



2026

**Implementación de modelos de visión artificial optimizados para la detección de
frescura de alimentos en dispositivos móviles: Caso FridgeEye**

ESTUDIANTES

Bryan S. Ruiz Hernandez

Johan S. Hernandez Daza

Juan E. García Pinzón

CURSO

Proyecto de Grado

PROFESORA

Lina María Chacón Rivera

Resumen.....	2
Abstract.....	3
Introducción	4
Marco Teórico.....	7
Estado del Arte.....	10
Fuentes de información	11
Estrategia de Búsqueda y criterios de exclusión y aceptación	11
Proceso de selección.....	13
Resumen del Estado del Arte	13
Metodología	15
Resultados	18
Resultados del entrenamiento del modelo de visión artificial.....	18
Configuración experimental	18
Curvas de entrenamiento y validación.....	20
Métricas finales de desempeño	21
Matriz de confusión por clase.....	23
Curvas F1-Confidence y Precision-Recall	24
Resultados del desarrollo del prototipo de aplicación móvil	26
Arquitectura general de la aplicación	26
Pantalla de inicio y resumen del inventario	26

Pantalla de captura por cámara	27
Pantalla de inventario detallado	28
Pantalla de galería de capturas	29
Análisis de Resultados	30
Análisis del modelo de visión artificial	31
Estabilidad y convergencia del entrenamiento	31
Cumplimiento de las metas de desempeño	32
Calidad de la clasificación por clase	33
Selección del umbral de confianza	33
Análisis del prototipo de aplicación móvil	34
Cobertura funcional frente a los objetivos del proyecto	34
Cumplimiento del paradigma On-device AI	35
Diseño de interacción y experiencia de usuario	36
Verificación de la hipótesis y respuesta a la pregunta de investigación	36
Propuesta de Solución	37
Síntesis de la Solución de Ingeniería	38
Modelo de Negocio y Oferta de Valor	38
Análisis de costos	39
Costos fijos	39
Costos variables	40

Costo del producto y modelo de negocio	40
Análisis de viabilidad económica.....	41
Análisis de sostenibilidad.....	41
Discusión.....	43
Contraste con la Literatura Previa	43
Implicaciones Para el Sector	43
Limitaciones del Estudio	44
Aporte al Cuerpo de Conocimiento.....	45
Plan de divulgación.....	45
Producto principal y productos derivados	45
Objetivos y ruta operativa	46
Costos del plan de divulgación.....	47
Proyección científica, tecnológica y empresarial	47
Conclusiones	48
Conclusión General.....	48
Sobre el Objetivo Específico de Desempeño Técnico	48
Sobre el Objetivo Específico Legal y Ambiental.....	49
Sobre el Objetivo Específico Económico.....	49
Cierre y proyección	50
Bibliografía	50

Resumen

El presente trabajo aborda el problema del desperdicio de alimentos en el contexto doméstico colombiano, fenómeno que de acuerdo con el Departamento Nacional de Planeación (DNP, 2016) alcanza las 9,76 millones de toneladas anuales en el país, de las cuales el 15,6 % se pierde en el consumo final dentro de los hogares. Para mitigar esta problemática, el proyecto FridgeEye desarrolló un prototipo de aplicación móvil basado en visión artificial y aprendizaje profundo bajo el paradigma de On-device AI (Edge Computing). La metodología combinó tres componentes complementarios: una revisión sistemática de la literatura basada en la declaración PRISMA, que partió de 379 registros iniciales y consolidó un corpus final de 15 artículos científicos de alta calidad metodológica; la adopción y curaduría del dataset FridgeEye-1K (denominación interna asignada al dataset de entrenamiento utilizado, que a un dataset público externo de más de 70.000 imágenes etiquetadas de productos perecederos) del cual se seleccionaron aproximadamente 50.000 imágenes útiles para el entrenamiento del modelo final, tras un proceso de filtrado por calidad, balance entre clases y representatividad de las condiciones lumínicas reales de uso doméstico; y el entrenamiento de un modelo basado en la arquitectura YOLO mediante Transfer Learning, con 120 épocas, optimizador AdamW, resolución de entrada de 640×640 píxeles y técnicas avanzadas de aumentación de datos (mosaic, mixup, randaugment y ajustes HSV). Los resultados obtenidos durante la validación superaron ampliamente la meta operativa del 85 % de exactitud: el modelo final alcanzó un $mAP@0,5$ de 98,5 %, un $mAP@0,5-0,95$ de 90,8 %, una precisión global de 95,0 % y un recall de 95,8 %, con tasas de acierto del 97 % tanto para la clase Fresco como para la clase Deteriorado. Como producto final se materializó un prototipo de aplicación móvil con interfaz

nativa que integra menú principal, captura por cámara, galería de productos y gestión de inventario, ejecutando la inferencia íntegramente en el dispositivo y cumpliendo por diseño los principios de la Ley 1581 de 2012 (Habeas Data). El análisis financiero a cinco años arrojó un Valor Presente Neto de \$103.252.278 COP, una Tasa Interna de Retorno del 59,03 % anual y un período de recuperación de la inversión de 1,67 años, indicadores que confirman la viabilidad integral del proyecto y consolidan a FridgeEye como un aporte innovador alineado con los Objetivos de Desarrollo Sostenible 9, 12 y 13.

Palabras clave: Visión artificial, aprendizaje profundo, Edge Computing, On-device AI, YOLO, Transfer Learning, desperdicio de alimentos, FridgeEye-1K, Ley 1581 de 2012, prefactibilidad.

Abstract

The present work addresses the problem of food waste in the Colombian domestic context, a phenomenon that according to the National Planning Department (DNP, 2016) reaches 9.76 million tons annually in the country, of which 15.6 % is lost at the final consumption stage inside households. To mitigate this problem, the FridgeEye project developed a mobile application prototype based on computer vision and deep learning under the On-device AI (Edge Computing) paradigm. The methodology combined three complementary components: a systematic literature review based on the PRISMA statement, which started from 379 initial records and consolidated a final corpus of 15 high-quality scientific articles; the adoption and curation of the FridgeEye-1K dataset (the internal label assigned to the training dataset used, which corresponds to an external public dataset of over 70,000 annotated images of perishable products) from which approximately 50,000 useful images were selected for the final model training, after a filtering process based on quality, class balance and representativeness of real

domestic lighting conditions; and the training of a YOLO-based model through Transfer Learning, with 120 epochs, AdamW optimizer, 640×640 pixel input resolution and advanced data augmentation techniques (mosaic, mixup, randaugment and HSV adjustments). The validation results far exceeded the 85 % accuracy operational target: the final model achieved an mAP@0.5 of 98.5 %, an mAP@0.5–0.95 of 90.8 %, an overall precision of 95.0 % and a recall of 95.8 %, with 97 % accuracy rates for both the Fresh and Spoiled classes. As a final product, a mobile application prototype was materialized with a native interface that integrates main menu, camera capture, product gallery and inventory management, running the inference entirely on the device and therefore complying by design with the principles of Colombia's Law 1581 of 2012 (Habeas Data). The five-year financial analysis yielded a Net Present Value of \$103,252,278 COP, an Internal Rate of Return of 59.03 % per annum and a payback period of 1.67 years, indicators that confirm the comprehensive feasibility of the project and consolidate FridgeEye as an innovative contribution aligned with Sustainable Development Goals 9, 12 and 13.

Keywords: Computer vision, deep learning, Edge Computing, On-device AI, YOLO, Transfer Learning, food waste, FridgeEye-1K, Law 1581 of 2012, pre-feasibility.

Introducción

Los desperdicios de comida hoy en día no son un simple descuido doméstico, hoy en día se han convertido en un problema estructural que golpea la sostenibilidad en todo el planeta. Los números de la FAO(2019) no mienten: aproximadamente el 14% de los alimentos producidos se pierden incluso antes de llegar a la venta al por menos (p. 24). Esta situación de hecho se agrava al llegar al consumidor final, en Colombia, según el DNP(2016) 9,76 millones de toneladas son desperdiciadas anualmente, donde el 15,6% (unas 1,53 millones de toneladas) se pierde en el consumo (p. 22), en las casas básicamente. Gran parte de este problema se debe a que la gente

simplemente olvida lo que tiene en la nevera o no tiene herramientas claras para saber qué se está dañando antes de que sea tarde.

La ciencia ha intentado atacar esto pasando de pruebas químicas lentas a soluciones de visión artificial que no dañan el producto. Se ha experimentado con cámaras hiperspectrales que detectan cambios bioquímicos, pero son carísimas para una cocina normal. Hoy en día los estudios se están enfocando en las redes neuronales convolucionales y modelos de detección de objetos como YOLOv8, ya que logran un equilibrio decente entre precisión y los recursos que consume el dispositivo. El problema es que todavía falta mucho por investigar sobre cómo funcionan estos modelos dentro de una nevera real (con sombras y montones de comida que afectan el funcionamiento del modelo) y cómo optimizarlos para dispositivos que no sean de alta gama. Aquí es donde entra "FridgeEye", un sistema que usa *Transfer Learning* para adaptar bases de datos gigantes al contexto específico de los alimentos que se consumen en Colombia, cuidando siempre el manejo legal de las imágenes bajo la Ley 1581.

El objetivo es armar un prototipo de aplicación móvil que clasifique automáticamente qué tan frescos están los productos para frenar el desperdicio en los hogares colombianos. Para lograrlo, se decidió ir por una revisión sistemática con metodología PRISMA y por el entrenamiento de un modelo de visión artificial que supere un F1-Score del 85 %. Si bien el plan original contemplaba la adaptación o creación de un dataset propio (denominado "FridgeEye-1K") con al menos 1.000 fotos etiquetadas, durante la ejecución se identificó que un dataset público externo de mayor escala ofrecía una base más sólida para el entrenamiento al cubrir una variedad más amplia de productos, estados de descomposición y condiciones lumínicas. En

consecuencia, el equipo adoptó dicho dataset público (que se mantiene en lo sucesivo bajo la denominación interna “FridgeEye-1K” para preservar la nomenclatura del proyecto) y aplicó un proceso de curaduría que consolidó aproximadamente 50.000 imágenes útiles a partir de más de 70.000 originales. No se trata solo de que el algoritmo funcione, sino de usar esa lógica en una interfaz de celular que responda rápido, casi en tiempo real, validando que sirva de verdad cuando se utiliza.

