

CLASIFICACIÓN DEL AGUACATE HASS EN TÉRMINOS DE SU MADUREZ
UTILIZANDO TÉCNICAS DE PROCESAMIENTO DE IMÁGENES Y ALGORITMOS DE
INTELIGENCIA ARTIFICIAL

ELIANA MARGARITA GONZÁLEZ APARICIO
CESAR ENRIQUE ROJAS HERNÁNDEZ

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA
2026

CLASIFICACIÓN DEL AGUACATE HASS EN TÉRMINOS DE SU MADUREZ
UTILIZANDO TÉCNICAS DE PROCESAMIENTO DE IMÁGENES Y ALGORITMOS DE
INTELIGENCIA ARTIFICIAL

ELIANA MARGARITA GONZÁLEZ APARICIO
CESAR ENRIQUE ROJAS HERNÁNDEZ

Trabajo de Grado para optar respectivamente al título de:

Ingeniera Electrónica

Ingeniero de Sistemas

Director:

PhD. Hoover Fabián Rueda Chacón

PhD. en Ingeniería Eléctrica y Computación

Codirector:

PhD. Hans Yecid Garcia Arenas

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA

2026

DEDICATORIA

A mi familia por ser mi principal apoyo durante esta etapa de mi vida.

Eliana González.

A todos los que me apoyaron durante este proceso, especialmente a mi familia.

Cesar Rojas.

AGRADECIMIENTOS

Agradecemos a Dios, a nuestros docentes Hoover Rueda y Hans Garcia por su infinita paciencia y guía en todo el proyecto.

Agradezco a mi padre Darley González por siempre animarme y recordarme que tengo su respaldo y cariño, mi madre Nohemy Aparicio por sus consejos y motivación en momentos inciertos, mis hermanos Jose González, Juan González y Ana González por compartir conmigo cada alegría en cada logro que obtenía, a César Rojas por permitirme acompañarlo en este proceso y ser de apoyo incondicional. Eliana González

Agradezco profundamente a mis padres, Damian Rojas y Trina Hernández, por ser el pilar fundamental en este proceso, por su apoyo incondicional, sus consejos, su cariño y por motivarme a seguir adelante incluso en los momentos más difíciles. A mis abuelitas, por animarme y motivarme cada vez que las veía, brindándome siempre palabras de aliento y cariño. A mi hermano, por acompañarme de distintas maneras a lo largo de este camino. También agradezco a todas las personas que hicieron parte de este proceso, por su tiempo, apoyo y cada palabra de ánimo que contribuyó a este logro. Finalmente, a Eliana Gonzalez, por su ayuda, compañía y apoyo durante este proceso. Cesar Rojas

CONTENIDO

	pág.
INTRODUCCIÓN	14
1 OBJETIVOS	18
1.1 OBJETIVO GENERAL	18
1.2 OBJETIVOS ESPECÍFICOS	18
2 MARCO DE REFERENCIA	19
2.1 AGUACATE HASS (<i>PERSEA AMERICANA MILL</i>)	19
2.1.1 Curva de maduración y etapas del fruto	19
2.1.2 Métodos tradicionales de evaluación de madurez del aguacate Hass	20
2.2 VISIÓN POR COMPUTADORA APLICADA A PRODUCTOS AGRÍCOLAS	22
2.2.1 Fundamentos de imágenes digitales y espacios de color	23
2.2.2 Segmentación de imágenes	24
2.3 INTELIGENCIA ARTIFICIAL APLICADA A LA CLASIFICACIÓN DE FRUTAS	25
2.3.1 Aprendizaje automático tradicional	25
2.3.2 Deep Learning y Redes Neuronales Convolucionales	26
2.3.2.1 Arquitectura ResNet	26
2.4 MÉTRICAS DE EVALUACIÓN DE MODELOS	28
2.5 SISTEMAS EMBEBIDOS PARA VISIÓN POR COMPUTADORA	29
3 MÉTODO PROPUESTO	30
3.1 CONJUNTO DE DATOS UTILIZADOS	30
3.1.1 Dataset externo	30
3.1.2 Dataset propio	31

3.1.2.1	Sistema de adquisición de imágenes	31
3.1.3	Estructura del archivo de registro para el dataset propio	32
3.2	PREPROCESAMIENTO DE IMÁGENES	33
3.3	DIVISIÓN DE LOS DATOS (SPLITS DE ENTRENAMIENTOS, VALIDACIÓN Y PRUEBA)	35
3.4	EXTRACCIÓN DE CARACTERÍSTICAS	37
3.5	ARQUITECTURAS DE MODELOS EVALUADAS	37
3.6	ARQUITECTURA SELECCIONADA: RESNET-50	39
3.7	ESTRATEGIAS DE ENTRENAMIENTO	39
3.8	DESPLIEGUE DEL MODELO DE CLASIFICACIÓN	40
3.9	SISTEMA DE PRUEBAS EN LA PLATAFORMA EMBEBIDA	40
4	RESULTADOS	42
4.1	ANÁLISIS DEL DATASET EXTERNO Y EL DATASET PROPIO	42
4.1.1	Comportamiento de la maduración para los datasets	42
4.1.2	Cambio de color de los datasets	43
4.2	RESULTADOS PRELIMINARES DE LOS MODELOS DE CLASIFICACIÓN	45
4.3	SEPARABILIDAD DEL ESPACIO DE CARACTERÍSTICAS MEDIANTE LDA	47
4.3.1	Comparación de separabilidad de los datasets	48
4.4	RESULTADOS CON RESNET-50	48
4.4.1	Curvas de entrenamiento	49
4.4.2	Métricas de clasificación por esquema y dataset	51
4.4.3	Desempeño, generalización e interpretabilidad del modelo	52
4.5	VALIDACIÓN EXPERIMENTAL EN RASPBERRY PI	53
4.5.1	Validación para el desarrollo de un dataset propio	53
4.5.2	Evaluación del dataset propio en la Raspberry Pi	54
4.5.3	Prueba en tiempo real	56

5 CONCLUSIONES	59
6 TRABAJO FUTURO	61
BIBLIOGRAFÍA	62

LISTA DE FIGURAS

	pág.
Figura 1 Evolución de la firmeza y de los componentes de color CIE L^* , a^* y b^* del aguacate Hass durante el almacenamiento, evidenciando cambios progresivos asociados al proceso de maduración.	21
Figura 2 Estados de maduración del aguacate según su porcentaje de materia seca.	22
Figura 3 Esquema de un bloque residual con conexiones de salto (<i>skip connections</i>) utilizado en arquitecturas ResNet.	27
Figura 4 Arquitectura general de ResNet-50 organizada en bloques residuales tipo <i>bottleneck</i> .	28
Figura 5 Distribución de datos según sus grupos de almacenamiento y categorías de maduración.	31
Figura 6 Muestras sin procesar del dataset externo correspondientes a diferentes etapas de maduración.	32
Figura 7 Muestras sin procesar del dataset propio correspondientes a diferentes etapas de maduración.	32
Figura 8 Distribución de imágenes del dataset propio según las etapas de maduración.	33
Figura 9 Esquema digital y montaje físico del sistema de adquisición de imágenes y clasificación de aguacates.	34
Figura 10 Muestras del dataset propio para cada etapa de maduración luego de la eliminación del fondo.	34
Figura 11 Muestras del dataset externo para cada etapa de maduración luego de la eliminación del fondo.	36

Figura 12	Distribución de los datasets después del preprocesamiento de los datos.	36
Figura 13	Arquitectura del proceso de extracción de características mediante ResNet-50 y su uso como entrada para clasificadores tradicionales.	38
Figura 14	Arquitectura del modelo ResNet-50 con ajuste de las capas de salida.	39
Figura 15	Duración promedio de la maduración para los aguacates Hass en el dataset externo por tipo de almacenamiento y el dataset propio.	43
Figura 16	Comparación del comportamiento del valor de color a (canal verde a rojo) en función de la categoría de madurez para el dataset propio y datasets externos bajo diferentes condiciones de almacenamiento (T10, T20 y ambiente). Se evidencia una tendencia creciente consistente, validando la coherencia del dataset construido respecto a referencias externas.	44
Figura 17	Evolución de los componentes de color del espacio CIE L*a*b* durante el almacenamiento del aguacate Hass en el dataset propio. Se observa una disminución de la luminosidad (L*) y del componente amarillo-azul (b*), junto con un incremento del componente verde-rojo (a*), evidenciando los cambios cromáticos asociados al proceso de maduración.	45
Figura 18	Proyección del espacio de características mediante Análisis Discriminante Lineal (LDA) para el dataset externo sin separación en tipos de almacenamiento.	47
Figura 19	Proyección del espacio de características mediante Análisis Discriminante Lineal (LDA) para el dataset externo y el dataset propio en sus distribuciones de 5 y 3 clases.	49
Figura 20	Curvas de precisión y pérdida para el entrenamiento de los datasets con 3 clases. Elaboración propia.	50
Figura 21	Mapas de activación por capa del modelo ResNet-50 para los modelos de 3 y 5 clases.	53

Figura 22	Resultados de las matrices de confusión sobre conjunto de pruebas independiente ejecutado en Raspberry Pi con modelos de 3 y 5 clases entrenados con el dataset externo.	54
Figura 23	Resultados de las matrices de confusión sobre conjunto de pruebas independiente ejecutado en Raspberry Pi con modelos de 3 y 5 clases entrenados con el dataset propio.	55
Figura 24	Montaje de la estructura en funcionamiento en tiempo real.	57
Figura 25	Visualización del funcionamiento en tiempo real del modelo para 2 muestras diferentes. Elaboración propia.	58

LISTA DE CUADROS

	pág.
Cuadro 1 Parámetros de configuración utilizados durante la captura de imágenes del dataset propio. Los valores fueron definidos mediante ajustes visuales iterativos, considerando principalmente la reproducción natural de los colores del aguacate bajo las condiciones de iluminación del montaje experimental, influenciadas por la temperatura de color de los LEDs (6500K). Adicionalmente, se ajustaron variables de enfoque, exposición, contraste y nitidez con el fin de mejorar la consistencia visual y resaltar características superficiales relevantes para el proceso de clasificación.	35
Cuadro 2 Resultados preliminares de clasificación sobre los datasets empleados.	46
Cuadro 3 Reportes de clasificación para los modelos de 3 y 5 clases evaluados con dataset propio y externo.	51
Cuadro 4 Reporte de clasificación con 5 clases empleando el dataset propio en la Raspberry Pi.	56
Cuadro 5 Reporte de clasificación con 3 clases empleando el dataset propio en la Raspberry Pi.	56

RESUMEN

TÍTULO: CLASIFICACIÓN DEL AGUACATE HASS EN TÉRMINOS DE SU MADUREZ UTILIZANDO TÉCNICAS DE PROCESAMIENTO DE IMÁGENES Y ALGORITMOS DE INTELIGENCIA ARTIFICIAL *

AUTORES: ELIANA MARGARITA GONZÁLEZ APARICIO, CESAR ENRIQUE ROJAS HERNÁNDEZ **

PALABRAS CLAVE: Aguacate Hass, visión por computadora, aprendizaje profundo, clasificación de imágenes, maduración de aguacates.

DESCRIPCIÓN: Este trabajo aborda el desarrollo de un sistema de clasificación automática del estado de maduración de aguacates Hass mediante técnicas de visión por computadora y aprendizaje profundo. Se emplean imágenes RGB adquiridas en condiciones controladas, las cuales son preprocesadas y organizadas en diferentes categorías de madurez. La propuesta incluye el uso de redes neuronales convolucionales, específicamente modelos basados en ResNet, aplicando estrategias de *transfer learning* y *fine-tuning* para mejorar el rendimiento del modelo.

