



**UNIVERSIDAD TÉCNICA DEL NORTE**  
**FACULTAD DE INGENIERÍA EN CIENCIAS AGROPECUARIAS Y**  
**AMBIENTALES**

**CARRERA: AGROINDUSTRIA**

**INFORME FINAL DEL TRABAJO DE INTEGRACIÓN**  
**CURRICULAR, MODALIDAD PRESENCIAL**

**TEMA:**

**“EXPERIMENTACIÓN NUMÉRICA DEL CAMBIO DE COLOR EN**  
**NARANJILLA (*S. quitoense lam*) ALMACENADA EN ATMÓSFERAS**  
**MODIFICADAS”**

**Trabajo de titulación previo a la obtención del título de Ingeniera Agroindustrial**

**Línea de investigación:** Gestión, producción, productividad, innovación y desarrollo socioeconómico.

**Autora:** Gruezo Gualavisí Jhoanna Pamela

**Director:** Ing. De la Vega Quintero Juan Carlos

Ibarra - 2024



**UNIVERSIDAD TÉCNICA DEL NORTE**  
**BIBLIOTECA UNIVERSITARIA**  
**IDENTIFICACIÓN E LA OBRA**

La Universidad Técnica del Norte dentro del proyecto Repositorio Digital Institucional, determinó la necesidad de disponer de textos completos en formato digital con la finalidad de apoyar los procesos de investigación, docencia y extensión de la Universidad.

Por medio del presente documento dejo sentada mi voluntad de participar en este proyecto, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
<b>CÉDULA DE IDENTIDAD:</b>	<b>DE</b>	1722751847	
<b>APELLIDOS</b>	Gruezo Gualavisí Jhoanna Pamela		
<b>YNOMBRES:</b>			
<b>DIRECCIÓN:</b>	Ibarra		
<b>EMAIL:</b>	<a href="mailto:jgruezog@utn.edu.ec">jgruezog@utn.edu.ec</a>		
<b>TELÉFONO FIJO:</b>		<b>TELF. MOVIL</b>	0982876544

DATOS DE LA OBRA	
<b>TÍTULO:</b>	“EXPERIMENTACIÓN NUMÉRICA DEL CAMBIO DE COLOR EN NARANJILLA ( <i>S. quitoense lam</i> ) ALMACENADA EN ATMÓSFERAS MODIFICADAS”
<b>AUTOR:</b>	Gruezo Gualavisí Jhoanna Pamela
<b>FECHA: AAAAMMDD</b>	2024/10/16
SOLO PARA TRABAJOS DE TITULACIÓN	
<b>CARRERA/PROGRAMA:</b>	<input checked="" type="checkbox"/> <b>GRADO</b> <input type="checkbox"/> <b>POSGRADO</b>
<b>TÍTULO POR EL QUE OPTA:</b>	Ingeniera Agroindustrial
<b>DIRECTOR:</b>	Ing. De la Vega Quintero Juan Carlos

## **AUTORIZACIÓN DE USO A FAVOR DE LA UNIVERSIDAD**

Yo, Gruezo Gualavisí Jhoanna Pamela, con cédula de identidad Nro. 1722751847, en calidad de autora y titular de los derechos patrimoniales de la obra o trabajo de integración curricular descrito anteriormente, hago entrega del ejemplar respectivo en formato digital y autorizo a la Universidad Técnica del Norte, la publicación de la obra en el Repositorio Digital Institucional y uso del archivo digital en la Biblioteca de la Universidad con fines académicos, para ampliar la disponibilidad del material y como apoyo a la educación, investigación y extensión; en concordancia con la Ley de Educación Superior Artículo 144.

Ibarra, a los 16 días del mes de Octubre de 2024

**EL AUTOR:**

Firma.....



Nombre: Gruezo Gualavisí Jhoanna Pamela

## CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 16 días, del mes de Octubre de 2024

**EL AUTOR:**

A handwritten signature in blue ink, appearing to read 'Gruezo Gualavisi Jhoanna Pamela', is written over a horizontal dotted line.

Gruezo Gualavisi Jhoanna Pamela

**CERTIFICACIÓN DIRECTOR DEL TRABAJO DE INTEGRACIÓN  
CURRICULAR**

Ibarra 16 de Octubre de 2024

Ing. De la Vega Quintero Juan Carlos

DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

CERTIFICA:

Haber revisado el presente informe final del trabajo de Integración Curricular, el mismo que se ajusta a las normas vigentes de la Universidad Técnica del Norte; en consecuencia, autorizo su presentación para los fines legales pertinentes.



