

SISTEMA BASADO EN INTELIGENCIA ARTIFICIAL PARA LA ESTIMACIÓN DE LA
UNIFORMIDAD DEL COLOR EN MANDARINAS

JOSEPH FERNANDO TRIGOS DELGADO
KEVIN SANTIAGO BAUTISTA MONSALVE

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
INGENIERÍA ELECTRÓNICA
BUCARAMANGA

2025

SISTEMA BASADO EN INTELIGENCIA ARTIFICIAL PARA LA ESTIMACIÓN DE LA
UNIFORMIDAD DEL COLOR EN MANDARINAS

JOSEPH FERNANDO TRIGOS DELGADO
KEVIN SANTIAGO BAUTISTA MONSALVE

Trabajo de grado para optar al título de Ingeniero Electrónico

Director

Hans Yecid Garcia Arenas
Doctor en Ingeniería Electrónica

Codirector

Sergio Andrés Urrea Vecino
Ingeniero Electrónico

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
INGENIERÍA ELECTRÓNICA
BUCARAMANGA

2025

AGRADECIMIENTOS

Quiero agradecer a mis padres, Essy Patricia Delgado y Jorge Alonso Trigos, por su apoyo constante y entrega absoluta, los cuales han sido esenciales para mi crecimiento profesional. Siempre me sentiré orgulloso de ser su hijo.

Mi agradecimiento se dirige también a los directores del proyecto, el Dr. Hans García y el Dr.(c) Sergio Urrea, por su orientación y los conocimientos compartidos durante este proyecto de grado. Agradezco igualmente al grupo de investigación CPS y a HDSP por el préstamo de los equipos.

AGRADECIMIENTOS

Quiero expresar mi más profundo agradecimiento a mi madre, Marisol Monsalve Mantilla, y a mi padre, German Raul Bautista Lizarazo, por ser pilares fundamentales en cada etapa de este camino. Agradezco también a todos mis familiares, quienes, de distintas maneras, han estado presentes brindándome palabras de aliento, compañía y confianza en los momentos más importantes. Gracias por creer en mí y por acompañarme con afecto en este proceso.

CONTENIDO

	pág.
Introducción.	12
1 Objetivos	14
1.1 Objetivo general	14
1.2 Objetivos específicos	14
2 Estado del arte	15
2.1 Mediciones del color en la agricultura.	15
2.2 Estandares en el color de frutos.	16
2.3 Espacios de color para el procesamiento de imágenes.	17
2.4 Algoritmos de detección de objetos	18
2.5 Índice de color.	20
3 Métodos estadísticos para la estimación de la uniformidad.	22
4 Metodología	25
4.1 Dataset	25
4.1.1 Selección de Hardware y entorno de desarrollo.	25
4.1.2 Selección de entorno de iluminación.	27
4.1.3 Captura y almacenamiento de imágenes.	28
4.1.3.1 Banda transportadora implementada	29
4.1.3.2 Parámetros para toma de datos	30
4.1.4 Etiquetado de mandarinas en imágenes.	32
4.2 Algoritmo de detección de mandarina	33
4.2.1 Selección de versión YOLO	34

4.3	Segmentación de mandarina	36
4.4	Cálculo del índice de uniformidad de color.	37
4.4.1	Espacio de color utilizado.	37
4.4.2	Cálculo de desviación estándar en los canales a y b.	38
4.4.3	Definición del índice.	39
5	Resultados.	40
5.1	Métricas de rendimiento para el algoritmo YOLO.	40
5.2	Rendimiento índice de uniformidad de color.	41
6	Conclusiones.	43
	Bibliografía.	44

LISTA DE CUADROS

	pág.
Cuadro 1 Cuadro comparativo de especificaciones técnicas para la selección de la cámara.	26
Cuadro 2 Métricas para evaluar el rendimiento del modelo YOLOv11s.	40

LISTA DE FIGURAS

	pág.
Figura 1 Visualización tridimensional (a) y bidimensional superior (b) del espacio de color CIELAB.	18
Figura 2 (a) Captura de imagen original en la banda transportadora. (b) Imagen de mandarinas en banda transportadora dividida en casillas del mismo tamaño.	20
Figura 3 (a) Imagen dividida en casillas del mismo tamaño con caja delimitadora en color azul. (b) Intersección entre la caja delimitadora y las casillas en que se dividió la imagen.	20
Figura 4 Espectros resultantes de las tres opciones de iluminación consideradas.	28
Figura 5 Banda transportadora utilizada para la toma de imágenes de mandarinas	29
Figura 6 Resultado de captura de imágenes de mandarinas teniendo en cuenta los parametros mencionado	31
Figura 7 Ilustración del proceso de etiquetado de mandarinas en el entorno de LabelMe.	33
Figura 8 Desempeño de diferentes versiones de YOLO, número de parámetros vs mAP50-95	35
Figura 9 (a) Mandarina original despues de pasar por yolo. (b) Histograma de la matriz de cocientes entre el canal rojo y el azul de la imagen de la mandarina. (c) Mandaririna segmentada despues de aplicar mascara	37
Figura 10 a) Mandarina segmentada. b) Histogramas de canal 'a' y canal 'b' de la mandarina. segmentada.	38

Figura 11 Organización de mandarina según su índice de uniformidad de color.

(a) Mandarina con índice de color 0.00032. (b) Mandarina con índice de color 0.0001996. (c) Mandarina con índice de color 0.0001588 (d) Mandarina con índice de color 0.0001585 (e) Mandarina con índice de color 0.0001481 (f) Mandarina con índice de color 0.0000477 (g) Mandarina con índice de color 0.0000427 (h) Mandarina con índice de color 0.00004163

41

Figura 12 (a) Mandarina con mas uniformidad de color, con un indice de uniformidad de 0.1713 (b) Mandarina con indice de uniformidad de 0.0574 (c) Mandarina con indice de uniformidad de 0.0345 (d) Mandarina con menos uniforidad de conlor, con un indice de 0.0248

42

RESUMEN

TÍTULO SISTEMA BASADO EN INTELIGENCIA ARTIFICIAL PARA LA ESTIMACIÓN DE LA UNIFORMIDAD DE COLOR EN MANDARINAS *

AUTOR: KEVIN SANTIAGO BAUTISTA MONSALVE, JOSEPH FERNANDO TRIGOS DELGADO **

PALABRAS CLAVE: Índice, Uniformidad, Mandarinas, Segmentación.

DESCRIPCIÓN: En la industria agrícola, la uniformidad de color se ha convertido en un criterio fundamental para la aceptación de frutos en el mercado y en la actualidad, el proceso de evaluación se realiza de manera manual, lo cual está sujeto a errores e inconsistencias en la clasificación. Es por ello que en este trabajo se desarrolló un sistema basado en inteligencia artificial con el propósito de estimar cuantitativamente la uniformidad del color en mandarinas poscosecha, utilizando técnicas de visión por computadora y aprendizaje profundo. Se implementó un subsistema de captura de imágenes que permite la adquisición de un conjunto de datos de imágenes de mandarinas obtenidas en un entorno controlado en condiciones óptimas. Tras la captura de imágenes, se realiza un procesamiento segmentación de las frutas y extracción de características relevantes para el análisis de color en el espacio CIELAB.

Con base en las características obtenidas, se propone un índice cuantitativo de uniformidad de color el cual se emplea para clasificar las mandarinas de acuerdo con estándares de calidad aplicables en la industria cítrica en Colombia. Finalmente, se evalúa el rendimiento del modelo propuesto mediante pruebas experimentales que demuestran su capacidad para estimar de manera precisa y confiable la uniformidad de color en mandarinas. Los resultados obtenidos muestran que el sistema desarrollado contribuye al mejoramiento de los procesos de selección y clasificación de frutas, lo cual tiene un impacto positivo en la calidad del producto final y la competitividad de los productores agrícolas.

* Trabajo de grado

** Facultad de fisicomecánicas. Escuela de ingeniería eléctrica, electrónica y telecomunicaciones. Programa académico. Director: Hans Yecid García Arenas. Doctor en Ingeniería Electrónica. Codirector: Sergio Andrés Urrea Vecino. Ingeniero Electrónico.

ABSTRACT

TITLE: ARTIFICIAL INTELLIGENCE-BASED SYSTEM FOR ESTIMATING COLOR UNIFORMITY IN MANDARINS *

AUTHOR: KEVIN SANTIAGO BAUTISTA MONSALVE, JOSEPH FERNANDO TRIGOS DELGADO **

Keywords: Index, uniformity, mandarins, segmentation.

