

NUEVA BASE DE DATOS DE DEFECTOS DE CAFÉ (RGB+NIR) PARA SEGMENTACIÓN SEMÁNTICA

*NEW COFFEE DEFECTS DATABASE (RGB+NIR)
FOR SEMANTIC SEGMENTATION*

Juan Camilo Mejía Hernández

Universidad Tecnológica de Pereira, Colombia
j.mejia1@utp.edu.co

Dairo Andrés Hernández Acevedo

Universidad Tecnológica de Pereira, Colombia
dairo.hernandez@utp.edu.co

Marlon Gómez Zapata

Universidad Tecnológica de Pereira, Colombia
marlon.gomez@utp.edu.co

Federico Gutiérrez Madrid

Universidad Tecnológica de Pereira, Colombia
fede9506@utp.edu.co

Héctor Fabio Quintero Riaza

Universidad Tecnológica de Pereira, Colombia
hquinte@utp.edu.co

Recepción: 14/noviembre/2024

Aceptación: 5/febrero/2025

Resumen

El café es uno de los productos agrícolas más importantes a nivel mundial, generando ingresos significativos para millones de pequeños agricultores. Sin embargo, la falta de información clara en la cadena productiva dificulta la valoración adecuada del producto. Para abordar este problema, el artículo presenta la creación de una nueva base de datos de imágenes de defectos en granos de café utilizando tecnologías de visión por computadora y segmentación semántica. Esta base contiene más de 200 imágenes en RGB e hiperespectral, cuidadosamente etiquetadas para incluir una variedad de defectos comunes, utilizando cámaras especializadas y algoritmos avanzados para capturar y procesar las imágenes. Los resultados demuestran que esta base de datos mejora significativamente la precisión en la identificación y clasificación de defectos, optimizando así la

producción y la calidad del café, representando un avance tecnológico valioso para la agricultura y facilitando el desarrollo de soluciones innovadoras, promoviendo un comercio más justo.

Palabras Clave: Café, Imágenes, Segmentación, Semántica, Defectos.

Abstract

Coffee is one of the most important agricultural products worldwide, generating significant income for millions of small farmers. However, the lack of clear information in the production chain makes it difficult to properly evaluate the product. To address this problem, the article presents the creation of a new database of coffee bean defect images using computer vision and semantic segmentation technologies. This database contains more than 200 RGB and hyperspectral images, carefully labeled to include a variety of common defects, using specialized cameras and advanced algorithms to capture and process the images. The results demonstrate that this database significantly improves the precision in the identification and classification of defects, thus optimizing the production and quality of coffee, representing a valuable technological advance for agriculture and facilitating the development of innovative solutions, promoting more trade. fair.

Keywords: *Coffee, Defects, Images, Segmentation, Semantics.*

1. Introducción

El café es uno de los productos agrícolas más importantes a nivel mundial, representando una fuente significativa de ingresos para millones de pequeños agricultores en regiones tropicales y jugando un papel crucial en la economía de muchos países. En el periodo 2019-2020, la producción global de café fue de 167 millones de sacos de 60 kg, y la exportación alcanzó los 112 millones de sacos [Williams, 2019]. Este mercado genera un volumen de ventas de 220,000 millones de euros anuales [Bouedron, 2019]. Sin embargo, uno de los principales problemas en el mercado global del café es la falta de información clara y accesible entre los diferentes actores de la cadena productiva [Ortega, 2022]. Esto limita la capacidad de los productores para negociar y hacer ofertas adecuadas, además, dificulta que