Adicionalmente, se implementan técnicas de aumento de datos para balancear las clases y mejorar la generalización del sistema. Se evalúan diferentes configuraciones de entrenamiento, así como métodos de extracción de características combinados con algoritmos de clasificación tradicionales. Los resultados evidencian la capacidad del modelo para identificar patrones visuales asociados a las distintas etapas de maduración, aunque se presentan desafíos en la separación de clases con características visuales similares. Este sistema se plantea como una herramienta útil para la automatización de procesos en la industria agroalimentaria.

* Trabajo de grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones. Escuela de Ingeniería de Sistemas e Informática. Director: PhD. Hoover Fabián Rueda Chacón. Codirector: PhD. Hans Yecid García Arenas.

ABSTRACT

TITLE: CLASSIFICATION OF HASS AVOCADO IN TERMS OF ITS RIPENESS USING IMAGE PROCESSING TECHNIQUES AND ARTIFICIAL INTELLIGENCE ALGORITHMS. *

AUTHORS: ELIANA MARGARITA GONZÁLEZ APARICIO, CESAR ENRIQUE ROJAS HERNÁNDEZ **

KEYWORDS: Hass avocado, computer vision, deep learning, image classification, avocado ripeness.

DESCRIPTION: This work addresses the development of an automated system for classifying the ripeness stages of Hass avocados using computer vision and deep learning techniques. RGB images acquired under controlled conditions are used, which are preprocessed and organized into different ripeness categories. The proposed approach incorporates convolutional neural networks, specifically ResNet-based models, applying *transfer learning* and *fine-tuning* strategies to improve model performance.

Additionally, data augmentation techniques are implemented to balance the classes and enhance the system's generalization capability. Different training configurations are explored, along with feature extraction methods combined with traditional classification algorithms. The results demonstrate the model's ability to identify visual patterns associated with different ripeness stages, although challenges remain in distinguishing classes with similar visual characteristics. This system is proposed as a useful tool for automating processes in the agrifood industry.

* Bachelor's Thesis

** Faculty of Physical-Mechanical Engineering, School of Electrical, Electronic, and Telecommunications Engineering, School of Systems Engineering & Informatics. Advisor: PhD. Hoover Fabián Rueda Chacón. Co-advisor: PhD. Hans Yecid García Arenas.

INTRODUCCIÓN

El sector agroindustrial colombiano ha experimentado en los últimos años un crecimiento acelerado, particularmente en la producción y exportación de aguacate Hass (*Persea americana* Mill.)¹. Este fruto se ha posicionado como la tercera fruta más exportada del país², convirtiéndose en un producto estratégico dentro de la economía nacional. Su alto valor nutricional³ y sus múltiples aplicaciones en la industria alimentaria, cosmética y médica⁴ han impulsado un aumento sostenido de la demanda en mercados internacionales, lo que plantea nuevos retos tecnológicos para garantizar estándares de calidad y competitividad en la cadena de producción y comercialización⁵.

Uno de los principales desafíos radica en la determinación del estado de madurez post-cosecha, un factor crítico que incide directamente en la vida útil, la aceptación en el mercado y la reducción de pérdidas⁶. Los métodos tradicionales empleados para esta tarea incluyen la medición de la firmeza de la pulpa, el contenido de aceite o el porcentaje de

¹ Ministerio de Agricultura. *1.500 toneladas de aguacate Hass colombiano le pondrán sabor al Super Bowl, el más grande evento deportivo de Estados Unidos*. Accedido: 2024-08-30. 2024.

² T. García Urrego. *Colombia triplicó sus exportaciones de aguacate Hass hacia Estados Unidos en 2024*. Accedido: 2024-10-28. 2024.

³ R.G. Araújo et al. «Avocado by-products: Nutritional and functional properties». En: *Trends in Food Science & Technology* 80 (2018), págs. 51-60. DOI: 10.1016/j.tifs.2018.07.027.

⁴ M. L. Dreher y A.J. Davenport. «Hass Avocado Composition and Potential Health Effects». En: *Critical Reviews in Food Science and Nutrition* 53.7 (2013), págs. 738-750. DOI: 10.1080/10408398.2011.556759.

⁵ Legiscomex.com. *El aguacate 'Hass' colombiano tiene un mundo de anaqueles esperando*. Accedido: 2024-10-28. 2024.

⁶ B. B. Wedding. «The non-invasive assessment of avocado maturity and quality». En: *School of Marine and Tropical Biology* (2018). DOI: 10.25903/5e969687c22e8.

materia seca⁷. Aunque son técnicas confiables, presentan limitaciones importantes: requieren tiempo prolongado, generan costos elevados y son invasivas o destructivas, lo que reduce el volumen de fruta disponible para la venta y restringe su aplicación a gran escala⁸.

Ante estas limitaciones, se han desarrollado alternativas basadas en tecnologías no invasivas, como la espectroscopía en el rango visible e infrarrojo cercano (Vis-NIR)⁹ y el uso de imágenes hiperespectrales (HSI)¹⁰. Estos enfoques han demostrado alta precisión¹¹ en la clasificación del aguacate Hass, pero requieren equipos especializados de alto costo y condiciones estrictas de iluminación, lo que dificulta su implementación en escenarios productivos reales¹². Por ello, el procesamiento digital de imágenes en espacios de color como RGB¹³ y L*a*b* se ha convertido en una alternativa viable y de menor costo para analizar características visuales, como el color y la textura de la piel¹⁴, que se correlacio-

⁷ L. S. Magwaza y S. Z. Tesfay. «A Review of Destructive and Non-destructive Methods for Determining Avocado Fruit Maturity». En: *Food Bioprocess Technol* 8 (2015). DOI: 10.1007/s11947-015-1568-y.

⁸ Wedding, ver n. 6.

⁹ A. Melado Herreros et al. «Postharvest ripeness assessment of 'Hass' avocado based on development of a new ripening index and Vis-NIR spectroscopy». En: *Postharvest Biology and Technology* 181 (2021), pág. 111683. DOI: 10.1016/j.postharvbio.2021.111683.

¹⁰ J. Pinto, H. Rueda y H. Arguello. «Classification of Hass avocado (persea americana mill) in terms of its ripening via hyperspectral images». En: *TecnoLógicas* 22.45 (2019), págs. 109-128. DOI: 10.22430/22565337.1232.

¹¹ Y. J. Davur et al. «Estimating the Ripeness of Hass Avocado Fruit Using Deep Learning with Hyperspectral Imaging». En: *Horticulturae* 9.5 (2023), pág. 599. DOI: 10.3390/horticulturae9050599.

¹² I. Arzate Vázquez et al. «Image Processing Applied to Classification of Avocado Variety Hass (Persea americana Mill.) During the Ripening Process». En: *Food and Bioprocess Technology* 4.7 (2011), págs. 1307-1313. DOI: 10.1007/s11947-011-0595-6.

¹³ Arzate Vázquez et al., ver n. 12.

¹⁴ D. Escobar Figueroa y E. Roa Guerrero. «Sistema de visión artificial para la identificación del estado de

nan con el estado de maduración del fruto¹⁵.

El presente proyecto se enmarca en este panorama, con el objetivo de desarrollar un sistema de clasificación de la madurez del aguacate Hass postcosecha utilizando imágenes RGB y algoritmos de inteligencia artificial. Para ello, se trabajó inicialmente con un dataset público de 14.710 imágenes de aguacates Hass almacenados en diferentes condiciones de temperatura (10 °C, 20 °C y ambiente)¹⁶. A partir de este recurso, se diseñó un proceso de curación y ajuste del dataset, que incluyó la unificación de clases y la aplicación de técnicas de aumento de datos. Posteriormente, se creó un dataset propio adaptado a las necesidades del proyecto, con el fin de validar los modelos en condiciones controladas mediante el montaje experimental implementado.

La fase experimental contempló pruebas de arquitecturas con modelos preentrenados (ResNet50¹⁷), aplicando estrategias de fine-tuning y extracción de características. Asimismo, se evaluaron clasificadores tradicionales como Linear Discriminant Analysis (LDA)¹⁸,

madurez de frutas (granadilla)». En: *Redes de Ingeniería* 7 (2016). DOI: 10.14483/udistrital.jour.redes.2016.1.a08.

¹⁵ A. Bhargava y A. Bansal. «Fruits and vegetables quality evaluation using computer vision: A review». En: *Journal of King Saud University - Computer and Information Sciences* 33.3 (2021), págs. 243-257. DOI: 10.1016/j.jksuci.2018.06.002.

¹⁶ P. Xavier. *Hass Avocado Ripening Photographic Dataset*. Col. de Pedro Rodrigues, Cristina L. M. Silva y Centro De Biotecnologia E Quimica Fina. Accedido: 2024-10-15. 2024. DOI: 10.17632/3XD9N945V8.1.

¹⁷ Kaiming He et al. «Deep Residual Learning for Image Recognition». En: (2016), págs. 770-778. DOI: 10.1109/CVPR.2016.90.

¹⁸ Richard O. Duda, Peter E. Hart y David G. Stork. *Pattern Classification*. 2.^a ed. Wiley-Interscience, 2001.

Support Vector Machines (SVM)¹⁹, Random Forest²⁰ y XGBoost²¹, los cuales permitieron analizar la separabilidad de las clases y complementar los resultados obtenidos con redes profundas. Un análisis exploratorio LDA evidenció las principales dificultades de clasificación, especialmente en las etapas tempranas de madurez (verde e inicio de maduración) y en la diferenciación entre frutos sobremaduros y dañados, debido a su alta similitud visual.

De forma paralela, se desarrolló un prototipo de sistema de visión basado en una Raspberry Pi 5 y una cámara RGB, bajo condiciones de iluminación controlada, lo que permitió la captura de imágenes propias y la validación práctica de los modelos entrenados. Este montaje representa un paso hacia la implementación real de un sistema accesible y de bajo costo para la industria, con potencial de ser escalado y adaptado a líneas de clasificación automatizadas.

¹⁹ A. Bhargava y A. Bansal. «Automatic Detection and Grading of Multiple Fruits by Machine Learning». En: *Food Analytical Methods* 13.3 (2020), págs. 751-761. DOI: 10.1007/s12161-019-01690-6.

²⁰ Leo Breiman. «Random Forests». En: *Machine Learning* 45.1 (2001), págs. 5-32. DOI: 10.1023/A:1010933404324.

²¹ Tianqi Chen y Carlos Guestrin. «XGBoost: A Scalable Tree Boosting System». En: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016, págs. 785-794. DOI: 10.1145/2939672.2939785.

1. OBJETIVOS

1.1. OBJETIVO GENERAL

Desarrollar un sistema de visión por computadora para clasificar aguacates Hass post-cosecha en cuanto a su madurez mediante técnicas de procesamiento de imágenes y algoritmos de inteligencia artificial.

1.2. OBJETIVOS ESPECÍFICOS

1. Recopilar bases de datos de fotografías de aguacates Hass postcosecha, para su estudio, categorización y etiquetado.
2. Implementar un algoritmo de inteligencia artificial para la clasificación de aguacates Hass postcosecha basado en imágenes de color RGB.
3. Implementar un prototipo de sistema de visión para la adquisición de imágenes de aguacates Hass usando una cámara RGB.
4. Validar el algoritmo desarrollado con imágenes adquiridas con el prototipo de sistema de visión sobre una muestra de aguacates Hass.

2. MARCO DE REFERENCIA

2.1. AGUACATE HASS (*PERSEA AMERICANA* MILL)

El aguacate Hass es una de las variedades más cultivadas y comercializadas a nivel mundial debido a su sabor, textura, contenido de aceite y buena vida postcosecha²². En Colombia, se ha consolidado como un producto estratégico para la economía nacional, con un crecimiento sostenido en su cultivo y exportación²³.

2.1.1. Curva de maduración y etapas del fruto El aguacate Hass es un fruto climatérico que continúa su proceso de maduración después de la cosecha debido a la producción de etileno²⁴. Durante este proceso ocurren cambios fisiológicos asociados principalmente a la firmeza, el color de la piel y el contenido de aceite²⁵. La piel del fruto presenta una transición progresiva de verde a tonos púrpura y negro, relacionada con la degradación de clorofilas y el aumento de otros pigmentos vegetales²⁶, mientras que la firmeza disminuye hasta alcanzar el estado óptimo de consumo.