Surge entonces la duda central: ¿En qué medida la implementación de modelos de visión artificial optimizados para *Edge Computing* permite realizar un diagnóstico preciso de la frescura de alimentos perecederos en dispositivos móviles dentro del contexto doméstico colombiano? La hipótesis apunta a que usar arquitecturas como YOLOv8, ajustadas con los datos específicos del proyecto, permitirá una precisión mayor al 85% a pesar los cambios de luz por sombras o por otros factores. Se asume que si el diagnóstico tarda menos de 3 segundos, el usuario realmente adoptará la herramienta, si no la verá como una herramienta lenta o poco útil. Así, se pasaría de desperdiciar montones de comida a prevenir que se dañe, cumpliendo con los estándares de responsabilidad social que necesita el mundo y que se expresan en algunos ODS como el 12: Producción y consumo responsables; o como el ODS 9: Industria, innovación e infraestructura, ya que estamos llevando innovación a los dispositivos de las personas sin tener que usar servidores gigantes propiedad de compañías muy bien establecidas.

Marco Teórico

Tirar comida a la basura no es solo un dilema ético, sino un golpe seco a la economía y al medio ambiente que golpea con más fuerza en regiones en desarrollo. En Colombia, el panorama resulta bastante crudo; según Villegas Correa (2017), el país desperdicia cerca del 34% de lo que

produce cada año. Las frutas y verduras se llevan la peor parte en esta estadística, debido a que se dañan rápido y resisten poco los errores de logística o almacenamiento. A nivel de hogar, el problema va más allá de comprar de más. Entra en juego una mezcla entre la psicología del consumidor y la forma en como están diseñados los electrodomésticos. De hecho, Waitt y Phillips (2016) señalan que la estructura de las neveras convencionales termina escondiendo los productos. Si algo no es fácilmente visible, se olvida, y lo que se olvida acaba inevitablemente podrido en el fondo de un cajón.

La forma de cerrar esta brecha entre los usuarios y sus alimentos, parecen ser las nuevas tendencias que apuntan al concepto de la "Cocina Inteligente" (Smart Kitchen). Básicamente, se busca conectar la tecnología de Internet de las Cosas (IoT) con los electrodomésticos para que el inventario se gestione más fácilmente y la comida dure más tiempo o al menos no se pierda. Pero esto tiene un problema que surge cuando intentamos meter cámaras en la cocina para que el sistema aprenda, pues tener cámaras en las cocinas es un tema legal y ético que pone a pensar a muchas personas. Golshany et al. (2025) advierten sobre los riesgos de mandar fotos o datos del hogar a servidores externos, subrayando que, en el contexto de las cocinas inteligentes, donde los dispositivos manejan información sensible, las vulnerabilidades representan un riesgo importante para la privacidad y la seguridad de los clientes (p. 10). Por lo que, si se quiere sacar adelante una aplicación como FridgeEye, no se puede ignorar el marco legal colombiano, sobre todo la Ley 1581 de 2012 (Habeas Data). Esto obliga, a replantear el diseño del sistema para que el procesamiento de datos se quede en casa y no termine en riesgo al ser enviado a la nube.

Para resolver estas problemáticas de privacidad, la visión artificial y el *deep learning* ejecutados localmente en los dispositivos parecen ser la mejor opción para revisar la calidad de la comida sin manipularla directamente. Según Gidado et al. (2026), estas herramientas son

capaces de detectar pequeños detalles como texturas, cambios de color o pequeñas deformaciones antes de que el producto se dañe del todo, sin obligar a los usuarios a compartir información con servicios en la nube. Antes, esto dependía únicamente del ojo humano, pero como señalan El-Beltagi et al. (2026), los métodos convencionales de análisis de calidad manuales son normalmente muy tardados, subjetivos e inconsistentes (p. 1). Provocando cuellos de botella en los procesos que puede ser resuelto con estas tecnologías.

Ahora, para que estos sistemas de visión artificial y *deep learning* no fallen al salir del laboratorio, las bases de datos son lo más importante. Unnikrishnan et al. (2026) dejan claro que, si se quiere captar cómo se daña realmente un alimento, hay que usar cámaras comunes y fotos que reflejen condiciones de luz naturales. La idea es que el sistema aprenda a lidiar con las sombras y reflejos que cualquier usuario tiene en su cocina, en lugar de entrenarse con fotos perfectas que no representan la realidad en el día a día.

Dentro de las arquitecturas con las que funcionan estos sistemas de inteligencia artificial (IA), los detectores de un solo disparo (Single-Shot Detectors), como los de la familia *You Only Look Once* (YOLO), parecen ser los que mejores resultados dan hoy en día. Su ventaja es que pueden clasificar objetos de un solo golpe, sin dar vueltas o reintentos innecesarios. Además, al pensar en hardware que no tiene la potencia de una supercomputadora, Aljami et al. (2026) ven en YOLOv8 una gran oportunidad para integrar estos sistemas en dispositivos con menos potencia. Según sus pruebas, el uso de aceleradores de inferencia es clave, ya que el formato *TensorRT Engine* ofreció un rendimiento superior en todas las versiones de YOLOv8, obteniendo reducciones en tiempo de ejecución que variaron entre un 52,4% y un 63,3% en comparación con los formatos de los modelos pesados tradicionales de *PyTorch* (PT) (p. 12). Básicamente, se gana una velocidad brutal sin sacrificar la capacidad de respuesta. Esta

eficiencia se nota todavía más cuando se analizan productos frescos; ahí, Teo y Chaw (2026) muestran que siempre hay una pelea entre qué tan preciso es el modelo y qué tan rápido corre. Sus datos son claros: "Transfer learning improved accuracy across all models; YOLOv11-Large achieved the highest mAP@0.5 of 0.897 but at a reduced frame rate, while the mid-sized YOLOv10-M delivered an mAP@0.5 of 0.890 with superior real-time performance" (p. 1) donde el mAP es la precisión promedio del modelo. Al final, se trata de encontrar ese punto medio donde el sistema sea lo suficientemente inteligente para no fallar, pero lo suficientemente ligero para que no se trabe en un celular o un sensor básico.

Por otro lado, aunque YOLOv8 se destaca por su eficiencia algorítmica, llevar su ejecución a teléfonos inteligentes no es una tarea sencilla debido a cuellos de botella térmicos, limitaciones en la memoria RAM y un consumo de batería que suele dispararse. FridgeEye se apoya entonces en el paradigma de computación en el borde (Edge Computing). Según Lai et al. (2026), la creciente demanda de inteligencia en dispositivos móviles ha provocado que la comprensión de modelos se convierta ampliamente en un enfoque fundamental (p. 1) para dispositivos móviles, demostrando que son una opción viable para mitigar la necesidad de gran capacidad computacional que se pierde al correr modelos en dispositivos IoT o en dispositivos móviles. Al optar por el procesamiento directo en el hardware (la famosa On-device AI) se logra evitar la latencia de transmisión, proteger la privacidad del usuario y, sobre todo, asegurar que la herramienta funcione incluso cuando un usuario no tiene conexión a internet.

El correcto despliegue de un proyecto como el que se plateamos depende completamente de adoptar estrategias como la cuantización, que le permitan al modelo entregar los resultados esperados. Estos procedimientos ajustan la precisión, pasando de un formato de punto flotante de 32 bits (Float32) a enteros de 8 bits (INT8). Al respecto, Bhushan et al. (2025) concluyen que la

implementación de cuantización bajo el ecosistema *TinyML* en modelos convolucionales, resalta la importancia de los intercambios entre precisión, uso de recursos y eficiencia energética (p. 13).

Sin embargo, lograr esta reducción no es tan simple, todo depende de cómo entrenemos el modelo. Maulana y Ramasamy (2026) advierten que, para detectar detalles críticos (como el punto exacto de madurez en una fruta), el Quantization-Aware Training (QAT), que permite al modelo adaptarse a formatos más pequeños (para máquinas con menos potencia por ejemplo) durante el entrenamiento, se mantiene consistentemente superior al Post-Training Quantization (PTQ), que solamente comprime el modelo una vez el entrenamiento a finalizado (p. 3). Así, el cruce entre visión artificial optimizada y procesamiento en el borde (Edge Computing) terminan por configurar el marco tecnológico necesario. Esta arquitectura permite abordar el desperdicio de alimentos en casa de manera eficiente y sin comprometer la privacidad de los usuarios.

Estado del Arte

El desarrollo teórico de este proyecto se basó en una revisión de literatura técnica y científica reciente. Esta primera parte del estado del arte busca detallar el proceso de cómo se identificaron, seleccionaron y sintetizaron los estudios revisados para demostrar transparencia en los fundamentos teóricos y metodológicos.

Fuentes de información

La búsqueda de artículos se realizó a través de bases de datos de alto impacto científico, las bases de datos usadas fueron:

- Scopus: Se seleccionó por el ser la base de datos científica más grande que existe, lo que permitía encontrar información de todos los temas necesarios para esta investigación.
- Springer: Esta base tiene un enfoque en ciencias de la computación e ingeniería, lo que nos da acceso a toda la parte técnica de esta investigación.
- Tayler & Francis: Aunque no está directamente relacionada con la ingeniería, esta base de datos nos permitió darle un segundo enfoque al proyecto en lo social y humano del desperdicio de alimentos.
- Google Scholar: Esta es una base de datos transversal que nos permitió encontrar información de todos los temas que se tocaron, información que no estaba indexada en otras bases de datos más técnicas, como proyectos de grado o información específicamente colombiana.