Description: In the agricultural industry, color uniformity is now a key criterion for market acceptance of fruits. Currently, the evaluation process is performed manually, which often leads to errors and inconsistencies in classification. To address this, the study developed an artificial intelligence-based system designed to quantitatively assess color uniformity in postharvest mandarins using computer vision and deep learning techniques. A dedicated image-capture subsystem was implemented to gather a dataset of mandarin images under controlled and optimal conditions. After acquiring the images, the fruits are segmented and relevant features are extracted for color analysis in the CIELAB space.

Based on these extracted features, a quantitative index of color uniformity was proposed and used to classify mandarins according to quality standards applicable in Colombia's citrus industry. Finally, experimental tests were conducted to evaluate the model's performance, demonstrating its ability to precisely and reliably estimate color uniformity. The results show that the developed system improves fruit selection and classification processes, positively impacting both the final product quality and the competitiveness of agricultural producers.

* Degree work

** Facultad de fisicomecánicas. Escuela de ingeniería eléctrica, electrónica y telecomunicaciones. Programa académico. Director: Hans Yecid García Arenas. Doctor en Ingeniería Electrónica. Codirector: Sergio Andrés Urrea Vecino. Ingeniero Electrónico

Introducción.

En Colombia, la agricultura es una actividad muy importante en el desarrollo económico y social del país, debido a que contribuye la seguridad alimentaria y sustenta múltiples cadenas productivas ¹. Su importancia en la producción de cítricos, como la naranja, la mandarina, el limón, la toronja y otras variedades propias de la diversidad colombiana; juegan un papel crucial en el desarrollo económico de regiones productoras. Según datos reportados por el Ministerio de Agricultura y desarrollo rural en 2021², las regiones del nor-orienté y occidente del país que ocupan el 57 % en cosecha de cítricos, cuentan con aproximadamente 50 mil hectáreas dedicadas a su cultivo.

Un parámetro importante que influye en la percepción de la calidad del fruto y su aceptación comercial por parte de los consumidores es la uniformidad de color, debido a que actúa como un indicador visual de frescura, madurez y sabor, lo cual se asocia también a la calidad del producto ³. Por lo tanto, garantizar un color uniforme permite mantener un buen valor comercial del producto, satisface las expectativas del mercado y mantiene la competitividad en la industria agrícola.

Actualmente la uniformidad del color se evalúa de manera convencional, es decir, utilizando métodos manuales basados en la visión de la persona para determinar su calidad

¹ Banco Mundial: *Agricultura*. 2024. <https://www.bancomundial.org/es/topic/agriculture/overview>

² Ministerio de Agricultura y Desarrollo Rural: *Cifras sectoriales de cítricos en Colombia*. Inf. téc. Ministerio de Agricultura y Desarrollo Rural, 2021. <https://sioc.minagricultura.gov.co/citricos/documentos/2021-03-31%20cifras%20sectoriales.pdf>

³ M. Valdes Restrepo et al.: *Sistema de medición del color como parámetro de calidad en la industria de alimentos*. En: *Temas Agrarios* 28.1 (2023), págs. 69-81. <https://doi.org/10.21897/rta.v28i1.3200>

según la apariencia general, convirtiéndose en un proceso susceptible a errores ⁴. Debido a la baja eficiencia en la clasificación manual, se ralentiza el proceso de comercialización del producto lo cual puede llevar a consecuencia económicas graves para los agricultores. También se afectará la calidad de los productos, lo que podría reducir la apertura a mercados que son importante para la venta de los cítricos.

La falta de un sistema automatizado y estandarizado en Colombia que permita caracterizar de manera cuantitativa la uniformidad del color en las mandarinas representa un desafío para la industria agrícola en el país, ya que la mandarina desempeña un papel clave en la economía de las diferentes regiones de producción colombianas, entre ellas la región de Simacota, Santander, en donde se cultiva mandarina Israelí ⁵. Es por lo anterior que la evaluación manual sigue siendo un método que reduce la competitividad con los productores y limita el acceso a mercados que demandan productos con características homogéneas.

En este proyecto se diseñó e implementó un sistema capaz de caracterizar cuantitativamente la uniformidad del color en las mandarinas poscosecha, empleando técnicas de visión por computadora e inteligencia artificial, utilizando un sistema compuesto por una cámara y banda transportadora para la adquisición de imágenes y diseñando un algoritmo capaz de medir el índice de uniformidad en las mandarinas.

⁴ K. Mathias-Rettig y K. Ah-Hen: *El color en los alimentos: un criterio de calidad medible*. En: *Agro Sur* 42.2 (2014), págs. 57-66. DOI: 10.4206/agrosur.2014.v42n2-07. <https://doi.org/10.4206/agrosur.2014.v42n2-07>

⁵ Luis Enrique Villamizar Marin: "Aporte del análisis espectral para la estimación de carbono orgánico del suelo en cultivos de cítricos". Tesis doct. Universidad Nacional de Colombia, 2023

1. Objetivos

1.1. Objetivo general

Diseñar e implementar un sistema capaz de caracterizar cuantitativamente la uniformidad del color en las mandarinas poscosecha, empleando técnicas de visión por computadora e inteligencia artificial.

1.2. Objetivos específicos

Implementar un sistema de captura de imágenes de mandarinas para la generación de un conjunto de datos.

Adquirir un conjunto de datos de imágenes de mandarinas por medio del sistema implementado.

Definir un índice cuantitativo de uniformidad del color para el análisis de las imágenes de mandarinas basado en un espacio de color determinado.

Diseñar e implementar un algoritmo de inteligencia artificial para la estimación del índice cuantitativo definido.

Evaluar el rendimiento del algoritmo de inteligencia artificial implementado utilizando el índice definido en el marco del proyecto.

2. Estado del arte

2.1. Mediciones del color en la agricultura.

El color es uno de los principales atributos evaluados en productos agroalimentarios, ya que naturalmente el consumidor atribuye el color a la madurez del producto⁶. En el caso de las mandarinas, el color es determinante en el proceso de selección; durante la cosecha, las mandarinas se recolectan manualmente y posteriormente se clasifican en contenedores siguiendo el criterio de similitud en su color⁷.

En la industria, se emplean colorímetros como la referencia PCE-CSM 1⁸, los cuales son dispositivos electrónicos especializados en la medición del color. El colorímetro proyecta luz sobre el objeto, la luz reflejada es captada por un sensor en el colorímetro y posteriormente atraviesa filtros que cuantifican la luz en valores RGB, por último, se comparan los valores RGB obtenidos con un patrón de referencia. Otra de las herramientas utilizadas en la industria para medir el color son un conjunto de tarjetas desarrolladas por el Departamento de Poscosecha del Instituto Valenciano de Investigaciones Agrarias (IVIA), las tarjetas emulan tonalidades de color para naranjas y mandarinas basándose en el índice visualizado en la ecuación 1.

$$IC = \frac{1000 \cdot a}{L \cdot b} \quad (1)$$

⁶ Sergio Cubero et al.: "Estimación del Índice de Color de los Cítricos utilizando dispositivos móviles". En: *VIII Congreso Ibérico de Agroingeniería*. UMH (Universidad Miguel Hernández). 2016, págs. 926-935

⁷ Catarina Pedro Pássaro Carvalho y Julián Londoño Londoño: *Estándares de cosecha y poscosecha para mandarina Clementina destinada al mercado en fresco*. En: (2013)

⁸ Higielectronix: *Colorímetro PCE Instruments PCE-CSM 1*. 2025. <https://higielectronix.com/venta-y-mantenimiento-de/equipos-de-medicion-bogota-colombia/colorimetros/pce-instruments-pce-csm-1/>

Donde a y b corresponden a las componentes cromáticas y L corresponde a la componente de luminancia del espacio de color CIELAB. Cada tarjeta cuenta con un orificio circular que manualmente facilita la comparación visual de una parte de la superficie del cítrico⁹.

2.2. Estándares en el color de frutos.

Los estándares de calidad regulan la clasificación y comercialización de diferentes frutos para su aceptación en los diferentes mercados que existen. Uno de los parámetros fundamentales a regular es la coloración el cual hace parte de la evaluación de la calidad de los cítricos e influye en la percepción por parte de los consumidores para la compra de dicho producto.

En las mandarinas, se exige que al menos un tercio de la superficie presente el color característico del fruto, buscando asegurar que los productos sean visualmente atractivos y cumplan con los criterios de maduración adecuados. En el caso de las naranjas, se acepta que tenga un tono verde siempre y cuando no supere un quinto de la superficie, manteniendo su apariencia uniforme y color típico ¹⁰. En otros cítricos como los limones, se permite la presencia de una coloración verde siempre que el fruto alcance un contenido mínimo de zumo especificado, garantizando la calidad a pesar de no tener presentar un color uniforme ¹¹.