los compradores puedan relacionarse y reconocer la calidad del café de los caficultores. La falta de información impide valorar correctamente el producto y asignar un precio justo, además de no poder diferenciar entre productos de alta y baja calidad. Para solucionar este problema, se han creado múltiples sistemas que generan, organizan y comunican información tanto a los encargados del proceso y la logística de trilla como a los compradores, usando tecnologías de visión por computadora, IoT y sistemas autónomos de medición [Guzmán, 2023]. La visión por computadora se ha convertido en una herramienta poderosa para la agricultura de precisión, permitiendo la detección temprana y precisa de enfermedades y defectos en plantas [Abade, 2021]. Esta tecnología utiliza algoritmos avanzados para analizar imágenes y extraer información relevante, lo que ayuda a los agricultores a tomar decisiones informadas para el manejo de sus cultivos [Abade, 2021]. La visión por computadora contempla cuatro enfoques metodológicos para el procesamiento de imágenes: segmentación semántica en la cual se clasifica píxel a píxel, clasificación de imágenes, detección de objetos y segmentación instantánea [Abade, 2021]. Entre las principales metodologías aplicadas a los cuatro enfoques cabe resaltar las Redes Neuronales Convolucionadas (CNN por sus siglas en inglés), las Redes Neuronales Recurrentes (RNN por sus siglas en inglés), la Red de Creencias Profundas (DBN por sus siglas en inglés), la Red de Confrontación Generativa (GAN por sus siglas en inglés) y el Aprendizaje por Refuerzo Profundo (DRL por sus siglas en inglés) [Goodfellow, 2016]. Aunque las metodologías mencionadas anteriormente presentan grandes aportes, se debe destacar las CNN ya que su tipología particular de red profunda y de retroalimentación las hace mucho más fáciles de entrenar y generalizar en ambientes prácticos [Salas, 2019], [Umar, 2024], [Biswas, 2024], [Yang, 2024], [Rizk, 2023], [Lee, 2023]. En el caso del café, la visión por computadora puede facilitar la identificación de defectos en los granos mediante la segmentación semántica, mejorando así la eficiencia y la calidad del proceso de producción, disminuyendo reprocesos y pérdidas [Alfaro, 2022]. En los últimos años, se han desarrollado numerosos estudios que aplican técnicas de visión por computadora y aprendizaje automático para la identificación de defectos en diferentes tipos de plantas, adquiriendo las imágenes de diferentes maneras, tales

como: imágenes en rojo, verde y azul (RGB por sus siglas en inglés), multiespectrales, hiperespectrales, microscópicas, cámaras de ultrasonido, resonancia magnética y tomografía por ordenador [Abade,2021]. En el caso de RGB, se destaca el trabajo de [Herrera, 2016], que propone un sistema de visión artificial para detectar el café apto para producción, en el que se desarrollaron dos algoritmos: uno para la clasificación del café (maduros e inmaduros), con la caracterización del color y el uso de un clasificador bayesiano, y el otro para la detección de la plaga de la broca, que busca marcas negras en los granos de café, indicativas de esta plaga. En el estudio de [Ramos, 2017], se propone un sistema de determinación de la producción del café mediante un ensayo no destructivo a partir de fotografías parciales de uno de los perfiles de las ramas. Por dar un ejemplo de hiperespectral, [Zhang, 2019] propone un nuevo enfoque basado en redes neuronales convolucionales profundas (DCNN) para la detección automatizada de enfermedades de cultivos utilizando imágenes hiperespectrales de muy alta resolución espacial capturadas con vehículos aéreos no tripulados. Estos trabajos han demostrado la efectividad de estas tecnologías para detectar enfermedades, plagas y otros problemas que afectan la calidad de los cultivos, partiendo de una base de datos debidamente etiquetada por expertos como insumo principal. Sin embargo, aunque existen varias bases de datos para el análisis de imágenes agrícolas, hay una notable inexistencia de conjuntos de datos específicos para el café, especialmente aquellos diseñados para la segmentación semántica, lo cual ayudaría a implementar diferentes CNN en los procesos de producción y mercadeo de este. Para llenar este vacío, este artículo permite conocer los procedimientos realizados en la generación de una nueva base de datos de defectos de café con codificación RGB e hiperespectral (Infrarrojo Cercano o NIR por sus siglas en inglés). Esta base de datos contiene más de 200 imágenes de alta resolución (1280x720), etiquetadas para incluir varios defectos comunes en los granos de café. Esta base de datos no solo es única en su tipo, sino que también ofrece una herramienta valiosa para la comunidad de investigadores y profesionales en el campo de la visión por computadora aplicada a la agricultura. Dicha base de datos facilitará el desarrollo de algoritmos más precisos para la identificación y

clasificación de defectos, mejorando así la calidad del café y optimizando los procesos de producción.