Estrategia de Búsqueda y criterios de exclusión y aceptación

Las búsquedas y sus respectivos criterios de elegibilidad se organizaron en tres ejes temáticos complementarios, debido a que el proyecto aborda áreas del conocimiento tanto técnicas como sociales.

El primer eje, dedicado a Inteligencia y Visión Artificial, sustentó la elección de YOLOv8 y MobileNetV3 mediante la cadena (“Deep Learning” OR “Computer Vision”) AND (“food freshness detection” OR “fruit quality assessment”). Se aceptaron las investigaciones que utilizaran redes neuronales del tipo YOLOv# y MobileNetV3, aplicaran Transfer Learning a la clasificación de frutas, verduras o productos cárnicos, y presentaran resultados en métricas como mAP, F1-Score o matrices de confusión. Se excluyeron los estudios anteriores a 2019 (salvo aquellos considerados teoría base), los estudios biológicos sobre la maduración de alimentos que

no integraran algoritmos de visión artificial, y los modelos de detección de objetos genéricos sin relación con el área alimentaria.

El segundo eje, dedicado al Impacto Social, Desperdicio de Alimentos y Contexto Local, delimitó la problemática mediante las consultas (“Food waste” OR “food loss”) AND (“household level” OR “domestic refrigeration”) y “Pérdida y desperdicio de alimentos en Colombia” AND “DNP” AND “seguridad alimentaria”. Se aceptaron los reportes internacionales y nacionales sobre pérdida y desperdicio (FAO, DNP), las investigaciones sobre comportamiento del consumidor y gestión doméstica de alimentos, y aquellas que vincularan los ODS 2, 12 y 13 con el desperdicio alimentario. Se descartaron los estudios anteriores a 2019 y las investigaciones enfocadas exclusivamente en desperdicios industriales o logísticos.

El tercer eje, dedicado a Edge AI, Cuantización y Optimización de Modelos, articuló consultas como (“Edge Computing” OR “On-device AI”) AND (“Model Quantization” OR “Pruning”) AND (“TensorFlow Lite” OR “TFLite”), (“Deep Learning” AND “Mobile Vision”) AND (“Inference Latency” OR “Power Consumption”) y (“benchmarking” OR “performance evaluation”) AND (“YOLOv8” OR “MobileNet”) AND (“TFLite” OR “Edge AI”) AND (“latency” OR “inference speed” OR “RAM usage”). Se aceptaron las investigaciones sobre Edge Computing y On-Device AI, las técnicas de cuantización y poda, y los marcos de inferencia móvil como TensorFlow Lite y TensorRT con mediciones empíricas de latencia, consumo energético o tamaño de modelo. Se excluyeron los estudios anteriores a 2019, los modelos tradicionales que requirieran infraestructura avanzada y las investigaciones sin fase de optimización para hardware limitado.

Proceso de selección

El proceso de selección inicio con un total de 22 artículos identificados, de los cuales no se detectó ningún duplicado. La revisión de este mismo número de artículos se centró en títulos, resúmenes y conclusiones para filtrar usando los criterios de aceptación y exclusión anteriormente mencionados. De este grupo de artículos, se analizaron a fondo 15 artículos completos, de los cuales finalmente se seleccionaron los mismos 15 artículos/investigaciones que finalmente fueron usados en la redacción de este documento.

Resumen del Estado del Arte

Los métodos de detección de frescura de los alimentos han cambiado mucho a lo largo del tiempo, pasando por sistemas industriales gigantes y revisiones manuales apegadas a la subjetividad de las personas que revisan cada alimento, ambas funcionando en los mismos lugares de producción. Las investigaciones actuales como las de Singh et al. (2025) y El-Beltagi et al. (2026) dejan claro que las redes neuronales ya resultan más viables que las revisiones manuales (las cuales se describen como “lentas, subjetivas e inconsistentes’ (p. 1, 11)). De todas formas, a pesar de los avances las investigaciones de Singh et al. (2025) enfatizan que variaciones de luz siguen representando un reto para la fiabilidad de los sistemas (p. 1), pues dependiendo de cómo le da la luz al objeto el sistema puede reaccionar de una u otra forma, lo que representa un reto técnico para las implementaciones modernas.

Por otro lado, respecto a la optimización de modelos, las investigaciones de Aljami et al. (2026) y Teo & Chaw (2026) muestran que los modelos YOLO (con sus versiones v8 y v10) son los que mejor funcionan cuando se habla de *edge AI*. Que combinados con cuantización y uso de TensorRT, logran niveles de precisión (mAP@0.5) de más de 89% p(1, 8).


Además, las investigaciones de Ben Aicha (2025) y Bhushan et al. (2025) demuestran que herramientas como TinyML y arquitecturas como las de MobileNet v2 y v3, ayudan a los

modelos a funcionar correctamente en dispositivos con menos recursos (Ben Aicha, 2025, p. 1), consumiendo además menos energía al balancear la precisión y los recursos que el dispositivo usa (Bhushan et al., 2025, p. 1, 14). También, los estudios de Unnikrishnan et al. (2026), enfatizan en la necesidad de capturar imágenes que se apeguen a la realidad de los entornos hogareños haciendo uso de teléfonos comunes y corrientes para tomar fotografías (p.2).

El detalle completo del estado del arte, con los autores, objetivos, metodologías, variables, hallazgos, limitaciones y relación con el proyecto FridgeEye para cada uno de los 15 artículos seleccionados, se presenta en el Anexo 1 (Anexo_1_Estado_del_Arte.xlsx) que acompaña este documento.

Figura 1

Diagrama PRISMA del proceso de identificación, cribado, elegibilidad e inclusión de los artículos científicos



Nota: Elaboración propia a partir del análisis bibliográfico realizado para el proyecto FridgeEye.

Metodología

Para esta investigación se decidió utilizar un enfoque cuantitativo. Esta elección facilita la medición de datos objetivos sobre el rendimiento del algoritmo y permite saber si el modelo de visión artificial elegido es realmente eficiente. Se sigue un diseño no experimental de corte

transversal, ya que no hubo ningún tipo de manipulación de variables, de hecho, se realizó un enfoque en evaluar el modelo de forma directa durante su fase de validación.

Además, el alcance que se determinó para este proyecto es descriptivo-correlacional. Ya que, por un lado, se analizan las capacidades de detección de las arquitecturas livianas antes mencionadas, como YOLOv8 y MobileNetv3, frente a distintos niveles de descomposición de alimentos. Pero, también, se busca establecer esa conexión matemática necesaria entre la compresión del modelo y las variables críticas, como la velocidad de respuesta (latencia) y la precisión obtenida al ejecutar el modelo en un celular, para demostrar con valores numéricos reales la viabilidad de esta propuesta.

Por otro lado, la muestra de datos utilizada para el entrenamiento del modelo final corresponde al dataset denominado internamente en el proyecto como “FridgeEye-1K”, el cual es un dataset público externo de más de 70.000 imágenes etiquetadas de productos perecederos. Si bien el plan original del proyecto contemplaba la consolidación de un dataset propio de al menos 1.000 imágenes mediante la combinación de recursos públicos y la captura adicional con cámaras de teléfonos comunes y corrientes, durante la ejecución se identificó que un dataset externo de mayor escala ofrecía una base más sólida para el entrenamiento al cubrir una variedad mucho más amplia de productos, estados de descomposición y condiciones lumínicas. Sobre dicho dataset el equipo aplicó un proceso de curaduría que incluyó la verificación del etiquetado, el balance entre las clases fresco y deteriorado y la eliminación de imágenes con problemas de calidad (resoluciones insuficientes, etiquetas inconsistentes o muestras redundantes), consolidando finalmente alrededor de 50.000 imágenes útiles para el entrenamiento. Esta decisión metodológica está alineada con los protocolos de Unnikrishnan et al. (2026), quienes demostraron que la captura de imágenes con dispositivos comerciales y bajo condiciones

lumínicas variables ayuda al modelo a lograr una generalización más robusta para los escenarios reales de uso del sistema (p. 2, 9).

En cuanto a las herramientas que se usaran para el desarrollo del modelo se usarán los entornos de *TensorFlow Lite* (validado para microcontroladores por Ben Aicha (2025)) y *TensorRT* (discutido para dispositivos de alto rendimiento por Maulana y Ramasamy (2026)), Ben Aicha determino que la cuantización a enteros de 8 bits, ofrecida por estas dos herramientas, es un procedimiento indispensable para evitar desbordamientos de memoria (*buffer overflows*) en dispositivos limitados (p. 1), básicamente para reducir los recursos usados por el modelo durante su ejecución, garantizando así unos tiempos de inferencia estables y reducidos. De esa forma el procesamiento técnico del modelo se dividirá en tres fases: El entrenamiento base del algoritmo mediante transferencia (*Transfer Learning*), la optimización del modelo durante su entrenamiento y no al final, mediante el uso de QAT, validado por Maulana y Ramasamy (2026) (p. 3); y finalmente el despliegue de todo el sistema en el dispositivo a través de *edge computing*, en este caso *edge AI*.

Por último, para validar la información recolectada durante las pruebas se dará uso de herramientas nativas del análisis de datos como Python con librerías como Pandas y TensorBoard. La validación de esta información se dividirá en dos grandes partes. En primer lugar, la evaluación del algoritmo ante el desbalance natural de clases, pues los alimentos podridos son estadísticamente menos frecuentes que los alimentos en buen estado, para ello se usará el Coeficiente de Correlación de Matthews (MCC) recomendado por Maulana y Ramasamy (2026) debido a su rigor estadístico ante estos casos de desbalance de clases (p. 3, 18), además, se usará la métrica de presión media promedio (mAP) estandarizada por Teo y Chaw (2026)(p. 1), junto con las métricas de F1-Score. Ahora ya con la validación del

funcionamiento del modelo, en segundo lugar, para validar los requerimientos no funcionales del sistema, se usarán técnicas de medición de desempeño en el borde como las documentadas por Aljami et al. (2026), cuantificando empíricamente la latencia de extremo a extremo (*End-to-End Latency*) y el rendimiento en cuadros por segundo (*FPS*) (p. 12) del procesamiento local.

