

JMNJE V4. N1. 129

Aplicación móvil basada en visión artificial y regresión lineal para el reconocimiento del estado de madurez y el pronóstico de rendimiento en cultivos de cacao (*Theobroma cacao* L): estudio de caso en la Finca Mendoza, Ecuador

Mobile application based on computer vision and linear regression for maturity status recognition and yield forecast in cocoa crops (*Theobroma cacao* L): case study at Finca Mendoza, Ecuador

Autores:

Angel Alberto Arce Ramírez
Universidad Agraria del Ecuador, Guayaquil, Ecuador
aarce@uagraria.edu.ec
<https://orcid.org/0000-0002-4421-6589>

Johanna Noemi Ramos Holguin
Universidad Agraria del Ecuador, Guayaquil, Ecuador
Jramos@uagraria.edu.ec
<https://orcid.org/0009-0007-7899-6556>

Autor de correspondencia: Angel Alberto Arce Ramírez, aarce@uagraria.edu.ec

Enviado: 23-08-2026
Aceptado: 07-10-2026

Revisado: 31-08-2026
Publicado: 08-10-2026

Cómo citar este artículo:

Arce Ramírez, A. A., & Ramos Holguin, J. N. (2026). Aplicación móvil basada en visión artificial y regresión lineal para el reconocimiento del estado de madurez y el pronóstico de rendimiento en cultivos de cacao (*Theobroma cacao* L): estudio de caso en la Finca Mendoza, Ecuador. *Journal of Multidisciplinary Novel Journeys & Explorations*, 4(1), 1-17. <https://doi.org/10.63688/xq1wz063>

© 2026; Los autores. Este es un artículo en acceso abierto, distribuido bajo los términos de una licencia Creative Commons (<https://creativecommons.org/licenses/by/4.0>) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea correctamente citada.



RESUMEN

Introducción: La determinación del grado de madurez del fruto y la estimación del rendimiento en fincas cacaoteras de Ecuador suele realizarse mediante observación empírica y registros manuales, lo que genera apreciaciones subjetivas, errores operativos y ausencia de información histórica sistematizada. Frente a esta problemática, el presente estudio tuvo como objetivo desarrollar y evaluar funcionalmente una aplicación móvil que integrara visión artificial y un modelo predictivo para el reconocimiento del estado de madurez del cacao y el pronóstico de rendimiento en la Finca Mendoza, Ecuador.

Metodología: Metodológicamente, la investigación se abordó desde un enfoque cualitativo, con diseño no experimental y carácter aplicado, descriptivo y documental; la información se recopiló mediante observación directa y entrevista semiestructurada al propietario de la finca, mientras que el desarrollo tecnológico se ejecutó bajo la metodología ágil de Programación Extrema (XP), incorporando una red neuronal convolucional para el análisis de imágenes y técnicas de regresión lineal para la proyección productiva.

Resultados: Como resultado, se identificaron seis funcionalidades principales orientadas al monitoreo y la gestión del cultivo, se modelaron las entidades Usuario, Producción, Imagen y Predicción como núcleo del sistema, y se implementaron módulos de captura y análisis de imágenes, pronóstico de rendimiento, reportes y recomendaciones, evidenciando una disminución perceptible en los tiempos de inspección y una mejora en la trazabilidad de la información agrícola.

Conclusiones: Se concluye que la herramienta reduce la dependencia de métodos empíricos y constituye un modelo replicable para la digitalización agrícola en contextos rurales similares

Palabras clave: aplicación móvil, cacao, visión artificial, aprendizaje automático.

ABSTRACT

Introduction: The determination of fruit ripeness and yield estimation on cacao farms in Ecuador is typically conducted through empirical observation and manual record-keeping, which gives rise to subjective assessments, operational errors, and a lack of systematized historical data. In response to this problem, the present study aimed to develop and functionally evaluate a mobile application integrating computer vision and a predictive model for recognizing cacao ripeness stages and forecasting yield at Finca Mendoza, Ecuador.

Methodology: Methodologically, the research was approached from a qualitative standpoint, employing a non-experimental design of an applied, descriptive, and documentary nature; data were collected through direct observation and a semi-structured interview with the farm owner, while the technological development was carried out under the Extreme Programming (XP) agile methodology, incorporating a convolutional neural network for image analysis and linear regression techniques for production projection.