²² AGROSAVIA. *Manejo del cultivo de aguacate Hass en Colombia*. Inf. téc. Accedido: 2025-09-13. Corporación Colombiana de Investigación Agropecuaria, 2019.

²³ BID Banco Interamericano de Desarrollo. *Estrategias Público-Privadas para el establecimiento de un ciclo de exportación de aguacate exitoso. Casos de Colombia y Perú*. Accedido: 2025-09-13. 2017.

²⁴ Katy A. Cox et al. «Skin colour and pigment changes during ripening of 'Hass' avocado fruit». En: *Postharvest Biology and Technology* 31.3 (2004), págs. 287-294. DOI: 10.1016/j.postharvbio.2003.09.008.

²⁵ N. M. Sierra et al. «Evaluation and modeling of changes in shelf life, firmness and color of 'Hass' avocado depending on storage temperature». En: *Journal of Food Processing and Preservation* 43.6 (2019), e13935. DOI: 10.1177/1082013219826825.

²⁶ Daniela Olivares et al. «Effects of Delaying the Storage of 'Hass' Avocados under a Controlled Atmosphere on Skin Color, Bioactive Compounds and Antioxidant Capacity». En: *Plants* 13.11 (2024), pág. 1455. DOI: 10.3390/plants13111455.

Con base en la información del dataset externo utilizado en este trabajo²⁷, se definieron cinco etapas de maduración: verde, transición, maduro etapa 1, maduro etapa 2 y dañado. Estudios recientes han demostrado que estas etapas se correlacionan con parámetros físicoquímicos como materia seca y contenido de aceite, los cuales sirven como referencia objetiva para determinar el estado de maduración²⁸.

Como se observa en la Figura 1, la firmeza disminuye principalmente durante los primeros días de almacenamiento, marcando la transición entre las etapas verde y madura, mientras que los parámetros de color presentan cambios graduales relacionados con el oscurecimiento de la cáscara. Este comportamiento indica que las etapas de maduración no tienen la misma duración, generando un desbalance natural en la cantidad de muestras recolectadas por categoría, especialmente entre la etapa verde y dañado.


2.1.2. Métodos tradicionales de evaluación de madurez del aguacate Hass La clasificación manual del estado de maduración del aguacate Hass requiere personal capacitado y puede verse afectada por la fatiga durante largas jornadas de trabajo. Por esta razón, se han desarrollado métodos postcosecha para determinar la madurez, entre ellos la cuantificación del contenido de aceite y el análisis de materia seca y humedad, mostrado en la Figura 2. Aunque estos métodos ofrecen alta precisión al basarse en análisis físicos y químicos, presentan desventajas asociadas a su carácter invasivo, además de requerir tiempos de procesamiento elevados²⁹.

²⁷ Xavier, ver n. 16.

²⁸ Y. Yahia et al. «Identification and Characterization of Phytochemicals in Avocado ('Hass') Fruit at Different Maturation and Ripening Stages». En: *Journal of Food Quality* (2025). DOI: 10.1155/jfq/7181926.

²⁹ Wedding, ver n. 6; Magwaza y Tesfay, ver n. 7.

Figura 1. Evolución de la firmeza y de los componentes de color CIE L^* , a^* y b^* del aguacate Hass durante el almacenamiento, evidenciando cambios progresivos asociados al proceso de maduración.



Tomado de N. M. Sierra et al. «Evaluation and modeling of changes in shelf life, firmness and color of 'Hass' avocado depending on storage temperature». En: *Journal of Food Processing and Preservation* 43.6 (2019), e13935. DOI: 10.1177/1082013219826825.

Como alternativa, se han investigado técnicas no destructivas basadas en espectroscopía Vis-NIR e imágenes hiperespectrales, las cuales permiten estimar parámetros como contenido de humedad, aceite y firmeza mediante el análisis de la respuesta espectral del fruto³⁰. Estas metodologías, complementadas con técnicas de análisis multivariado como análisis de componentes principales (PCA) e índices de vegetación, han demostrado una

³⁰ Magwaza y Tesfay, ver n. 7.

Figura 2. Estados de maduración del aguacate según su porcentaje de materia seca.

MADURACIÓN AGUACATE / AVOCADO MATURING				
	1	2	3	4
GRADO MADURACIÓN				
CONDICIÓN DEL AGUACATE	DURO NO MADURO	FIRME CASI MADURO	MADURO LISTO PARA COMER	PASADO DEMASIADO MADURO
CONTENIDO DE MATERIA SECA	21 a 23%	23% a 30%	35%	37%

Tomada de Dmass Business. *Aguacate Mexicano de Exportación*. Accedido: 2024-10-15.

alta correlación con parámetros de calidad y maduración del aguacate Hass³¹.

2.2. VISIÓN POR COMPUTADORA APLICADA A PRODUCTOS AGRÍCOLAS

La visión por computadora se ha consolidado como una herramienta clave en la automatización de procesos agrícolas, especialmente en tareas de inspección, clasificación y control de calidad de frutas y hortalizas³². Su principal ventaja radica en la capacidad de analizar atributos externos de forma no destructiva, rápida y objetiva, permitiendo evaluar características como color, textura, tamaño, forma y defectos superficiales³³.

³¹ Pinto, Rueda y Arguello, ver n. 10.

³² Tadhg Brosnan y Da-Wen Sun. «Inspection and grading of agricultural and food products by computer vision systems—a review». En: *Computers and Electronics in Agriculture* 36.2 (2002), págs. 193-213. DOI: [https://doi.org/10.1016/S0168-1699\(02\)00101-1](https://doi.org/10.1016/S0168-1699(02)00101-1).

³³ Juan Pablo Guerra y Francisco Cuevas. «Application of Digital Image Processing Techniques for Agriculture: A Review». En: *Digital Image Processing - Latest Advances and Applications*. Ed. por Francisco

En productos agrícolas, estas técnicas han sido ampliamente utilizadas para la detección de madurez, clasificación comercial, identificación de enfermedades y automatización de líneas de selección postcosecha³⁴. En el caso del aguacate Hass, la visión por computadora resulta particularmente relevante debido a la estrecha relación entre el color externo de la piel y las etapas de maduración del fruto.

2.2.1. Fundamentos de imágenes digitales y espacios de color Una imagen digital puede representarse como una matriz de píxeles, donde cada píxel almacena información de intensidad o color. En imágenes RGB, cada píxel se compone de tres canales correspondientes a rojo (R), verde (G) y azul (B)³⁵. Aunque RGB es el espacio de color más utilizado en sistemas de captura digital, en aplicaciones de visión por computadora y segmentación suelen emplearse representaciones alternativas como HSV (*Hue, Saturation, Value*), ya que permiten separar la información cromática de la iluminación³⁶. En este espacio, *Hue* representa el tono dominante, *Saturation* la pureza del color y *Value* la intensidad lumínica.

De manera complementaria, el espacio de color CIE $L^*a^*b^*$ permite describir el color de forma más cercana a la percepción visual humana mediante tres componentes: lumino-

Cuevas, Pier Luigi Mazzeo y Alessandro Bruno. London: IntechOpen, 2024. Cap. 2. DOI: 10.5772/intechopen.1004767.

³⁴ José Blasco et al. «Automated Systems Based on Machine Vision for Inspecting Citrus Fruits from the Field to Postharvest—A Review». En: *Food and Bioprocess Technology* 9 (2016), págs. 1623-1639. DOI: 10.1007/s11947-016-1767-1; Guerra y Cuevas, ver n. 33.

³⁵ Rafael C. Gonzalez y Richard E. Woods. *Digital Image Processing*. 4.^a ed. Pearson, 2018; Jesús Raúl Martínez Sandoval et al. «Color Analysis and Image Processing Applied in Agriculture». En: *Image Processing in Agriculture*. IntechOpen, 2017. DOI: 10.5772/intechopen.71539.

³⁶ Guerra y Cuevas, ver n. 33.

sidad (L^*), eje verde-rojo (a^*) y eje azul-amarillo (b^*). Esta representación resulta especialmente útil para analizar cambios cromáticos asociados al proceso de maduración de frutos³⁷.

2.2.2. Segmentación de imágenes La segmentación consiste en separar el objeto de interés del fondo o de otras regiones irrelevantes de la imagen. En aplicaciones agrícolas, esta etapa es fundamental para aislar frutos, hojas, tallos o defectos superficiales³⁸. La segmentación basada en color es una de las estrategias más utilizadas en visión por computadora aplicada a agricultura, debido a que muchos productos presentan diferencias cromáticas claras entre el objeto de interés y el fondo³⁹ y en HSV ha sido ampliamente utilizada en la detección de defectos en frutas, clasificación por color, detección de madurez y separación de frutos en sistemas robotizados⁴⁰.

En este trabajo, la segmentación permitió aislar el aguacate del fondo uniforme del montaje experimental, reduciendo ruido visual y mejorando la extracción de características relacionadas con color y forma. El espacio HSV es especialmente adecuado para la segmentación de frutas, ya que el canal de tono (H) permite identificar rangos cromáticos específicos con menor sensibilidad a cambios de iluminación en comparación con RGB⁴¹.

³⁷ Katherine León et al. «Color measurement in Lab units from RGB digital images». En: *Food Research International* 39.10 (2006). Physical Properties VI, págs. 1084-1091. DOI: <https://doi.org/10.1016/j.foodres.2006.03.006>.

³⁸ Brosnan y Sun, ver n. 32; Guerra y Cuevas, ver n. 33.

³⁹ Martínez Sandoval et al., ver n. 35.

⁴⁰ H. Patel y R. Jain. «Automatic Fruit Defect Detection Using HSV and RGB Color Space Model». En: *International Journal of Innovative Research in Computer Science and Technology* 2.4 (2014); Blasco et al., ver n. 34.

⁴¹ Patel y Jain, ver n. 40.

En el caso del aguacate Hass, la conversión de RGB a HSV facilita la diferenciación entre el fruto y el fondo, especialmente en las primeras etapas donde predominan tonos verdes bien definidos.

2.3. INTELIGENCIA ARTIFICIAL APLICADA A LA CLASIFICACIÓN DE FRUTAS

La clasificación automática de frutas mediante imágenes puede abordarse desde dos enfoques principales: aprendizaje automático tradicional y aprendizaje profundo. El primero depende de la extracción manual de características, mientras que el segundo aprende automáticamente representaciones jerárquicas a partir de los datos⁴². En aplicaciones agrícolas, ambos enfoques han demostrado utilidad para tareas como clasificación por madurez, detección de defectos, estimación de calidad y separación comercial⁴³.

2.3.1. Aprendizaje automático tradicional Los métodos tradicionales de aprendizaje automático requieren una etapa previa de extracción manual de características, donde se calculan descriptores de color, textura, forma o estadísticas derivadas de la imagen⁴⁴. Estas características son utilizadas posteriormente por algoritmos de clasificación como: Análisis Discriminante Lineal (LDA)⁴⁵, Máquinas de Soporte Vectorial (SVM)⁴⁶, Random

⁴² Yann LeCun, Yoshua Bengio y Geoffrey Hinton. «Deep learning». En: *Nature* 521 (2015), págs. 436-444. DOI: 10.1038/nature14539.

⁴³ Andreas Kamilaris y Francesc X. Prenafeta-Boldú. «Deep learning in agriculture: A survey». En: *Computers and Electronics in Agriculture* 147 (2018), págs. 70-90. DOI: 10.1016/j.compag.2018.02.016.

⁴⁴ Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.

⁴⁵ Duda, Hart y Stork, ver n. 18.

⁴⁶ B. H. Cho et al. «Determination of Hass Avocado Ripeness During Storage Based on Smartphone Image and Machine Learning Model». En: *Food and Bioprocess Technology* 13.9 (2020), págs. 1579-1587. DOI: 10.1007/s11947-020-02494-x; Bhargava y Bansal, «Automatic Detection and Grading of Multiple Fruits by Machine Learning», ver n. 19.