Resultados

Los resultados obtenidos durante el desarrollo del proyecto FridgeEye se organizan en dos bloques complementarios. En primer lugar, se presentan los hallazgos del entrenamiento y validación del modelo de visión artificial encargado de discriminar entre alimentos frescos y deteriorados a partir de imágenes capturadas por la cámara del teléfono. En segundo lugar, se describen los resultados del desarrollo del prototipo de aplicación móvil que integra ese modelo en una interfaz nativa para el usuario doméstico. La organización de ambos bloques sigue el orden de los productos derivados de los objetivos específicos del proyecto.

Resultados del entrenamiento del modelo de visión artificial

Configuración experimental

El modelo final se entrenó sobre la arquitectura YOLO en modalidad de detección, partiendo de pesos pre-entrenados sobre el dataset COCO mediante la técnica de Transfer Learning. La Tabla 1 sintetiza los parámetros principales de la configuración experimental utilizada para el entrenamiento del modelo final.

Tabla 1

Configuración experimental del entrenamiento del modelo de visión artificial

Categoría	Parámetro	Valor
Arquitectura	Modelo base	YOLO (modalidad de detección)

Arquitectura	Inicialización	Pesos pre-entrenados sobre COCO (Transfer Learning)
Entrenamiento	Épocas máximas	120 (parada temprana de 25 sin mejora)
Entrenamiento	Tamaño de lote	32 imágenes
Entrenamiento	Resolución de entrada	640 × 640 píxeles
Entrenamiento	Precisión	Mixta (AMP) activada
Entrenamiento	Semilla aleatoria	Fija
Optimización	Optimizador	AdamW
Optimización	Tasa de aprendizaje	0,001 inicial con decaimiento coseno
Optimización	Momento	0,937
Optimización	Decaimiento de pesos	0,0005
Pérdidas	Box loss (cajas)	7,5
Pérdidas	Class loss	0,5
	(clasificación)	
Pérdidas	DFL loss (distribución focal)	1,5
Aumentación	HSV	h=0,02; s=0,75; v=0,4
Aumentación	Volteo vertical	Probabilidad 0,3
Aumentación	Volteo horizontal	Probabilidad 0,5
Aumentación	Mosaic	Probabilidad 1,0

Aumentación	Mixup	Probabilidad 0,1
Aumentación	Copy-paste	Probabilidad 0,1
Aumentación	Erasing	Probabilidad 0,3
Aumentación	RandAugment	Activado
Entorno	Hardware	GPU Nvidia (Google Colab)
Entorno	Tiempo total	~22.346 s (~6 h 12 min)

Nota: Parámetros utilizados en el entrenamiento del modelo final del proyecto


FridgeEye.

Curvas de entrenamiento y validación

La Figura 2 presenta la evolución de las funciones de pérdida y de las métricas de validación a lo largo de las 120 épocas de entrenamiento. En la fila superior se observan las pérdidas de entrenamiento (box loss, class loss y DFL loss) junto con las métricas de precisión global y recall global, mientras que la fila inferior muestra las pérdidas de validación equivalentes y las métricas mAP@0,5 y mAP@0,5–0,95.

Figura 2

Evolución de las funciones de pérdida y de las métricas de validación durante las 120 épocas de entrenamiento del modelo final.



Nota: Fuente: salida del proceso de entrenamiento del proyecto.

Los valores inicial y final de cada serie graficada en la Figura 2 son los siguientes: el mAP@0,5 pasó de 0,803 en la primera época a 0,985 en la última; el mAP@0,5–0,95 pasó de 0,516 a 0,908; la precisión global pasó de 0,733 a 0,950; y el recall global pasó de 0,771 a 0,958. Las pérdidas de entrenamiento partieron de valores cercanos a 0,889 (box), 1,185 (cls) y 1,427 (df_l) y descendieron hasta 0,305, 0,239 y 1,040 respectivamente. Las pérdidas de validación correspondientes pasaron de 1,211, 0,971 y 1,982 a 0,405, 0,294 y 0,999 al final del entrenamiento.

Métricas finales de desempeño

Los valores obtenidos en la última época de entrenamiento, correspondientes al modelo seleccionado como solución final, se sintetizan en la Tabla 2.

Tabla 2

Métricas finales del modelo de visión artificial sobre el conjunto de validación.

Métrica	Valor	Interpretación
---------	-------	----------------

Precisión global (P)	0,9501 (95,0 %)	Proporción de detecciones correctas sobre el total de detecciones realizadas.
Recall global (R)	0,9581 (95,8 %)	Proporción de objetos reales correctamente detectados por el modelo.
mAP@0,5	0,9846 (98,5 %)	Precisión promedio con umbral de IoU de 0,5; mide la calidad global de detección.
mAP@0,5–0,95	0,9078 (90,8 %)	Promedio del mAP en umbrales de IoU de 0,5 a 0,95; mide la calidad espacial estricta.
F1-Score máximo (todas las clases)	0,95	F1 combinado óptimo, alcanzado en un umbral de confianza de 0,477.
Pérdida de validación (box)	0,4051	Error en la localización de las cajas delimitadoras.
Pérdida de validación (cls)	0,2937	Error en la clasificación entre Fresco y Deteriorado.
Pérdida de validación (DFL)	0,9987	Error en la distribución focal sobre las cajas predichas.

Nota: Valores obtenidos al cierre de la época 120 del proceso de entrenamiento del modelo final sobre el conjunto de validación.


El conjunto de métricas reportadas en la Tabla 2 corresponde a la evaluación del modelo sobre el conjunto de validación al cierre de la época 120, manteniendo los hiperparámetros descritos en la subsección de configuración experimental.

Matriz de confusión por clase

La Figura 3 presenta la matriz de confusión normalizada del modelo final sobre el conjunto de validación, con las dos clases de interés fresco y deteriorado y la clase residual background propia de la formulación YOLO.

Figura 3

Matriz de confusión normalizada del modelo final sobre el conjunto de validación



Nota: Cada celda representa la proporción de muestras de la clase verdadera (eje horizontal) que fueron predichas como la clase de la fila (eje vertical).


Los valores reportados en la matriz son los siguientes: el 97 % de las muestras reales de la clase Fresco fueron predichas como Fresco y el 1 % como Deteriorado; el 97 % de las muestras reales de la clase Deteriorado fueron predichas como Deteriorado y el 2 % como Fresco. La columna correspondiente a la clase background presenta valores de 0,60 para predicciones como Fresco y 0,40 para predicciones como Deteriorado.

Curvas F1-Confidence y Precision-Recall

Las Figuras 4 y 5 presentan, respectivamente, la curva F1-Confidence y la curva Precision-Recall del modelo final sobre el conjunto de validación.

Figura 4


Curva F1-Confianza del modelo final



Nota: La línea azul gruesa corresponde al promedio sobre todas las clases y alcanza un máximo de 0,95 a un umbral de confianza de 0,477.

Figura 5

Curva Precision-Recall del modelo final



Nota: Valores de $AP@0,5$ de 0,981 para la clase Fresco, 0,989 para Deteriorado y 0,985 para el promedio sobre ambas clases ($mAP@0,5$).

En la curva F1-Confianza, el F1-Score combinado alcanza su valor máximo de 0,95 a un umbral de confianza de 0,477. En la curva Precision-Recall, los valores de $AP@0,5$ reportados son de 0,981 para la clase Fresco, 0,989 para la clase Deteriorado y 0,985 como promedio sobre ambas clases ($mAP@0,5$).

Resultados del desarrollo del prototipo de aplicación móvil

El segundo bloque de resultados corresponde al prototipo funcional de aplicación móvil que integra el modelo de visión artificial entrenado. El desarrollo se estructuró sobre cuatro pantallas accesibles desde una barra de navegación inferior persistente: una vista de inicio con el resumen del inventario, la captura de imágenes mediante la cámara del dispositivo, la gestión detallada del inventario por producto y la exploración del histórico de capturas en una galería.

Arquitectura general de la aplicación

La aplicación se construyó con una arquitectura modular dividida en cuatro vistas principales, accesibles desde una barra de navegación inferior persistente compuesta por los

íconos de inicio, cámara, inventario y galería. El modelo de visión artificial se carga en memoria al iniciar la aplicación y se invoca localmente cada vez que el usuario captura una imagen. La persistencia de los productos identificados se realiza también de manera local, en el almacenamiento del propio teléfono.

Pantalla de inicio y resumen del inventario

La Figura 6 muestra la pantalla de inicio de la aplicación. En la parte superior se ubica el encabezado con el logo y el nombre de la marca FridgeEye y un indicador de notificaciones. A continuación se presenta una tarjeta principal con un saludo personalizado, un mensaje contextual y la etiqueta Nevera activa, acompañada de íconos que indican categorías de productos. La sección inferior consolida tres indicadores numéricos del inventario: el total de alimentos registrados, los que se encuentran próximos a vencer y los que aún están frescos. Por debajo, una lista de alimentos recientes presenta los últimos productos diagnosticados, mostrando para cada uno su nombre y una etiqueta visual con el resultado de la clasificación.

Figura 6

Pantalla de inicio de la aplicación móvil FridgeEye




Nota: Tarjeta de bienvenida, indicadores agregados del inventario y listado de alimentos recientes.

Pantalla de captura por cámara

La Figura 7 corresponde a la pantalla de captura por cámara, accesible desde la barra de navegación inferior. Esta vista habilita el sensor del teléfono y muestra el cuadro de captura con un marco verde que delimita la zona donde se ubica el alimento o la sección del refrigerador. Una instrucción textual en la parte inferior del marco, “Coloca el alimento dentro del marco”, guía el encuadre. El botón circular central activa la captura y desencadena el procesamiento local de la imagen mediante el modelo de visión artificial.

