EIEI ACOFI 2025
5º Congreso Latinoamericano de Ingeniería
Más Información: www.acofi.edu.co/eiei
Ingeniería de impacto para cuidar y transformar la vida
ACOFI: 50 años por la excelencia de la educación en ingeniería.

Determinación no destructiva de la calidad en fresas empacadas en PET mediante imágenes RGB e IR

Carlos Alberto Bejarano Martínez, Martha Patricia Caro Gutiérrez, Carlos Alberto Parra Rodríguez

Pontificia Universidad Javeriana
Bogotá, Colombia

Resumen

Se desarrolló un método para identificar, segmentar y analizar la variación de color, la presencia de moho (*Botrytis cinerea*) y la temperatura de la epidermis en fresas empacadas en PET, sin comprometer su integridad. El procesamiento de imágenes se llevó a cabo mediante un modelo YOLO V8 de visión por computadora, entrenado con un conjunto de 1,100 imágenes RGB. En estas imágenes, se etiquetaron características fisiológicas asociadas con la satisfacción del consumidor. Las evaluaciones realizadas mediante métricas de clasificación demostraron la efectividad del método propuesto, con un accuracy mínimo del 80%, una precisión del 100% en todos los casos, un recall mínimo del 91.84% y valores de F1-score superiores al 95%. Este enfoque aporta al conocimiento científico, dado que solo se ha identificado un estudio previo que emplea YOLO V8 en el análisis de fresas. En comparación con otros modelos usados en literatura en la poscosecha de fresa tales como CNN, Mask R-CNN, discriminación lineal y no lineal, y AlexNet, el método propuesto cuenta con un desempeño igual o superior.

Palabras clave: procesamiento de imágenes; calidad visual; logística alimentaria

Abstract

A method was developed to identify, segment, and analyze color variation, the presence of mold (Botrytis cinerea), and the epidermal temperature of strawberries packed in PET, without compromising their integrity. Image processing was carried out using a YOLO V8 computer vision model, trained with a dataset of 1,100 RGB images. In these images, physiological characteristics associated with consumer satisfaction were labeled.

DOI: https://doi.org/10.26507/paper.4589

Evaluations using classification metrics demonstrated the effectiveness of the proposed method, with a minimum accuracy of 80%, 100% precision in all cases, a minimum recall of 91.84%, and F1-score values exceeding 95%. This approach contributes to scientific knowledge, as only one previous study has been identified that employs YOLO V8 for strawberry analysis. Compared to other models used in the postharvest analysis of strawberries—such as CNN, Mask R-CNN, linear and nonlinear discriminant analysis, and AlexNet—the proposed method shows equal or superior performance.

Keywords*: image processing; visual quality; food logistics*

1. Introducción

En la Cadena de Suministro Agroalimentaria – CSA - la calidad se entiende como el grado con el que las características inherentes al producto alimenticio aseguran el cumplimiento de requerimientos que garantizan la satisfacción del consumidor, la inocuidad y la conformidad regulatoria (Prieto et al., 2008). En el contexto colombiano según la Encuesta Nacional Logística – ENL - se sabe que, en el sector agropecuario del total de pedidos entregados en un año, cerca del 26% presenta algún tipo de daño fisiológico y no cumple con los requerimientos de calidad (DNP, 2022). Entre los principales efectos de esta realidad se destaca el incumplimiento de la demanda por el incremento de hasta el 15% de pérdidas y desperdicios, y el incremento hasta el 60% de los precios por el aumento del costo logísticos (DNP, 2016; Keizer et al., 2017).

En línea con el diagnóstico que reporta el Plan de Abastecimiento de la Región Central RAP-E (2020), uno de los factores que más explica el comportamiento de los pedidos entregados con daños de calidad del sector agropecuario, es la dificultad para administrar las operaciones logísticas en la etapa de poscosecha. Más específicamente el escaso uso de herramientas de análisis de datos para examinar patrones en las operaciones logísticas que faciliten la planeación de la logística alimentaria.

Ahora bien, la presente investigación toma como referencia la CSA de fresa. Esto debido a que la fresa es un producto altamente perecedero (Cybulska et al., 2022) y es muy sensible a las condiciones de manipulación y de conservación durante poscosecha (Nunes et al., 2021). Además, se encuentra priorizada en Colombia por el Plan Estratégico de Ciencia, Tecnología e Innovación – PECTIA, y se encuentra priorizada por el Plan Departamental de Extensión Agropecuaria – PDEA – de la Gobernación de Cundinamarca.