El resto del artículo está organizado de la siguiente manera: en la sección II se presentan los procedimientos y equipos utilizados para la creación de la base de datos. En la sección III, se describen las características y presentación final de la base de datos. Finalmente, en las secciones IV y V, se presentan las discusiones y conclusiones respectivamente de nuestro trabajo.

2. Métodos

La creación de la base de datos es fruto de un proyecto de investigación que se lleva a cabo entre la trilladora de café CINTAGRO S.A ubicada Calarcá (Quindío - Colombia) y la Universidad Tecnológica de Pereira. Dicho proyecto busca construir un prototipo para la identificación de defectos en granos de café que pasan a través de una cinta transportadora previa al empaque y exportación de estos. La cinta transportadora tiene un ancho de 50 *cm*, Figura 1.



Fuente: elaboración propia

Figura 1 Cinta transportadora de café de la empresa CINTAGRO SA.

La creación de la base de datos comenzó con una muestra de café en buen estado (excelso), y muestras de café con los defectos (Negros, Vinagres, Broca Severa, Inmaduros, Cortados o Mordido, Broca Punto, Conchas, Ámbar), lo cuales se requieren identificar mediante visión por computadora. Para ello, de la mano con expertos de la empresa CINTRAGO SA. apoyados en la tabla de defectos del café generada por la Federación Nacional de Cafeteros de Colombia [Puerta, 2015], se

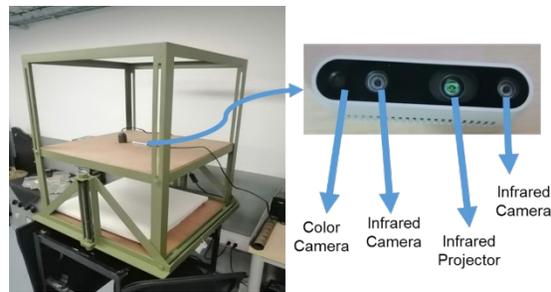
proporcionaron muestras de los defectos anteriormente mencionados. Una muestra de los defectos se puede apreciar en la Figura 2. En el desarrollo de la nueva base de datos de defectos de café, se recopilaron imágenes de granos de café utilizando una cámara capaz de capturar espectros RGB y NIR. Las imágenes fueron capturadas en el Laboratorio de Vibraciones Mecánicas de la Universidad Tecnológica de Pereira, en el cual se controla la temperatura y luminosidad en la adquisición de las imágenes.



Fuente: elaboración propia

Figura 2 Muestras de defectos de café clasificada por expertos.

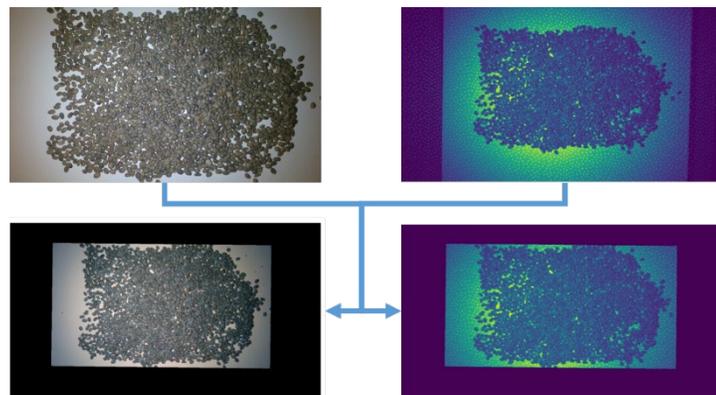
Para la adquisición de imágenes RGB y NIR, se utilizó la cámara de profundidad Intel RealSense D435, la cual ofrece profundidad de calidad para una variedad de aplicaciones. A elección de esta cámara se debió no solo a su amplio campo de visión, que resulta ideal para aplicaciones en robótica, realidad aumentada y virtual, sino también a su condición de Fabricante de Equipo Original (OEM). Esto último facilita su integración con todos los algoritmos de adquisición desarrollados en Python. La cámara D435 se puede observar junto al montaje de adquisición en la Figura 3. El montaje incluye una plataforma diseñada para ajustar el brillo y el eje focal de la cámara, ubicada a 25 cm de donde estará posicionado el café. Esta distancia se determinó para asegurar que el software que controla la cámara pueda capturar toda el área de la cinta transportadora.