⁹ Cubero et al. 2016

¹⁰ ibíd.

¹¹ Unión Europea, Reglamento (CE) No 1799/2001 de la Comisión, de 13 de septiembre de 2001, Diario Oficial de las Comunidades Europeas, Bruselas, 2001. Disponible en: <https://eur-lex.europa.eu/legal-content/ES/TXT/PDF/?uri=CELEX:32001R1799>

2.3. Espacios de color para el procesamiento de imágenes.

El procesamiento de imágenes es fundamental para la clasificación de datos visuales, el uso de arreglos numéricos que las computadoras son capaces de interpretar mediante lenguajes de programación dentro de los que se incluyen Python, C++, R, los cuales permiten representar los espacios de color, almacenando la información cromática de cada pixel. Los espacios de color son distribuciones específicas en planos bidimensionales o tridimensionales; buscan representar parte de la gama de colores percibida por el ser humano de una forma normalizada¹². Existen diferentes espacios de color donde destacan RGB, HSV, CMYK y CIELAB; cada uno se adapta a diferentes aplicaciones de procesamiento. La elección del espacio de color adecuado es importante en el proceso de visión por computadora, influye directamente en la precisión del análisis¹³.

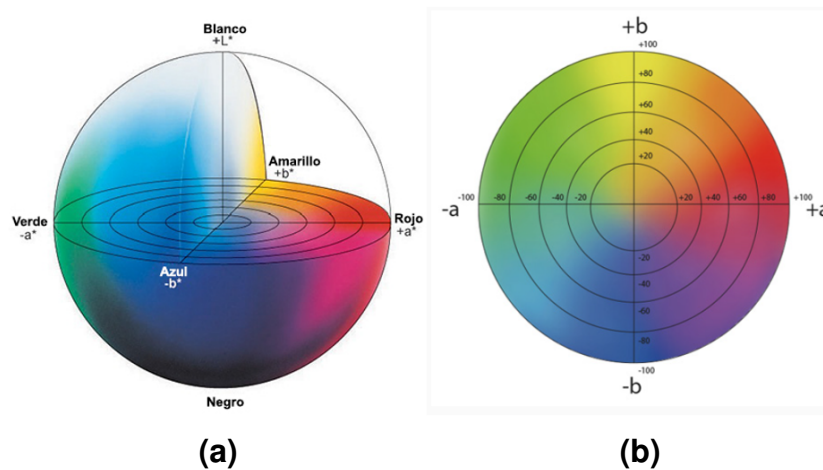
El espacio de color CIELAB se creó con el objetivo de ser un espacio perceptualmente uniforme, lo que significa que una variación numérica entre dos colores debería corresponder a una diferencia percibida similar por el ojo humano¹⁴. El espacio de color CIELAB, como se observa en la figura 1 se define mediante tres componentes principales: L* (Luminancia), definida desde el color negro (valor 0) hasta el blanco (valor 100); componente a (cromática verde-rojo), y componente b (cromática azul-amarillo).

¹² Marco Antonio Alonso Pérez: *Espacios de Color RGB, HSI y sus Generalizaciones a n-Dimensiones*. En: *INAOE, Tonantzintla* (2009)

¹³ *ibíd.*

¹⁴ P Ganesan, V Rajini y R Immanuvel Rajkumar: *Segmentation and edge detection of color images using CIELAB color space and edge detectors*. En: *INTERACT-2010* (2010), págs. 393-397

Figura 1. Visualización tridimensional (a) y bidimensional superior (b) del espacio de color CIELAB.



Fuente: LABORATORIOS SEYCO. Espacio CIELab 3D [imagen en línea]. Disponible en: <https://www.laboratorioseyco.com/wp-content/uploads/2023/10/Espacio-CIELab-3D.png>

2.4. Algoritmos de detección de objetos

La detección de objetos es una tarea importante dentro del campo de la visión por computadora debido a que su objetivo principal es localizar y clasificar entidades dentro de una imagen o video¹⁵. El proceso de detección es un trabajo complejo debido a que se debe determinar la posición exacta del objeto, especificando las coordenadas exactas de la ubicación para poder ofrecer información vital para el análisis e interacción con el entorno visual¹⁶.

Dentro de los algoritmos de detección de objetos se pueden distinguir dos categorías

¹⁵ IBM: *Detección de objetos*. 2025. <https://www.ibm.com/mx-es/think/topics/object-detection>

¹⁶ IBM Corporation: *What is object detection?* 2024. <https://www.ibm.com/think/topics/object-detection>


principales: los detectores de dos etapas, como lo es Region-based Convolutional Neural Networks”, “Faster Region-based Convolutional Neural Networks” “Mask Region-based Convolutional Neural Networks” que operan primero poniendo regiones de interés dentro de la imagen y, en la segunda etapa, clasificando el contenido de dichas regiones. Por otro lado, están los detectores de una etapa como lo son “You Only Look Once”(YOLO), “Single Shot Detection”(SSD), RetinaNetz .EfficientDet”, que predicen las cajas delimitadoras y las probabilidades de clase de los objetos desde la imagen completa y de manera simultánea, lo que traduce en una notable eficiencia en términos de velocidad de procesamiento en comparación con los algoritmos de dos etapas ¹⁷.

YOLO es un detector de una sola etapa que realiza simultáneamente la detección y clasificación de objetos mediante una red neuronal convolucional ¹⁸. En primer lugar, divide la imagen en cuadrículas de tamaño NxN, como se ilustra en la figura 2. Luego, se generan las cajas delimitadoras, que resaltan los objetos presentes en la imagen, basándose en la probabilidad de que cada celda contenga un objeto y descartando aquellas que no lo hacen, como se muestra en la figura 3-a. Finalmente, se establece un umbral de intersección entre las cajas delimitadoras y las celdas de la cuadrícula, conservando únicamente aquellas que son relevantes y que predicen correctamente tanto la ubicación como la clase del objeto como se muestra en la figura 3-b.

¹⁷ Neptune AI: *Object Detection Algorithms and Libraries*. 2024. <https://neptune.ai/blog/object-detection-algorithms-and-libraries>


¹⁸ DataCamp: *Explicación de la detección de objetos de YOLO*. 2024. <https://www.datacamp.com/es/blog/yolo-object-detection-explained>

Figura 2. (a) Captura de imagen original en la banda transportadora. (b) Imagen de mandarinas en banda transportadora dividida en casillas del mismo tamaño.



Fuente: Elaboración propia.

Figura 3. (a) Imagen dividida en casillas del mismo tamaño con caja delimitadora en color azul. (b) Intersección entre la caja delimitadora y las casillas en que se dividió la imagen.



Fuente: Elaboración propia.

2.5. Índice de color.

Los índices de color se han convertido en herramientas importantes para la agricultura, en donde la eficiencia y la sostenibilidad son primordiales, es por ello que se usan para proporcionar información valiosa sobre la salud y vigor de los cultivos, pigmentación en las hojas de plantas, evaluar y detectar daños por enfermedades y plagas o predecir la

productividad de las plantas ¹⁹ .

Otra forma en que se usa el índice de color especificado en la ecuación 1 es para determinar el rango de maduración en frutas como lo son la papaya, la guayaba y el tomate ²⁰ en donde se utilizan índices de color asociados a diferentes estados de maduración y teniendo en cuenta diferentes propiedades fisicoquímicas, mecánicas y organolépticas como los son el pH, el "Soluble Solid Content"(SSC) y la firmeza. Las imágenes utilizadas para este propósito tienen que caracterizarse mediante el espacio de color CIELAB debido a que es el estándar internacional de medición de color adaptado por la Comisión Internacional de Iluminación ²¹ .

¹⁹ Solvi: *Which Vegetation Index Should I Use?* Consultado el 28 de marzo de 2025. 2023. <https://solvi.ag/blog/which-vegetation-index-should-i-use/>

²⁰ Minelkis Machado Molina, Annia García Pereira y Neili Machado García: *Propuesta de rangos de Índice de Color según estados de maduración en frutas*. En: *Revista Ciencias Técnicas Agropecuarias* 28.4 (2019), págs. 1-8. <https://www.redalyc.org/journal/932/93261708002/html/>

²¹ Datacolor: *¿Qué es el CIELAB?* 2023. <https://www.datacolor.com/es/business-solutions/blog/que-es-cielab/>

3. Métodos estadísticos para la estimación de la uniformidad.

Para el análisis específico de colores rojizos y verdosos típicos de una mandarina, los canales 'a' y 'b' en el espacio de color CIELAB toman gran relevancia. El canal 'a' se convierte en la componente principal para el análisis ya que captura las variaciones entre rojo y verde como se observa en la figura 1. El canal 'b' también aporta tonalidades específicas en mandarinas, específicamente los tonos amarillentos que comúnmente acompañan al color rojo en las mandarinas. Por el contrario, el canal de luminocidad (L) podría no aportar información relevante para el análisis de las tonalidades rojizas y verdosas. Al contar con un entorno de iluminación controlado, las variaciones en la iluminación serán mínimas y por otro lado, permitirá descartar los reflejos que tienen ciertas mandarinas con la luz blanca debido a la composición de su piel.