Retomando el tema central de la investigación, el objetivo principal de la planeación de la logística alimentaria es garantizar que los alimentos lleguen de manera eficiente, segura y oportuna desde su origen hasta el consumidor final (Mejjaouli & Babiceanu, 2018). Para lograrlo, es indispensable tener un proceso claro en el que se recopile y analice una variedad de datos clave para verificar que las actividades logísticas se realizan de acuerdo con los requerimientos (Chan et al., 2020).

A partir de los hallazgos de Zhang *et al.* (2020), Kazancoglu *et al.* (2021), Li *et al.* (2017) y Widodo *et al.* (2020), los datos clave para planear la logística alimentaria y que tienen impacto

potencial en el indicador de pedidos con daños de calidad son: la vida útil del alimento, las condiciones de manipulación y conservación, los tiempos de operación, los niveles máximos aceptables de daños de calidad, y los problemas recurrentes de calidad. De estos datos, la investigación se centra inicialmente en los problemas recurrentes de calidad. Los otros datos corresponden a futuras fases de la investigación.

A partir de lo anterior, el alcance que tiene la investigación es desarrollar un método que genere datos de calidad visual que se relacionan con la vida útil para facilitar la identificación de patrones durante la etapa de poscosecha. Para lograrlo se propone el uso de la tecnología digital Computer Vision (CV). Los datos con los que se identificará la vida útil son valores de unas propiedades de calidad que se correlacionan altamente con la aceptación del cliente y que se pueden determinar en la epidermis sin la necesidad de manipular el producto. Es decir, de forma no destructiva.

La tecnología CV es una herramienta de IA muy potente que permite analizar automáticamente parámetros de calidad a partir de una imagen digitalizada y de esta manera facilita la evaluación objetiva y no destructiva de las características visuales de calidad de productos agrícolas (Wang et al., 2022). Comparando con el método destructivo tradicional que se utiliza en las CSAs para determinar las propiedades de calidad, CV presenta varias ventajas. De acuerdo con Bhujel *et al.* (2022) y Wang *et al.* (2018), CV es más rápido, rentable y flexible que los métodos destructivos convencionales. Estos últimos, en el caso de la evaluación visual, son propensos a errores, no son fiables y exigen un gran esfuerzo humano debido a la naturaleza laboriosa de la inspección manual (Sader et al., 2021).

En trabajos previos de la presente investigación se identificó que las propiedades de calidad que se pueden determinar a través de CV en la epidermis de la fresa y que tienen la capacidad de explicar los daños en poscosecha son: la temperatura externa, variación de color, arrugamiento y presencia de moho (*Botrytis Cinerea*). Estas conclusiones están soportadas en los hallazgos de Jedermann *et al.* (2007), Defraeye *et al.,* (2021) y Ktenioudaki *et al.* (2022).

Para identificar el estado del arte se realizó una revisión de literatura aplicando el marco PRISMA con palabras clave relacionadas con el uso de tecnologías digitales en la CSA de fresa. La conclusión de esta revisión de literatura es que la tecnología digital que más se usa es Machine Learning, con tendencia a usar regresiones (multivariantes y PLSR) y Support Vector Machine (VSM). El principal uso de esta tecnología es evaluar firmeza, nivel de madurez y defectos visuales en las fresas sobre imágenes VIS, espectrales, hiperespectrales y NIRS. En todos estos casos se disponen las fresas una a una en el sistema de adquisición de imágenes, es decir capturan una imagen para cada fruto y no varios al mismo tiempo. La segunda tecnología digital más usada es Deep Learning para procesar y analizar imágenes VIS haciendo uso principalmente de Convolutional Neural Networks – CNN, con el fin de detectar magulladuras y nivel de madurez.

Con base en la revisión de literatura se identifica un vacío en el conocimiento y es que hasta el momento no se ha aplicado CV en imágenes del espectro VIS o RGB de fresas empacadas en PET para medir en la epidermis la presencia de moho (*Botrytis Cinerea*), variación de color y arrugamiento. Las investigaciones identificadas que aplican CV en el espectro VIS, las fresas no están empacadas y evalúan firmeza, acidez titulable, absorbancia, magulladuras y aspecto. Otro

vacío identificado es que no se ha aplicado CV en imágenes térmicas de fresa empacadas en PET para determina la temperatura externa del fruto.