Fuente: elaboración propia

Figura 3 Depth Camera D435 y su respectivo montaje.

Ahora, la cámara D435 permite capturar imágenes NIR y RGB, pero con cámaras independientes, lo cual genera problemas en la segmentación semántica por problemas de alineación entre los píxeles, lo cual se soluciona mediante los algoritmos dados en los módulos de realsense para Python [Brahmanage, 2019]. Las imágenes RGB y su alineación se pueden apreciar en la Figura 4.



Fuente: elaboración propia

Figura 4 Alineación de las imágenes RGB y NIR en imágenes de granos de café.

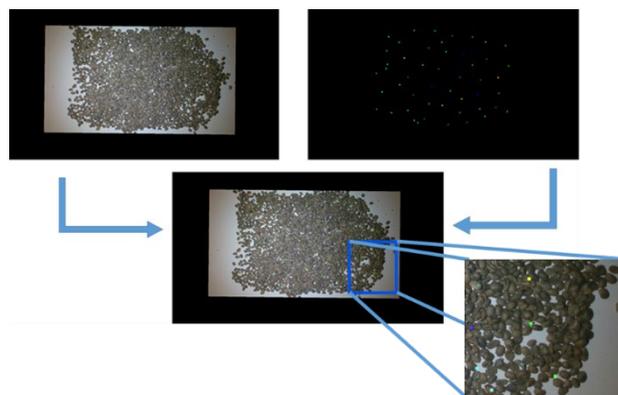
Con el sistema que emula la cinta transportadora y las imágenes RGB y NIR alineadas, se comienzan a adquirir con una frecuencia de granos basada en un modelo estadístico compatible con las condiciones industriales. Este modelo se fundamenta en la probabilidad de aparición de defectos en los granos de café durante los procesos de selección y empaquetado, como se muestra en la Tabla 1. La cantidad de granos y sus respectivos defectos se determinó tras analizar 1400 muestras de café de pequeños productores del Quindío, Colombia. Basándose en estos datos, se desarrolló un algoritmo que estima un número aleatorio de granos

con defectos (limitado por su promedio y desviación) para cada toma de imagen. Este número varía cada vez que se captura una nueva imagen. Una vez generada la lista de granos, estos se colocan aleatoriamente sobre la base del montaje final para evitar patrones fijos y garantizar la versatilidad de los algoritmos que se estrenarán con la base de datos. Después de posicionar los granos en la plataforma, se procede a la adquisición y etiquetado de las imágenes, utilizando colores para diferenciar los defectos. Cabe destacar que la plataforma puede contener hasta 1300 granos, lo que puede hacer que la identificación de los defectos sea compleja para la persona encargada del etiquetado. Para abordar este desafío, se desarrolló un programa que en tiempo real genera una marca en la imagen a medida que se posicionan los granos defectuosos. Luego, las dos imágenes se superponen y eso nos permite generar una guía para el siguiente proceso de etiquetado, Figura 5.

Tabla 1 Número y tipo de granos en 300 g de café CITA.

