

FridgeEye


Implementación de visión artificial On-Device
para detección de frescura de alimentos en hogares
colombianos

Equipo

Bryan S. Ruiz Hernández
Johan S. Hernández Daza
Juan E. García Pinzón

Directora

Lina María Chacón Rivera



acreditada
en alta calidad
res. N° 023654 del Mineducación
10/12/21, vigencia 10/12/27



El problema

Embudo de delimitación: global → nacional → núcleo doméstico

1 · Global

14%

de los alimentos producidos se pierde antes de llegar a la venta

Fuente: FAO, 2019.

2 · Nacional

9,76MT

de alimentos desperdiciados anualmente en Colombia

Fuente: DNP, 2016.

3 · Hogar

15,6%

del desperdicio ocurre en el consumo doméstico (1,53 Mt/año)

Fuente: DNP, 2016.

Causa raíz identificada

La estructura cerrada del refrigerador esconde los productos: lo que no es visible se olvida, y lo olvidado termina como desecho biológico (Waitt & Phillips, 2016). El consumidor carece de una herramienta no invasiva, en tiempo real y respetuosa de la Ley 1581, para diagnosticar la frescura de sus perecederos antes de que se pierdan.

Pregunta de investigación y objetivos

Pregunta orientada a la viabilidad integral · objetivo general y tres específicos

PREGUNTA DE INVESTIGACIÓN

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

01 TÉCNICA Y DATOS

Evaluar el desempeño del modelo de visión artificial sobre el dataset FridgeEye-1K mediante F1-Score, MCC y mAP.

02 LEGAL Y AMBIENTAL

Validar el cumplimiento de la Ley 1581 mediante procesamiento 100 % On-Device y cuantificar la contribución a los ODS 12 y 13.

03 ECONÓMICA Y MERCADO

Analizar la prefactibilidad económica del proyecto mediante PESTAL, Porter, DOFA y el cálculo de TIR, VPN y ROI a cinco años.

Marco teórico

Revisión sistemática PRISMA · 15 fuentes seleccionadas (2019–2026)

379

IDENTIFICADOS

Scopus, Springer, Taylor & Francis, Google Scholar

210

CRIBADOS

Sin duplicados · revisión de título y resumen

45

ELEGIBLES

Texto completo · cumplen criterios de inclusión

15

INCLUIDOS

Síntesis del marco teórico final

BRECHA EN LA LITERATURA

Ningún estudio revisado integra simultáneamente **(i)** dataset local colombiano · **(ii)** cuantización QAT validada en gama media · **(iii)** cumplimiento Ley 1581 por diseño. **FridgeEye cubre las tres dimensiones.**

IDEAS CLAVE DEL MARCO TEÓRICO

Edge AI ya es competitivo

Aljami et al. (2026): TensorRT reduce 52–63 % el tiempo de inferencia en YOLOv8 frente a PyTorch en dispositivos móviles.

Transfer Learning + QAT supera a PTQ

Teo & Chaw (2026): mAP@0.5 = 0,897 en YOLOv11-L. Maulana & Ramasamy (2026): QAT supera PTQ para frescura.

Datasets realistas son condición necesaria

Unnikrishnan et al. (2026): cámaras comunes + luz natural. FridgeEye-1K adopta este protocolo para Colombia.

Privacidad obliga a procesar local

Golshany et al. (2025): IoT en cocinas expone datos. Ley 1581/2012 obliga a no transmitir imágenes del hogar.

Metodología



Enfoque y variables declaradas conceptual y operacionalmente

ENFOQUE	ALCANCE	DISEÑO	MUESTRA	TÉCNICAS	INSTRUMENTOS
Cuantitativo	Descriptivo– correlacional	No experimental transversal	FridgeEye-1K (~50.000 img.)	Transfer Learning + Aumentación	Python · Pandas TensorBoard

VARIABLES DECLARADAS

Coherentes con los objetivos específicos · definidas conceptual y operacionalmente

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL (cómo se mide)
OE-1 Exactitud del modelo	Capacidad del modelo para discriminar correctamente alimentos frescos y alimentos en descomposición.	F1-Score $\geq$ 0,85 · mAP $\geq$ 0,85 sobre el conjunto de validación.
OE-1 Latencia end-to-end	Tiempo desde la captura de la imagen hasta el resultado mostrado al usuario.	Milisegundos medidos en smartphone de gama media (Snapdragon 6, 4 GB RAM) · meta < 3 s.
OE-2 Cumplimiento Ley 1581	Apego al régimen de Habeas Data colombiano respecto a las imágenes del hogar.	Cero transmisiones de imagen al exterior del dispositivo (auditoría de tráfico de red con Wireshark).
OE-3 Viabilidad económica	Capacidad del proyecto de generar valor financiero frente a la inversión requerida.	VPN > 0 · TIR > 15 % · ROI Año 1 > 50 % · Payback < 3 años.