El modelo de CV que se propone en la investigación es el modelo YOLO V8 (*You Only Look Once, versión 8*). En un trabajo previo de la presente investigación se realizó una entrevista estructurada a un experto donde se compararon los modelos YOLO V8, Faster R-CNN, SSD y Retinanet. En conclusión, el modelo YOLO V8 se ajusta mejor al contexto de la investigación porque se destaca por su capacidad para aprender características complejas, además combina alta velocidad de procesamiento con una precisión significativa, permitiendo la detección de objetos en tiempo real.

Por todo lo anterior, el objetivo de la investigación es desarrollar un método para identificar, segmentar y analizar la variación de color, la presencia de moho (*Botrytis cinerea*) y la temperatura de la epidermis en fresas empacadas en PET soportado en el modelo YOLO V8, sin comprometer su integridad.

2. Materiales y métodos

2.1 Materia prima

Se utilizaron fresas de variedad Albión entre los estados 4 a 6 con mínimo un 70% de madurez (ICONTEC, 1997). Se adquirió el material vegetal directamente en la unidad productiva de la empresa Fresas Shimaná, quien sirve como caso de estudio. Todos los frutos utilizados tienen similitud en madurez, tamaño, color, masa y firmeza. Además de estar libres de daño mecánico y enfermedades. Las fresas utilizadas en el estudio se cosecharon en horas de la mañana y posteriormente se transportaron en condiciones ambientales hasta la ciudad de Cajicá en donde se hizo el montaje del experimento. Se utilizaron empaques PET en presentación de 250, 500 y 1,000 g. Durante el experimento se conservaron los empaques entre 0 y 5°C y HR cercana al 75% haciendo uso de un refrigerador casero (LG, GS51BPP, China). Además, se midieron las condiciones del aire ambiente cercano a las fresas, se registró la temperatura (°C) y la humedad relativa (%) cada 5 minutos con un termohigrómetro con data logger (EL USB 2 LCD, Lascar, USA) en un punto central del lote de empaques.

2.2 Protocolo para la adquisición de las imágenes

Para la adquisición de las imágenes se utilizó el diseño que se presenta en la Figura 1 en condiciones ambientales. Se garantizó que el tiempo de permanencia de las fresas por fuera del sistema de refrigeración fuera el mínimo para no afectar su conservación. Se registró la masa del empaque con tara usando una balanza (Philco, Pgr000j6, China) de precisión ± 0.1 g. La frecuencia de adquisición fue de 6 h desde que se empacaron hasta que desarrollaron hongos o presentaron lixiviación.

Figura 1. Diseño del Sistema de adquisición de imágenes puesto en marcha. Elaboración propia

Se utilizó un aro de *Iluminación* (HX, MJ45, China) de 30W y 45 cm de radio con tres tipos diferentes de luz clara. El aro de luz se posiciona por encima a 6 cm de la cámara y a 20 cm de la muestra. Para el cambio de color de iluminación el aro cuenta con un control remoto. Para la difusión de la iluminación se utilizó una tela blanca que recubre el exterior del contenedor y cuenta con un espacio en la parte superior para la cámara.

Se utilizó el smartphone CAT S62 Pro (Caterpillar, China) que tiene la *Cámara* 12 MP Sony con sensor doble píxel para la adquisición de la imagen VIS. El mismo celular trae integrada la cámara térmica FLIR ® para adquirir la imagen IR. Los parámetros de control de la cámara definidos fueron: Sin FX, SCN auto, WB daylight-7000 K, f 1/8, ISO 200, foco macro, resolución HD de 1440 X 1080 en ambos espectros y velocidad de obturación 1/100. La cámara se ubica a 14 cm de la muestra para las tres presentaciones de empaque PET.

El *Contenedor* es una estructura en balso de base cuadrada de 40 cm y una altura de 25 cm. En la parte superior se diseñó un soporte para el celular para asegurar que la cámara estuviese siempre en la misma posición cenital. Se utilizó de fondo papel bond mate y sobre este se marcaron los vértices inferiores de cada presentación de empaque PET como guía de referencia para ubicar el empaque en cada tiempo de observación. En *Hardware* se utilizó un cable USB para la transferencia de datos entre el celular y una CPU. Para el etiquetado y la codificación del nombre de cada imagen se utilizó una CPU con sistema operativo Windows 10 Pro de 64 bits, Intel® Core™ i5-4590S y 12 GB. En *Software* se utilizó CVAT® para el etiquetado de cada una de las imágenes.