Forest⁴⁷, XGBoost⁴⁸.

2.3.2. Deep Learning y Redes Neuronales Convolucionales El aprendizaje profundo ha transformado la clasificación de imágenes al permitir que los modelos aprendan automáticamente representaciones jerárquicas directamente desde los píxeles, eliminando la necesidad de diseñar manualmente las características⁴⁹. Dentro de este enfoque, las redes neuronales convolucionales (CNN) son especialmente efectivas para tareas de visión por computadora, ya que emplean capas convolucionales para extraer patrones espaciales como bordes, texturas y formas, mientras que las capas de agrupación reducen la dimensionalidad y mejoran la robustez frente a variaciones espaciales⁵⁰. Finalmente, las capas completamente conectadas utilizan las características aprendidas para realizar la clasificación final.

2.3.2.1. Arquitectura ResNet Una de las principales limitaciones de las redes profundas es el problema del *vanishing gradient*, en el cual los gradientes disminuyen progresivamente durante el entrenamiento, dificultando el aprendizaje en capas profundas⁵¹. Para abordar este problema, la arquitectura ResNet introduce bloques residuales con conexiones de salto (*skip connections*), donde la salida del bloque se expresa como: $y = F(x) + x$, donde $F(x)$ representa la transformación residual aprendida. La Figura 3 presenta el esquema general de un bloque residual.

⁴⁷ Breiman, ver n. 20.


⁴⁸ Chen y Guestrin, ver n. 21.

⁴⁹ LeCun, Bengio e Hinton, ver n. 42.

⁵⁰ Cho et al., ver n. 46; L. Chen et al. «Review of Image Classification Algorithms Based on Convolutional Neural Networks». En: *Remote Sensing* 13.22 (2021), pág. 4712. DOI: 10.3390/rs13224712.

⁵¹ He et al., ver n. 17.

Figura 3. Esquema de un bloque residual con conexiones de salto (*skip connections*) utilizado en arquitecturas ResNet.



Tomado de Chinthakunta Manjunath et al. «Enhancing Glaucoma Detection in Fundus Images: A ResNet based Segmentation and Advanced ML Algorithms with Duck Pack Optimizer». En: *International Research Journal of Multidisciplinary Technovation* (mar. de 2025), págs. 108-120. DOI: 10.54392/irjmt2529.


Dentro de esta familia, ResNet-50 corresponde a una arquitectura de 50 capas organizada en bloques tipo *bottleneck*, como se muestra en la Figura 4. Esta estructura permite extraer características profundas de manera eficiente, manteniendo un balance entre capacidad de representación y costo computacional⁵². En aplicaciones de clasificación de imágenes, ResNet-50 permite capturar desde patrones básicos de color y bordes hasta características complejas relacionadas con textura y forma⁵³. Además, la disponibilidad de pesos preentrenados sobre ImageNet facilita su adaptación mediante técnicas de *transfer learning* y *fine-tuning* en datasets de tamaño moderado⁵⁴.

⁵² He et al., ver n. 17.

⁵³ Ian Goodfellow, Yoshua Bengio y Aaron Courville. *Deep Learning*. MIT Press, 2016.

⁵⁴ Sinno Jialin Pan y Qiang Yang. «A Survey on Transfer Learning». En: *IEEE Transactions on Knowledge and Data Engineering* 22.10 (2010), págs. 1345-1359; Simon Kornblith, Jonathon Shlens y Quoc V. Le. «Do Better ImageNet Models Transfer Better?». En: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019, págs. 2661-2671.

Figura 4. Arquitectura general de ResNet-50 organizada en bloques residuales tipo *bottle-neck*.



Tomada de Chinthakunta Manjunath et al. «Enhancing Glaucoma Detection in Fundus Images: A ResNet based Segmentation and Advanced ML Algorithms with Duck Pack Optimizer». En: *International Research Journal of Multidisciplinary Technovation* (mar. de 2025), págs. 108-120. DOI: 10.54392/irjmt2529.

2.4. MÉTRICAS DE EVALUACIÓN DE MODELOS

La evaluación del desempeño de los modelos de clasificación se realizó mediante métricas derivadas de la matriz de confusión, la cual relaciona las clases reales y las predichas⁵⁵. Entre las métricas empleadas se encuentran *accuracy*, *precision*, *recall* y *F1-score*. La *accuracy* mide el porcentaje global de aciertos del modelo, mientras que *precision* y *recall* permiten evaluar el impacto de falsos positivos y falsos negativos, respectivamente. Por su parte, el *F1-score* combina ambas métricas en una sola medida, siendo especialmente útil en escenarios con desbalance entre clases⁵⁶. Adicionalmente, la matriz de confusión permite identificar las etapas de maduración con mayor solapamiento visual y analizar los patrones de error del modelo. Finalmente, se evaluó la capacidad de generalización mediante el análisis de posibles fenómenos de *overfitting*, comparando el

⁵⁵ Goodfellow, Bengio y Courville, ver n. 53.

⁵⁶ David M. W. Powers. «Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation». En: *arXiv preprint arXiv:2010.16061* (2020).

desempeño obtenido en entrenamiento y validación⁵⁷.

2.5. SISTEMAS EMBEBIDOS PARA VISIÓN POR COMPUTADORA

La Raspberry Pi es una plataforma de bajo costo, alta versatilidad y amplia adopción en aplicaciones de visión por computadora y agricultura inteligente, con capacidad para ejecutar sistemas operativos completos, integrar cámaras y periféricos, y procesar datos en tiempo real⁵⁸. Basada en arquitectura ARM, ofrece un balance entre consumo energético y capacidad de procesamiento, lo que la hace útil en escenarios de inferencia en campo. En comparación con microcontroladores convencionales, su mayor disponibilidad de memoria y potencia de cómputo permite ejecutar tareas más complejas, como segmentación de imágenes, extracción de características y despliegue de modelos de aprendizaje profundo. En aplicaciones agrícolas, estas capacidades facilitan el monitoreo no destructivo de frutos, la detección de enfermedades, el conteo automatizado y la clasificación por etapas de maduración⁵⁹.

⁵⁷ Goodfellow, Bengio y Courville, ver n. 53.

⁵⁸ Raspberry Pi Foundation. *Raspberry Pi Documentation*. Official documentation. 2023; Kamilaris y Prenafeta-Boldú, ver n. 43.

⁵⁹ Kamilaris y Prenafeta-Boldú, ver n. 43; Konstantinos G. Liakos et al. «Machine Learning in Agriculture: A Review». En: *Sensors* 18.8 (2018), pág. 2674. DOI: 10.3390/s18082674.

3. MÉTODO PROPUESTO

3.1. CONJUNTO DE DATOS UTILIZADOS

Para el desarrollo y evaluación del sistema de clasificación del estado de maduración del aguacate Hass se emplearon dos conjuntos de datos independientes: un dataset externo obtenido de internet⁶⁰ y un dataset propio construido específicamente para este proyecto. Ambos conjuntos fueron tratados como pruebas separadas, sin realizar mezcla de datos entre ellos, con el fin de analizar de manera objetiva el desempeño del modelo bajo diferentes condiciones de adquisición y etiquetado.


3.1.1. Dataset externo El dataset externo, reportado por Xavier et al.⁶¹ y desarrollado en Portugal, está conformado por 14,710 imágenes RGB de aguacate Hass, distribuidas como se observa en la Figura 5 y organizadas en tres condiciones de almacenamiento: T10, T20 y temperatura ambiente (TAM). Cada aguacate fue fotografiado diariamente desde dos lados opuestos. Para este trabajo se seleccionó el grupo T20 debido a sus condiciones de almacenamiento las cuales fueron las mas similares al dataset propio.

Las imágenes se encuentran etiquetadas en cinco etapas de maduración: Unripe, Breaking, Ripe (First Phase), Ripe (Second Phase) y Overripe. Adicionalmente, se realizó una reducción a tres clases agrupando las categorías 1–2 y 3–4, debido al solapamiento observado mediante análisis LDA. Todas las imágenes fueron redimensionadas a 224×224 píxeles para adaptarse a los modelos de aprendizaje profundo utilizados. La Figura 6 presenta ejemplos de imágenes del dataset externo.

⁶⁰ Xavier, ver n. 16.

⁶¹ Xavier, ver n. 16.

Figura 5. Distribución de datos según sus grupos de almacenamiento y categorías de maduración.



3.1.2. Dataset propio El dataset propio fue construido con el objetivo de replicar la estructura del dataset externo y evaluar el desempeño del modelo utilizando muestras reales de aguacate Hass provenientes de Santander, Colombia. Este conjunto está conformado por 1,656 imágenes RGB correspondientes a 24 aguacates únicos monitoreados durante 30 días de maduración, como se observa en la Figura 7. Las muestras fueron almacenadas a temperatura ambiente entre 23 °C y 27 °C, con un promedio de 24.4 °C. Las imágenes fueron etiquetadas siguiendo las mismas cinco categorías de maduración definidas en el dataset externo y posteriormente redimensionadas a 800 × 800 píxeles. A diferencia del dataset externo, se capturaron cuatro imágenes por aguacate para cubrir diferentes vistas del fruto y aumentar la variabilidad visual del conjunto de datos. La distribución de las clases se presenta en la Figura 8.

3.1.2.1. Sistema de adquisición de imágenes La estructura de captura fue construida con tubos de PVC de media pulgada y una base de poliestireno expandido recubierta

Figura 6. Muestras sin procesar del dataset externo correspondientes a diferentes etapas de maduración.




Figura 7. Muestras sin procesar del dataset propio correspondientes a diferentes etapas de maduración.




en color blanco, utilizada como fondo físico durante la adquisición de imágenes. Esta configuración permitió reducir la influencia de elementos externos y facilitar posteriormente el proceso de segmentación del aguacate.

El sistema de iluminación estuvo compuesto por 12 tiras LED distribuidas alrededor de la estructura, proporcionando una iluminación homogénea y reduciendo sombras y reflejos sobre la superficie del fruto. Las imágenes fueron capturadas con una cámara Logitech C920 utilizando parámetros fijos de adquisición (Cuadro 1), manteniendo condiciones constantes de iluminación y posicionamiento para todas las muestras.

3.1.3. Estructura del archivo de registro para el dataset propio Ambos dataset cuentan con un archivo CSV que almacena la información asociada a cada imagen. Estos archivos incluyen campos como el nombre del archivo de imagen, la clase de maduración asignada, el identificador del aguacate (muestra) y el día del experimento. En el caso del dataset externo, el CSV también incorpora información adicional relacionada con el grupo

Figura 8. Distribución de imágenes del dataset propio según las etapas de maduración.




de almacenamiento y la temperatura, mientras que en el dataset propio se omitieron estos campos al no ser aplicables.

3.2. PREPROCESAMIENTO DE IMÁGENES

Con el objetivo de estandarizar las imágenes y reducir la influencia de factores externos, todas las imágenes del dataset propio y externo fueron sometidas a un mismo pipeline de preprocesamiento previo al entrenamiento. Inicialmente, se realizó la eliminación del fondo utilizando segmentación basada en el espacio de color HSV, reemplazándolo por un fondo blanco uniforme para mantener coherencia visual con el montaje experimental. Este procedimiento se aplicó de manera idéntica a ambos datasets, como se muestra en

Figura 9. Esquema digital y montaje físico del sistema de adquisición de imágenes y clasificación de aguacates.



las Figuras 10 y 11.

Figura 10. Muestras del dataset propio para cada etapa de maduración luego de la eliminación del fondo.



Posteriormente, se aplicaron técnicas de aumento de datos exclusivamente sobre el conjunto de entrenamiento, incluyendo rotaciones, inversiones horizontales y traslaciones, con el fin de mitigar el desbalance entre clases y mejorar la capacidad de generalización del modelo. Finalmente, todas las imágenes fueron redimensionadas a 224×224 píxeles y normalizadas utilizando los parámetros de ImageNet requeridos por las arquitecturas evaluadas.