Results: As a result, six core functionalities oriented toward crop monitoring and management were identified; the User, Production, Image, and Prediction entities were modeled as the core of the system; and modules for image capture and analysis, yield forecasting, reporting, and recommendations were implemented, evidencing a perceptible reduction in inspection times and an improvement in the traceability of agricultural information.

Conclusions: It is concluded that the tool reduces dependence on empirical methods and constitutes a replicable model for agricultural digitalization in similar rural contexts.

Keywords: mobile application, cocoa, computer vision, machine learning, yield prediction.



1. INTRODUCCIÓN

En la última década las herramientas como la visión artificial, el Marching Learning están transformando el sector agrícola, ha permitido automatizar tareas, reducir cargas operativas, mejorando significativamente la toma de decisiones, en los cultivos de cacao, donde identificar la calidad del grano depende del momento de la cosecha. Es ahí donde estas tecnologías ofrecen una alternativa objetiva, rápida y de bajo costo, frente a la tradicional basada en conocimientos empíricos del productor.

La producción de cacao constituye uno de los pilares agroexportadores de Ecuador, además mantiene una posición relevante en la oferta mundial de cacao fino de aroma. Sin embargo, buena parte de la producción proviene de fincas de pequeña y mediana donde el control de calidad y la planificación de la cosecha se sostienen sobre métodos empíricos, poco estandarizados, lo que incrementa el riesgo de cosechas inoportunas, pérdidas económicas y variabilidad en la calidad organoléptica del grano.

1.1 Revisión de literatura

La agricultura inteligente depende en gran medida del aprendizaje automático (ML). El ML se aplica a la gestión y selección de cultivos. Por ejemplo, diversos cultivos crecen bien en diferentes tipos de suelo. Los agricultores deben desempeñar su papel en la selección de la superficie óptima para sus cultivos (Ali et al., 2025). En esa línea, (Vicuña Pino et al., 2024) indica que. Se usaron métricas para monitorear el proceso de aprendizaje (y prueba) de la red neuronal. En este modelo, solo se consideró la accuracy (fracción de imágenes que son correctamente clasificadas). La función de IOOS especificada fue categorical_crossentropy. La función de Ioos es uno de los parámetros necesarios para cuantificar qué tan cerca está una determinada red neuronal de su estado ideal durante el proceso de entrenamiento.

Para los autores López et al. (2024) aseguran que una gran variedad de procesos que se llevan a cabo dentro de la agricultura ha sido automatizados, por lo tanto, establecieron que para la parte de la predicción es necesario la aplicación de modelos de aprendizaje que presenten aproximaciones en la producción, permitiendo de esta manera la toma de decisiones por parte de los agricultores en cuanto deben sembrar, todo esto tomando en cuenta el posible rendimiento que tiene a partir de los cálculos generados



Respecto a la determinación del estado de madurez, estudio realizado por (Heredia-Gómez et al., 2020a) se abordó el problema de la cosecha inoportuna del cacao, que afecta su calidad organoléptica, genera pérdidas económicas y riesgos para la salud debido a la dificultad de estandarizar la identificación de madurez por métodos artesanales. Para superar estas limitaciones, los autores diseñaron una herramienta portable, económica y personalizada basada en redes neuronales convolucionales (YOLOv3-tiny). Los autores (Kacoutchy Jean AYIKPA, 2022), indican que: Para ayudar a las cooperativas de agricultores a determinar la madurez de las vainas de cacao a tiempo, nuestro estudio evalúa el uso de herramientas de automatización basándose en medidas de similitud. Aunque técnicas estándar, como la inspección visual y el pesaje, se utilizan comúnmente para identificar la madurez de las vainas de cacao.

En un enfoque distinto, (Ayikpa et al., 2023) compararon extractores de características (MobileNet y matrices de co-ocurrencia de niveles de gris, GLCM) combinados con distintos espacios de color, logrando una precisión de clasificación de 99.61% con la combinación GLCM espacio Lab distancia chi-cuadrado, superando ampliamente los métodos de inspección visual tradicionales.