Debido a la relación directa que existe entre los valores de intensidad en los canales 'a' y 'b', se plantea desarrollar un análisis estadístico multivariable²². El primer paso es organizar los datos de intensidad de los píxeles de la mandarina segmentada en una matriz de doble columna, la primera y segunda columna corresponden a todos los valores de intensidad en los canales 'a' y 'b', respectivamente²³. La ecuación 2 representa la matriz de intensidades.

²² Statgraphics: *Multivariate Methods*. 2025. <https://www.statgraphics.com/multivariate-methods>

²³ Richard D. Wilkinson: *1.1 Notation*. 2025. <https://rich-d-wilkinson.github.io/MATH3030/1.1-notation.html>

$$\mathbf{X} = \begin{bmatrix} a_0 & b_0 \\ a_1 & b_1 \\ \vdots & \vdots \\ a_n & b_m \end{bmatrix} \quad (2)$$

La estructura matricial de los datos permite posteriormente representar visualmente su distribución en un diagrama de dispersión 2D, los valores del canal 'a' representará el eje X y los valores del canal 'b' estarán en el eje Y. Cada punto en el diagrama de dispersión corresponde a un pixel de la mandarina y su posición la determinan sus valores de intensidad en los dos canales. De esta distribución de puntos se puede extraer información importante sobre la uniformidad del color de la mandarina. Si los puntos se encuentran agrupados, es un indicador de que la mayoría de los pixeles tienen valores de intensidad similares, indicando directamente una alta uniformidad de color en la mandarina. Por otro lado, si los puntos se encuentran dispersos en el diagrama, es un indicador de menor uniformidad de las intensidades en una mandarina.

Para trasladar el concepto visual de dispersión y agrupación a una base matemática, se emplea la matriz de covarianza²⁴, vista en la ecuación 3. La matriz de covarianza aplicada a los canales 'a' y 'b' del espacio CIELAB de una imagen de mandarina permite cuantificar la variabilidad conjunta de ambos datos. Se construye combinando la varianza, encargada de medir la dispersión de cada canal alrededor de su media y la covarianza, evalúa la dependencia lineal entre los canales 'a' y 'b' proporcionando información de cómo varían en conjunto los colores. Un valor de covarianza positivo denota que cuando los valores de intensidad en el canal 'a' aumentan, los colores de intensidad en el canal 'b' también aumentan, mientras que con un valor de covarianza negativo, sugiere una

²⁴ Cuemath: *Covariance Matrix - Formula, Examples, Definition, Properties*. 2025. <https://www.cuemath.com/algebra/covariance-matrix/>

relación inversa.

Ya que son dos las variables analizadas, la matriz de covarianza tendrá un tamaño 2X2, donde su diagonal principal contiene la varianza del canal 'a' y la varianza del canal 'b', la diagonal secundaria contiene la covarianza de ambos canales, como se visualiza en la ecuación 3.

$$\mathbf{C}(a, b) = \begin{pmatrix} \text{Var}(\mathbf{a}) & \text{Cov}(\mathbf{a}, \mathbf{b}) \\ \text{Cov}(\mathbf{b}, \mathbf{a}) & \text{Var}(\mathbf{b}) \end{pmatrix} \quad (3)$$

Una vez obtenida la matriz de covarianza, se procede al cálculo de los valores propios (eigenvalores). En un diagrama de dispersión, los eigenvalores indican la magnitud de la dispersión de los datos a lo largo de las direcciones donde se concentra la mayor variabilidad; es decir, permiten identificar en qué direcciones los datos están más dispersos, lo que resulta fundamental para evaluar la uniformidad del color²⁵.

El proceso matemático para calcular los eigenvalores consiste en resolver la ecuación característica de la matriz de covarianza, como lo expresa la ecuación 4.

$$\det \begin{vmatrix} \text{Var}(a) - \lambda & \text{Cov}(a, b) \\ \text{Cov}(b, a) & \text{Var}(b) - \lambda \end{vmatrix} = 0 \quad (4)$$

²⁵ Vincent Spruyt: *A geometric interpretation of the covariance matrix*. En: *Computer Vision for Dummies Website*, <https://www.visiondummy.com/2014/04/geometric-interpretation-covariance-matrix/> (accessed 23 June 2021) (2014)

4. Metodología

4.1. Dataset

El conjunto de datos utilizado para entrenar el modelo de inteligencia artificial fue generado de manera autónoma en las instalaciones del grupo de investigación de *High Dimensional Signal Processing* (HDSP). Para la elaboración del dataset, se tuvo en consideración aspectos técnicos, como la selección de la cámara, el desarrollo y ejecución de un algoritmo para captura y almacenamiento de imágenes encontrado en el repositorio de GitHub llamado Sistema-para-estimaci-n-de-la-uniformidad-del-color-en-mandarinas²⁶, el uso de una banda transportadora parametrizada diseñada por el grupo HDSP y la selección del entorno de iluminación. El dataset final consta de 270 imágenes en formato RGB de 8 bits de profundidad y almacenadas en formato .tiff, distribuidas en 215 para entrenamiento, 40 para validación y 15 para testeo.

4.1.1. Selección de Hardware y entorno de desarrollo. Para la selección de la cámara perteneciente al hardware del subsistema de captura de imágenes, se llevó a cabo una evaluación comparativa entre tres referencias disponibles en el grupo de investigación HDSP, como se visualiza en el cuadro 1, en donde se comparan las siguientes cámaras: Canon EOS Rebel T3, EOS M50 y Logitech C920.

²⁶ Josephts1: *Sistema para la estimación de la uniformidad del color en mandarinas*. <https://github.com/Josephts1/Sistema-para-la-estimaci-n-de-la-uniformidad-del-color-en-mandarinas.git>. 2025

Cuadro 1. Cuadro comparativo de especificaciones técnicas para la selección de la cámara.

Letra	Especificación	EOS REBEL T3	EOS M50	LOGITECH C920	Peso
P	Cantidad total de píxeles [MP]	12.6	25.8	2	$0.3876e-2 \times P$
R	Máxima resolución [P]	4272x2848	6000x4000	1920x1080	$0.41e-8 \times R$
V	Velocidad de obturación [ms]	[0.25 - 16]	[0.25 - 30e3]	[7.28]	$0.3e-2 \times V$
C	Campo visual diagonal [°][mm]	6.581 @ 55 19.928 @ 18	1.685 @ 215 72.662 @ 4.3	78	$0.128e-3 \times C$
T	Transferencia de imágenes	Manual (1)	Manual (1)	Automático (1)	$0.2 \times T$
A	Ajuste de parámetros con Python	No (0)	No (0)	Si (1)	$0.2 \times A$
D	Disponibilidad	No (0)	No (0)	Si (1)	$0.2 \times D$
	Puntaje Total	0.32	0.59	0.71	

Fuente: Elaboración propia.

La elección de la cámara se definió mediante la ecuación 5 ya que nos permite elegir entre las referencias teniendo en cuenta las especificaciones mas importantes que se

necesitan, dándole mas peso a la disponibilidad y al ajuste de parametros con python. Las letras de la ecuación representan una características de las camaras y se definen en el cuadro 1

$$\text{Puntaje} = (0,38e - 2 \times P) + (0,41e - 8 \times R) + (0,3e - 2 \times V) + (0,12e - 3 \times C) + (0,2 \times T) + (0,2 \times A) + (0,2 \times D) \quad (5)$$


Gracias al puntaje total obtenido por la cámara Logitech c920, se decidió utilizarla como herramienta para la captura de imágenes de mandarinas.