Cuadro 1. Parámetros de configuración utilizados durante la captura de imágenes del dataset propio. Los valores fueron definidos mediante ajustes visuales iterativos, considerando principalmente la reproducción natural de los colores del aguacate bajo las condiciones de iluminación del montaje experimental, influenciadas por la temperatura de color de los LEDs (6500K). Adicionalmente, se ajustaron variables de enfoque, exposición, contraste y nitidez con el fin de mejorar la consistencia visual y resaltar características superficiales relevantes para el proceso de clasificación.

Parámetro	Valor	Descripción
Balance de blancos (WB)	6500K	Controla la temperatura de color de la imagen, compensando la iluminación ambiental para que los colores se representen de manera natural y consistente.
Enfoque	10	Determina el plano de nitidez de la imagen, permitiendo capturar detalles superficiales del aguacate como textura y rugosidad.
Exposición	58	Regula la cantidad de luz que llega al sensor, influyendo directamente en la luminosidad general y en la visibilidad de detalles sin sobreexposición.
Brillo	152	Ajusta el nivel global de intensidad luminosa de la imagen, afectando la percepción de zonas claras y oscuras.
Contraste	118	Controla la diferencia entre las regiones claras y oscuras, mejorando la separación visual de formas y relieves en la superficie del fruto.
Saturación	288	Define la intensidad de los colores, permitiendo resaltar variaciones cromáticas asociadas a los estados de maduración.
Nitidez	223	Acentúa los bordes y detalles finos de la imagen, facilitando la identificación de patrones texturales relevantes.

3.3. DIVISIÓN DE LOS DATOS (SPLITS DE ENTRENAMIENTOS, VALIDACIÓN Y PRUEBA)


La división de los datos se realizó a nivel de aguacate (muestra) y no por imágenes individuales, asegurando que todas las fotografías de un mismo fruto pertenecieran ex-

Figura 11. Muestras del dataset externo para cada etapa de maduración luego de la eliminación del fondo.



clusivamente a un único conjunto de entrenamiento, validación o prueba. Esta estrategia permitió evitar problemas de *data leakage* y obtener una evaluación más confiable del desempeño del modelo.

Figura 12. Distribución de los datasets después del preprocesamiento de los datos.



Para ambos conjuntos de datos, la distribución final de estos conjuntos de datos se puede

observar en la Figura 12, sobre los cuales se aplicaron las siguientes pautas:

- **Proporción de la división:** Se asignó un 80 % de los aguacates al entrenamiento y el 20 % restante a los grupos de validación y prueba.
- **Método de selección:** La asignación de muestras fue aleatoria y reproducible, utilizando una semilla fija para barajar los identificadores de los aguacates.
- **Aplicación selectiva del aumento de datos:** Una vez divididas las muestras, el proceso de aumento de datos se ejecutó únicamente sobre el conjunto de entrenamiento, manteniendo los conjuntos de validación y prueba con las imágenes originales para asegurar resultados comparables y objetivos.


3.4. EXTRACCIÓN DE CARACTERÍSTICAS

Con el fin de analizar la capacidad discriminativa de las características aprendidas por la red convolucional, se utilizó una arquitectura ResNet-50 preentrenada eliminando su capa final de clasificación. De esta manera, cada imagen fue representada mediante un vector de 2048 características obtenido después de la capa de *Global Average Pooling*. Este procedimiento se realizó tanto para el esquema de cinco como de tres clases. Posteriormente, las características fueron normalizadas mediante estandarización para garantizar una distribución con media cero y varianza unitaria.

3.5. ARQUITECTURAS DE MODELOS EVALUADAS

Como parte de la estrategia de evaluación, se compararon distintas arquitecturas de redes neuronales convolucionales preentrenadas sobre ImageNet, incluyendo ResNet-50,

Figura 13. Arquitectura del proceso de extracción de características mediante ResNet-50 y su uso como entrada para clasificadores tradicionales.



MobileNetV2⁶² y AlexNet⁶³. En todos los casos, la capa de clasificación original fue reemplazada por una cabeza personalizada adaptada al número de clases del problema. A partir de los resultados obtenidos, ResNet-50 fue seleccionada como la arquitectura principal debido a su mejor desempeño. Posteriormente, esta red se utilizó como extractor de características profundas, empleando la salida de la capa de *Global Average Pooling* para generar vectores de 2048 dimensiones por imagen. Como se muestra en la Figura 13, es-

⁶² Andrew G. Howard, Menglong Zhu, Bo Chen et al. «MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications». En: *arXiv preprint arXiv:1704.04861* (2017).


⁶³ Alex Krizhevsky, Ilya Sutskever y Geoffrey E. Hinton. «ImageNet classification with deep convolutional neural networks». En: *Commun. ACM* 60.6 (mayo de 2017), 84–90. DOI: 10.1145/3065386.

tos vectores fueron utilizados como entrada para clasificadores tradicionales como LDA, SVM, Random Forest y XGBoost, con el fin de evaluar la separabilidad del espacio latente aprendido por la red convolucional.

3.6. ARQUITECTURA SELECCIONADA: RESNET-50

En el modelo final de la Figura 14, se reemplazó la capa final de la ResNet-50 por una cabeza de clasificación personalizada diseñada para adaptar la red, originalmente entrenada para 1,000 clases, a los estados de madurez específicos del aguacate, también se implementaron funciones de activación no lineales, normalización por lotes y mecanismos de regularización mediante *dropout*, lo que permitió mejorar la generalización del modelo.

Figura 14. Arquitectura del modelo ResNet-50 con ajuste de las capas de salida.



3.7. ESTRATEGIAS DE ENTRENAMIENTO

Para el entrenamiento de ResNet-50 se empleó una estrategia de *Transfer Learning* y *Fine-tuning* utilizando pesos preentrenados sobre ImageNet. Con el fin de preservar las características visuales generales y reducir el sobreajuste, las capas iniciales del *backbone* convolucional permanecieron congeladas, mientras que el ajuste fino se realizó únicamente sobre los bloques residuales más profundos (*layer3* y *layer4*) y la cabeza de clasificación personalizada. Esta configuración permitió adaptar el modelo a los patrones específicos de maduración del aguacate Hass manteniendo la estabilidad del aprendizaje previo.

3.8. DESPLIEGUE DEL MODELO DE CLASIFICACIÓN

El modelo entrenado en PyTorch se exportó al formato ONNX (*Open Neural Network Exchange*) con el fin de facilitar su despliegue en dispositivos embebidos como la Raspberry Pi. Para ello, primero se reconstruyó la arquitectura del modelo, se cargaron los pesos entrenados desde el archivo de mejor desempeño que se obtuvo del entrenamiento y se dejó el modelo en modo de evaluación. Posteriormente, utilizando una entrada de ejemplo con las dimensiones esperadas por la red ($3 \times 224 \times 224$), se realizó la exportación mediante `torch.onnx.export`, incluyendo los pesos, definiendo los nombres de entrada y salida, y configurando el tamaño del lote como dinámico. Finalmente, el archivo ONNX generado fue validado con la librería `onnx` para verificar que la exportación se hubiera realizado correctamente.

La implementación en la Raspberry Pi sigue un procedimiento muy similar. Se utiliza la librería ONNX Runtime para cargar directamente el modelo unificado en formato `.onnx` en modo evaluación, el cual va a recibir las imágenes. Una vez inicializado el modelo, se emplea OpenCV para capturar estas imágenes en tiempo real desde la cámara. Cada imagen es preprocesada y enviada al modelo, el cual realiza una inferencia rápida y devuelve la etapa de maduración correspondiente. Este proceso se repite de forma continua para clasificar cada imagen capturada, permitiendo obtener predicciones en tiempo real con un bajo costo computacional.

3.9. SISTEMA DE PRUEBAS EN LA PLATAFORMA EMBEBIDA

Para evaluar el desempeño del sistema en condiciones de operación reales, se realizó la transición del modelo a una plataforma embebida utilizando una Raspberry Pi 5⁶⁴ (8GB

⁶⁴ Raspberry Pi Foundation, ver n. 58.

RAM, 64GB ROM), asegurando la consistencia operativa al emplear el mismo montaje físico e iluminación utilizados durante la fase de adquisición de datos.

La validación se llevó a cabo bajo dos modalidades complementarias: primero, se ejecutaron inferencias sobre imágenes estáticas nuevas utilizando el modelo en formato *.pth* para verificar que la precisión no se degradara al cambiar de hardware. Posteriormente, se implementó una prueba de video en tiempo real mediante la optimización del modelo al formato ONNX, lo que permitió procesar cuadros de video de forma continua directamente en la CPU. En esta fase, el sistema replica el pipeline de preprocesamiento original al eliminar el fondo en el espacio de color HSV antes de clasificar cada imagen, confirmando así la viabilidad técnica y la robustez de la plataforma para soportar cargas de procesamiento exigentes en un escenario funcional.

4. RESULTADOS


4.1. ANÁLISIS DEL DATASET EXTERNO Y EL DATASET PROPIO

Con el fin de caracterizar las diferencias entre ambos datasets y comprender el comportamiento del proceso de maduración, se realizó un análisis de la distribución temporal de las etapas y de la evolución del color durante la maduración del aguacate Hass. Este análisis permitió identificar los desbalances entre clases, así como variaciones cromáticas asociadas tanto al estado de maduración como a las condiciones de adquisición de las imágenes.

4.1.1. Comportamiento de la maduración para los datasets En la Figura 15 se puede observar que el grupo T10 (10°C) presenta los tiempos más prolongados, superando los 6 días en la etapa inicial y manteniéndose sobre los 5 días en las fases finales, confirmando el efecto ralentizador de la refrigeración. Este grupo además describe una curva en forma de V con una caída abrupta en la etapa 2, lo que indica que el frío no solo retrasa el proceso sino que altera su dinámica interna. Por su parte, los grupos T20 y Tam (temperatura ambiente) muestran una maduración más rápida, con transiciones de entre 1.5 y 3 días por etapa, y una dispersión notablemente menor, lo que sugiere que a mayor temperatura el proceso tiende a ser más uniforme y predecible entre muestras.

En contraste, el dataset propio muestra un comportamiento más ordenado y consistente: el número de muestras se mantiene constante en todas las etapas ($n=24$), garantizando una distribución balanceada. Se observa una tendencia descendente clara, donde las etapas iniciales registran tiempos de permanencia significativamente mayores (cerca de 12 días) lo que puede sugerir que los frutos fueron cortados de manera temprana. Este tiempo disminuye y se estabiliza alrededor de 3-4 días en las etapas intermedias y fi-


Figura 15. Duración promedio de la maduración para los aguacates Hass en el dataset externo por tipo de almacenamiento y el dataset propio.



nales. La variabilidad también se reduce progresivamente, resultando en un conjunto de datos más homogéneo y con mejor definición temporal, características que lo hacen más adecuado como referencia para el entrenamiento de modelos de clasificación.

4.1.2. Cambio de color de los datasets La Figura 16 muestra la evolución del canal a^* (espacio CIE $L^*a^*b^*$) a lo largo de las cinco etapas de maduración, obtenido extrayendo un parche central de 30×30 píxeles por imagen y promediando los valores por categoría y grupo. Este canal captura el desplazamiento cromático de verde hacia rojo/café, por lo que su incremento progresivo es coherente con los cambios visuales de la cáscara del aguacate Hass durante la maduración. Se observa que el cambio más pronunciado ocu-


Figura 16. Comparación del comportamiento del valor de color a^* (canal verde a rojo) en función de la categoría de madurez para el dataset propio y datasets externos bajo diferentes condiciones de almacenamiento (T10, T20 y ambiente). Se evidencia una tendencia creciente consistente, validando la coherencia del dataset construido respecto a referencias externas.



re entre las etapas 1 y 3, donde la pendiente es notablemente mayor, correspondiendo a las etapas de verde a transición y de transición a maduro1. A partir de la etapa 3 la curva se aplana, indicando que las diferencias cromáticas entre etapas finales son progresivamente menores y más difíciles de distinguir con este canal de forma aislada. Respecto a la comparación entre datasets, el dataset propio parte de valores consistentemente más bajos en las etapas iniciales y converge hacia los del dataset externo solo en las etapas finales, lo que evidencia una diferencia sistemática en la representación cromática del mismo estado de maduración según el origen de las imágenes. Esta discrepancia dificulta la unificación de ambos datasets para tareas de clasificación basadas en color, ya que un modelo entrenado con ambas fuentes estaría expuesto a representaciones cromáticas distintas para una misma etapa.