En cuanto al pronóstico de rendimiento, (Muñoz Ordoñez et al., 2023) aplicaron modelos estadísticos de regresión para investigar la relación entre el rendimiento del cultivo de café en Colombia y sus factores impulsores, concluyendo que la adquisición temprana y precisa de estimaciones de cosecha es determinante para la estabilidad del mercado alimentario. (Universidad Técnica Estatal de Quevedo et al., 2024), en un Diseño Completamente Aleatorizado con doce tratamientos sobre tres variedades de cacao (Nacional, Forastero y Trinitario), combinaron análisis de componentes principales (PCA) con la fórmula de rendimiento por hectárea ($P = N_m \times IM \times N_p$) y determinaron que el número de mazorcas maduras y sanas constituye un indicador confiable del rendimiento, destacando a la variedad Trinitario con un máximo de 2245.42 kg/ha/año. En Ecuador, (Aguirre-Munizaga et al., 2025) implementó una aplicación web para la estimación de la productividad cacaotera en Guayaquil, evidenciando una reducción del margen de error en las proyecciones de cosecha y una mejor identificación de zonas con mayor potencial productivo.

Los antecedentes citados bases sólidas de estudios que realizan la clasificación del estado de madurez del cacao a través de visión artificial combinadas con IOT. otras citas en



cambio se concentran en la predicción estadística del rendimiento sin integrar reconocimiento visual del fruto, existió según las investigaciones oportunidades para integrar el reconocimiento del estado de madurez y pronóstico de rendimiento en una única herramienta móvil orientada al usuario final, que sea accesible para productores de cacao.

1.2 Justificación y problema de investigación

En el estudio realizado, para reconocer el estado del fruto y pronosticar el rendimiento aún se dependía de la impericia del ser humano y del análisis manual, esto originaba errores y retraso en la toma de decisiones limitando las cosechas, ocasionando en la mayoría de los casos pérdidas económicas.

La ausencia de herramientas tecnológicas especializadas dificulta, además, la recopilación y el análisis de datos en tiempo real. A partir de esta problemática se formuló la pregunta de investigación: ¿cómo mejoraría el reconocimiento del estado del fruto y el pronóstico del rendimiento del cacao con la implementación de una aplicación móvil especializada?

El objetivo general del estudio fue desarrollar una aplicación móvil que, mediante visión artificial y modelos predictivos de aprendizaje automático, permitiera el reconocimiento del estado del fruto y el pronóstico de rendimiento de los cultivos de cacao en la Finca Mendoza. Para lograr este cometido se fracciona en cuatro objetivos específicos. Que se cumplieron a cabalidad

2. METODOLOGÍA

2.1 Enfoque, tipo y diseño de investigación

El enfoque de esta investigación fue cualitativo, ya que buscó comprender en profundidad las necesidades, percepciones y experiencias del usuario respecto al uso de tecnologías digitales para el control de estado del fruto y el pronóstico del rendimiento en los cultivos de cacao. A través de técnicas cualitativas como la entrevista y la observación directa en campo, se recopiló información sobre las prácticas actuales de producción, los desafíos enfrentados por los agricultores, y cómo una solución tecnológica puede responder a esas realidades.

Este enfoque permitió interpretar cómo se relacionan los usuarios con la tecnología, qué factores influyen en su adopción, y qué elementos son necesarios para diseñar una herramienta que realmente se adapte al contexto social, cultural y operativo de la finca. Por



tanto, más allá de validar métricas estadísticas, se prioriza la comprensión del entorno y el desarrollo de una solución centrada en el usuario final.

2.2 Recolección de datos

Para el levantamiento de datos se aplicaron dos técnicas, la primera fue la observación directa que fue realizada en el campo registrando las rutinas de tareas agrícolas, el tiempo que realiza las inspecciones y la formas de evaluar las mazorcas de cacao.

La entrevista semiestructurada se dirigió al propietario de la finca para indagar sobre las condiciones actuales de producción, los desafíos en la determinación del momento de cosecha y las herramientas utilizadas para la toma de decisiones. Ambas técnicas fueron complementarias: la información obtenida en la entrevista permitió contrastar y validar los hallazgos de la observación de campo, siguiendo un procedimiento de triangulación de fuentes propio de los diseños cualitativos no experimentales.

2.3 Metodología de desarrollo de software

El desarrollo del aplicativo se ejecutó bajo la metodología ágil de Programación Extrema (XP), seleccionada por su naturaleza ligera, iterativa y centrada en la retroalimentación continua con el usuario final (Abuchar, 2023; Raeburn, 2025). El ciclo de desarrollo se organizó en cinco fases:

Tabla 1.