Defecto [cant.]	Promedio [cant.]	Desviación [cant.]
Excelso	1150	10.01
Negros	6.2	9.2
Vinagres	12.5	16.4
Broca severa	27	23.7
Inmaduros	7	9.4
Cortados	33.6	25.6
Broca punto	4.3	11.6
Conchas	2.2	6.2
Ambar	1.3	3.7

Fuente: elaboración propia



Fuente: elaboración propia

Figura 5 Metodología para el etiquetado de imágenes de la base de datos.

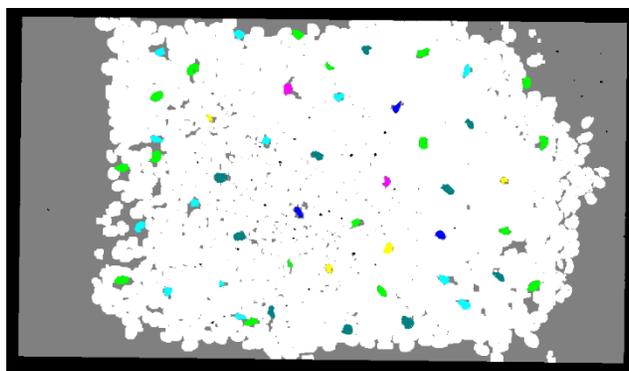
Para identificar una imagen con defectos, se colorea manualmente cada grano de café para generar las etiquetas correspondientes que permitan clasificar los defectos. Este procedimiento detallado se ilustra en la Figura 6. Esta técnica de etiquetado manual es crucial para asegurar la precisión en la identificación y categorización de los defectos, proporcionando datos de alta calidad que son esenciales para entrenar los algoritmos de segmentación semántica. Además, este proceso también permite una mejor visualización y comprensión de la distribución y naturaleza de los defectos en los granos de café, facilitando así el análisis posterior y el desarrollo de soluciones para la mejora de la calidad del café.

Para finalizar, se realiza el etiquetado de los píxeles que faltan por colorear, lo que se realiza mediante un algoritmo que distingue entre fondo, granos buenos y defectos etiquetados. Gracias a lo anterior, se logra crear una imagen que representa las etiquetas de cada píxel y se puede apreciar en la Figura 7.



Fuente: elaboración propia

Figura 6 Coloreado manual de los granos defectuosos del café.



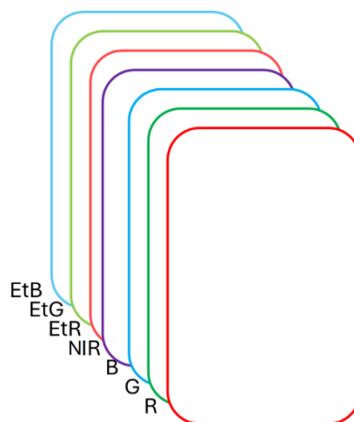
Fuente: elaboración propia

Figura 7 Etiqueta completa de las imágenes de la base de datos.

El proceso de coloreado de los granos no defectuosos se realiza mediante un algoritmo de segmentación que distingue el umbral del fondo que simula la cinta transportadora y los granos de café. El anterior proceso es posible gracias a la estandarización de las condiciones de iluminación y el previo etiquetado de los granos defectuosos.

3. Resultados

La base datos de granos defectuosos del café se etiqueta pensando en que será usada para procesos de clasificación basados en Segmentación Semántica en donde se clasifica píxel a píxel. Gracias a lo anterior, cada imagen de la base de datos se guarda como un sistema tridimensional, Figura 8.



Fuente: elaboración propia

Figura 8 Formato organizacional de la base de datos de defectos del café.