Adicional, en la Figura 17, se puede observar como el color de la cáscara cambia de a lo largo de los días de almacenamiento. La luminosidad (L^*) disminuye, reflejando cómo

Figura 17. Evolución de los componentes de color del espacio CIE $L^*a^*b^*$ durante el almacenamiento del aguacate Hass en el dataset propio. Se observa una disminución de la luminosidad (L^*) y del componente amarillo-azul (b^*), junto con un incremento del componente verde-rojo (a^*), evidenciando los cambios cromáticos asociados al proceso de maduración.



la corteza se va oscureciendo con el tiempo Figura 17(a). Por otro lado, el parámetro verde/rojo (a^*) muestra una curva que al principio los valores son muy bajos debido al color verde intenso de la fruta, pero a mitad del proceso suben rápidamente hacia valores mayores a medida que el aguacate pierde su color verde y se vuelve oscuro Figura 17(b). Finalmente, los componentes amarillos (b^*) también decrecen por completo Figura 17(c).

4.2. RESULTADOS PRELIMINARES DE LOS MODELOS DE CLASIFICACIÓN

El cuadro 2 presenta los resultados de una evaluación preliminar realizada con el objetivo de identificar la arquitectura y el enfoque de clasificación más adecuados para el problema. Se compararon tres arquitecturas de deep learning (ResNet-50, MobileNetV2 y AlexNet) además de la combinación de ResNet-50 con clasificadores clásicos (LDA, SVM, Random Forest y XGBoost), evaluando su comportamiento en ambos datasets y bajo los dos esquemas de clasificación. Esta exploración inicial permitió orientar las decisiones de diseño del sistema antes de profundizar en el análisis del modelo seleccionado.

Como primera exploración se evaluaron tres arquitecturas de deep learning de forma

Cuadro 2. Resultados preliminares de clasificación sobre los datasets empleados.


Modelo	Modelo 3 clases		Modelo 5 clases	
	Val.	Test	Val.	Test
Dataset propio				
MobileNetV2	77.47	70.08	70.65	59.22
AlexNet	74.05	68.73	63.84	57.36
ResNet50	81.52	77.85	72.96	68.48
ResNet50 + LDA	75.00	72.00	27.00	26.00
ResNet50 + SVC	83.00	74.00	66.00	59.00
ResNet50 + Random Forest	81.00	77.00	73.00	66.00
ResNet50 + XGBoost	84.00	79.00	71.00	66.00
Dataset externo				
MobileNetV2	76.66	74.46	72.25	69.36
AlexNet	72.25	69.13	57.53	55.97
ResNet50	81.65	79.05	76.63	72.25
ResNet50 + LDA	70.00	69.00	40.00	40.00
ResNet50 + SVC	79.00	77.00	69.00	66.00
ResNet50 + Random Forest	82.00	79.00	67.00	69.00
ResNet50 + XGBoost	81.00	77.00	72.00	71.00

directa: ResNet-50, MobileNetV2 y AlexNet. De las tres, ResNet-50 demostró ser la más estable y consistente, alcanzando entre 77 % y 79 % en test para 3 clases en ambos datasets y manteniendo resultados competitivos en 5 clases sin caídas abruptas entre validación y test. MobileNetV2 y AlexNet quedaron por debajo en todos los escenarios, especialmente en 5 clases donde ninguna superó el 70 % en test, lo que descartó su uso como arquitectura base. A partir de este resultado, y con el objetivo de validar si las características internas extraídas por ResNet-50 contenían información discriminativa de calidad, se planteó combinarlas con clasificadores clásicos como SVM, Random Forest y XGBoost. La hipótesis era que si estas representaciones eran suficientemente ricas, incluso modelos simples deberían lograr un buen desempeño. Los resultados confirmaron esta idea: XGBoost y Random Forest alimentados con las características de ResNet-50 alcanzaron entre 77 % y 79 % en test para 3 clases, igualando o superando a las

arquitecturas de deep learning evaluadas de forma directa, lo que sirvió como evidencia sólida de que ResNet-50 genera representaciones intrínsecamente discriminativas para este problema.

4.3. SEPARABILIDAD DEL ESPACIO DE CARACTERÍSTICAS MEDIANTE LDA

Figura 18. Proyección del espacio de características mediante Análisis Discriminante Lineal (LDA) para el dataset externo sin separación en tipos de almacenamiento.



Dado que ResNet-50 presentó el mejor desempeño en las pruebas iniciales, se analizó la separabilidad de sus representaciones mediante LDA para el dataset externo con 5 clases, proyectando las características en dos dimensiones. Las clases muestran una separación general adecuada; sin embargo, también se evidencia solapamiento entre etapas adyacentes y una alta variabilidad interna al combinar todas las condiciones de

almacenamiento, como se observa en la Figura 18, estos resultados motivaron el uso exclusivo del grupo T20 del dataset externo, debido a su mayor similitud con las condiciones del dataset propio, permitiendo una comparación más consistente y una evaluación más precisa de la separabilidad entre clases.


4.3.1. Comparación de separabilidad de los datasets La Figura 19 presenta las proyecciones LDA del espacio de características extraídas por ResNet-50 en su configuración base, para ambos datasets y esquemas de clasificación. El objetivo de este análisis es verificar si las representaciones del modelo, sin ningún ajuste adicional, son suficientes para separar las clases de maduración.

Los resultados para los cuatro escenarios se obtienen clústeres claramente diferenciados y sin solapamiento significativo, lo que confirma que ResNet-50 genera representaciones intrínsecamente discriminativas para este problema. En el escenario de 5 clases, ambos datasets muestran cinco agrupaciones bien definidas y espacialmente separadas a lo largo del eje LD1, con una dispersión intra-clase reducida. En el escenario de 3 clases la separación es aún más evidente, con clústeres más compactos y mayor distancia entre grupos. El dataset propio presenta en general una organización ligeramente más compacta, mientras que el externo muestra una dispersión moderadamente mayor, aunque sin comprometer la separabilidad. En conjunto, estos resultados validan que las características aprendidas por ResNet-50 capturan información visual suficiente para distinguir las etapas de maduración del aguacate Hass incluso antes de cualquier proceso de *fine-tuning*.

4.4. RESULTADOS CON RESNET-50

Con base en los resultados preliminares y en el análisis de separabilidad mediante LDA, se seleccionó ResNet-50 como la arquitectura principal para las pruebas finales de clasi-


Figura 19. Proyección del espacio de características mediante Análisis Discriminante Lineal (LDA) para el dataset externo y el dataset propio en sus distribuciones de 5 y 3 clases.



ficación. A continuación, se presentan los resultados obtenidos tras aplicar el proceso de entrenamiento y ajuste fino sobre los datasets propio y externo, evaluando su desempeño en los escenarios de 3 y 5 clases.

4.4.1. Curvas de entrenamiento La Figura 20 presenta de forma consolidada las curvas de entrenamiento y validación para ambos datasets bajo los esquemas de 3 y 5 clases. En el escenario de 3 clases (subgráficas a y b), ambos datasets muestran un comportamiento estable y una convergencia progresiva: el dataset externo alcanza su

Figura 20. Curvas de precisión y pérdida para el entrenamiento de los datasets con 3 clases. Elaboración propia.



punto óptimo en la época 17 con un *accuracy* de validación cercano al 87%, mientras que el propio lo hace también alrededor de la época 16 superando el 91 %, con una brecha menor entre entrenamiento y validación. Al aumentar la granularidad a 5 clases (subgráficas c y d), el comportamiento se vuelve notablemente más inestable en ambos casos: las oscilaciones en validación son persistentes y los puntos óptimos se desplazan, situándose en la época 10 para el dataset externo y en la época 22 para el propio, reflejando la mayor dificultad para establecer fronteras de decisión entre etapas visualmente similares. En conjunto, la comparación directa entre esquemas confirma que la granularidad de la clasificación es el factor más determinante en la estabilidad del entrenamiento: a

menor número de clases, mayor consistencia en la convergencia y mejor generalización, independientemente del dataset utilizado.

Cuadro 3. Reportes de clasificación para los modelos de 3 y 5 clases evaluados con dataset propio y externo.

(a) Dataset propio, 3 clases					(b) Dataset externo, 3 clases				
Clase	precision	recall	f1-score	support	Clase	precision	recall	f1-score	support
Verde	0.9774	0.9924	0.9848	131	Verde	1.0000	0.8592	0.9242	142
Maduro	0.9155	0.8125	0.8609	80	Maduro	0.8477	0.9176	0.8813	182
Dañado	0.7234	0.8500	0.7816	40	Dañado	0.8148	0.8684	0.8408	76
accuracy			0.9124	251	accuracy			0.8875	400
macro avg	0.8721	0.8850	0.8758	251	macro avg	0.8875	0.8817	0.8821	400
weighted avg	0.9172	0.9124	0.9130	251	weighted avg	0.8955	0.8875	0.8888	400

(c) Dataset propio, 5 clases					(d) Dataset externo, 5 clases				
Clase	precision	recall	f1-score	support	Clase	precision	recall	f1-score	support
Verde	0.8730	0.9821	0.9244	56	Verde	0.9077	0.8429	0.8741	70
Transición	0.9355	0.8657	0.8992	67	Transición	0.7778	0.7778	0.7778	72
Maduro1	0.6757	0.6944	0.6849	36	Maduro1	0.7000	0.5147	0.5932	68
Maduro2	0.7188	0.4792	0.5750	48	Maduro2	0.7477	0.7281	0.7378	114
Dañado	0.5778	0.8125	0.6753	32	Dañado	0.7059	0.9474	0.8090	76
accuracy			0.7824	239	accuracy			0.7625	400
macro avg	0.7561	0.7668	0.7518	239	macro avg	0.7678	0.7622	0.7584	400
weighted avg	0.7903	0.7824	0.7777	239	weighted avg	0.7651	0.7625	0.7578	400

4.4.2. Métricas de clasificación por esquema y dataset Como se presenta en el Cuadro 3, en los reportes de clasificación para los cuatro escenarios evaluados, el patrón más evidente es que la reducción de 5 a 3 clases mejora el desempeño de forma consistente en ambos datasets: el *accuracy* pasa de 78,24 % a 91,24 % en el dataset propio y de 76,25 % a 88,75 % en el externo. Sin embargo, el Macro F1 resulta más informativo que el *accuracy* global dado el desbalance de clases, y en ambos casos la diferencia entre Macro F1 y Weighted F1 es pequeña, lo que indica que el modelo no depende exclusivamente de las clases mayoritarias para sostener su rendimiento. En el esquema de 3 clases, la clase Verde es la mejor clasificada en ambos datasets por su distintividad


cromática, mientras que Dañado concentra los errores más frecuentes, combinando baja precisión por falsos positivos y confusiones con estados avanzados de madurez, comportamiento que se explica tanto por su menor representación en el conjunto de datos como por su similitud visual con Maduro.

Al aumentar la granularidad a 5 clases, las clases intermedias Maduro1 y Maduro2 se convierten en el principal problema del modelo en ambos datasets, con caídas notables en recall y F1-score que reflejan la dificultad de establecer fronteras de decisión claras dentro de un proceso de maduración continuo. La clase dañado presenta un comportamiento particular: alto *recall* pero baja precisión, lo que implica una detección conservadora con presencia de falsos positivos, genera clasificaciones erróneas de frutos en buen estado. Comparando entre datasets, el propio supera ligeramente al externo en 3 clases (91.24 % vs 88.75 %), mientras que en 5 clases los resultados convergen (78.24 % vs 76.25 %), sugiriendo que el techo de desempeño está determinado por la complejidad del esquema de clasificación más que por el origen de las imágenes.