Fases de la metodología XP aplicadas al desarrollo del sistema

Fase	Actividades principales
Planificación	Levantamiento de requerimientos mediante entrevista y observación directa; priorización de historias de usuario; definición del cronograma y los recursos.
Diseño	Elaboración de diagramas UML (casos de uso, clases, secuencia) y prototipo funcional en Figma; diseño de la base de datos relacional en MySQL.
Codificación	Implementación de los módulos de captura y procesamiento de imágenes, gestión de usuarios, pronóstico de rendimiento, reportes y recomendaciones, en Java/Android Studio (cliente móvil) y PHP/MySQL con API REST (backend).



Fase	Actividades principales
Pruebas	Ejecución de pruebas de integración (comunicación entre módulos), de rendimiento (tiempos de carga y respuesta) y de usabilidad (experiencia de uso en campo).
Lanzamiento	Despliegue en infraestructura como servicio (IaaS) en la nube, elaboración del manual de usuario y capacitación del propietario de la finca.

Nota. Elaboración propia a partir del proceso de desarrollo documentado.

2.4 Arquitectura técnica y modelos implementados

El módulo de reconocimiento del estado del fruto se basó en una red neuronal convolucional (CNN) entrenada para clasificar las mazorcas en tres categorías inmaduro, maduro y sobre maduro a partir de imágenes capturadas con la cámara del dispositivo móvil, siguiendo el enfoque de clasificación de tres clases empleado en estudios previos sobre determinación de madurez del cacao (Heredia-Gómez et al., 2020; Villamizar & Pérez, 2021; Ayikpa et al., 2023). El módulo de pronóstico de rendimiento se implementó mediante un modelo de regresión lineal entrenado con datos históricos de producción y variables agronómicas (lote, mes, variedad), consistente con el uso de la regresión lineal como técnica de referencia para relacionar variables ambientales y de manejo con el rendimiento agrícola (AWS, 2025; Muñoz et al., 2023). La comunicación entre el cliente móvil, el backend y la base de datos se implementó mediante una API REST (IBM, 2025), sobre una arquitectura desplegada en infraestructura como servicio (IaaS) (Google Cloud, 2025), y el flujo de integración y depuración de los datos históricos se gestionó mediante un proceso ETL (Microsoft, 2025).

Tabla 2.

Componentes tecnológicos del sistema

Componente funcional	Técnica/modelo	Tecnología
Reconocimiento del fruto	Red neuronal convolucional (CNN)	Java, Android Studio
Pronóstico de rendimiento	Regresión lineal	PHP, API REST
Persistencia de datos	Modelo relacional / ETL	MySQL



Componente funcional	Técnica/modelo	Tecnología
Diseño de interfaz	Prototipado colaborativo	Figma
Infraestructura	Hosting en la nube	IaaS

2.5 Consideraciones éticas y legales

El desarrollo del aplicativo observó el marco legal ecuatoriano vigente en materia de acceso a las tecnologías de información y comunicación (Constitución de la República del Ecuador, 2021, art. 16), protección de la autoría intelectual del software producido (Ley de Propiedad Intelectual, 2013, art. 28) y calidad e integridad de los datos personales tratados por el sistema (Asamblea Nacional del Ecuador, 2019, art. 16). El propietario de la finca fue informado sobre el propósito del estudio y participó de manera voluntaria en la entrevista y en la validación del prototipo.

2.6 Tratamiento analítico de la información

La información cualitativa recolectada en la entrevista y la observación se organizó mediante análisis de contenido temático, agrupando los hallazgos en categorías (método de reconocimiento del fruto, proceso de registro, dificultades de calidad, información requerida, factores de rendimiento y tiempo de inspección), que se sintetizan en la Tabla 3. Este procedimiento permitió transformar evidencia cualitativa en requerimientos funcionales y no funcionales verificables durante las fases de diseño y prueba. Cabe señalar como límite metodológico que el estudio no incluyó una validación estadística inferencial del desempeño de los modelos de clasificación y regresión (p. ej., matrices de confusión, mAP o error cuadrático medio), a diferencia de estudios de referencia como Heredia-Gómez et al. (2020) o Ayikpa et al. (2023); este aspecto se discute en la sección 4 y se plantea como línea de trabajo futuro.