Figura 7

Pantalla de captura por cámara de la aplicación móvil FridgeEye



Nota: Marco visual de encuadre y botón de captura. La inferencia se ejecuta íntegramente en el dispositivo.

Pantalla de inventario detallado

La Figura 8 presenta la pantalla de inventario. En la parte superior, un campo de búsqueda permite filtrar el inventario por nombre del alimento. Cada producto se presenta en una tarjeta independiente que incluye su nombre, la cantidad de unidades registradas y una o más etiquetas visuales que indican el estado de frescura diagnosticado por el modelo. A la derecha de cada tarjeta se ubican dos botones de acción rápida: uno para confirmar el consumo o procesamiento del producto y otro para eliminarlo del inventario.

Figura 8

Pantalla de inventario detallado de la aplicación móvil FridgeEye



Nota: Campo de búsqueda, tarjetas por producto y acciones rápidas de confirmación y eliminación.

Pantalla de galería de capturas

La Figura 9 muestra la pantalla de galería, que despliega el historial de imágenes capturadas a través de la cámara de la aplicación, asociadas con sus respectivas etiquetas de clasificación. Cuando aún no se han realizado capturas, la galería presenta un estado vacío informativo que invita al usuario a tomar su primera fotografía desde la pestaña Cámara.

Figura 9

Pantalla de galería de capturas de la aplicación móvil FridgeEye

Galería

Sin fotos aún



No hay fotos todavía

Las fotos tomadas con la cámara
aparecerán aquí



Inicio



Cámara



Inventario



Galería

Nota: Estado vacío inicial que se presenta antes de la primera utilización de la cámara.

Análisis de Resultados

Esta sección interpreta los hallazgos presentados en el capítulo anterior frente a los objetivos específicos del proyecto, a la pregunta de investigación que orientó el estudio y a la literatura científica revisada bajo el protocolo PRISMA. El análisis se organiza en tres bloques: el primero examina el desempeño del modelo de visión artificial, el segundo evalúa la solución materializada en el prototipo móvil y el tercero confronta el conjunto de resultados con la hipótesis y la pregunta inicial del proyecto.

Análisis del modelo de visión artificial

Estabilidad y convergencia del entrenamiento

El comportamiento de las curvas presentadas en la Figura 2 evidencia un proceso de entrenamiento estable y bien calibrado, dividido en tres etapas. En la primera etapa, que abarca las primeras veinte épocas, las pérdidas decrecen de forma pronunciada y las métricas escalan rápidamente: el $mAP@0,5$ pasa de 0,803 a valores cercanos a 0,98 en este lapso, lo que indica que el modelo absorbe rápidamente las características discriminantes entre alimentos frescos y deteriorados gracias al aprovechamiento de los pesos pre-entrenados sobre COCO mediante la técnica de Transfer Learning. En la segunda etapa, entre las épocas veinte y cien, las métricas mantienen una mejora gradual y consistente, sin oscilaciones bruscas que sugieran inestabilidad o sobreajuste. Finalmente, a partir de la época ciento diez se observa la estabilización característica del decaimiento coseno, lo que confirma que el modelo alcanzó la convergencia plena dentro del presupuesto de épocas planeado.

Un aspecto clave del análisis es el alineamiento estrecho entre las curvas de entrenamiento y las de validación a lo largo de todo el proceso. Las pérdidas de validación se mantienen consistentemente por debajo de las de entrenamiento, y las métricas de validación por encima, sin que se observe un punto de divergencia evidente. Este comportamiento descarta señales de sobreajuste y confirma que las técnicas de aumentación de datos elegidas, en particular mosaic, mixup y RandAugment, cumplieron su función de fortalecer la generalización del modelo frente a las variaciones lumínicas y de oclusión típicas del entorno doméstico. El hecho de que el entrenamiento haya completado las 120 épocas sin disparar el criterio de parada temprana refuerza esta lectura: el modelo siguió mejorando hasta el final del presupuesto computacional disponible.

Cumplimiento de las metas de desempeño

El conjunto de métricas finales reportadas en la Tabla 2 supera ampliamente las metas operativas planteadas en la metodología del proyecto. La meta operativa principal, un F1-Score superior al 85 %, no solo se cumple sino que se excede en diez puntos porcentuales: el F1-Score máximo del modelo alcanza el 95 %. La precisión global de 95,0 % y el recall global de 95,8 % indican un balance casi simétrico entre falsos positivos y falsos negativos, sin sesgos sistemáticos hacia ninguna de las dos clases.

En cuanto a las métricas de detección, el $\text{mAP}@0,5$ de 98,5 % confirma que prácticamente todos los objetos relevantes son correctamente detectados por el modelo cuando se aplica el umbral estándar de Intersección sobre Unión (IoU) de 0,5. Más exigente es el $\text{mAP}@0,5-0,95$, que promedia el desempeño sobre umbrales de IoU de 0,5 a 0,95 en pasos de 0,05 y alcanza el 90,8 %. La diferencia de aproximadamente ocho puntos porcentuales entre ambas métricas es consistente con el comportamiento típico de los modelos YOLO sobre datasets bien etiquetados y refleja un balance adecuado entre la clasificación correcta de los productos y la delimitación precisa de las cajas que los encierran. Este resultado va en línea con los hallazgos de Teo y Chaw (2026), quienes reportaron un $\text{mAP}@0,5$ de 0,897 en YOLOv11-Large sobre un dataset de productos frescos comparable, e incluso supera esos valores de referencia gracias al volumen y a la diversidad del corpus utilizado en este proyecto.

Calidad de la clasificación por clase

La matriz de confusión presentada en la Figura 3 evidencia un desempeño altamente equilibrado entre las dos clases de interés. El 97 % de las muestras reales de Fresco se predicen correctamente como Fresco y el 97 % de las muestras reales de Deteriorado se clasifican correctamente como Deteriorado. La confusión cruzada entre ambas clases es residual y casi simétrica, ya que solo el 1 % de los Frescos se predice erróneamente como Deteriorado y solo el

2 % de los Deteriorados se predice erróneamente como Fresco. Desde una perspectiva práctica para el caso de uso doméstico, este patrón es particularmente favorable, ya que tanto los falsos positivos (alimentos frescos marcados como deteriorados) como los falsos negativos (alimentos deteriorados marcados como frescos) ocurren con frecuencia comparable y muy baja, evitando así un sesgo conservador o permisivo del sistema.

Las celdas correspondientes a la clase background, con valores de 0,60 hacia Fresco y 0,40 hacia Deteriorado, reflejan el comportamiento esperado de los detectores YOLO ante regiones de imagen que no contienen objetos. Estas celdas no afectan la calidad del diagnóstico de frescura sobre los productos efectivamente detectados, ya que se refieren a la asignación de la clase de fondo durante el cálculo del mAP, y son consistentes con los benchmarks reportados por Aljami et al. (2026) sobre el comportamiento de las variantes YOLOv8 en hardware de borde.

Selección del umbral de confianza

Las curvas paramétricas presentadas en las Figuras 4 y 5 permiten extraer dos conclusiones operativas relevantes para el despliegue del modelo en la aplicación móvil. La curva F1-Confianza muestra que el F1-Score combinado alcanza su máximo de 0,95 en un umbral de confianza de 0,477, valor que será adoptado como umbral por defecto en la inferencia del prototipo. Adicionalmente, la curva se mantiene por encima de 0,90 en un rango amplio de umbrales que va aproximadamente de 0,15 a 0,85, lo que indica una tolerancia importante del modelo frente a la calibración del umbral. Esta robustez descarta la necesidad de ajustes finos para los distintos escenarios de uso previstos en el hogar y simplifica la operación del sistema para el usuario final.

La curva Precision-Recall, por su parte, ratifica la calidad de la separación entre las clases con valores de AP@0,5 de 0,981 para Fresco y 0,989 para Deteriorado, ambos por encima del

98 %. La forma de la curva, prácticamente plana en el rango superior antes de descender abruptamente cerca de recall igual a 1, es característica de los detectores que operan con un margen amplio de seguridad y confirma que el modelo es apto para los escenarios domésticos reales planteados en el alcance del proyecto.

Análisis del prototipo de aplicación móvil

Cobertura funcional frente a los objetivos del proyecto

El prototipo de aplicación móvil presentado en las Figuras 6 a 9 cubre el flujo completo de uso previsto en los objetivos del proyecto. La pantalla de inicio (Figura 6) cumple la función de tablero ejecutivo del inventario, ofreciendo al usuario una visión inmediata del estado de sus alimentos sin necesidad de abrir vistas adicionales. La pantalla de captura por cámara (Figura 7) materializa el momento operativo central del sistema, donde se ejecuta el modelo de visión artificial entrenado para emitir el diagnóstico de frescura. La pantalla de inventario (Figura 8) ofrece la gestión detallada producto a producto, con acciones de consumo o descarte que cierran el ciclo de uso. Finalmente, la pantalla de galería (Figura 9) actúa como repositorio visual del historial de inferencias, permitiendo al usuario revisar y validar las clasificaciones del modelo a posteriori.

Esta cobertura responde directamente al objetivo general del proyecto, que planteaba la creación de un prototipo de aplicación móvil capaz de clasificar la frescura de productos perecederos en el contexto doméstico colombiano. Cada una de las cuatro pantallas atiende uno de los momentos del flujo de usuario, sin redundancias ni vacíos funcionales evidentes en el alcance planteado.