4.1.2. Selección de entorno de iluminación. Para la selección práctica del subsistema de iluminación se realizaron pruebas comparativas utilizando tres configuraciones disponibles en el grupo HDSP. La primera opción consistió en dos pares de tiras LED ubicadas de manera perpendicular a la banda transportadora, permitiendo el control individual de cada par de tiras. La segunda opción evaluó el desempeño de dos bombillos incandescentes operando en conjunto, su ubicación permitía la iluminación localizada de la zona de captura. La tercera opción integró un par de tubos LED junto con una lámina difusora, instalados en la parte superior del laboratorio. Estas tres configuraciones fueron sometidas a evaluación perceptual del color y reflexión de las mandarinas, considerando la uniformidad y consistencia de la iluminación para el proceso de captura de imágenes con la cámara web. De manera complementaria, se aplicó un criterio teórico mediante el uso del espectrómetro Ocean Insight flame vis-nir, compatible con el software OceanView, para analizar el comportamiento espectral de cada opción de iluminación. En este análisis se estableció como requisito que la respuesta en intensidad fuera similar en el rango de

500 a 630 nm, comprendido aproximadamente entre los tonos verdes y rojizos²⁷, que se observan en las mandarinas durante su proceso de maduración. La figura 4 ilustra los tres espectros obtenidos para las tres opciones, el espectro color azul corresponde a la iluminación por dos tiras LED, el espectro color rojo corresponde a la iluminación por dos luces alógenas y el espectro color verde corresponde a la iluminación por par de tubos LED instalados en el laboratorio HDSP.

La opción del par de tubos LED junto con una lámina difusora, mostró un comportamiento espectral más uniforme en el rango [500 a 630 nm] en comparación a las otras dos opciones, garantizando así la calidad y consistencia de la captura de imágenes.

Figura 4. Espectros resultantes de las tres opciones de iluminación consideradas.



Fuente: Elaboración propia.

4.1.3. Captura y almacenamiento de imágenes. La captura de imágenes se realizó con el propósito de generar un conjunto de datos adecuado para el entrenamiento del algoritmo de detección de mandarina, para ello, se realizaron diferentes pruebas teniendo en cuenta características como posición de cámara, tamaño de la imagen, tiempo de

²⁷ DM Lasprilla: *Manual de recomendaciones técnicas para su cultivo en el departamento de Cundinamarca*. En: *Bogotá: Corredor Tecnológico Agroindustrial (2020)*, págs. 26-31

integración, movimiento de la banda transportadora y frecuencia de captura.

4.1.3.1. Banda transportadora implementada Se utilizó una banda transportadora implementada en las instalaciones del laboratorio de HDSP para la adquisición de imágenes en movimiento de las mandarinas como se puede ver en la figura 5. La banda está compuesta por diversos elementos como lo son el motor paso a paso NEMA 17, un driver TB6600 y un microcontrolador Raspberry Pi Pico.

Figura 5. Banda transportadora utilizada para la toma de imágenes de mandarinas



La banda transportadora utiliza un motor NEMA 17 que funciona convirtiendo señales digitales en movimientos discretos, permitiendo el control preciso de la banda transportadora. El elemento encargado de gestionar el funcionamiento del motor es el driver TB6600,

ya que permite ajusten en corriente de salida en un rango de 0.5 A y 3.5 A. Además, permite el ajuste de pasos por revolución en el motor según lo que se necesite.

El microcontrolador que usa la banda para la configuración de los parámetros del motor es la Raspberry Pi Pico, el cual actúa como unidad central de procesamiento para ejecutar el software encargado de controlar la banda transportadora. El lenguaje en que está programado el microcontrolador es MicroPython, ya que es versátil y adecuado para las aplicaciones embebidas

4.1.3.2. Parámetros para toma de datos La cámara se posicionó a 43 cm sobre la banda transportadora, ya que permite un enfoque adecuado para capturar la mayor cantidad de mandarinas posibles, sin la pérdida de detalles de cada una de las tomas y garantizando la consistencia en el conjunto de datos generado.

La resolución de las imágenes capturadas es una variable importante que permite el análisis de las características de color en la superficie de cada mandarina. Una resolución inferior podría reducir la precisión de la detección y segmentación de las mandarinas, mientras que resoluciones altas aumentarían el tamaño de los archivos y la carga computacional, es por ello que la mejor resolución encontrada fue de 1920 x 1080 píxeles, permitiendo un equilibrio entre la calidad de las imágenes y la eficiencia de procesamiento.

El tiempo de integración representa el periodo en que el sensor de la cámara se encuentra expuesto a la luz para cada captura, influyendo directamente en la calidad de la imagen. Teniendo en cuenta lo anterior, el tiempo de integración se configuró en 15.6 ms, permitiendo una adecuada captación de luz sin comprometer la claridad o nitidez de las imágenes adquiridas.

La velocidad de la banda transportadora permite el paso de las mandarinas por debajo

de la cámara, afectando directamente la frecuencia de captura de imágenes y la cantidad de información recopilada. Una velocidad excesiva podría causar imágenes borrosas, mientras que una velocidad muy baja reduciría la eficiencia en el proceso de adquisición, es por ello que la velocidad definida fue de 0.010 m/s, permitiendo el flujo continuo de mandarinas sin afectar negativamente la calidad de las imágenes capturadas.

El algoritmo para la captura de imágenes se desarrolló utilizando el entorno de desarrollo integrado (IDE) Visual Studio Code. Para ello, se configuró un entorno virtual que ejecuta la versión 3.13.0 de Python, en conjunto con la última versión de la librería CV2. Esta plataforma facilitó la integración y ejecución de funciones avanzadas para el procesamiento y almacenamiento de imágenes, asegurando la robustez y escalabilidad del sistema. El formato en que se guardaron las imágenes fue el .tiff, debido a que permite almacenar las imágenes sin pérdida de calidad y soporta imágenes de gran resolución, considerando que las imágenes tienen un tamaño de 1920 x 1080 píxeles, lo cual asegura que no se pierda detalles importantes de las mandarinas para un análisis preciso de la uniformidad de color.

Todos los parámetros anteriores se establecieron para poder obtener una buena toma de los datos y que pudieran ser analizados de la mejor forma. En la figura 6 se puede visualizar el resultado de configuración de los parámetros.

Figura 6. Resultado de captura de imágenes de mandarinas teniendo en cuenta los parámetros mencionado



4.1.4. Etiquetado de mandarinas en imágenes. El etiquetado de imágenes constituye una etapa esencial en el preprocesamiento para el entrenamiento de modelos supervisados de Inteligencia Artificial (IA), ya que asigna información digital como las coordenadas espaciales o la clase de cada objeto, a elementos específicos de una imagen, facilitando su interpretación por los algoritmos de IA. Existen diversos métodos de etiquetado, entre ellos la delimitación mediante figuras geométricas y la segmentación, que sigue punto a punto la silueta del objeto. La información de los elementos etiquetados usando figuras geométricas pueden exportarse en formato COCO, VOC o YOLO, cada formato cuenta con una sintaxis para organizar y estructurar las etiquetas de manera comprensible tanto para humanos como para máquinas²⁸.

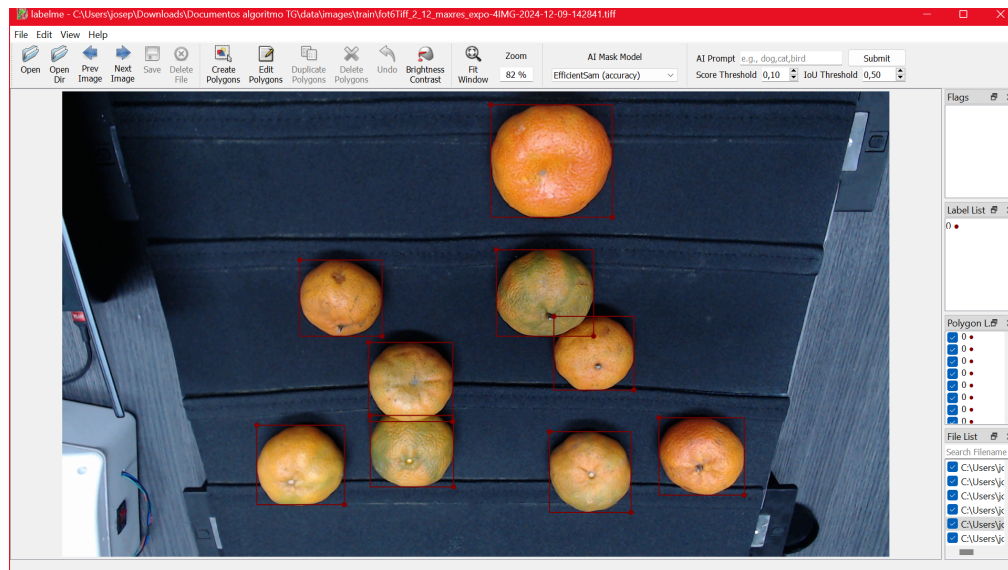
Para la tarea de etiquetado de imágenes del dataset se optó por utilizar la herramienta LabelMe²⁹, debido a que, permite el acceso local desde Python, garantizando la privacidad de los datos, además, de su compatibilidad con imágenes en formato .tiff. Para acceder a LabelMe y proceder con la tarea de etiquetado de imágenes se utilizó la consola de Visual Studio Code, se creó un entorno virtual que integra la versión 3.13.0 de Python y la herramienta LabelMe. En la figura 7 se ilustra un ejemplo del etiquetado de múltiples mandarinas mediante cuadros delimitadores (bounding boxes) en el entorno de LabelMe, cada cuadro delimitador asigna la clase “0” a la mandarina. Luego de etiquetar todas las mandarinas en la imagen, LabelMe retorna un archivo con el mismo nombre de la imagen y en formato .json, este formato no lo recibe YOLO, por lo que fue utilizado un código en Python que permite convertir archivos .json en archivos .txt³⁰.