3. RESULTADOS

3.1 Diagnóstico de necesidades de la Finca Mendoza

La observación directa y la entrevista al propietario evidenciaron que el reconocimiento del estado del fruto se realiza de forma manual y empírica, basada en el color de la cáscara y, ocasionalmente, en la apertura de la mazorca para verificar la pepa; el registro de la producción se mantiene en un cuaderno físico, sin generación de informes formales; y la inspección de campo demanda entre una y dos horas, entre una y dos veces por



semana. Estos hallazgos permitieron identificar seis funcionalidades funcionales prioritarias (captura de imagen, registro de producción, generación de reportes, almacenamiento de datos, obtención de pronósticos y recomendaciones) y requisitos no funcionales de usabilidad, rapidez, confiabilidad, escalabilidad y accesibilidad móvil.

Tabla 3.

Diagnóstico del proceso tradicional de control del estado del fruto en la Finca Mendoza

Aspecto observado/consultado	Resultado registrado
Método de reconocimiento del fruto	Manual y empírico, basado en el color de la cáscara y, ocasionalmente, apertura de la mazorca.
Proceso de registro de datos	Manual en cuaderno físico; sin informes ni registros formales de producción.
Dificultad principal de calidad	Cosecha en momento inoportuno (antes o después del punto óptimo), con pérdida de calidad y rendimiento.
Información requerida en la app	Historial de producción por lote y mes, cantidad de frutos maduros, aviso de tiempo de cosecha y alertas de anomalías.
Factores clave del rendimiento	Manejo agronómico (poda, abono), variedad de cacao (p. ej., CCN-51) y condiciones climáticas imprevistas.
Tiempo requerido para la inspección	Entre 1 y 2 horas, de 1 a 2 veces por semana (mayor frecuencia en temporada de cosecha).

Nota. Elaboración propia a partir de la observación directa y la entrevista al propietario.

3.2 Diseño estructural del sistema

A partir de los requerimientos identificados se elaboraron diagramas de casos de uso, de clases y de secuencia, así como un prototipo de interfaz en Figma. El modelado de entidades definió cuatro objetos centrales del dominio: Usuario, Producción, Imagen y Predicción, y el flujo de secuencia estableció el recorrido completo desde la captura de la imagen hasta el retorno del resultado de clasificación y su almacenamiento.



Tabla 4.*Resultados del diseño estructural mediante UML y prototipado*

Elemento diseñado	Resultado registrado
Diagrama de casos de uso	Identificación de 6 funciones principales del sistema
Diagrama de clases	Modelado de las entidades Usuario, Producción, Imagen y Predicción
Diagrama de secuencia	Flujo detallado de captura, análisis y retorno del resultado
Prototipo en Figma	Interfaz con pantallas de inicio de sesión, menú, captura, reportes y predicciones
Flujo de navegación	Estructura optimizada para el trabajo en campo
Alineación con requerimientos	100 % de los requerimientos funcionales representados en el diseño

3.3 Codificación e implementación de módulos

La fase de codificación materializó los seis módulos definidos en el diseño: captura de imágenes, procesamiento y clasificación mediante CNN, gestión de usuarios, pronóstico de rendimiento mediante regresión lineal, generación de reportes de calidad y producción, y recomendaciones agronómicas basadas en el estado del cultivo. El backend, desarrollado en PHP con base de datos MySQL, se comunicó con el cliente móvil (Java/Android Studio) mediante una API REST, habilitando la captura en campo y la respuesta inmediata del análisis de madurez, así como la exportación de reportes en formatos PDF y Excel.

Tabla 5.*Resultados de la codificación por módulo funcional*

Módulo/funcionalidad	Descripción del resultado	Tecnologías
Reconocimiento del fruto	Modelo de red neuronal convolucional (CNN) para clasificar la mazorca en inmadura, madura o sobremadura a partir de imágenes capturadas por el móvil.	Android Studio, Java, CNN



Módulo/funcionalidad	Descripción del resultado	Tecnologías
Pronóstico de rendimiento	Algoritmo de regresión lineal entrenado con datos históricos y variables agronómicas (lote, mes, variedad).	PHP (backend), API REST
Gestión de datos	Base de datos relacional y APIs para el flujo de registros, imágenes, resultados de análisis y pronósticos.	MySQL, PHP, ETL
Informes y gráficos	Lógica de generación de informes exportables (PDF/Excel) y visualización de gráficos de rendimiento.	Java/Android Studio, PHP

3.4 Implementación, pruebas y validación operativa

Aplicación móvil para reconocimiento del estado del fruto y el pronóstico de rendimiento de cultivos de cacao fue desplegado en un entorno de hosting IaaS, fueron integradas las APIs, la base de datos y los modelos de análisis. Las pruebas de integración realizadas corroboraron la correcta comunicación entre los módulos de procesamiento de imágenes, pronóstico y generación de reportes.