Ing. De la Vega Quintero Juan Carlos

C.C.: 1002958856

## APROBACIÓN DEL COMITÉ CALIFICADOR

El Comité Calificador del trabajo de Integración Curricular “Experimentación numérica del cambio de color en naranjilla (*S. quitoense lam*) almacenada en atmósferas modificadas” elaborado por Gruezo Gualavisí Jhoanna Pamela, previo a la obtención del título del Ingeniera en Agroindustria, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte.



Ing. De la Vega Quintero Juan Carlos

C.C.: 1002958856



Ing. Jácome Aguirre Gabriel Alexis

C.C.:1003432802

## **DEDICATORIA**

*A Dios, por guiarme y permitirme alcanzar mis objetivos. A mis padres, que fueron mi más grande motivación y apoyo en esta etapa, gracias por su sacrificio y amor incondicional. A mi familia, por creer en mí y demostrarme su cariño en cada momento. A mis amigos y seres queridos, este camino fue maravilloso a su lado. Esta tesis es un reflejo de mi gratitud y todo lo que inspiran en mi vida.*

**Jhoanna Gruezo**

## **AGRADECIMIENTO**

*Agradezco a la Universidad Técnica del Norte, por abrirme sus puertas ayudándome en mi crecimiento académico.*

*Expreso mi sincero agradecimiento a mi director de tesis, Ing. Juan Carlos de la Vega, por su paciencia y por compartir sus conocimientos, ha sido un excelente guía en el desarrollo de este trabajo. A mi asesor, Ing. Gabriel Jácome, por sus aportes en este estudio. Al Ing. Juan Guamán, por su colaboración y tiempo dedicado a partes fundamentales de este proyecto.*

*A mis queridos amigos, Sol Q. y Pablo R. Gracias por la motivación constante y su compañía en este camino.*

*Sebastián, gracias por tu ayuda, sobre todo por tu amor y paciencia, por ser mi cómplice y mi mejor amigo.*

**Jhoanna Gruezo**



## RESUMEN EJECUTIVO

El color y su cambio gradual durante el almacenamiento es uno de los indicadores más relevantes en la maduración de productos de origen vegetal. Este estudio se enfocó en modelar el cambio de color de la naranjilla en función del tiempo de almacenamiento en atmósferas modificadas bajo cinco temperaturas de refrigeración (2, 6, 10, 14 y 18°C), empleando modelos de regresión y redes neuronales para simular y predecir su comportamiento. Se utilizaron más de 100 unidades experimentales, distribuidas en distintas condiciones de almacenamiento, y se registraron datos del cambio de color cada dos días durante un periodo de 15 días mediante imágenes digitales y la aplicación *RGB Detector*, la cual proporcionó las coordenadas RGB de cada color. Los datos recopilados fueron procesados en MATLAB usando las herramientas *Regression Learner* y *Neural Net Fitting*, para analizar cuatro indicadores clave ( $R^2$ , MSE, RMSE y AIC) e identificar el modelo más representativo. Asimismo, se desarrolló una aplicación con *App Designer* que permite predecir este cambio mediante el ingreso de los datos de almacenamiento, brindando una herramienta útil para productores y exportadores. Los resultados revelaron que el tiempo de almacenamiento fue el principal factor que influyó en el cambio de color, por encima de las concentraciones de gases, siendo el modelo *Best Levenberg-Marquard*, trabajado con 5 neuronas en *Neural Net Fitting*, el que mejor representó este fenómeno, con un ajuste a la variabilidad de datos del 96%. Finalmente, a pesar de que no se implementó la supervisión visual en tiempo real por limitaciones tecnológicas, la aplicación ofrece predicciones precisas basadas en datos numéricos.

**Palabras clave:** Maduración, concentración de gases, temperatura, predicción, RGB, datos numéricos.

## ABSTRACT

Color and its gradual change during storage is one of the most relevant indicators of ripening in plant-based products. This study focused on modeling the color change of naranjilla as a function of storage time in modified atmospheres under five refrigeration temperatures (2, 6, 10, 14, and 18 °C), using regression models and neural networks to simulate and predict its behavior. More than 100 experimental units were used, distributed across different storage conditions, and color change data was recorded every two days over a 15-day period using digital images and the *RGB Detector* app, which provided the RGB coordinates of each color. The collected data was processed in MATLAB, using the *Regression Learner* and *Neural Net Fitting* tools, analyzing four key indicators ( $R^2$ , MSE, RMSE, and AIC) to identify the most representative model. Additionally, an application was developed with *App Designer* that allows predicting this change by entering storage data, providing a useful tool for producers and exporters. The results revealed that storage time was the main factor influencing the color change, over gas concentrations, where the *Best Levenberg-Marquardt* model (with 5 neurons in Neural Net Fitting) best represented this phenomenon, showing a data variability fit of 96%. Finally, although real-time visual monitoring was not implemented due to technological limitations, the application offers accurate predictions based on numerical data.