Se adquirieron imágenes en frutos cosechados en el mes época de invierno y en época de verano. Los frutos de invierno corresponden a la repetición número 1 (R1) donde se estudiaron 3 empaques (réplicas) por cada presentación. Por su parte los frutos de verano, corresponde a la repetición número 2 (R2) y se estudiaron 6 empaques (réplicas) por cada presentación. En R1 se adquirieron 459 imágenes y en R2, 2,079 imágenes. La Figura 2 muestra un ejemplo de ambas imágenes.

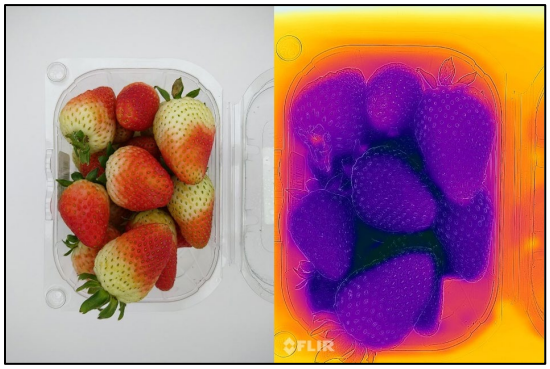

Figura 2. Ejemplo de imagen RGB (izquierda) y la superposición con la IR (derecha) para la misma réplica. Elaboración propia.

2.3 Etiquetado de las imágenes

Se utilizó la herramienta CVAT® para segmentar y etiquetar sobre un lote de 1,100 imágenes RGB las etiquetas que se listan en la Tabla 1. Como se observa en la tabla, en la propiedad variación de color se utilizaron 4 etiquetas que corresponden a estados diferentes de las fresas durante la etapa de poscosecha. Para arrugamiento y presencia de moho se utilizó una sola etiqueta en cada caso. Durante el proceso de etiquetado en cada imagen se segmentó la mayor cantidad de áreas de cada etiqueta. Sobre las imágenes IR no se realizó un proceso de etiquetado porque solo tienen el propósito de determinar la temperatura de la epidermis.

Tabla 1. Etiquetas aplicadas a las imágenes por cada propiedad de calidad.

Propiedad de calidad	Etiqueta	Descripción sobre la imagen VIS	Ejemplo de segmentación
Variación de Color	Calidad	Tejido que muestra el nivel óptimo de madurez fisiológica y comercial. Epidermis con color rojo intenso uniforme, brillante, libre de manchas marrones, zonas descoloridas, magulladuras o signos de moho. No tiene zonas verdes o blancas.	
	Inmadura	Tejido que muestra inmadurez fisiológica, usualmente se presenta en la parte del diámetro más grande cercano al cáliz. Epidermis con color blanco, verde y/o matices rojo pálido.	
	Sobremadura	Tejido que muestra sobremadurez comercial e inicio de la etapa de ablandamiento o en algunos casos senescencia. Se caracteriza por epidermis color rojo oscuro. En algunas áreas puede ser opaca y se puede observar ruptura del tejido. Puede perder forma y mostrar descomposición.	
	Enfermedad	Tejido que muestra síntomas de enfermedades características de la fresa como Antracnosis o estados previos al desarrollo de microorganismos. Se presenta en la epidermis manchas oscuras color marrón y/o hendiduras con borde de color rosado.	

Arrugamiento	Arrugamiento	Tejido que muestra síntomas de deshidratación por transpiración. La epidermis es rugosa y presenta pliegues o arrugas. El color es oscuro y apagado. A veces el arrugamiento viene acompañado de manchas marrones.	
Presencia de moho (*Botrytis cinérea*)	Hongos	Tejido que muestra la presencia de microorganismos. Epidermis con presencia de moho gris y velloso.	

Elaboración propia.

2.4 Arquitectura de YOLO V8

El modelo YOLO V8 es un modelo de detección de objetos que funciona bajo el principio de realizar la detección en una sola pasada sobre la imagen, en lugar de dividir la detección en varias etapas como otros modelos de detección (por ejemplo, R-CNN). YOLO V8 se basa en una combinación de técnicas avanzadas de redes neuronales convolucionales (CNNs) optimizadas para la detección de objetos en tiempo real, mejorando el rendimiento y la eficiencia en comparación con versiones anteriores. Gao *et al.* (2024) indican que el proceso de detección de este modelo puede dividirse en las siguientes seis etapas: preprocesamiento de la imagen, extracción de características, Neck, Capa de decodificación de salida, predicción de cuadros delimitadores y clasificación, y postprocesameinto de la detección.