También se realizaron las pruebas de rendimiento que evaluaron los tiempos de carga y respuesta ante distintos volúmenes de datos, en cuanto las pruebas de usabilidad, que se realizaron con el propietario de la finca, validaron la facilidad de uso del sistema en condiciones reales de campo. Obteniendo como resultado operativo más relevante, el tiempo de inspección se redujo de 1 a 2 horas mediante el método manual a un intervalo de minutos con la aplicación móvil, sustituyendo el registro en cuaderno físico por el almacenamiento digital estructurado.



Tabla 6.

Resultados de la implementación y validación del sistema

Fase de implementación	Resultado/validación	Indicador de éxito
Despliegue	Puesta en marcha de la aplicación móvil y los servicios de backend (API, base de datos, modelos ML) en un entorno IaaS.	Acceso funcional desde el dispositivo móvil del productor
Pruebas de calidad	Superación de pruebas de integración, rendimiento y usabilidad en campo.	Tiempos de carga aceptables; usabilidad validada por el usuario final
Digitalización de procesos	Sustitución del registro manual por el uso de la aplicación para el control de producción y análisis del fruto.	Reducción del tiempo de inspección (1–2 horas → minutos)
Adopción y soporte	Capacitación del usuario final y entrega del manual de usuario.	Operación autónoma del sistema por parte del propietario

Nota. Los resultados presentados corresponden a evidencia funcional y cualitativa de validación en campo; el estudio no reporta métricas cuantitativas de precisión (p. ej., exactitud de clasificación o error de predicción de rendimiento), lo que se identifica como una limitación.

4. DISCUSIÓN

Los resultados de la investigación confirman que, antes de aplicar la apps, la Finca Mendoza presentaba la misma problemática descrita en la literatura sobre determinación manual de la madurez del cacao: con alta dependencia de la experiencia empírica del agricultor, ausencia de herramientas tecnológicas y elevado riesgo de error humano (Heredia-Gómez et al., 2020a). Esta coincidencia refuerza la validez externa del diagnóstico y justifica la pertinencia de una solución tecnológica en contextos productivos similares de pequeña escala.

Para el diseño de la aplicación móvil, para diagramas UML permitió comprender funcionalmente el sistema, a la vez anticipar los flujos operativos del productor, como lo señalado por.(Universidad Cooperativa de Colombia & Patiño Martínez, 2022) sobre la utilidad del proceso de diseño de diagramas de casos de uso, en el marco del ciclo de vida



del desarrollo de software, para la etapa de especificación de requisitos, tanto para los desarrolladores como para los usuarios finales.

. La validación del prototipo con el propietario de la finca respalda además la pertinencia de un enfoque de diseño centrado en el usuario para la adopción de tecnología en entornos rurales con experiencia tecnológica limitada.

Respecto al reconocimiento del estado de madurez, la incorporación de una red neuronal convolucional es consistente con el enfoque metodológico de (Villalba et al., 2021) Allí se reportaron precisiones superiores al 90% mediante redes neuronales convolucionales para la clasificación de estados de maduración del plátano, y con (Ayikpa et al., 2023) los autores desarrollaron un sistema para clasificar la madurez de mazorcas de cacao utilizando técnicas de visión por computadora. que alcanzaron 99.61% de precisión combinando GLCM y espacio de color Lab y la medida de distancia chi-cuadrado.

Sin embargo, a diferencia de los estudios analizados, el presente trabajo no reportó una métrica cuantitativa formal de precisión del modelo entrenado, limitándose a una validación funcional. Esto constituye una brecha relevante frente al estado del arte, mientras (Heredia-Gómez et al., 2020b) determinaron mediante pruebas estadísticas ANOVA y Kruskal-Wallis que las variaciones en el tamaño de las imágenes de entrada no afectan significativamente el desempeño del modelo de clasificación basado en redes neuronales convolucionales

En cuanto al pronóstico de rendimiento, la elección de un modelo de regresión lineal es coherente con el enfoque de (Muñoz Ordoñez et al., 2023), quienes emplearon regresión para relacionar el rendimiento del café con sus factores impulsores en Colombia, y complementa el enfoque de (Universidad Técnica de Machala et al., 2025) propone un Modelo Integrado de Adopción de Tecnologías en la Agricultura (MIATA), destacando la importancia de la Inteligencia Artificial y el Internet de las Cosas. Validado en la producción de cacao.