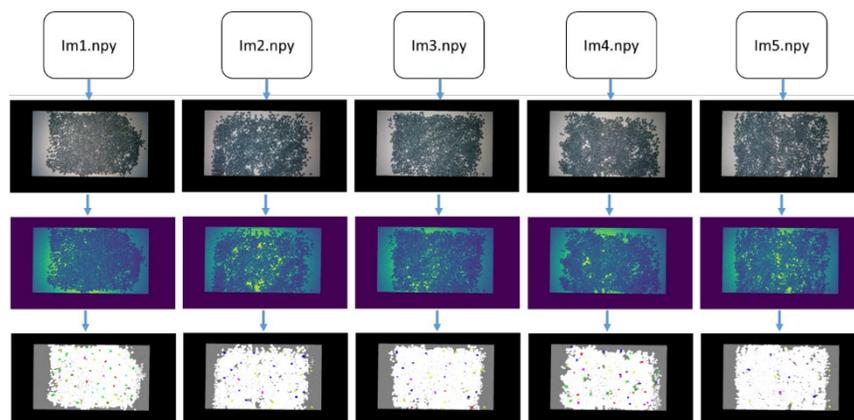
Los archivos de la base de datos tienen un arreglo tridimensional de $1280 \times 720 \times 7$, donde las columnas y filas corresponden a la resolución de la cámara, y las capas representan diferentes tipos de datos. Las primeras tres capas contienen la imagen en formato RGB (rojo, verde y azul). La cuarta capa contiene la imagen en infrarrojo cercano (NIR). Las capas cinco, seis y siete contienen los colores representativos de las etiquetas de los defectos, codificados en RGB (EtR, EtG, EtB), según se detalla en la Tabla 2. Esta estructura permite combinar información visible e infrarroja, facilitando la detección y clasificación precisa de defectos en los granos de café.

Tabla 2 Color y codificación RGB para cada clase en el arreglo tridimensional.

Defecto [cant.]	Color	Valor (R, G,B)
Excelso	Gris	(128,128,128)
Negros	Azul	(0,0,255)
Vinagre	Turquesa	(255,255,0)
Broca severa	Rojo	(255,0,0)
Inmaduros	Amarillo	(0,255,255)
Cortados mordidos	Verde	(0,255,0)
Broca punto	Verde oscuro	(128,128,0)
Conchas	Azul oscuro	(255,128,0)
Ambar	Rosado	(255,0,255)
Fondo	Blanco	(255,255,255)

Fuente: elaboración propia

La base de datos se construye como antes mencionada para reconstruir cualquier imagen desde un archivo único. El archivo único entregado por imagen esta codificado en “.npz”, el cual es el formato de archivo binario estándar del módulo de Python llamado NumPy para conservar una única matriz arbitraria en el disco, Figura 9. La base de datos cuenta dos doscientos archivos repartidos de manera aleatoria en entrenamiento, test y validación con un porcentaje de 59.5, 10 y 30.5% respectivamente. Dichos valores porcentuales se escogieron al analizar diferentes bases de datos usadas en experimentos relacionados con la segmentación semántica, tal como es “Cityscapes” (base de datos de 5000 imágenes urbanas de 50 ciudades diferentes) [Fu, 2021]. Lo anterior se realiza para estandarizar los trabajos realizados y así generar una mejor comparación cuantitativa de los resultados.



Fuente: elaboración propia

Figura 9 Sistema organizacional de la base de datos de defectos del café.

4. Discusión

Los resultados obtenidos confirman la hipótesis de que una base de datos de defectos del café de imágenes RGB y NIR, son un gran aporte para la comunidad ya que, junto a técnicas de visión por computadora ayudarán en el proceso de producción mundial. Además, se podría plantear la hipótesis de que el uso de imágenes RGB y multiespectrales incrementaría la precisión al detectar defectos en los granos de café e incluso motivar a la creación de bases similares. Otra hipótesis interesante sería explorar si la implementación de algoritmos avanzados de aprendizaje automático, como las Redes Neuronales Convolucionales (CNN), puede mejorar aún más el proceso de clasificación de defectos en comparación con los métodos actuales. La mejora en la precisión de la identificación de defectos podría optimizar los procesos de producción, disminuyendo los reprocesos y las pérdidas, y mejorando la calidad del producto final. Esto, a su vez, podría aumentar la competitividad de los productores en el mercado global y promover prácticas agrícolas más sostenibles. La integración de esta base de datos con sistemas de inteligencia artificial podría automatizar completamente el proceso de clasificación de defectos, eliminando la necesidad de intervención humana y aumentando la eficiencia. Además, la posibilidad de aplicar esta metodología a otras industrias agrícolas podría revolucionar el monitoreo y control de calidad en diferentes cultivos, promoviendo una agricultura más precisa y sostenible.