²⁸ Ross Girshick et al.: “Rich feature hierarchies for accurate object detection and semantic segmentation”. En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014, págs. 580-587

²⁹ LABELME. Labelme: AI Image Annotation & Dataset Creation [en línea]. 2025. Disponible en: <https://labelme.io/>

³⁰ Josephts1 2025

Figura 7. Ilustración del proceso de etiquetado de mandarinas en el entorno de LabelMe.



Fuente: Elaboración propia.

4.2. Algoritmo de detección de mandarina

Al pensar en dar solución a un problema basándose en algoritmos de inteligencia artificial, se debe considerar una rigurosa investigación en términos de arquitectura y capacidad computacional que conlleva utilizar el algoritmo, al igual que determinar cual algoritmo se adapta mejor a la naturaleza de los datos y al problema a resolver. En este caso, el análisis del cambio de color en las mandarinas exigía el uso de imágenes de alta resolución para capturar con detalle esos cambios de color³¹. En consideración al alto contenido de píxeles, realizar un análisis individual o por grupo de píxeles incrementa el tiempo de entrenamiento y demanda una gran capacidad de procesamiento en la GPU de una laptop con recursos limitados. Por estas razones, se optó por utilizar el algoritmo

³¹ Miguel Miranda: *La imagen digital*. En: *Gen 63.2* (2009), págs. 134-136

YOLO, que con una etapa permite detectar objetos, reduciendo considerablemente el tiempo de entrenamiento.

Desde 2023 con su versión YOLOv8, el modelo YOLO³² introdujo nuevas funciones y mejoras para optimizar el rendimiento, la flexibilidad y la eficiencia, haciéndolo un modelo compatible con una amplia gama de aplicaciones de visión por computadora. Para compensar las limitaciones en hardware, se utilizó la herramienta Google Colab³³, que permite el acceso a GPUs disponibles en servidores remotos como Google Cloud³⁴. El algoritmo YOLO se estructura en tres partes principales: "Backbone", "Neck" y "Head". Backbone, basado en la estructura CSPDarknet53³⁵, actúa como la etapa inicial de la red neuronal, se encarga de extraer características relevantes de imágenes de entrada de 640x640 píxeles. Neck funciona como una conexión directa entre Backbone y Head. Finalmente, Head se encarga de predecir los cuadros delimitadores, las coordenadas espaciales, la clase del objeto y la puntuación de confianza³⁶.

4.2.1. Selección de versión YOLO Para la implementación del modelo YOLO se utilizó la librería de Python Ultralytics, ya que permite acceder a gran variedad de versiones, desde YOLOv3 hasta la más reciente YOLOv11. Se decidió limitar la evaluación a un rango de versiones recientes (YOLOv8 a YOLOv11), donde cada versión cuenta con cuatro subversiones variando el número de parámetros a utilizar, dado el tiempo disponible para

³² Ultralytics: *Ultralytics Documentation*. 2025. <https://docs.ultralytics.com>

³³ Google: *Google Colaboratory*. 2025. <https://colab.research.google.com>

³⁴ Google: *Servicios de computación en la nube Google Cloud*. 2025. <https://cloud.google.com/?hl=es>

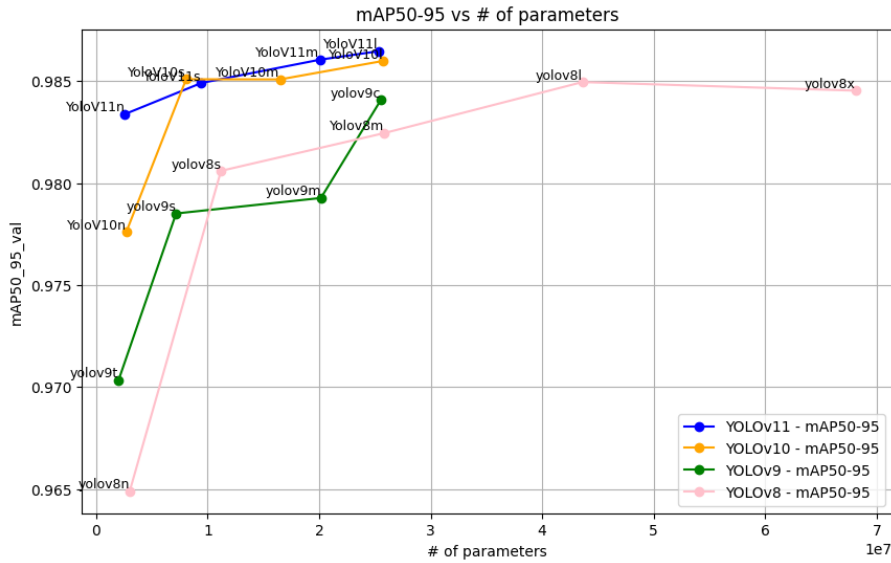
³⁵ GeeksforGeeks: *Darknet53*. 2024. <https://www.geeksforgeeks.org/darknet-53/>

³⁶ YOLOv8: *YOLOv8 Architecture Explained*. 2024. https://yolov8.org/yolov8-architecture-explained/#1_Backbone_Network

hacer pruebas de rendimiento. La selección se fundamentó en dos criterios objetivos: el valor mAP50-95 obtenido con el conjunto de validación y la cantidad total de parámetros del modelo.

El proceso de entrenamiento se inició accediendo al archivo de configuración (.yaml), el cual accede al dataset en carpetas de imágenes y etiquetas, subdivididas en los conjuntos de entrenamiento, validación y testeo, y define la clase cero como "fruta". Posteriormente, se instaló la última versión de Ultralytics, conforme a las recomendaciones de los desarrolladores. Con los pesos del modelo inicializados a cero, se procedió al entrenamiento durante 500 épocas, utilizando un tamaño de batch de 16 imágenes y un learning rate inicial de 1e-4. Finalmente, el modelo se sometió al proceso de validación para extraer la métrica mAP50-95, la cual permitió determinar la versión de YOLO que ofrecía el mejor rendimiento para la aplicación. La versión que tuvo una mejor métrica mAP50-95 y menor uso de parámetros de entrenamiento fue la versión YOLOv11s.

Figura 8. Desempeño de diferentes versiones de YOLO, número de parámetros vs mAP50-95



Fuente: Elaboración propia.

4.3. Segmentación de mandarina

La segmentación de la mandarina se realizó debido a que se necesitaba aislar el fruto del fondo de la banda transportadora, y así poder evitar interferencias en la medición de la uniformidad de color en las imágenes capturadas.

Se importó el modelo de YOLO entrenado con el dataset que se adquirió con el subsistema de captura de imágenes y que arrojó mejor rendimiento. Una vez cargado el modelo, se procede a importar las imágenes generadas al aplicar el algoritmo de YOLO sobre el conjunto de datos elegidos para el testeo.

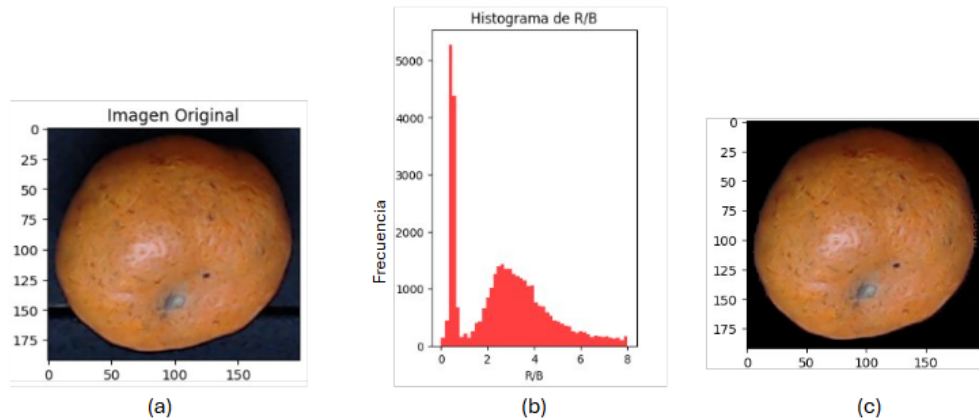
Para analizar las imágenes e identificar únicamente la mandarina eliminando el fondo de la banda transportadora, se generó una matriz correspondiente al cociente de la división entre el canal rojo y azul de las imágenes como se muestra en la ecuación.

$$F = \frac{R}{B} \quad (6)$$

Donde F se refiere a la matriz de cocientes, R al canal rojo de la imagen y B al canal azul.