Cumplimiento del paradigma On-device AI

Uno de los pilares del proyecto consiste en la ejecución exclusivamente local de la inferencia, decisión que da cumplimiento por diseño a la Ley 1581 de 2012 (Habeas Data). La arquitectura del prototipo, en la que el modelo se carga en memoria al iniciar la aplicación y se invoca localmente con cada captura sin que la imagen abandone el dispositivo en ningún momento, materializa este pilar de forma directa. La persistencia de los productos identificados se realiza también en el almacenamiento local del teléfono, lo que evita por completo la categoría jurídica de transferencia internacional de datos y elimina los requisitos administrativos asociados a la autorización del titular para el manejo de imágenes capturadas en el interior del hogar.

Esta decisión arquitectónica responde directamente a las advertencias documentadas por Golshany et al. (2025), quienes alertan sobre los riesgos de privacidad asociados a las cocinas conectadas mediante IoT que transmiten información sensible a servidores externos (p. 10), y confirma la pertinencia del paradigma On-device AI defendido a lo largo del marco teórico del proyecto.

Diseño de interacción y experiencia de usuario

Más allá del cumplimiento funcional, el prototipo incorpora varios elementos de diseño que apuntan a una experiencia de usuario fluida y de baja curva de aprendizaje. La barra de navegación inferior persistente con los íconos de Inicio, Cámara, Inventario y Galería ofrece al usuario una referencia constante de su posición dentro de la aplicación y facilita la transición entre funcionalidades sin necesidad de menús anidados. La codificación cromática del prototipo, con verde para acciones positivas o estados de frescura saludables y rojo para acciones de descarte o estados de vencimiento, refuerza la legibilidad y reduce la carga cognitiva sobre el usuario. El marco verde de la pantalla de cámara y la instrucción textual asociada guían al

usuario hacia una captura óptima, condición necesaria para que el modelo opere sobre imágenes con la calidad mínima requerida.

Verificación de la hipótesis y respuesta a la pregunta de investigación

La pregunta de investigación que orientó el estudio interrogaba en qué medida la implementación de modelos de visión artificial optimizados para Edge Computing permite realizar un diagnóstico preciso de la frescura de alimentos perecederos en dispositivos móviles dentro del contexto doméstico colombiano. La hipótesis asociada sostenía que la utilización de arquitecturas como YOLOv8, ajustadas con los datos específicos del proyecto, permitiría una precisión superior al 85 % a pesar de las variaciones lumínicas y de los demás factores propios del entorno real.

Los resultados obtenidos confirman la hipótesis con un margen considerable: el F1-Score alcanzado por el modelo final asciende al 95 %, esto es, diez puntos porcentuales por encima de la meta operativa, y el mAP@0,5 supera el 98 %. El alineamiento entre las curvas de entrenamiento y de validación, junto con la simetría de la confusión cruzada entre clases, indica que el modelo es robusto frente a las condiciones que la hipótesis identificaba como críticas, esto es, cambios de luz y oclusiones. La adopción del corpus público externo de gran escala, en lugar del dataset propio de pequeña escala inicialmente planeado, contribuyó significativamente a este resultado al exponer al modelo a una variedad mucho mayor de productos, estados de descomposición y condiciones de captura.

Por su parte, la integración del modelo en el prototipo móvil bajo el paradigma On-device AI da respuesta operativa a la pregunta de investigación: el diagnóstico de frescura es viable en el contexto doméstico colombiano siempre que se transite hacia arquitecturas Edge Computing que mantengan el procesamiento dentro del dispositivo. Este enfoque resuelve simultáneamente

las restricciones técnicas, legales y de privacidad identificadas en el marco teórico y materializa la propuesta innovadora del proyecto sobre la base de tecnología disponible y financieramente viable, según se documentó en la sección de prefactibilidad económica del trabajo.

Propuesta de Solución

Esta sección presenta la propuesta integral de solución del proyecto FridgeEye, que articula la solución técnica desarrollada con un modelo de negocio sostenible, un análisis de costos y de viabilidad económica, y un análisis del aporte del proyecto al desarrollo sostenible. La propuesta se construye sobre los productos descritos en la sección de resultados (el modelo de visión artificial entrenado y el prototipo de aplicación móvil) y los proyecta hacia un escenario de despliegue real en el mercado colombiano.

Síntesis de la Solución de Ingeniería

La solución consiste en una aplicación móvil nativa que ejecuta de manera local un modelo de visión artificial basado en la arquitectura YOLO para diagnosticar el estado de frescura de alimentos perecederos. La aplicación se compone de cuatro pantallas funcionales (inicio, cámara, inventario y galería) que cubren el flujo completo del usuario doméstico y se apoya en un stack tecnológico maduro y de código abierto: TensorFlow Lite y TensorRT para la inferencia local, PyTorch para el entrenamiento, el dataset FridgeEye-1K (dataset público externo auditado por el equipo) para el aprendizaje del modelo y las cámaras nativas del smartphone como sensor de entrada. El diferenciador competitivo de la propuesta reside en la conjunción de tres elementos: el procesamiento 100 % On-Device, que cumple por diseño la Ley 1581 de 2012. La adopción de un dataset de gran escala con revisión dirigida a las condiciones reales del refrigerador doméstico, y un modelo entrenado con métricas que superan los benchmarks reportados en la literatura reciente sobre Edge AI aplicado a productos perecederos.

Modelo de Negocio y Oferta de Valor

El modelo de negocio se estructura sobre un esquema mixto B2C y B2B que aprovecha la baja estructura de costos recurrentes derivada del paradigma On-Device. En el segmento B2C, la oferta principal es FridgeEye App Premium, una suscripción anual dirigida al usuario doméstico con un precio inicial de \$60.000 COP por usuario al año y una base proyectada de 1.500 usuarios en el primer año. En el segmento B2B, la oferta es FridgeEye Enterprise, una licencia anual dirigida a retailers, supermercados independientes y servicios de alimentación, con un precio inicial de \$950.000 COP por contrato y una base inicial proyectada de ocho clientes.

La oferta de valor diferenciada se sostiene en cuatro elementos. En primer lugar, el diagnóstico automático y específico de frescura reemplaza la inspección humana subjetiva y reduce el desperdicio al alertar de forma anticipada sobre los productos próximos a vencer. En segundo lugar el procesamiento local elimina la necesidad de conexión a internet permanente y garantiza el cumplimiento de la Ley 1581 sin gestiones administrativas adicionales. En tercer lugar, la compatibilidad con teléfonos de gama media amplía el mercado potencial al no requerir hardware premium. Finalmente, el dataset curado para el contexto agroalimentario hace que la precisión del modelo se mantenga alta sobre productos comunes.

Análisis de costos

El análisis de costos del proyecto a un horizonte de cinco años fue desarrollado con el simulador financiero proveído por la universidad y se estructura en costos fijos, costos variables y costo del producto. El detalle completo del modelo financiero se encuentra en el Anexo 2 (Simulador_financiero_fridgeeye.xlsx) que acompaña este documento.

Costos fijos

Los costos fijos del primer año totalizan aproximadamente \$41.020.000 COP y agrupan los rubros que el proyecto debe cubrir independientemente del volumen de ventas. El componente más representativo corresponde a la nómina técnica, con \$18.000.000 COP destinados al equipo de aprendizaje automático y desarrollo móvil. La nómina administrativa asciende a \$9.360.000 COP y la nómina de ventas y mercadeo digital a \$6.000.000 COP. Los gastos fijos operativos suman \$3.530.000 COP y se distribuyen entre arriendo (\$2.500.000 COP), servicios públicos (\$250.000 COP), telefonía (\$125.000 COP), internet (\$350.000 COP), papelería (\$25.000 COP), pólizas de seguros (\$200.000 COP) y dominio y hosting del sitio web (\$80.000 COP). Una decisión arquitectónica fundamental se refleja en el área de outsourcing de servicios cloud, que se reduce a \$600.000 COP anuales al eliminar la inferencia alojada en servidores externos, frente a los aproximadamente \$2.400.000 COP típicos de un esquema cloud equivalente. A estos costos fijos se suma un presupuesto de marketing de \$8.000.000 COP en el año uno, que decrece de manera gradual en los años posteriores.

Costos variables

Los costos variables del proyecto están dominados por la comisión de los marketplaces de aplicaciones móviles, que asciende al 30 % del precio de venta tanto en Google Play como en App Store, y por los costos de soporte y atención al cliente que escalan con la cantidad de usuarios activos en la app. En el modelo de negocio planteado, el costo variable por usuario del segmento B2C se sitúa en aproximadamente \$12.000 COP anuales, equivalente al 20 % del precio de venta, valor que incluye la comisión del marketplace y un margen para soporte. En el segmento B2B, el costo variable por contrato se sitúa en \$120.000 COP anuales, equivalente al 12,6 % del precio, valor que incluye soporte técnico personalizado y el acompañamiento de la integración por parte del equipo de la empresa cliente.

Costo del producto y modelo de negocio

El costo unitario del producto, entendido como el costo marginal de servir un usuario adicional una vez que el modelo está entrenado y la aplicación desplegada, se mantiene por debajo de los \$15.000 COP en el segmento B2C y de los \$150.000 COP en el segmento B2B. Esta estructura de costos marginales bajos es característica del paradigma On-Device, ya que el modelo se ejecuta en el dispositivo del usuario y no consume recursos centralizados del operador. El margen bruto resultante por venta supera el 80 % en ambos segmentos, lo cual habilita la escalabilidad del modelo de negocio sin necesidad de crecer la infraestructura del operador en proporción al número de usuarios servidos.

Análisis de viabilidad económica

La inversión total requerida en el año cero del proyecto asciende a \$42.160.000 COP, distribuida entre \$12.000.000 COP de inversión fija (que incluye equipos de cómputo para entrenamiento, dispositivos de prueba, intangibles del registro de propiedad intelectual y gastos de puesta en marcha) y \$30.160.000 COP de capital de trabajo para seis meses de costos operativos, nómina técnica y marketing de lanzamiento. La estructura de financiación se planteó como un esquema mixto en el que los fundadores aportan el 50 % de la inversión (\$21.080.000 COP) y el 50 % restante se cubre mediante un crédito bancario al 15 % anual a tres años.