La aportación distintiva del presente estudio, frente a ambos antecedentes, radica en que el pronóstico de rendimiento no se trata como un análisis estadístico aislado, sino como un módulo integrado a la misma aplicación móvil que realiza el reconocimiento visual del fruto, replicando en un solo flujo operativo lo que en la literatura revisada aparece como funciones separadas ya sea en dispositivos embebidos especializados (Heredia-Gómez et al., 2020a) o en aplicaciones web orientadas exclusivamente a la estimación de productividad (Universidad Técnica Estatal de Quevedo et al., 2024)



Esta integración de reconocimiento de madurez, pronóstico de rendimiento, generación de reportes y recomendaciones agronómicas dentro de una única aplicación móvil orientada a un productor específico constituye la principal novedad científica del estudio frente al estado del arte revisado, que tiende a abordar estas funciones de manera independiente. No obstante, la ausencia de métricas cuantitativas de desempeño de los modelos limita la comparabilidad directa de la precisión alcanzada frente a estudios como (Ayikpa et al., 2023).

5. CONCLUSIONES

El presente estudio demostró la viabilidad técnica y operativa de integrar, en una única arquitectura móvil accesible, el reconocimiento del estado de madurez de mazorcas de cacao (Universidad Técnica Estatal de Quevedo et al., 2024) mediante redes neuronales convolucionales (CNN) y la estimación del rendimiento agronómico basada en regresión lineal. La adopción de la metodología ágil Programación Extrema (XP), complementada con un diseño centrado en el usuario mediante diagramas UML y prototipado funcional, permitió materializar una herramienta adaptada a la dinámica del productor rural, mitigando la dependencia histórica de métodos empíricos y registros en papel en la Finca Mendoza.

La principal contribución científica y práctica de este trabajo radica en la unificación de dos componentes que tradicionalmente se abordan de manera desarticulada en la literatura: la clasificación fenológica por visión artificial y el pronóstico productivo. A nivel operativo, la solución optimizó la gestión agronómica al reducir los tiempos de inspección en campo de 1 hasta 2 horas a pocos minutos, dotando a la explotación de trazabilidad digital y soporte para la toma de decisiones oportunas en la cosecha.

Como limitación metodológica, debe señalarse que la validación del sistema se enfocó en aspectos funcionales, de usabilidad y de integración técnica, prescindiendo de una evaluación estadística cuantitativa inferencial del rendimiento predictivo de los modelos (p. ej., matrices de confusión, precisión/exhaustividad o error cuadrático medio). En consecuencia, se definen como líneas prioritarias para futuras investigaciones: (i) la validación estadística y benchmarking de los algoritmos bajo diversas condiciones lumínicas y variedades de cacao; (ii) la adaptación de los modelos para inferencia en el borde (edge computing) sin dependencia de conectividad constante; y (iii) la evaluación del impacto económico y agronómico a mediano y largo plazo en múltiples fincas cacaoteras de la región.



Para validar las necesidades se obtuvo un diagnóstico de la Finca Mendoza confirmando que los métodos tradicionales basados en la intuición y el papel consumen demasiado tiempo y son propensos a errores, lo que justificó la urgencia de digitalizar la gestión de cosecha en pequeñas parcelas.

El uso de los diagramas UML, fue gran ayuda para el diseño de la aplicación centrado en el usuario, tanto en el modelado del sistema, como las pruebas del prototipo en la plataforma Figma, se adaptó al contexto agrícola rural evidenciando que una interfaz limpia derriba las barreras de uso en personas con bajo dominio tecnológico.

La viabilidad de la arquitectura técnica ha demostrado que es plenamente factible articular en una aplicación móvil algoritmos de visión por computadora (CNN), modelos predictivos (regresión lineal), bases de datos y servicios en la nube, sentando una base técnica escalable para el agro.