2.5 Evaluación del rendimiento del modelo

Para validar el modelo YOLO V8 desarrollado, se evaluó su rendimiento en el entrenamiento con las métricas Accuracy (Ecuación 1), Precision (Ecuación 2), Recall (Ecuación 2) y F1 Score (Ecuación 4) en un conjunto de 50 imágenes de prueba que no hicieron parte del set de entrenamiento.

$$\text{Accuracy} = \frac{TN+TP}{TN+TP+FN+FP} \tag{1}$$

$$\text{Precision} = \frac{TP}{TP+FP} \tag{2}$$

$$\text{Recall} = \frac{TP}{FN+TP} \tag{3}$$

$$F1 = 2 \cdot \frac{\text{Precision} * \text{Recall}}{\text{Precision}+\text{Recall}} = \frac{TP}{TP+\frac{1}{2}(FP+FN)} \tag{4}$$

Para obtener los resultados en el conjunto de imágenes de prueba se aplicó el algoritmo con el modelo YOLO V8 para obtener las segmentaciones e identificaciones predichas. Posteriormente, se aplicó el método manual que se utiliza en el caso de estudio al mismo conjunto de imágenes de prueba para obtener las segmentaciones e identificaciones verdaderas. Finalmente se realizó un análisis comparativo entre ambos métodos para obtener por cada imagen y para cada etiqueta los verdaderos positivos (TP), verdaderos negativos (TN), falsos negativos (FN) y falsos positivos (FP).

3. Resultados y discusión

Los resultados de cada una de las métricas para cada etiqueta se muestran en la Tabla 2. Desde el punto de vista del Accuracy, el modelo tiende a categorizar las áreas de las fresas en las etiquetas correctas. El mínimo valor de 70% que se obtiene en la etiqueta *Arrugamiento* significa que en ocasiones resulta difícil identificar el umbral que divide *Arrugamiento* de *Sobremadura*, dado que en este último estado de las fresas también se puede presentar arrugamiento. En las demás etiquetas se obtiene un Accuracy mínimo del 80% y como era de esperarse, en las etiquetas *Calidad*, *Inmadura* y *Sobremadura* se obtienen valores superiores al 90%. Esto último se debe a que en cada una de estas etiquetas se contó con mayor cantidad de segmentaciones de entrada a la etapa de entrenamiento.

Ahora bien, dado que se está hablando de un caso no balanceado, es decir que no hay el mismo número de áreas o segmentaciones de cada una de las etiquetas, se decidió por complementar el análisis con las métricas de Precision, Recall y F1 score. A partir de la métrica Precision se identifica que el modelo predice muy bien cada una de las etiquetas y como se obtiene el valor de 100% para todas, el modelo no comete errores al clasificarlas como positivos, es decir la probabilidad de presentarse falsos positivos es nula.

Por su parte los valores de Recall confirman que el modelo YOLO V8 en las etiquetas *Hongos*, *Enfermedad* y *Arrugamiento* obtiene falsos negativos (valores por debajo del 65%), es decir que hay una probabilidad que existan áreas en la imagen con estas etiquetas, pero el modelo no logra identificarlas todas. Para las etiquetas *Calidad*, *Inmadura* y *Sobremadura*, el Recall muestra que el modelo es capaz de identificar la mayoría de las áreas con estas características porque se registran valores por encima del 91%. Finalmente, la métrica F1 score que combina Precision y Recall, indica especialmente para las etiquetas *Calidad*, *Inmadura* y *Sobremadura* que tanto Precision como Recall son superiores al 95%, es decir que el modelo para estas etiquetas tiene un buen equilibrio entre identificar correctamente los verdaderos positivos y minimizar los falsos positivos.

Tabla 2. Métricas de evaluación del entrenamiento por etiqueta.

Métrica	Calidad	Inmadura	Sobremadura	Hongos	Enfermedad	Arrugamiento
TP	45	48	49	10	17	24
FN	4	2	1	7	10	15
FP	-	-	-	-	-	-
TN	1	-	-	33	23	11
Accuracy (%)	92	96	98	86	80	70
Precision (%)	100	100	100	100	100	100
Recall (%)	91.84	96	98	58.82	62.96	61.54
F1 score (%)	95.74	97.96	98.99	74.07	77.27	76.19

Elaboración propia.