Resultados del modelo

Métricas finales sobre el conjunto de validación · superan ampliamente la meta del 85 %

98,5 %

mAP@0,5

Detección con IoU 0,5

95,0 %

F1-Score logrado

Pico a umbral de confianza 0,477

90,8 %

mAP@0,5-0,95

Localización espacial estricta

97 %

Acierto por clase

Tanto Fresco como Deteriorado

HALLAZGO PRINCIPAL

Supera benchmarks publicados

Teo y Chaw (2026) reportaron mAP@0,5 = 0,897 en YOLOv11-Large.

Nuestro modelo

Alcanza mAP@0,5 = 0,985 (~ 9 pp por encima).

Hipótesis

YOLOv8n (cuantizado 90,8 %) sobre TFLite/TensorRT

Configuración

120 épocas · AdamW · 640 × 640 · Transfer Learning desde COCO.

Confusión por clase

97 % Fresco · 97 % Deteriorado · confusión cruzada residual.

Comparativa:

Aljami et al. (2026) demuestran reducciones de 52-63 % en tiempo de ejecución con TensorRT en YOLOv8. Ben Aicha (2025) y Bhushan et al. (2025) validan TinyML/cuantización 90,8 % en dispositivos con < 2 GB RAM. El stack está disponible, documentado y probado en escenarios análogos.


Análisis de viabilidad

Tres dimensiones · una sola conclusión: VIABLE

TÉCNICA

Stack maduro y desempeño alcanzado

- $F1 = 95\%$ · $mAP@0,5 = 98,5\%$
- Meta $> 85\%$ superada por 10 pp
- TensorFlow Lite + TensorRT disponibles
- Pipeline replicable a otros dominios



LEGAL + AMBIENTAL

Cumplimiento Ley 1581 por diseño

- Cero transmisión de imágenes al exterior
- Auditable por análisis de tráfico de red
- Cero huella eléctrica de servidores cloud
- Aporte directo a ODS 9, 12, 13



ECONÓMICA


Viable con margen amplio sobre 15 %

- VPN = \$103,2 M COP
- TIR = 59,03 % (vs WACC 15 %)
- ROI Año 1 = 143,29 %
- Recuperación = 1,67 años



Resultados del prototipo móvil

Cuatro pantallas funcionales · inferencia 100 % On-Device · cumple Ley 1581 por diseño




Inicio

Resumen del inventario



Cámara

Captura con inferencia local



Inventario

Gestión por producto



Galería

Historial de capturas

Conclusiones y aporte a los ODS

Cuatro hallazgos derivados de los objetivos · alineación directa con la Agenda 2030

OBJETIVO 1

Desempeño técnico que supera la meta

F1 = 95 % y mAP@0,5 = 98,5 % sobre el conjunto de validación, superando ampliamente la meta del 85 %.

OBJETIVO 2

Cumplimiento legal por diseño

Arquitectura On-Device elimina la transferencia de imágenes y cumple la Ley 1581 sin gestiones administrativas.

OBJETIVO 2

Aporte ambiental cuantificable

2,5 kg CO₂eq evitados por kg de alimento salvado y cero inferencia cloud 24/7 (ODS 12, 13, 9).

OBJETIVO 3

Viabilidad económica con holgura

VPN \$103 M COP, TIR 59 %, ROI 143 % Año 1 y payback 1,67 años con inversión inicial de \$42 M COP.

TRANSVERSAL

Aporte transversal innovador

Dataset curado para alimentos colombianos + inferencia local + cumplimiento normativo: combinación no identificada en la literatura revisada.

Plan de Divulgación y Visibilidad Científica (Ruta Scopus)

Fase 1: Preparación

Consolida tu identidad científica antes de publicar y prepara la visibilidad temprana de tu manuscrito.

Fase 2: Acceso

Prioriza rutas de acceso abierto y deposita versiones permitidas en repositorios validados.

Fase 3: Amplificación

Promueve activamente en ecosistemas académicos y canales sociales para disparar el impacto de citación.



**La IA puede vivir en
el bolsillo, sin renunciar
a la privacidad.**

Gracias. Abrimos el panel de preguntas.



La misma U. en tu bolsillo

acreditada
en alta calidad
res. N° 023654 del Mineducación
10/12/21, vigencia 10/12/27



LA CALIDAD
LA CONSTRUIMOS JUNTOS.

SOMOS LA U. DEL
EMPRENDIMIENTO
SOSTENIBLE.