**Keywords:** Ripening, gas concentration, temperature, prediction, RGB, numerical data.

## LISTA DE SIGLAS

**AM.** Atmósferas Modificadas.

**AC.** Atmósferas Controladas.

**BMP.** Mapa de Bits. (Formato de imágenes)

**FAO.** Organización de las Naciones Unidas para la Agricultura y la Alimentación.

**GIF.** Graphics Interchange Format. (Formato de imágenes)

**IA.** Inteligencia Artificial.

**JPEG.** Joint Photographic Experts Group. (Formato de imágenes)

**MAGAP.** Ministerio de Agricultura y Ganadería y Pesca.

**PNG.** Portable Network Graphics. (Formato de imágenes)

**R<sup>2</sup>.** Coeficiente de determinación

**MSE.** Error cuadrático medio

**RMSE.** Desviación estándar de los valores residuales

**AIC.** Criterio de Información de Akaike

**RGB.** Red, Green, Blue (Espacio de color)

**BLM.** Best Levenberg Marquard

**SCG.** Best Scaled Conjugated Gradient

# ÍNDICE DE CONTENIDO

CAPÍTULO I .....	9
Introducción .....	9
1.1    Problema de investigación.....	9
1.2    Justificación.....	10
1.3    Objetivos .....	11
1.4    Hipótesis.....	12
CAPÍTULO II.....	13
Marco teórico .....	13
2.1    La naranjilla en Ecuador y sus variedades .....	13
2.2    Naranjilla <i>Solanum quitoense</i> .....	13
2.3    Índice de madurez .....	14
2.4    Transporte y conservación de la naranjilla.....	15
2.5    Métodos de conservación .....	16
2.6    Técnicas de almacenamiento en envase .....	16
2.7    Estandarización de la fruta .....	17
2.8    Procesamiento digital de imagen.....	20
2.9 <i>Machine Learning</i> .....	24
2.10 <i>Regression Learner</i> .....	24
2.11   Redes neuronales.....	25
2.12 <i>App Designer</i> .....	27
2.13   Modelos estadísticos de validación .....	27
CAPÍTULO III.....	30
Materiales y métodos .....	30

3.1	Tipo de investigación .....	30
3.2	Ubicación del lugar de estudio .....	30
3.3	Materiales, equipos y software .....	30
3.4	Métodos, técnicas e instrumentos.....	31
CAPÍTULO IV.....		41
Resultados y discusión.....		41
4.1	Datos obtenidos del análisis de cambio de color en la naranjilla dadas distintas condiciones de almacenamiento. ....	41
4.2	Modelo representativo del cambio de color mediante inteligencia artificial ..	48
4.3	Sistema de supervisión, control y adquisición de datos aplicando el modelo de IA	54
Conclusiones y recomendaciones .....		60
5.1	Conclusiones .....	60
5.2	Recomendaciones.....	60
Referencias.....		62
Anexos .....		66
Anexo 1.Especificaciones del empaque.....		66
Anexo 2. Codificación de la aplicación .....		68
Anexo 3.Codificación del modelo seleccionado como el mejor del sistema.....		68
Anexo 4. Introducción de datos en MATLAB para el proceso de predicción.....		69
Anexo 5. Predicción y validación de datos con uno de los modelos entrenados en <i>regression learner (Linear regression-linear)</i> .....		69

## ÍNDICE DE TABLAS

<i>Tabla 1 Taxonomía de la Naranjilla.....</i>	<i>14</i>
<i>Tabla 2 Equipos, Materiales, Insumos y Reactivos .....</i>	<i>30</i>
<i>Tabla 3 Propiedades físico-químicas a Evaluar.....</i>	<i>32</i>
<i>Tabla 4 Condicionamiento por el Porcentaje de Dispersión T. ....</i>	<i>34</i>
<i>Tabla 5 Factores en Estudio para cada tratamiento aplicado.....</i>	<i>35</i>
<i>Tabla 6 Estandarización de la Materia Prima .....</i>	<i>41</i>
<i>Tabla 7 Recopilación de datos.....</i>	<i>43</i>
<i>Tabla 8 Variación de gases por temperatura .....</i>	<i>47</i>
<i>Tabla 9 Entrenamiento de datos con Regression Learner .....</i>	<i>49</i>
<i>Tabla 10 Validación de datos con Regression Learner.....</i>	<i>50</i>
<i>Tabla 11 Entrenamiento de datos con Best Levenberg-Marquard (BLM) en Neural Net Fitting.....</i>	<i>51</i>
<i>Tabla 12 Entrenamiento de datos con Best Scaled Conjuhated Gradient (SCG) en Neural Net Fitting.....</i>	<i>51</i>
<i>Tabla 13 Validación de datos con Neural Net Fitting.....</i>	<i>52</i>