En literatura aplicada en la poscosecha de fresa se registran valores similares de las métricas de desempeño. Es el caso de Choi *et al.* (2021) quienes desarrollaron un modelo CNN que clasifica imágenes RGB de fresa entre frescas, magulladas y con moho. Con el modelo lograron un Accuracy promedio del 90% y un valor del F1 score superior al 95.8 % en todas las clases. Por su parte Zhou

et al. (2022) detectaron magulladuras en imágenes RGB de fresa capturadas por una cámara bajo luz incandescente y ultravioleta (UV). Aplicaron el modelo Mask R-CNN para detectar con exactitud si una fresa esta magullada o no bajo ambas condiciones de iluminación. Para la detección de magulladuras en fresas bajo luz UV, el F1 score fue de 99%, y la puntuación F1 más alta para la clasificación de la gravedad de las magulladuras en fresas fue del 92%.

Yue *et al.* (2020) desarrollaron un método rápido, no destructivo, preciso y cómodo para la identificación de la madurez de las fresas mediante teléfonos inteligentes. Utilizaron tres modelos de clasificación; discriminación de regresión lineal múltiple, discriminación de regresión no lineal multivariante y la regresión SoftMax. Cada método clasifica muestras de fresa en tres categorías (madura, medianamente madura e inmadura) y logran un Accuracy promedio del 94,44%, precisión superior al 85% y valores de F1 score de las tres clases superiores al 90%.

Ni *et al.* (2021) propusieron una mejora al modelo AlexNet para la clasificación de 5 estados de fresa (verde, inmadura, madura comercial, deformada y enferma). Lograron que el Accuracy del modelo pasara de la versión base de AlexNet a la mejorada del 89.34% al 95.75%, los cambios se presentan en el tamaño de la convolución de Kernel y el aumento en el número de capas convolucionales. Respecto a otras aplicaciones del modelo YOLO V8 en fresa, apenas se pudo identificar la investigación de M. Liu *et al.* (2023) quienes identificaron fresas maduras y puntos clave del tallo en un cultivo elevado bajo invernadero. Registraron valores de precisión entre 94.54% y 98.14% para todas las clases.

A partir de lo anterior, se determina que el modelo YOLO V8 desarrollado es efectivo en la segmentación e identificación de diversas propiedades de calidad en la poscosecha de fresa empacada en PET. Sin embargo, la variabilidad en el rendimiento de las etiquetas *Hongos*, *Enfermedad* y *Arrugamiento* respecto a las otras etiquetas sugiere la necesidad de optimización de hiperparámetros para mejorar el equilibrio entre Precision y Recall. Por lo cual, en una futura investigación se debería incrementar la representación de las etiquetas menos precisas en el conjunto de entrenamiento para mejorar el aprendizaje del modelo en estas áreas de las fresas.

4. Conclusiones

Se logró desarrollar un método no destructivo soportado en CV que determina las propiedades de calidad seleccionadas en imágenes RGB de fresas conservadas en empaque PET. Las propiedades de calidad que determina puntualmente sobre la imagen RGB (VIS) son la variación de color, arrugamiento y presencia de hongos (*Botrytis cinérea*) a través de un conjunto de etiquetas. El método también determina la temperatura de la epidermis en la imagen IR sin la necesidad del uso de etiquetas.

A partir de los resultados de las métricas de clasificación se identifica que el método no destructivo desarrollado tiene alto rendimiento en la segmentación e identificación de las etiquetas *Calidad*, *Inmadura* y *Sobremadura*. Respecto a las etiquetas *Enfermedad* y *Arrugamiento* se registró un bajo desempeño y por lo tanto no se recomienda su uso para el análisis de patrones. En el caso de la etiqueta *Hongos*, pese a que el desempeño no fue muy bueno se tiene la capacidad de identificar

al menos una segmentación de hongos en la imagen, criterio que es suficiente para la evaluación de la calidad. De acuerdo con los resultados mencionados, se tiene el argumento suficiente para concluir que se cumplió el objetivo planteado.

Sobre el estado del arte de las aplicaciones del modelo YOLO V8 en fresa, los resultados de esta investigación contribuyen al conocimiento porque apenas se identificó un solo estudio en literatura que esta enmarcado en el contexto de producción. Por lo cual, esta investigación es el primer estudio que aplica el modelo YOLO V8 en la poscosecha de fresa con resultados que confirman el alto desempeño del modelo para aplicaciones en condiciones reales.