Un aspecto crítico discutido es la necesidad de estandarizar las condiciones de captura de imágenes, como la iluminación y la temperatura, para asegurar la consistencia en los datos obtenidos. Este control riguroso de las condiciones experimentales es esencial para minimizar las variaciones y garantizar la fiabilidad de los resultados. A pesar de los avances logrados, el estudio presenta algunas limitaciones. La base de datos, aunque robusta, podría beneficiarse de una mayor diversidad en términos de variedades de granos y condiciones ambientales. Además, la dependencia de equipos de alta tecnología puede ser una barrera para pequeños productores que no tienen acceso a estos recursos.

Se recomienda la automatización del proceso de etiquetado y la expansión de la base de datos para incluir más variedades de defectos y tipos de imágenes. Esto

permitirá el desarrollo de algoritmos más robustos y versátiles, beneficiando no solo a la industria del café, sino también a otros sectores agrícolas con problemas similares. La continuidad de este trabajo podría abrir nuevas oportunidades para la implementación de tecnologías avanzadas en la agricultura, contribuyendo a la sostenibilidad y eficiencia del sector.

5. Conclusiones

Se presentó una base de datos de defectos de granos de café a partir de imágenes RGB y NIR para abordar la precisión detrás del reconocimiento y la clasificación de defectos. La base de datos se desarrolló en un laboratorio que simula el funcionamiento de una banda transportadora de una trilladora de café, con el objetivo de tener condiciones similares de adquisición. Por otro lado, la creación de la base de datos establecida es una herramienta valiosa para la investigación y el desarrollo en la industria del café y los cimientos necesarios para normalizar los procesos de inspección de la calidad. Al disponer de un conjunto de datos debidamente etiquetado y accesible, se espera la adhesión a las técnicas uniformes y objetivas entre quienes merecen los defectos del café.

La implementación de esta base de datos en la industria del café podría tener un impacto significativo en la cadena de valor. Los productores se beneficiarían de una evaluación más precisa de la calidad de sus granos, permitiéndoles negociar precios justos y mejorar su posición en el mercado. Además, los compradores tendrían mayor confianza en la calidad del producto que adquieren, reduciendo disputas y mejorando la transparencia en las transacciones comerciales.

La metodología desarrollada podría transferirse a otras aplicaciones dentro de la agroindustria, lo que desarrollará la posibilidad de que se generen bases de datos similares para otros productos relacionados. Del mismo modo, trabajos posteriores podrían abordar la realización de mejoras en los algoritmos de segmentación y asociación, posiblemente investigando otros modos de imágenes o métodos de deep learning para extrapolar los resultados tal y como se alcanzan.

Desde el punto de vista de la implementación de esta tecnología, se espera que la misma genere un impacto positivo en lo relativo al lado económico: reduce las

pérdidas asociadas con la ausencia de defectos detectados y mejora la calidad del producto enviado al consumidor. Asimismo, abona a la sostenibilidad de la cadena de suministro del café, al garantizar que solo los granos tratados de mejor calidad lleguen a los establecimientos o puntos de venta, reduciendo las pérdidas y optimizando los recursos.