La evaluación financiera a cinco años, descontada a una tasa de evaluación del 15 % equivalente al costo de oportunidad del capital, arroja un Valor Presente Neto (VPN) de \$103.252.278 COP, una Tasa Interna de Retorno (TIR) del 59,03 % anual y un Retorno sobre la Inversión (ROI) del 143,29 % al cierre del primer año, calculado sobre la inversión fija inicial. El período de recuperación de la inversión se sitúa en 1,67 años, lo que confirma que el flujo de caja libre acumulado al cierre del segundo año ya supera el desembolso inicial. La interpretación

conjunta de estos indicadores valida la viabilidad económica del proyecto con un margen amplio frente a la tasa de evaluación del 15 %, y posiciona la eliminación de los costos recurrentes de inferencia en la nube como la principal palanca de generación de valor frente al esquema cloud equivalente.

Análisis de sostenibilidad

El aporte del proyecto al desarrollo sostenible se materializa en su contribución a tres Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas. En primer lugar, el proyecto se alinea con el ODS 12 (Producción y consumo responsables), específicamente con la meta 12.3, que busca reducir a la mitad el desperdicio mundial de alimentos per cápita para 2030. Cada kilogramo de alimento que el sistema FridgeEye permita salvar evita aproximadamente 2,5 kilogramos de CO₂ equivalente, según las estimaciones de la FAO (2019). En un hogar colombiano promedio que desperdicia cerca de 41 kilogramos de alimentos al año, la adopción efectiva del sistema podría traducirse en una reducción de hasta 100 kilogramos de CO₂ equivalente por hogar al año.

En segundo lugar, el proyecto se alinea con el ODS 13 (Acción por el clima) mediante una doble contribución: la reducción de las emisiones de metano por descomposición anaerobia de residuos orgánicos en rellenos sanitarios y la eliminación del consumo eléctrico asociado a la inferencia cloud 24/7. Esta segunda contribución es estructural del paradigma On-Device, ya que cada inferencia ejecutada localmente en el dispositivo del usuario evita el consumo energético de un servidor centralizado. Si bien el impacto unitario por inferencia es bajo, agregado al volumen potencial de usuarios constituye una reducción significativa de la huella energética del sector de inteligencia artificial aplicada al consumo masivo.

En tercer lugar, el proyecto se alinea con el ODS 9 (Industria, innovación e infraestructura) al demostrar que la innovación puede llegar al hogar sin demandar infraestructura corporativa compleja ni grandes inversiones en hardware especializado. El uso de teléfonos inteligentes de gama media como plataforma de despliegue democratiza el acceso a la inteligencia artificial y reduce las barreras tecnológicas y económicas que históricamente han limitado la adopción de soluciones de visión artificial en el ámbito doméstico de los países en desarrollo.

Discusión

Esta sección interpreta el conjunto de hallazgos del proyecto FridgeEye a la luz de la literatura científica revisada en el marco teórico y el estado del arte, identifica las implicaciones técnicas, prácticas y empresariales de los resultados obtenidos, y reconoce de manera explícita las limitaciones del estudio para acotar el alcance de las conclusiones que se derivan en la siguiente sección.

Contraste con la Literatura Previa

Los resultados del modelo entrenado se posicionan por encima de los benchmarks reportados en los estudios incluidos en la revisión sistemática del proyecto. Teo y Chaw (2026) reportaron un $mAP@0,5$ de 0,897 sobre un dataset de productos frescos comparable, valor que el modelo de FridgeEye supera con un $mAP@0,5$ de 0,985 gracias a la mayor escala del dataset usado y a la configuración rigurosa de Transfer Learning y aumentación de datos descrita en la sección de metodología. Por su parte, Aljami et al. (2026) demostraron la viabilidad de las variantes de YOLOv8 sobre hardware embebido, hallazgo que este trabajo extiende al contexto específico del diagnóstico de frescura. La superioridad del Quantization-Aware Training (QAT) frente al Post-Training Quantization (PTQ) reportada por Maulana y Ramasamy (2026) se

reconoce como una decisión metodológica recomendada para futuras iteraciones del modelo, en las que la cuantización a INT8 será aplicada para reducir el tamaño del modelo y la latencia de inferencia en dispositivos móviles.

Implicaciones Para el Sector

Las implicaciones de los hallazgos trascienden el alcance específico del prototipo. Desde una perspectiva técnica, el proyecto demuestra que el paradigma On-Device AI es viable en hardware móvil de gama media para tareas de visión artificial de complejidad moderada, lo cual abre la puerta a su adopción en otros dominios del consumo masivo (cosmética, medicamentos, prendas de vestir). Desde una perspectiva regulatoria, el caso FridgeEye ilustra cómo el cumplimiento estricto de la Ley 1581 puede convertirse en una idea competitiva sostenible frente a soluciones cloud foráneas, en línea con las advertencias de Golshany et al. (2025) sobre los riesgos de privacidad asociados al IoT en el hogar. Desde una perspectiva empresarial, la estructura de costos del modelo On-Device, en la que el costo marginal por usuario tiende a cero una vez desplegado el modelo, habilita modelos de negocio escalables sin la fricción de la infraestructura cloud.

Limitaciones del Estudio

El estudio reconoce de manera explícita varias limitaciones que acotan el alcance de los hallazgos. En primer lugar, el modelo entrenado se conservó en precisión completa (FP32) y la cuantización a INT8 mediante QAT, planteada como meta operativa en la metodología, queda como un paso de optimización futuro. En segundo lugar, la latencia de inferencia de extremo a extremo en dispositivos físicos no fue medida empíricamente en esta entrega, ya que el modelo se validó sobre infraestructura de cómputo en la nube y no en un smartphone real. En tercer lugar, el dataset adoptado, si bien de gran escala y diversidad, no fue construido específicamente

para el contexto agroalimentario colombiano, lo que puede afectar la precisión sobre variedades locales. Finalmente, el prototipo de aplicación móvil se entrega en fase de prototipo funcional y no en versión de producción, por lo cual los procesos de pruebas de usuario, certificación de tiendas y soporte operativo continuo deben planificarse como una etapa siguiente del desarrollo.

Aporte al Cuerpo de Conocimiento

Más allá de los resultados específicos del modelo y del prototipo, el proyecto aporta un marco metodológico replicable para problemas análogos de visión artificial aplicada al consumo masivo. La secuencia revisión sistemática PRISMA, adopción y curaduría de un corpus público de gran escala, Transfer Learning sobre arquitecturas livianas y despliegue local mediante Edge Computing constituye una hoja de ruta concreta para equipos que enfrenten restricciones similares de privacidad, conectividad y costo de infraestructura. El caso FridgeEye también documenta de forma explícita un pivot metodológico (del dataset propio al dataset público externo) que ilustra cómo las decisiones de ingeniería de datos pueden tener un impacto mayor sobre el desempeño del modelo que las decisiones de arquitectura o de hiperparámetros.

Plan de divulgación

El plan de divulgación define los medios, escenarios y estrategias mediante los cuales se proyectarán los resultados del trabajo de grado más allá del ámbito académico, con el fin de que el aporte generado por el proyecto FridgeEye trascienda la presentación final y se transforme en un producto científico, tecnológico y empresarial concreto.

Producto principal y productos derivados

El producto principal del plan consiste en la elaboración y sometimiento de un artículo científico que sintetice los hallazgos del proyecto, dirigido a una revista indexada del área de ciencias computacionales o de ingeniería aplicada. Las revistas objetivo identificadas son

Computers (MDPI), Discover Computing (Springer) y el International Journal of Advanced Computer Science and Applications (IJACSA), todas con factor de impacto consolidado y políticas de acceso abierto compatibles con el calendario académico del equipo. Como productos derivados se contemplan la publicación del código fuente del prototipo y de los notebooks de entrenamiento en un repositorio público de GitHub bajo licencia MIT, y la presentación del proyecto en la convocatoria Impacta de la Universidad EAN como propuesta de emprendimiento universitario.

Objetivos y ruta operativa

El plan se propone tres objetivos específicos. Primero, publicar el artículo científico en una revista indexada con cuartil mínimo Q2 dentro de los doce meses siguientes a la sustentación final. Segundo, abrir el código fuente y la documentación técnica del prototipo bajo una licencia permisiva (MIT) dentro de los tres meses siguientes a la sustentación. Tercero, someter la propuesta empresarial a la convocatoria Impacta EAN o a una incubadora análoga dentro del primer semestre del año posterior al cierre del proyecto académico.

La ruta operativa se organiza en cuatro fases secuenciales. La fase de preparación, que abarca los meses uno y dos, se dedica a la redacción del manuscrito, al refinamiento de las figuras y tablas en formato adecuado para revista y al cumplimiento de los requisitos editoriales (longitud, citas, idioma). La fase de sometimiento, en el mes tres, consiste en la elección final de la revista, la preparación de la carta de presentación y el envío formal. La fase de revisión por pares, que típicamente abarca de tres a seis meses, requiere la atención de las observaciones de los revisores y la preparación de las versiones revisadas del manuscrito. Finalmente, la fase de publicación cierra el ciclo con la versión final del artículo disponible para la comunidad

científica. En paralelo a esta ruta, el equipo desarrolla el repositorio público y prepara la propuesta para Impacta EAN.

Costos del plan de divulgación

Los costos directos del plan de divulgación se estiman en aproximadamente \$2.000.000 COP. El rubro principal corresponde al cargo por procesamiento de artículo (APC) en caso de optar por una revista de acceso abierto, con un valor estimado entre \$1.200.000 y \$1.800.000 COP dependiendo de la revista seleccionada. Como rubro secundario se incluye la inscripción opcional a un congreso nacional de ingeniería de sistemas, con un costo aproximado de \$500.000 COP. El alojamiento del repositorio público en GitHub no implica costo monetario. El tiempo dedicado por los integrantes del equipo a la redacción, revisión y atención de los procesos editoriales se considera un aporte en especie sin valor monetario directo, aunque su valor de oportunidad debe ser reconocido en el cierre del proyecto académico.