4.4.3. Desempeño, generalización e interpretabilidad del modelo La Figura 21 muestra la evolución de las activaciones internas de ResNet-50 a través de sus capas convolucionales para dos configuraciones distintas: (a) el modelo entrenado con el dataset externo en el esquema de 3 clases, y (b) el modelo entrenado con el dataset propio en el esquema de 5 clases. En ambos casos, desde las primeras capas (conv1 y layer1) el modelo suprime de forma efectiva el fondo y concentra la activación sobre la región del aguacate, comportamiento que se refina progresivamente hacia las capas más profundas. En layer3 y layer4 la activación converge hacia zonas específicas del fruto, indicando que el modelo extrae características semánticas relevantes para la clasificación y no ruido de fondo. El hecho de que este patrón sea consistente en ambas configuraciones, con distintos esquemas de clasificación y distintos orígenes de datos, confirma que ResNet-50 discrimina de forma robusta el objeto de interés y que sus representaciones generalizan

correctamente independientemente del dataset o la granularidad del esquema utilizado.

Figura 21. Mapas de activación por capa del modelo ResNet-50 para los modelos de 3 y 5 clases.




4.5. VALIDACIÓN EXPERIMENTAL EN RASPBERRY PI

4.5.1. Validación para el desarrollo de un dataset propio Como una de las pruebas se evaluó si era viable utilizar directamente el dataset externo para entrenar el modelo y desplegarlo en el sistema de adquisición propio, evitando así la construcción de un dataset nuevo. Los resultados de esta prueba, mostrados en la Figura 22, evidenciaron que el enfoque no era suficiente: en el esquema de 3 clases el modelo clasificaba Verde con un rendimiento aceptable, pero Maduro y Dañado presentaban confusiones elevadas entre sí. En el esquema de 5 clases la situación era más crítica, con las clases intermedias clasificadas de forma inconsistente y errores notablemente mayores.

La causa es directa: el dataset externo fue capturado con dispositivos, iluminación y condiciones distintas a las del sistema propio, por lo que el modelo aprendió patrones visuales que no corresponden a las imágenes que iba a recibir en operación real. Al enfrentarse a una distribución visual diferente, su capacidad de clasificación se degradó de forma significativa. Este resultado demostró que entrenar con datos de otro entorno y desplegar en el propio introduce una brecha de dominio que el modelo no puede superar, y justificó la

Figura 22. Resultados de las matrices de confusión sobre conjunto de pruebas independiente ejecutado en Raspberry Pi con modelos de 3 y 5 clases entrenados con el dataset externo.




decisión de construir un dataset capturado bajo las mismas condiciones del sistema real, lo cual, como se mostró en las secciones anteriores, mejoró el rendimiento de forma clara y consistente.

4.5.2. Evaluación del dataset propio en la Raspberry Pi Los resultados obtenidos en la Raspberry Pi que muestra la Figura 23 muestran un comportamiento consistente con lo observado durante la evaluación local, lo que confirma que el traslado del modelo a la plataforma embebida no introduce degradación significativa en la capacidad de clasificación.

En los cuadros 5 y ?? para el modelo de 3 clases, la exactitud global alcanza el 89.89 % sobre 455 muestras completamente nuevas, un resultado muy cercano al 91.24 % obtenido localmente. El Macro F1 de 0.8654 también es coherente con el 0.8758 de la evaluación original, lo que indica que el modelo generaliza bien a datos no vistos en condiciones reales de captura. El patrón de errores se mantiene igual: Verde sigue siendo la

Figura 23. Resultados de las matrices de confusión sobre conjunto de pruebas independiente ejecutado en Raspberry Pi con modelos de 3 y 5 clases entrenados con el dataset propio.



clase mejor clasificada, y la frontera entre Maduro y Dañado concentra los errores más relevantes, con algunos aguacates maduros clasificados como dañados y viceversa. Que este comportamiento se replique de forma tan fiel en hardware diferente es una señal positiva de estabilidad del modelo.

El modelo de 5 clases presenta una exactitud del 74.29% y un Macro F1 de 0.7076, valores ligeramente inferiores a los obtenidos localmente (78.24% y 0.7518 respectivamente). La diferencia es pequeña pero consistente con lo esperado: al ser un problema más complejo, cualquier variación en las condiciones de captura o procesamiento tiene mayor impacto. La matriz de confusión confirma que los patrones de error se mantienen: Verde y Transición se clasifican bien, mientras que Maduro1, Maduro2 y Dañado concentran la mayoría de los errores. Llama la atención que Transición presenta un número considerable de confusiones hacia Maduro1, lo que sugiere que en este conjunto de pruebas las imágenes de transición capturadas en el dispositivo presentaban característi-

Cuadro 4. Reporte de clasificación con 5 clases empleando el dataset propio en la Raspberry Pi.

Clase	Precision	Recall	F1-score	Support
Verde	0.9825	0.9573	0.9697	234
Maduro	0.8431	0.8543	0.8487	151
Dañado	0.7568	0.8000	0.7778	70
Accuracy		0.8989		455
Macro avg	0.8608	0.8705	0.8654	455
Weighted avg	0.9015	0.8989	0.9000	455


Cuadro 5. Reporte de clasificación con 3 clases empleando el dataset propio en la Raspberry Pi.

Clase	Precision	Recall	F1-score	Support
Verde	0.9424	0.9704	0.9562	135
Transición	0.9412	0.6465	0.7665	99
Maduro1	0.4839	0.8451	0.6154	71
Maduro2	0.5577	0.3625	0.4394	80
Dañado	0.7500	0.7714	0.7606	70
Accuracy		0.7429		455
Macro avg	0.7350	0.7192	0.7076	455
Weighted avg	0.7734	0.7429	0.7408	455

cas más avanzadas de madurez que las vistas durante el entrenamiento. Maduro2 sigue siendo la clase más problemática, con menos de la mitad de sus muestras clasificadas correctamente y errores distribuidos principalmente hacia Maduro1 y Dañado, replicando exactamente la debilidad estructural identificada en la evaluación local.

4.5.3. Prueba en tiempo real Para la prueba de clasificación en video (Figura 24), el sistema fue configurado con una tasa de inferencia limitada a 2 FPS, decisión justificada por la naturaleza estática del objeto a clasificar: dado que el aguacate no se desplaza durante la captura, no se requiere una frecuencia de muestreo alta y reducirla permite al

Figura 24. Montaje de la estructura en funcionamiento en tiempo real.



procesador de la Raspberry Pi operar con mayor estabilidad. Los registros muestran que el sistema mantiene valores cercanos a los 2 FPS de forma consistente durante toda la ejecución, lo que indica que el pipeline completo captura, preprocesamiento e inferencia ONNX se sostiene sin interrupciones dentro de ese margen establecido.

La eliminación de fondo se ejecuta en segundo plano sin renderizarse sobre el video mostrado en pantalla (Figura 25), esta decisión fue tomada para reducir la carga de procesamiento sobre el dispositivo y evitar cuellos de botella en la visualización. El frame que ve el usuario corresponde a la imagen original de la cámara, mientras que internamente el modelo recibe la versión preprocesada. El sistema además permite pausar la inferencia y activar o desactivar el preprocesamiento mediante controles de teclado, lo que facilita su uso en un entorno de prueba real.

En cuanto a las predicciones, el sistema muestra en pantalla las dos clases con mayor probabilidad en cada frame. Las capturas evidencian niveles de confianza elevados, por encima del 80 % en la mayoría de los casos, y la segunda predicción corresponde con-

Figura 25. Visualización del funcionamiento en tiempo real del modelo para 2 muestras diferentes. Elaboración propia.



sistentemente a la clase adyacente en el espectro de madurez, lo cual es coherente con el comportamiento observado en las pruebas con imágenes estáticas. En conjunto, esta prueba confirma que la Raspberry Pi es capaz de sostener el pipeline de clasificación en tiempo real de forma funcional dentro de las condiciones de operación definidas para el sistema.

5. CONCLUSIONES

Los resultados obtenidos a lo largo de este trabajo permiten concluir que es posible construir un sistema de clasificación de estados de madurez en aguacates a partir de imágenes RGB, tanto en un entorno de evaluación local como desplegado sobre una plataforma embebida. Sin embargo, el camino hacia ese resultado dejó aprendizajes importantes sobre las condiciones necesarias para que el sistema funcione de manera confiable.

El primer hallazgo relevante está relacionado con la importancia de la consistencia entre los datos de entrenamiento y las condiciones reales de operación. El uso de un dataset externo demostró ser un punto de partida válido para explorar la viabilidad del enfoque, pero los resultados evidenciaron una degradación clara en el rendimiento al momento de clasificar imágenes capturadas con el sistema de adquisición propio. Esto se atribuye a las diferencias en iluminación, dispositivo y condiciones generales de captura entre ambos entornos. Al construir un dataset propio bajo el mismo montaje utilizado durante las pruebas, el rendimiento mejoró de forma consistente en ambos modelos, lo que confirma que adaptar los datos al contexto específico de la aplicación es tan importante como la arquitectura del modelo en sí.

No obstante, aun con el dataset propio persisten dificultades en la clasificación de los estados intermedios y avanzados de madurez. La transición entre etapas como Maduro1, Maduro2 y Dañado representa el mayor reto del sistema, y los patrones de confusión observados en las matrices apuntan a una limitación de fondo: la imagen RGB por sí sola no siempre aporta suficiente información para distinguir con precisión estos estados, cuyas diferencias visuales pueden ser sutiles o ambiguas. Explorar fuentes de información complementarias en la misma imagen, como características de textura, análisis en otros espacios de color o técnicas de atención que focalicen regiones más discriminativas, re-

presenta una dirección natural para mejorar la separación entre estas clases.

Adicionalmente, las pruebas realizadas en la Raspberry Pi demostraron que es posible tener un sistema de clasificación funcional sobre hardware de bajo costo, capaz de sostener un proceso completo de captura, preprocesamiento e inferencia en tiempo real dentro de los parámetros definidos. Para el tipo de aplicación evaluada, donde el objeto es estático y no se requiere alta frecuencia de muestreo, el dispositivo responde de manera adecuada. Sin embargo, si se busca escalar el sistema hacia algo más complejo (incorporar segmentación semántica previa a la clasificación, procesar modelos más grandes o aumentar la tasa de inferencia) la Raspberry Pi en su configuración actual encontraría limitaciones computacionales importantes. En ese escenario sería necesario explorar optimizaciones adicionales del modelo, el uso de aceleradores de hardware dedicados, o migrar hacia una plataforma con mayor capacidad de procesamiento que permita sostener pipelines más exigentes sin comprometer el rendimiento del sistema.

6. TRABAJO FUTURO

Como principales líneas de trabajo futuro se identifican dos direcciones que apuntan directamente a las limitaciones encontradas durante el desarrollo de este sistema. La primera tiene que ver con enriquecer la información disponible en la imagen. Dado que el espectro RGB limita la discriminación entre estados de madurez visualmente similares, una mejora natural sería incorporar una cámara NoIR u otro dispositivo que permita capturar propiedades del aguacate más allá del color y la textura superficial, como la reflectancia en el espectro infrarrojo, que puede estar relacionada con cambios internos de madurez no visibles a simple vista. Esto implicaría construir un nuevo dataset aprovechando las capacidades de ese tipo de sensor, lo que potencialmente aportaría características más discriminativas para las clases intermedias del espectro de madurez donde el sistema actual presenta mayores dificultades.