REFERENCIAS BIBLIOGRÁFICAS

- Aguirre-Munizaga, M., Chang-Zorilla, S., Rivera, D. V., & Vera-Lucio, N. (2025). Implementation of a web application for estimating cocoa productivity using machine learning. En A. Rocha, C. Ferrás, & H. Calvo (Eds.), *Information technology and systems* (Vol. 1447, pp. 382–390). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-93109-3_34
- Ali, Z., Muhammad, A., Lee, N., Waqar, M., & Lee, S. W. (2025). Artificial intelligence for sustainable agriculture: A comprehensive review of AI-driven technologies in crop production. *Sustainability*, 17(5), 2281. <https://doi.org/10.3390/su17052281>
- Ayikpa, K. J., Mamadou, D., Gouton, P., & Adou, K. J. (2023). Classification of cocoa pod maturity using similarity tools on an image database: Comparison of feature extractors and color spaces. *Data*, 8(6), 99. <https://doi.org/10.3390/data8060099>
- Heredia-Gómez, J. F., Rueda-Gómez, J. P., Talero-Sarmiento, L. H., Ramírez-Acuña, J. S., & Coronado-Silva, R. A. (2020). Determinación de la madurez de mazorcas de cacao, haciendo uso de redes neuronales convolucionales en un sistema embebido. *Revista Colombiana de Computación*, 21(2), 42–55. <https://doi.org/10.29375/25392115.4030>
- Ayikpa, K. J. (2022). CocoaMFDB [Conjunto de datos]. Mendeley Data. <https://doi.org/10.17632/9MSJJH3NP6.2>



- Muñoz Ordoñez, C. C., Cobos Lozada, C. A., & Muñoz Ordóñez, J. F. (2023). Predicción del rendimiento de cultivos de café: Un mapeo sistemático. *Ingeniería y Competitividad*, 25(3). <https://doi.org/10.25100/iyv.v25i3.13171>
- Patiño Martínez, F. Y. (2022). Elaboración de diagramas de casos de uso. Ediciones Universidad Cooperativa de Colombia. <https://doi.org/10.16925/gcgp.60>
- Izquierdo, J. A., Jaramillo, J. F., Loja, N. M., & Maon-Olivo, B. (2025). Modelo integrado de adopción de tecnologías en la agricultura. Caso de estudio: IA e IoT aplicadas en producción de cacao. *Espacios*, 46(3), 480–492. <https://doi.org/10.48082/espacios-a25v46n03p38>
- Vera-Chang, J. F., Herrera-Tamayo, N. L., Alvarez-Sanchez, A. R., Alvarez-Aspiazu, A. A., Díaz-Camposano, E. G., & Vásquez-Cortez, L. H. (2024). Comportamiento agronómico de cuarenta y un cruces interclonales de cacao (*Theobroma cacao* L.) en Ecuador. *Revista U.D.C.A Actualidad & Divulgación Científica*, 27(2). <https://doi.org/10.31910/rudca.v27.n2.2024.2729>
- Vicuña Pino, A. E., Molina Noboa, J. F., Espín Carrasco, L. M., & Erazo Moreta, O. R. (2024). Aprendizaje profundo aplicado a la clasificación de granos de cacao (*Theobroma cacao* L.) según la calidad de fermentación. *Revista Científica y Tecnológica UPSE*, 11(2), 92–104. <https://doi.org/10.26423/rctu.v11i2.838>
- Villalba, A., Requena, T., Solanilla, F., & Rangel, J. C. (2021). Prototipo de un sistema que determine el estado de madurez de un plátano utilizando deep learning y visión artificial. *Revista de Iniciación Científica*, 6. <https://doi.org/10.33412/rev-ric.v6.0.3155>

CONFLICTO DE INTERESES

No existe.

FINANCIAMIENTO

No aplica.

CONTRIBUCIÓN DE AUTORÍA

Conceptualización: Angel Alberto Arce Ramírez, Johanna Noemi Ramos Holguin.

Metodología: Angel Alberto Arce Ramírez, Johanna Noemi Ramos Holguin.

Investigación: Angel Alberto Arce Ramírez, Johanna Noemi Ramos Holguin.



Redacción – borrador original: Angel Alberto Arce Ramírez, Johanna Noemi Ramos Holguin.

Redacción – revisión y edición: Angel Alberto Arce Ramírez, Johanna Noemi Ramos Holguin.

