optar al título de Ingeniero de Alimentos. Bogotá D.C.: Universidad de Bogotá Jorge

Tadeo Lozano, Facultad de Ciencias Naturales e Ingeniería, Programa de Ingeniería de Alimentos, 2021.

INSTITUTO TECNOLÓGICO DE CASTILLA Y LEÓN (ITCL). Tecnología de imagen hiperespectral en la industria alimentaria [en línea]. Burgos: ITCL, 28 mar. 2023. Disponible en: <https://itcl.es/blog/imagen-hiperespectral-seguridad-alimentaria/>.

LALIBERTÉ, Brigitte, et al . Guía para la evaluación de la calidad y el sabor del cacao. Trad. Karen Amaya Vecht. Roma, Italia: Bioersity International, 2023. 216 p. ISBN 978-92-9255-295-4.

MUNDACA CUEVA, Giancarlo. Análisis de la calidad del grano de cacao mediante imágenes hiperespectrales usando técnicas de visión artificial. Tesis de maestría para optar al grado de Magíster en Ingeniería. Piura, Perú: Universidad de Piura, Escuela de Posgrado, 2016.

NGUYEN, Dinh T, et al. A method for non-destructive determination of cocoa bean fermentation levels based on terahertz hyperspectral imaging. En: International Journal of Food Microbiology. Vol. 365 (2022). Art. 109537. DOI: 10.1016/j.ijfoodmicro.2022.109537.

OMAS-AS, Andrey, et al. Machine Learning as a Strategic Tool: A Comprehensive Literature Review for Advancing Agricultural Analysis, with Emphasis on the Cocoa Bean Quality Assessment. En: International Journal of Scientific Research and Engineering Development. Vol. 7, No. 1 (ene.-feb. 2024), p. 269-281.

PYTHON SOFTWARE FOUNDATION. Python Documentation [en línea]. Wilmington, Delaware: Python Software Foundation, 2025. Disponible en: <https://docs.python.org/>.

QUINTANA FUENTES, Lucas Fernando y GARCÍA JEREZ, Alberto. Evaluación integral de la calidad sensorial del cacao. Bogotá D.C.: Sello Editorial UNAD, 2021. ISBN 978-958-651-778-2. DOI: 10.22490/9789586517782.

REDMON, Joseph, et al. You Only Look Once: Unified, Real-Time Object Detection. En: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, Nevada, Estados Unidos, 2016. p. 779-788. DOI: 10.1109/CVPR.2016.91.

REGALADO, Miguel. ¿Qué es la prueba de corte del cacao y cuándo puede ser útil? En: Perfect Daily Grind español [en línea]. Reino Unido: Perfect Daily Grind Ltd., 23 ago. 2019. Disponible en: <https://perfectdailygrind.com/es/2019/08/23/que-es-la-prueba-de-corte-del-cacao-y-cuando-puede-ser-util/>.

RUIZ ESPITIA, Miller Jaer. Análisis de la calidad del grano de cacao modelo araucano en tres materiales regionales FSA13, FEAR5 y FTA2 en Saravena, Arauca. Trabajo de grado de maestría. Bogotá D.C.: Universidad de Bogotá Jorge Tadeo Lozano, Facultad de Ciencias Naturales e Ingeniería, Maestría en Ingeniería de Procesos y Sistemas Industriales, 2023. 73 p.

SÁNCHEZ, Karen, et al. Classification of Cocoa Beans Based on their Level of Fermentation using Spectral Information. En: Tecnológicas. Vol. 24, No. 50 (2021). Art. e1654. DOI: 10.22430/22565337.1654.

SUÁREZ, Juan, et al. Automated Classification of Cocoa Bean Fermentation Levels Using Computer Vision. En: XXV Symposium of Image, Signal Processing, and Artificial Vision (STSIVA). Armenia, Colombia. 2025. p. 1-5. DOI: 10.1109/STSIVA66383.2025.11156348.

SWISS PLATFORM FOR SUSTAINABLE COCOA (SWISSCO). Cocoa facts and figures [en línea]. Berna, Suiza: Swiss Platform for Sustainable Cocoa, 2024. Disponible en: <https://www.kakaoplattform.ch/about-cocoa/cocoa-facts-and-figures..>

WANDEL MARROQUÍN, Marion. Nuevas tecnologías y agricultura 4.0: impacto en los recursos humanos de la industria agrícola en Centroamérica. Trabajo de fin de grado para optar al título de Grado en Administración y Dirección de Empresas con Mención en Internacional. Madrid, España: Universidad Pontificia Comillas, Facultad de Ciencias Económicas y Empresariales (ICADE), 2021.

WIEME, Jana, et al. Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review. En: *Biosystems Engineering*. Vol. 222 (2022), p. 156-176. DOI: 10.1016/j.biosystemseng.2022.07.013.