Una limitación que se identifica en la investigación es el color de la iluminación porque, al cambiar el color de amarillo claro a blanco, la identificación de las características visuales de las fresas puede variar e incluso la decisión de lo que se considera alta calidad. Otra limitación es la generalización de los resultados porque la adquisición de las imágenes se realizó sobre fresas que se cultivaron con prácticas agronómicas estandarizadas, por consiguiente, existe la posibilidad de un comportamiento fisiológico en poscosecha diferente al trabajar con frutos con otras prácticas agronómicas

5. Referencias

- Bhujel, A., Khan, F., Basak, J. K., Jaihuni, M., Sihalath, T., Moon, B. E., Park, J., & Kim, H. T. (2022). Detection of gray mold disease and its severity on strawberry using deep learning networks. *Journal of Plant Diseases and Protection*, *129*(3), 579–592. https://doi.org/10.1007/s41348-022-00578-8
- Chan, F. T. S., Wang, Z. X., Goswami, A., Singhania, A., & Tiwari, M. K. (2020). Multi-objective particle swarm optimisation based integrated production inventory routing planning for efficient perishable food logistics operations. *International Journal of Production Research*, *58*(17), 5155–5174. https://doi.org/10.1080/00207543.2019.1701209
- Choi, J. Y., Seo, K., Cho, J. S., & Moon, K. D. (2021). Applying convolutional neural networks to assess the external quality of strawberries. *Journal of Food Composition and Analysis*, *102*(July), 104071. https://doi.org/10.1016/j.jfca.2021.104071
- Cybulska, J., Drobek, M., Panek, J., Cruz-Rubio, J. M., Kurzyna-Szklarek, M., Zdunek, A., & Frąc, M. (2022). Changes of pectin structure and microbial community composition in strawberry fruit (Fragaria × ananassa Duch.) during cold storage. *Food Chemistry*, *381*(July 2021). https://doi.org/10.1016/j.foodchem.2022.132151
- Defraeye, T., Shrivastava, C., Berry, T., Verboven, P., Onwude, D., Schudel, S., Bühlmann, A., Cronje, P., & Rossi, R. M. (2021). Digital twins are coming: Will we need them in supply chains of fresh horticultural produce? *Trends in Food Science and Technology*, *109*, 245–258. https://doi.org/10.1016/j.tifs.2021.01.025
- DNP. (2016). *Pérdida y desperdicio de alimentos en Colombia*.
- DNP. (2022). *Encuesta Nacional Logística*.
- Gao, C., Zhang, Q., Tan, Z., Zhao, G., Gao, S., Kim, E., & Shen, T. (2024). Applying optimized YOLOv8 for heritage conservation: enhanced object detection in Jiangnan traditional private gardens. *Heritage Science*, *12*(1), 31. https://doi.org/10.1186/s40494-024-01144-1
- ICONTEC. (1997). *Norma Técnica Colombiana NTC 4103:1997 - Frutas frescas. Fresas variedad chandler. Especificaciones.*