Una vez obtenida la matriz de cocientes, se crea una máscara binaria la cual se genera aplicando un umbral a la matriz de la división entre el canal rojo y azul. Los valores que sean mayores a 0.95 se marcan con True, mientras que aquellos que no cumplan la condición se marcan con False. El valor de umbral 0.95 fue determinado mediante un análisis a histogramas de la relación rojo sobre azul de diversas imágenes de mandarinas. En la figura 9-a y en la figura 9-b se puede ver un ejemplo de la imagen original y el histograma correspondiente a la división del canal rojo entre el azul respectivamente. Por último, se le aplica la máscara creada a la imagen original, obteniendo así la mandarina segmentada como se muestra en la figura 9-c.

Figura 9. (a) Mandarina original despues de pasar por yolo. (b) Histograma de la matriz de cocientes entre el canal rojo y el azul de la imagen de la mandarina. (c) Mandanrina segmentada despues de aplicar mascara



4.4. Cálculo del índice de uniformidad de color.

Debido a la inexistencia de un índice que permita medir la uniformidad del color en las mandarinas, se tuvo el desafío de desarrollar un índice propio. La definición de un índice implica generar una variable cuantitativa que permita evaluar una característica cualitativa, en este caso, la uniformidad del color en las mandarinas.

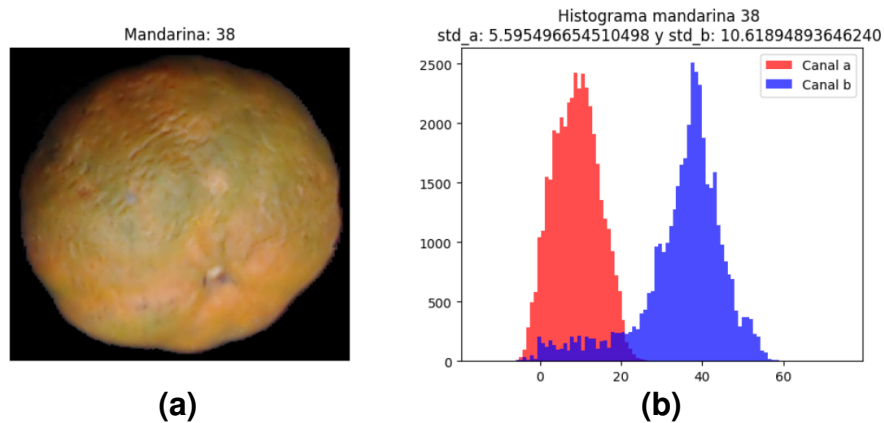
4.4.1. Espacio de color utilizado. Para poder analizar objetivamente el color en las mandarinas, se deben comprender los diferentes espacios de color y para que objetivo fueron creados. El espacio de color RGB está involucrado en la captura de imágenes para este proyecto, pero su objetivo es mostrar colores según la sensibilidad de los sensores en el dispositivo. Esto quiere decir que, mismos valores de intensidad en RGB pueden percibirse diferente al variar la sensibilidad de los sensores. La dependencia del espacio de color RGB con el sensor añade inexactitud a la evaluación objetiva de la uniformidad del color en las mandarinas.

El espacio de color CIELAB asemeja de gran manera sus componentes para emular la percepción humana del color al añadir una componente de luminancia y los otros dos

componentes, que representan la información cromática, distribuyen los cuatro colores únicos de la visión humana: rojo, verde, azul y amarillo³⁷. CIELAB se ha convertido en un estándar en diversas industrias y aplicaciones porque permite detectar pequeñas diferencias de color, debido a su cercana uniformidad desde el punto de vista perceptual. La independencia de dispositivos y su fundamento en la percepción humana, convierten a CIELAB en un espacio de color acorde para evaluar objetivamente la uniformidad del color en las mandarinas.

4.4.2. Cálculo de desviación estándar en los canales a y b. Al tener presente las variaciones de los canales a y b que pueden llegar a tener las mandarinas al ser representadas en el espacio de color CIELAB, se consideró visualizar la distribución de los valores de píxeles de cincuenta imágenes de prueba mediante un histograma, en la figura 10 se observan los histogramas de los canales a y b para la mandarina número treinta y ocho.

Figura 10. a) Mandarina segmentada. b) Histogramas de canal 'a' y canal 'b' de la mandarina. segmentada.



Fuente: elaboración propia.

³⁷ Chromatone: *Modelos de color perceptuales*. 2025. <https://chromatone.center/theory/color/models/perceptual/>

4.4.3. Definición del índice. Para la generación del índice se utilizó el concepto estadístico de la matriz de covarianza, eigenvectores y eigenvalores. Como ya es sabido, los eigenvalores indican que tan dispersos están los datos. En primera instancia, se planteó que el índice estuviere dado por el producto de los eigenvalores ya que un valor mayor indicaría una mayor dispersión de datos y por ende, una menor uniformidad. Se planteó el índice como la ecuación.

$$IC = \frac{1}{\pi \cdot e1 \cdot e2} \quad (7)$$

donde $e1$ y $e2$ corresponden a los eigenvalores resultantes de la matriz de covarianza. Para que el valor del índice fuera más intuitivo, para que la mandarina que obtenga el mayor índice corresponde a la mandarina más uniforme.

5. Resultados.

En este capítulo se presentan los resultados obtenidos tras la implementación y evaluación del sistema basado en inteligencia artificial para la estimación de la uniformidad del color en mandarinas. Los resultados incluyen el rendimiento del modelo YOLOv11s utilizado para la detección de las mandarinas, la metodología aplicada para la obtención de resultados cuantitativos y la organización de las mandarinas según el índice de uniformidad calculado.

5.1. Métricas de rendimiento para el algoritmo YOLO.

El modelo YOLOv11s utilizado para la detección de mandarinas fue entrenado con un conjunto de datos de imágenes capturadas bajo las condiciones especificadas en capítulos anteriores y se evaluó mediante métricas estándar de detección de objetos, obteniendo resultados como se muestran en el cuadro 2 considerando métricas que incluyen mAP, "recall" y precisión, cada una con un propósito específico que permite evaluar la efectividad del modelo.

Cuadro 2. Métricas para evaluar el rendimiento del modelo YOLOv11s.


Parámetro	Rendimiento
mAP50-95	0.95
mAP50	0.995
Recall	0.99
Precisión	0.997
Número de parámetros	9,413,187

Las métricas fueron obtenidas con un total de 9,413,187 parámetros en el modelo, lo cual evidencia su alta capacidad de generalización y precisión en la identificación de mandarinas y que significa que el modelo YOLOv11s es adecuado para ser implementado en la etapa de segmentación de mandarina en el sistema propuesto.

5.2. Rendimiento índice de uniformidad de color.

Para analizar los resultados obtenidos del índice de color de uniformidad en mandarinas, se hizo una prueba con 30 mandarinas las cuales se organizaron según su índice de uniformidad de color ordenándolas desde la que presentó mayor uniformidad hasta la de menor uniformidad. Los resultados se presentan en la figura 11 en donde se registran los puestos 1, 6, 10, 11, 17, 21, 24 y 30 respectivamente, corroborando que se pudo lograr un correcto calculo del índice y una buena organizacion de las mandarinas según su uniformidad de color.


Figura 11. Organización de mandarina según su índice de uniformidad de color. (a) Mandarina con índice de color 0.00032. (b) Mandarina con índice de color 0.0001996. (c) Mandarina con índice de color 0.0001588 (d) Mandarina con índice de color 0.0001585 (e) Mandarina con índice de color 0.0001481 (f) Mandarina con índice de color 0.0000477 (g) Mandarina con índice de color 0.0000427 (h) Mandarina con índice de color 0.00004163



Para corroborar y evaluar el correcto funcionamiento del índice de uniformidad de color utilizado, se generó un dataset sintético de mandarinas a las cuales se les aplicó el mismo procedimiento de las imágenes reales, organizándolas de mayor al menor índice como se puede ver en la figura 12. La práctica anterior permitió corroborar que el índice desarrollado funciona correctamente y es capaz de diferenciar los distintos grados de uniformidad,

respaldando la capacidad del sistema para producir resultados precisos y consistentes bajo diferentes condiciones y con distintos conjuntos de datos.