Proyección científica, tecnológica y empresarial

La proyección del proyecto se articula en tres dimensiones complementarias. En la dimensión científica, la publicación del artículo en una revista indexada genera citas esperadas en investigaciones posteriores sobre Edge AI aplicado a la sostenibilidad alimentaria y consolida una referencia bibliográfica nacional sobre el tema. En la dimensión tecnológica, la apertura del código fuente y del corpus de entrenamiento curado permite que otros equipos de investigación o de desarrollo construyan sobre los hallazgos del proyecto, replicando la metodología en dominios análogos o extendiéndola con nuevas capacidades. En la dimensión empresarial, la ejecución del plan de negocio descrito en la sección de Propuesta de Solución, ya sea como emprendimiento independiente o en el marco de Impacta EAN, transforma el prototipo

académico en un producto de mercado que potencialmente puede atender al consumidor doméstico colombiano y a clientes corporativos del sector retail.

Conclusiones

Las siguientes conclusiones consolidan los principales aportes del proyecto FridgeEye, alineadas con el problema planteado, con los objetivos específicos formulados en la introducción y con los análisis realizados a lo largo del documento. Se presenta una conclusión general que sintetiza el conjunto de la investigación, seguida por una conclusión derivada de cada uno de los tres objetivos específicos del proyecto, y un cierre que proyecta el alcance del aporte.

Conclusión General

El proyecto FridgeEye demostró que es viable, en términos técnicos, legales, ambientales y económicos, implementar un sistema de visión artificial basado en Edge Computing y Transfer Learning para el diagnóstico automático de frescura de alimentos perecederos en hogares colombianos. El trabajo cumplió integralmente con la pregunta de investigación planteada al articular una revisión sistemática rigurosa, una metodología cuantitativa con variables operacionalizadas, un modelo entrenado con métricas superiores a las metas operativas, un prototipo de aplicación móvil funcional que materializa la propuesta y un análisis de prefactibilidad económica que confirma la sostenibilidad financiera del modelo de negocio.

Sobre el Objetivo Específico de Desempeño Técnico

Respecto al primer objetivo específico, el entrenamiento del modelo de visión artificial sobre el corpus FridgeEye-1K alcanzó un F1-Score combinado de 95 % y un mAP@0,5 de 98,5 %, superando ampliamente la meta operativa del 85 % planteada en la metodología. El comportamiento estable de las curvas de entrenamiento y validación a lo largo de las 120 épocas, junto con la simetría de la confusión cruzada entre las clases fresco y deteriorado, confirma que

el modelo es robusto frente a las variaciones lumínicas y de oclusión identificadas como críticas en el marco teórico. La adopción del corpus público externo de gran escala, en lugar del dataset propio de pequeña escala inicialmente planeado, fue una decisión metodológica determinante para alcanzar estos niveles de desempeño.

Sobre el Objetivo Específico Legal y Ambiental

Respecto al segundo objetivo específico, la arquitectura On-Device adoptada en el prototipo de aplicación móvil garantiza el cumplimiento por diseño de la Ley 1581 de 2012, al mantener la totalidad del procesamiento de imágenes en el dispositivo del usuario y eliminar cualquier transferencia de datos personales a infraestructuras externas. Adicionalmente, el proyecto contribuye de manera directa a los ODS 12 (producción y consumo responsables), 13 (acción por el clima) y 9 (industria, innovación e infraestructura) mediante la reducción del desperdicio doméstico, la eliminación del consumo energético continuo de servidores cloud y la democratización del acceso a la inteligencia artificial en hardware de gama media.

Sobre el Objetivo Específico Económico

Respecto al tercer objetivo específico, el análisis de prefactibilidad económica desarrollado con el simulador financiero institucional confirma la viabilidad del proyecto con un margen amplio frente a la tasa de evaluación del 15 % exigida. Con una inversión inicial de \$42.160.000 COP, financiada en partes iguales entre los fundadores y un crédito bancario, FridgeEye genera un valor presente neto de \$103.252.278 COP, una tasa interna de retorno del 59,03 % anual y un período de recuperación de la inversión de 1,67 años. La palanca diferencial frente al esquema cloud equivalente es la eliminación de los costos recurrentes de inferencia en servidores externos, que pasa de \$2.400.000 COP anuales a \$600.000 COP en el modelo On-

Device, consolidando esta diferencia como la principal fuente de creación de valor económico del proyecto.

Cierre y proyección

El proyecto FridgeEye consolida un aporte innovador al campo de la ingeniería de software aplicada a la sostenibilidad alimentaria al integrar simultáneamente tres dimensiones que no fueron identificadas en conjunto en ninguno de los 15 artículos revisados: datos curados para el contexto agroalimentario, procesamiento exclusivamente local en dispositivos móviles de gama media y cumplimiento estricto del marco normativo colombiano. La ruta abierta para investigaciones futuras incluye la cuantización del modelo a enteros de 8 bits mediante *QAT*, la medición empírica de la latencia en dispositivos físicos, la exploración de la integración con *Small Language Models* locales para generar recomendaciones inteligentes de consumo y la ampliación del corpus con productos específicos de la canasta básica colombiana. La ejecución de estas líneas de trabajo permitirá transitar del prototipo académico actual a un producto comercial de mercado, alineado con los objetivos de desarrollo sostenible y respetuoso de la privacidad del consumidor doméstico.

Bibliografía

Aljami, H. M., Alrowais, N. A., AlAwajy, A. M., Alhrgan, S. O., Aldwaani, R. A., Alsawadi, M. S., Saqib, N. U., Alam, S. S., & Alsubaie, R. (2026). Benchmarking YOLOv8 Variants for Object Detection Efficiency on Jetson Orin NX for Edge Computing Applications. *Computers*, 15(2), 74. <https://doi.org/10.3390/computers15020074>

Ben Aicha, F. Optimized embedded AI: efficient implementation of CNNs on ESP32-CAM for real-time image classification. *Computing* **107**, 206 (2025). <https://doi.org/10.1007/s00607-025-01559-z>

Bhushan, C.M., Koppuravuri, P., Prasanthi, N. *et al.* Deploying TinyML for energy-efficient object detection and communication in low-power edge AI systems. *Sci Rep* **15**, 44299 (2025). <https://doi.org/10.1038/s41598-025-27818-9>

DNP. (2016). Pérdidas y desperdicios de alimentos en Colombia: Estudio sobre la situación actual. Departamento Nacional de Planeación.
<https://colaboracion.dnp.gov.co/CDT/Prensa/Publicaciones/P%C3%A9rdida%20y%20desperdicio%20de%20alimentos%20en%20colombia.pdf>

El-Beltagi, H. S., Gad, M., Khedr, N., Abdel-Haleem, M., Al Saikhan, M. S., Shalaby, T. A., El-Mogy, M. M., & Khedr, E. H. (2026). Harnessing artificial intelligence and machine learning for fruit quality management: A comprehensive review. *Journal of Stored Products Research*, 116, 102920. <https://doi.org/10.1016/j.jspr.2025.102920>

FAO. (2019). *El estado mundial de la agricultura y la alimentación: Progresos en la lucha contra la pérdida y el desperdicio de alimentos.*
<https://openknowledge.fao.org/server/api/core/bitstreams/2120f787-5a49-41f5-a9fb-f4ceaac98b2c/content>

Gidado, M. J., Nagoor Gunny, A. A., Gopinath, S. C. B., Devi, M., & Ibrahim, A. M. (2026). Artificial intelligence and machine learning in postharvest fruit quality assessment: Current challenges, recent advances, and future prospects. *Journal of Stored Products Research*, 116, 102959. <https://doi.org/10.1016/j.jspr.2026.102959>

Golshany, H., Ni, Y., Yu, Q., & Fan, L. (2025). IoT-enabled smart kitchen technologies and their impact on food storage, preparation, and culinary experiences: A systematic review. *Food Research International*, 213, 116557. <https://doi.org/10.1016/j.foodres.2025.116557>

Lai, N., Dewi, D.A., Maidin, S.S. et al. A comprehensive review of lightweight deep learning models for edge computing with future directions. *Discov Computing* 29, 110 (2026).

<https://doi.org/10.1007/s10791-026-10021-3>

Maulana, D., & Ramasamy, R. K. (2026). Systematic Review of Quantization-Optimized Lightweight Transformer Architectures for Real-Time Fruit Ripeness Detection on Edge Devices. *Computers*, 15(1), 69. <https://doi.org/10.3390/computers15010069>

Singh, R., Nickhil, C., R.Nisha et al. A Comprehensive Review of Advanced Deep Learning Approaches for Food Freshness Detection. *Food Eng Rev* 17, 127–160 (2025).

<https://doi.org/10.1007/s12393-024-09385-3>

Shi Han Teo and Jun Kit Chaw. “Edge Artificial Intelligence for Real-Time Fresh Produce Identification in Retail Weighing Systems”. *International Journal of Advanced Computer Science and Applications (ijacsa)* 17.1 (2026).

<http://dx.doi.org/10.14569/IJACSA.2026.0170176>

Unnikrishnan, D., Deepak, K., Yogini Aishwaryaa, P. T. S., & Bagyammal, T. (2026). Multimodal perishable fruits and vegetables dataset. *Data in Brief*, 65, 112545.

<https://doi.org/10.1016/j.dib.2026.112545>

Villegas Correa, M. (2017). La pérdida y el desperdicio de alimentos en Colombia. Universidad de los Andes. Disponible en: <https://hdl.handle.net/1992/61625>

Waitt, G., & Phillips, C. (2016). Food waste and domestic refrigeration: a visceral and material approach. *Social & Cultural Geography*, 17(3), 359–379. <https://doi-org.bdbiblioteca.universidadean.edu.co/10.1080/14649365.2015.1075580>