- Jedermann, R., Emond, J.-P., & Lamg, W. (2007). Shelf life prediction by intelligent RFID. In *Dynamics in Logistics* (pp. 231–238).
- Kazancoglu, Y., Ekinci, E., Mangla, S. K., Sezer, M. D., & Kayikci, Y. (2021). Performance evaluation of reverse logistics in food supply chains in a circular economy using system dynamics. *Business Strategy and the Environment*, *30*(1), 71–91. https://doi.org/10.1002/bse.2610
- Keizer, M. De, Akkerman, R., Grunow, M., Bloemhof, J. M., Haijema, R., & Vorst, J. G. A. (2017). Logistics network design for perishable products with heterogeneous quality decay. *European Journal of Operational Research*, *262*, 535–549.
- Ktenioudaki, A., Esquerre, C. A., Do Nascimento Nunes, C. M., & O'Donnell, C. P. (2022). A decision support tool for shelf-life determination of strawberries using hyperspectral imaging technology. *Biosystems Engineering*, *221*, 105–117. https://doi.org/10.1016/j.biosystemseng.2022.06.013
- Li, Y., Chu, F., & Chen, K. (2017). Coordinated Production Inventory Routing Planning for Perishable Food. *IFAC-PapersOnLine*, *50*(1), 4246–4251. https://doi.org/10.1016/j.ifacol.2017.08.829
- Liu, M., Chu, Z., Cui, M., Yang, Q., Wang, J., & Yang, H. (2023). Red Ripe Strawberry Recognition and Stem Detection Based on Improved YOLO v8-Pose. *Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery*, *54*, 244–251. https://doi.org/10.6041/j.issn.1000-1298.2023.S2.029
- Mejjaouli, S., & Babiceanu, R. F. (2018). Cold supply chain logistics: System optimization for real-time rerouting transportation solutions. *Computers in Industry*, *95*, 68–80. https://doi.org/10.1016/j.compind.2017.12.006
- Ni, J., Gao, J., Li, J., Yang, H., Hao, Z., & Han, Z. (2021). E-AlexNet: quality evaluation of strawberry based on machine learning. *Journal of Food Measurement and Characterization*, *15*(5), 4530–4541. https://doi.org/10.1007/s11694-021-01010-9
- Nunes, G., Teixeira, F., Schwarz, K., Camargo, C. K., De Resende, J. T. V., Dos Santos, E. F., Franco, B. C., & Novello, D. (2021). Influence of genetic variability on the quality of strawberry cultivars: Sensorial, physical-chemical and nutritional characterization. *Acta Scientiarum - Agronomy*, *43*(November), 1–10. https://doi.org/10.4025/actasciagron.v43i1.46862
- Prieto, M., María Mouwen, J., & Cerdeño Sánchez, A. (2008). Concepto de calidad en la industria alimentaria. *Interciencia*, *33*(4).
- Región Central RAP-E. (2020). *Plan de Abastecimiento Alimentario*.
- Sader, S., Husti, I., & Daroczi, M. (2021). A review of quality 4.0: definitions, features, technologies, applications, and challenges. *Total Quality Management and Business Excellence*, 1–19. https://doi.org/10.1080/14783363.2021.1944082
- Wang, H., Wang, Q., Zhai, J., Yuan, D., Zhang, W., Xie, X., Zhou, B., Cai, J., & Lei, Y. (2022). Design of Fast Acquisition System and Analysis of Geometric Feature for Highway Tunnel Lining Cracks Based on Machine Vision. *Applied Sciences (Switzerland)*, *12*(5). https://doi.org/10.3390/app12052516
- Wang, H., Weng, Z., & Li, Y. (2018). Design of high-speed image acquisition system based on FPGA. *Proceedings of the 30th Chinese Control and Decision Conference, CCDC 2018*, 2682–2686. https://doi.org/10.1109/CCDC.2018.8407580
- Widodo, K. H., Perdana, Y. R., Thompson, R. G., Purwoto, H., Kurniawan, D. A., & Soemardjito, J. (2020). Current research on city logistics and possible adoption in developing countries. *AIP Conference Proceedings*, *2217*. https://doi.org/10.1063/5.0000774
- Yue, X.-Q., Shang, Z.-Y., Yang, J.-Y., Huang, L., & Wang, Y.-Q. (2020). A smart data-driven rapid method to recognize the strawberry maturity. *Information Processing in Agriculture*, *1*(7). https://doi.org/10.1016/j.inpa.2019.10.005

- Zhang, G., Li, G., & Peng, J. (2020). Risk assessment and monitoring of green logistics for fresh produce based on a support vector machine. *Sustainability (Switzerland)*, *12*(18), 1–20. https://doi.org/10.3390/su12187569
- Zhou, X., Ampatzidis, Y., Lee, W. S., Zhou, C., Agehara, S., & Schueller, J. K. (2022). Deep learning-based postharvest strawberry bruise detection under UV and incandescent light. *Computers and Electronics in Agriculture*, *202*. https://doi.org/10.1016/j.compag.2022.107389

Sobre los autores

- **Carlos Alberto Bejarano**: Ingeniero Industrial de la Pontificia Universidad Javeriana, Magister en Ingeniería Agrícola de la Universidad Nacional de Colombia, Candidato a Doctor en Ingeniería de la Universidad Javeriana. Engagement Manager en Cognizant. bejarano.carlos@javeriana.edu.co
- **Martha Patricia Caro**: Ingeniera Industrial de la Pontificia Universidad Javeriana, Máster en Logística Integral de la Universidad Pontificia Comillas, Doctora en Ingeniería de la Pontificia Universidad Javeriana. Profesora Asociada. mpcaro@javeriana.edu.co
- **Carlos Alberto Parra**: Ingeniero Electrónico de la Pontificia Universidad Javeriana, Magíster en Ingeniería Eléctrica de la Universidad de los Andes, Doctor en Robótica de la Universidad Paul Sabatier. Profesor Titular. carlos.parra@javeriana.edu.co

---

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2025 Asociación Colombiana de Facultades de Ingeniería (ACOFI)