6. Bibliografía y Referencias

- [1] Abade, A., Ferreira, P. A., & de Barros Vidal, F. (2021). Plant diseases recognition on images using convolutional neural networks: A systematic review. *Computers and Electronics in Agriculture*, 185, 106125.
- [2] Alfaro Barreto, M. M. (2022). Propuesta de mejora para incrementar la eficiencia del proceso de fabricación de hojuelas de cereales a través de herramientas de Lean Manufacturing en una empresa del sector alimenticio.
- [3] Biswas, S., Saha, I., & Deb, A. (2024). Plant disease identification using a novel time-effective CNN architecture. *Multimedia Tools and Applications*, 1-23.
- [4] Bouedron, E., Cochet, H., & Belchi, P. (2019). Effets et limites du commerce équitable fairtrade sur les producteurs de café arabica d'une région de piémont andin, au Pérou. *Revue internationale des études du développement*, 147–175.
- [5] Brahmanage, G., & Leung, H. (2019, October). Outdoor RGB-D mapping using intel-realsense. In *2019 IEEE SENSORS* (pp. 1-4). IEEE.
- [6] Fu, J., Liu, J., Jiang, J., Li, Y., Bao, Y., & Lu, H. (2021). Scene segmentation with dual relation-aware attention network. *IEEE Transactions on Neural Networks and Learning Systems*, 32(6), 2547–2560.
- [7] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- [8] Guzmán Farfán, Á. M., & Sosa Buñay, G. J. (2023). Desarrollo de un sistema de detección de la plaga *Monilia* bajo una plataforma IoT y Visión Artificial para las mazorcas de cacao (Bachelor's thesis).
- [9] Herrera, J. C., Medina, S., Beleño, K., & González, O. G. (2016). Diseño de un sistema automático de selección de frutos de café mediante técnicas de visión artificial. *Revista UIS Ingenierías*, 15(1), 7–14.

- [10] Lee, C. P., Lim, K. M., Song, Y. X., & Alqahtani, A. (2023). Plant-CNN-ViT: plant classification with ensemble of convolutional neural networks and vision transformer. *Plants*, 12(14), 2642.
- [11] Ortega Farez, E. I., & Rodriguez Marquez, Y. A. (2022). Estrategia de marca blanca en cadenas de supermercados internacionales para lograr la comercialización del café orgánico “El Negrito” al mercado de España en el 2022.
- [12] Puerta, G. I. (2015). Buenas prácticas para la prevención de los defectos de la calidad del café: Fermento reposado fenólico y mohoso. Centro Nacional de Investigaciones de Café (Cenicafé).
- [13] Ramos, P., Prieto, F. A., Montoya, E., & Oliveros, C. E. (2017). Automatic fruit count on coffee branches using computer vision. *Computers and Electronics in Agriculture*, 137, 9–22.
- [14] Rizk, F. H., Arkhstan, S., Zaki, A. M., Kandel, M. A., & Towfek, S. K. (2023). Integrated CNN and waterwheel plant algorithm for enhanced global traffic detection. *Full Length Article*, 6(2), 36-6.
- [15] Salas, J., de Barros Vidal, F., & Martínez-Trinidad, F. (2019). Deep learning: current state. *IEEE Latin America Transactions*, 17(12), 1925-1945.
- [16] Umar, M., Altaf, S., Ahmad, S., Mahmoud, H., Mohamed, A. S. N., & Ayub, R. (2024). Precision Agriculture Through Deep Learning: Tomato Plant Multiple Diseases Recognition with CNN and Improved YOLOv7. *IEEE Access*.
- [17] Williams, G. W. (2019). The Overlooked Agricultural Trade Promotion Program of the USDA Trade Aid Packages. *Choices*, 34(4), 1-8.
- [18] Yang, B., Li, M., Li, F., Wang, Y., Liang, Q., Zhao, R., ... & Wang, J. (2024). A novel plant type, leaf disease and severity identification framework using CNN and transformer with multi-label method. *Scientific Reports*, 14(1), 11664.
- [19] Zhang, X., Han, L., Dong, Y., Shi, Y., Huang, W., Han, L., ... & Sobeih, T. (2019). A deep learning-based approach for automated yellow rust disease detection from high-resolution hyperspectral UAV images. *Remote Sensing*, 11(13), 1554.