Figura 12. (a) Mandarina con mas uniformidad de color, con un indice de uniformidad de 0.1713 (b) Mandarina con indice de uniformidad de 0.0574 (c) Mandarina con indice de uniformidad de 0.0345 (d) Mandarina con menos uniformidad de conlor, con un indice de 0.0248



6. Conclusiones.

Se implementó un sistema de captura de imágenes de mandarinas, el cual consiste en una banda transportadora, una cámara logitech y un sistema de iluminación de un entorno para la obtención de imágenes de mandarinas con las cuales se entrenó el algoritmo de detección de objetos.

Se implementó un algoritmo YOLOv11s, seleccionado con base en la métrica mAp50-95 en donde obtuvo un rendimiento muy bueno. Fue entrenado con los datos adquiridos por el sistema de captura de imágenes. También se implementó un algoritmo el cual segmentaba las imágenes que arrojaba YOLO, esto con el fin de extraer las características más importantes de la mandarina para definir el índice de uniformidad.

Se desarrolló un subsistema para la captura de imágenes y creación de un dataset. Mediante la definición de la fórmula (5) se realizó una selección cuantitativa de la cámara asociada al subsistema. Posterior a la selección de la cámara, se desarrolló un algoritmo en Python para la captura y almacenamiento de imágenes. Almacenadas en un dataset, las imágenes de entrenamiento y validación fueron etiquetadas para realizar, posteriormente el entrenamiento de la red YOLOv11s. Como paso final, se definió un índice cuantitativo que permite evaluar la uniformidad del color en mandarinas.

Se definió un índice cuantitativo para calcular la uniformidad de color en las mandarinas, el cual se basa en la dispersión de los valores del canal a y b del espacio de color CieLab, identificando patrones de agrupación o dispersión y empleando una matriz de covarianza para calcular los eigenvalores que permite establecer un índice cuantitativo.

Bibliografía.

Agremo: *Yellow Color Index Analysis - Agremo*. 2025. <https://www.agremo.com/products/yellow-color-index-analysis/>.

Banco Mundial: *Agricultura*. 2024. <https://www.bancomundial.org/es/topic/agriculture/overview>.

Carvalho, Catarina Pedro Pássaro y Julián Londoño Londoño: *Estándares de cosecha y poscosecha para mandarina Clementina destinada al mercado en fresco*. En: (2013).

Chromatone: *Modelos de color perceptuales*. 2025. <https://chromatone.center/theory/color/models/perceptual/>.

Cubero, Sergio et al.: “Estimación del Índice de Color de los Cítricos utilizando dispositivos móviles”. En: *VIII Congreso Ibérico de Agroingeniería*. UMH (Universidad Miguel Hernández). 2016, págs. 926-935.

Cuemath: *Covariance Matrix - Formula, Examples, Definition, Properties*. 2025. <https://www.cuemath.com/algebra/covariance-matrix/>.

DataCamp: *Explicacion de la deteccion de objetos de YOLO*. 2024. <https://www.datacamp.com/es/blog/yolo-object-detection-explained>.

Datacolor: *¿Qué es el CIELAB?* 2023. <https://www.datacolor.com/es/business-solutions/blog/que-es-cielab/>.

Ganesan, P, V Rajini y R Immanuvel Rajkumar: *Segmentation and edge detection of color images using CIELAB color space and edge detectors*. En: *INTERACT-2010* (2010), págs. 393-397.

GeeksforGeeks: *Darknet53*. 2024. <https://www.geeksforgeeks.org/darknet-53/>.

Girshick, Ross et al.: "Rich feature hierarchies for accurate object detection and semantic segmentation". En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014, págs. 580-587.

Google: *Google Colaboratory*. 2025. <https://colab.research.google.com>.

Google: *Servicios de computación en la nube Google Cloud*. 2025. <https://cloud.google.com/?hl=es>.

Higielectronix: *Colorímetro PCE Instruments PCE-CSM 1*. 2025. <https://higielectronix.com/venta-y-mantenimiento-de/equipos-de-medicion-bogota-colombia/colorimetros/pce-instruments-pce-csm-1/>.

IBM: *Detección de objetos*. 2025. <https://www.ibm.com/mx-es/think/topics/object-detection>.

IBM Corporation: *What is object detection?* 2024. <https://www.ibm.com/think/topics/object-detection>.

Josephts1: *Sistema para la estimación de la uniformidad del color en mandarinas*. <https://github.com/Josephts1/Sistema-para-la-estimacion-de-la-uniformidad-del-color-en-mandarinas.git>. 2025.

Lasprilla, DM: *Manual de recomendaciones técnicas para su cultivo en el departamento de Cundinamarca*. En: *Bogotá: Corredor Tecnológico Agroindustrial* (2020), págs. 26-31.

Mathias-Rettig, K. y K. Ah-Hen: *El color en los alimentos: un criterio de calidad medible*. En: *Agro Sur* 42.2 (2014), págs. 57-66. DOI: 10.4206/agrosur.2014.v42n2-07. <https://doi.org/10.4206/agrosur.2014.v42n2-07>.

Ministerio de Agricultura y Desarrollo Rural: *Cifras sectoriales de cítricos en Colombia*. Inf. téc. Ministerio de Agricultura y Desarrollo Rural, 2021. <https://sioc.minagricultura.gov.co/citricos/documentos/2021-03-31%20cifras%20sectoriales.pdf>.

Miranda, Miguel: *La imagen digital*. En: *Gen* 63.2 (2009), págs. 134-136.

Molina, Minelkis Machado, Annia García Pereira y Neili Machado García: *Propuesta de rangos de Índice de Color según estados de maduración en frutas*. En: *Revista Ciencias Técnicas Agropecuarias* 28.4 (2019), págs. 1-8. <https://www.redalyc.org/journal/932/93261708002/html/>.

Neptune AI: *Object Detection Algorithms and Libraries*. 2024. <https://neptune.ai/blog/object-detection-algorithms-and-libraries>.

Pérez, Marco Antonio Alonso: *Espacios de Color RGB, HSI y sus Generalizaciones a n-Dimensiones*. En: *INAOE, Tonantzintla* (2009).

Redmon, Joseph et al.: *You Only Look Once: Unified, Real-Time Object Detection*. 2016. arXiv: 1506.02640 [cs.CV]. <https://arxiv.org/abs/1506.02640>.

Solvi: *Which Vegetation Index Should I Use?* Consultado el 28 de marzo de 2025. 2023. <https://solvi.ag/blog/which-vegetation-index-should-i-use/>.

Spruyt, Vincent: *A geometric interpretation of the covariance matrix*. En: *Computer Vision for Dummies Website*, [https://www.visiondummy.com/2014/04/geometric-interpretation-covariance-matrix/\(accessed 23 June 2021\)](https://www.visiondummy.com/2014/04/geometric-interpretation-covariance-matrix/(accessed%2023%20June%202021)) (2014).

Statgraphics: *Multivariate Methods*. 2025. <https://www.statgraphics.com/multivariate-methods>.

Ultralytics: *Ultralytics Documentation*. 2025. <https://docs.ultralytics.com>.

Unión Europea: *Reglamento (CE) No 1799/2001 de la Comisión, de 12 de septiembre de 2001, por el que se establecen las normas de comercialización de los cítricos*. Inf. téc. Diario Oficial de las Comunidades Europeas, 2001. <https://eur-lex.europa.eu/legal-content/ES/TXT/PDF/?uri=CELEX:32001R1799>.

Valdes Restrepo, M. et al.: *Sistema de medición del color como parámetro de calidad en la industria de alimentos*. En: *Temas Agrarios* 28.1 (2023), págs. 69-81. <https://doi.org/10.21897/rta.v28i1.3200>.

Villamizar Marin, Luis Enrique: “Aporte del análisis espectral para la estimación de carbono orgánico del suelo en cultivos de cítricos”. Tesis doct. Universidad Nacional de Colombia, 2023.

Wilkinson, Richard D.: *1.1 Notation*. 2025. <https://rich-d-wilkinson.github.io/MATH3030/1.1-notation.html>.

YOLOv8: *YOLOv8 Architecture Explained*. 2024. https://yolov8.org/yolov8-architecture-explained/#1_Backbone_Network.