La segunda línea se enfoca en la automatización del proceso de clasificación. El sistema actual requiere que los aguacates se presenten de forma individual y estática frente a la cámara, lo que limita su aplicabilidad en un entorno de producción real. Incorporar un modelo que combine segmentación y clasificación permitiría detectar y clasificar múltiples aguacates simultáneamente, incluso en movimiento, abriendo la posibilidad de integrar el sistema en una línea de transporte automatizada sin intervención manual. Para esto sería necesario evaluar arquitecturas más especializadas en detección y segmentación, así como considerar hardware con mayor capacidad de procesamiento que pueda sostener ese tipo de pipeline de forma eficiente.

BIBLIOGRAFÍA

- Agricultura, Ministerio de. *1.500 toneladas de aguacate Hass colombiano le pondrán sabor al Super Bowl, el más grande evento deportivo de Estados Unidos*. Accedido: 2024-08-30. 2024 (vid. pág. 14).
- AGROSAVIA. *Manejo del cultivo de aguacate Hass en Colombia*. Inf. téc. Accedido: 2025-09-13. Corporación Colombiana de Investigación Agropecuaria, 2019 (vid. pág. 19).
- Araújo, R.G. et al. «Avocado by-products: Nutritional and functional properties». En: *Trends in Food Science & Technology* 80 (2018), págs. 51-60. DOI: 10.1016/j.tifs.2018.07.027 (vid. pág. 14).
- Arzate Vázquez, I. et al. «Image Processing Applied to Classification of Avocado Variety Hass (Persea americana Mill.) During the Ripening Process». En: *Food and Bioprocess Technology* 4.7 (2011), págs. 1307-1313. DOI: 10.1007/s11947-011-0595-6 (vid. pág. 15).
- Bhargava, A. y A. Bansal. «Automatic Detection and Grading of Multiple Fruits by Machine Learning». En: *Food Analytical Methods* 13.3 (2020), págs. 751-761. DOI: 10.1007/s12161-019-01690-6 (vid. págs. 17, 25).
- «Fruits and vegetables quality evaluation using computer vision: A review». En: *Journal of King Saud University - Computer and Information Sciences* 33.3 (2021), págs. 243-257. DOI: 10.1016/j.jksuci.2018.06.002 (vid. pág. 16).
- Bishop, Christopher M. *Pattern Recognition and Machine Learning*. Springer, 2006 (vid. pág. 25).

- Blasco, José et al. «Automated Systems Based on Machine Vision for Inspecting Citrus Fruits from the Field to Postharvest—A Review». En: *Food and Bioprocess Technology* 9 (2016), págs. 1623-1639. DOI: 10.1007/s11947-016-1767-1 (vid. págs. 23, 24).
- Breiman, Leo. «Random Forests». En: *Machine Learning* 45.1 (2001), págs. 5-32. DOI: 10.1023/A:1010933404324 (vid. págs. 17, 26).
- Brosnan, Tadhg y Da-Wen Sun. «Inspection and grading of agricultural and food products by computer vision systems—a review». En: *Computers and Electronics in Agriculture* 36.2 (2002), págs. 193-213. DOI: [https://doi.org/10.1016/S0168-1699\(02\)00101-1](https://doi.org/10.1016/S0168-1699(02)00101-1) (vid. págs. 22, 24).
- Business, Dmass. *Aguacate Mexicano de Exportación*. Accedido: 2024-10-15 (vid. pág. 22).
- Chen, L. et al. «Review of Image Classification Algorithms Based on Convolutional Neural Networks». En: *Remote Sensing* 13.22 (2021), pág. 4712. DOI: 10.3390/rs13224712 (vid. pág. 26).
- Chen, Tianqi y Carlos Guestrin. «XGBoost: A Scalable Tree Boosting System». En: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016, págs. 785-794. DOI: 10.1145/2939672.2939785 (vid. págs. 17, 26).
- Cho, B. H. et al. «Determination of Hass Avocado Ripeness During Storage Based on Smartphone Image and Machine Learning Model». En: *Food and Bioprocess Technology* 13.9 (2020), págs. 1579-1587. DOI: 10.1007/s11947-020-02494-x (vid. págs. 25, 26).

- Cox, Katy A. et al. «Skin colour and pigment changes during ripening of 'Hass' avocado fruit». En: *Postharvest Biology and Technology* 31.3 (2004), págs. 287-294. DOI: 10.1016/j.postharvbio.2003.09.008 (vid. pág. 19).
- Davur, Y. J. et al. «Estimating the Ripeness of Hass Avocado Fruit Using Deep Learning with Hyperspectral Imaging». En: *Horticulturae* 9.5 (2023), pág. 599. DOI: 10.3390/horticulturae9050599 (vid. pág. 15).
- Desarrollo, BID Banco Interamericano de. *Estrategias Público-Privadas para el establecimiento de un ciclo de exportación de aguacate exitoso. Casos de Colombia y Perú*. Accedido: 2025-09-13. 2017 (vid. pág. 19).
- Dreher, M. L. y A.J. Davenport. «Hass Avocado Composition and Potential Health Effects». En: *Critical Reviews in Food Science and Nutrition* 53.7 (2013), págs. 738-750. DOI: 10.1080/10408398.2011.556759 (vid. pág. 14).
- Duda, Richard O., Peter E. Hart y David G. Stork. *Pattern Classification*. 2.^a ed. Wiley-Interscience, 2001 (vid. págs. 16, 25).
- Escobar Figueroa, D. y E. Roa Guerrero. «Sistema de visión artificial para la identificación del estado de madurez de frutas (granadilla)». En: *Redes de Ingeniería* 7 (2016). DOI: 10.14483/udistrital.jour.redes.2016.1.a08 (vid. pág. 15).
- García Urrego, T. *Colombia triplicó sus exportaciones de aguacate Hass hacia Estados Unidos en 2024*. Accedido: 2024-10-28. 2024 (vid. pág. 14).
- Gonzalez, Rafael C. y Richard E. Woods. *Digital Image Processing*. 4.^a ed. Pearson, 2018 (vid. pág. 23).

Goodfellow, Ian, Yoshua Bengio y Aaron Courville. *Deep Learning*. MIT Press, 2016 (vid. págs. 27-29).

Guerra, Juan Pablo y Francisco Cuevas. «Application of Digital Image Processing Techniques for Agriculture: A Review». En: *Digital Image Processing - Latest Advances and Applications*. Ed. por Francisco Cuevas, Pier Luigi Mazzeo y Alessandro Bruno. London: IntechOpen, 2024. Cap. 2. DOI: 10.5772/intechopen.1004767 (vid. págs. 22-24).

He, Kaiming et al. «Deep Residual Learning for Image Recognition». En: (2016), págs. 770-778. DOI: 10.1109/CVPR.2016.90 (vid. págs. 16, 26, 27).

Howard, Andrew G., Menglong Zhu, Bo Chen et al. «MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications». En: *arXiv preprint arXiv:1704.04861* (2017) (vid. pág. 38).

Kamilaris, Andreas y Francesc X. Prenafeta-Boldú. «Deep learning in agriculture: A survey». En: *Computers and Electronics in Agriculture* 147 (2018), págs. 70-90. DOI: 10.1016/j.compag.2018.02.016 (vid. págs. 25, 29).

Kornblith, Simon, Jonathon Shlens y Quoc V. Le. «Do Better ImageNet Models Transfer Better?». En: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019, págs. 2661-2671 (vid. pág. 27).

Krizhevsky, Alex, Ilya Sutskever y Geoffrey E. Hinton. «ImageNet classification with deep convolutional neural networks». En: *Commun. ACM* 60.6 (mayo de 2017), 84–90. DOI: 10.1145/3065386 (vid. pág. 38).

LeCun, Yann, Yoshua Bengio y Geoffrey Hinton. «Deep learning». En: *Nature* 521 (2015), págs. 436-444. DOI: 10.1038/nature14539 (vid. págs. 25, 26).

- Legiscomex.com. *El aguacate 'Hass' colombiano tiene un mundo de anaqueles esperando*. Accedido: 2024-10-28. 2024 (vid. pág. 14).
- León, Katherine et al. «Color measurement in Lab units from RGB digital images». En: *Food Research International* 39.10 (2006). Physical Properties VI, págs. 1084-1091. DOI: <https://doi.org/10.1016/j.foodres.2006.03.006> (vid. pág. 24).
- Liakos, Konstantinos G. et al. «Machine Learning in Agriculture: A Review». En: *Sensors* 18.8 (2018), pág. 2674. DOI: 10.3390/s18082674 (vid. pág. 29).
- Magwaza, L. S. y S. Z. Tesfay. «A Review of Destructive and Non-destructive Methods for Determining Avocado Fruit Maturity». En: *Food Bioprocess Technol* 8 (2015). DOI: 10.1007/s11947-015-1568-y (vid. págs. 15, 20, 21).
- Manjunath, Chinthakunta et al. «Enhancing Glaucoma Detection in Fundus Images: A ResNet based Segmentation and Advanced ML Algorithms with Duck Pack Optimizer». En: *International Research Journal of Multidisciplinary Technovation* (mar. de 2025), págs. 108-120. DOI: 10.54392/irjmt2529 (vid. págs. 27, 28).
- Martínez Sandoval, Jesús Raúl et al. «Color Analysis and Image Processing Applied in Agriculture». En: *Image Processing in Agriculture*. IntechOpen, 2017. DOI: 10.5772/intechopen.71539 (vid. págs. 23, 24).
- Melado Herreros, A. et al. «Postharvest ripeness assessment of 'Hass' avocado based on development of a new ripening index and Vis-NIR spectroscopy». En: *Postharvest Biology and Technology* 181 (2021), pág. 111683. DOI: 10.1016/j.postharvbio.2021.111683 (vid. pág. 15).

- Olivares, Daniela et al. «Effects of Delaying the Storage of 'Hass' Avocados under a Controlled Atmosphere on Skin Color, Bioactive Compounds and Antioxidant Capacity». En: *Plants* 13.11 (2024), pág. 1455. DOI: 10.3390/plants13111455 (vid. pág. 19).
- Pan, Sinno Jialin y Qiang Yang. «A Survey on Transfer Learning». En: *IEEE Transactions on Knowledge and Data Engineering* 22.10 (2010), págs. 1345-1359 (vid. pág. 27).
- Patel, H. y R. Jain. «Automatic Fruit Defect Detection Using HSV and RGB Color Space Model». En: *International Journal of Innovative Research in Computer Science and Technology* 2.4 (2014) (vid. pág. 24).
- Pinto, J., H. Rueda y H. Arguello. «Classification of Hass avocado (persea americana mill) in terms of its ripening via hyperspectral images». En: *TecnoLógicas* 22.45 (2019), págs. 109-128. DOI: 10.22430/22565337.1232 (vid. págs. 15, 22).
- Powers, David M. W. «Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation». En: *arXiv preprint arXiv:2010.16061* (2020) (vid. pág. 28).
- Raspberry Pi Foundation. *Raspberry Pi Documentation*. Official documentation. 2023 (vid. págs. 29, 40).
- Sierra, N. M. et al. «Evaluation and modeling of changes in shelf life, firmness and color of 'Hass' avocado depending on storage temperature». En: *Journal of Food Processing and Preservation* 43.6 (2019), e13935. DOI: 10.1177/1082013219826825 (vid. págs. 19, 21).
- Wedding, B. B. «The non-invasive assessment of avocado maturity and quality». En: *School of Marine and Tropical Biology* (2018). DOI: 10.25903/5e969687c22e8 (vid. págs. 14, 15, 20).

- Xavier, P. *Hass Avocado Ripening Photographic Dataset*. Col. de Pedro Rodrigues, Cristina L. M. Silva y Centro De Biotecnologia E Quimica Fina. Accedido: 2024-10-15. 2024. DOI: 10.17632/3XD9N945V8.1 (vid. págs. 16, 20, 30).
- Yahia, Y. et al. «Identification and Characterization of Phytochemicals in Avocado ('Hass') Fruit at Different Maturation and Ripening Stages». En: *Journal of Food Quality* (2025). DOI: 10.1155/jfq/7181926 (vid. pág. 20).