## INDICE DE FIGURAS

<i>Figura 1 Fruto de Naranja</i> .....	14
<i>Figura 2 Índice de Madurez de la Naranja</i> .....	15
<i>Figura 3 Representación visual del sistema RGB</i> .....	19
<i>Figura 4 Tipos de Imágenes Digitales; (a) RGB; (b) Indexada; (c) Escala de Grises; (d) Binaria</i> .....	22
<i>Figura 5 Técnicas de regresión en MATLAB</i> .....	25
<i>Figura 6 Esquema de una red neuronal conectada</i> .....	26
<i>Figura 7 Esquema general de una matriz de confusión</i> .....	29
<i>Figura 8 Matriz de confusión del algoritmo googlenet</i> .....	55
<i>Figura 9 Matriz de confusión del algoritmo resnet50</i> .....	56
<i>Figura 10 Matriz de confusión del algoritmo resnet101</i> .....	57
<i>Figura 11 Gráfica de regresión del modelo de Neural Net Fitting con 5 neuronas del algoritmo LM</i> .....	58
<i>Figura 12 Aplicación creada en App Designer</i> .....	59

# CAPÍTULO I

## Introducción

### 1.1 Problema de investigación

La naranjilla (*S. quitoense Lam*) es un fruto con gran potencial exportador gracias a su sabor y valor nutricional, siendo un producto de interés agroindustrial (Gómez et al., 2014). Según el MAGAP (2022), en Ecuador, existen diversas variedades de naranjilla que representan el 0.03% de las exportaciones agropecuarias, Sin embargo, su manejo postcosecha presenta múltiples retos, ya que es un fruto perecedero (Medina et al., 2023).

En varios países, las escasas instalaciones de almacenamiento causan pérdidas de alimentos frescos como frutas y hortalizas. Durante la etapa postcosecha, la tasa de desperdicio es de 7.5 % y en cuanto al almacenamiento, del 5 % (FAO, 2011). Particularmente, la naranjilla es sensible a condiciones inadecuadas de almacenamiento, afectando una de sus principales características: el color, mismo que tiene un rol crucial durante la maduración, dado que este factor visual es un indicador importante tanto para la cosecha como para el consumo (Andrade et al., 2019).

El color es una característica que cambia aún después de la cosecha de la fruta, y a través de todos los procesos a los que se somete. El consumidor tiene preferencia por productos que tienen una apariencia atractiva, y el color es uno de los primeras particularidades en ser juzgadas (Wills, 2007). Este atributo es subjetivo, por lo que su medición exacta requiere del uso de instrumentos y reactivos específicos, los cuales en ocasiones pueden representar un costo fuera del alcance de algunos negocios (Phillips, 2024). La relevancia del color desde una perspectiva de estimación de calidad, precisa implementar métodos accesibles para obtener datos reproducibles sin depender de



equipos costosos (Mathias y Kong Ah, 2014). Sin embargo, no existen muchos estudios dedicados a este objetivo.

La naturaleza dependiente del color está influenciada por diversos factores, lo que abre la posibilidad de desarrollar un modelo matemático que prediga sus variaciones basándose en las condiciones de almacenamiento de la fruta. La experimentación numérica sería una manera práctica de llevar un control aplicado al cambio de color en la naranjilla.

## **1.2 Justificación**

La exigencia de calidad para los productos hortícolas frescos en los mercados actuales está en aumento, por lo cual, los productores planifican todo el proceso con el objetivo de satisfacer los requerimientos comerciales (García et al., 2011). Por esta razón, es imprescindible la aplicación de métodos de almacenamiento y de tecnologías postcosecha que permitan implementar un modelo de predicción de cambios ópticos (Orlando et al., 2023).

Para la industria alimentaria, iniciando por el sector primario de producción, es muy importante estimar el cambio de color en función del tiempo, para esto, son de gran utilidad los modelos matemáticos, principalmente para estimar el periodo de madurez y posterior a esto poder tomar decisiones sobre el destino de la fruta (Orlando et al., 2023). Con la experimentación numérica, el uso del modelo correcto permitiría predecir el comportamiento de la naranjilla y optimizar las posibilidades de transporte y su exportación.

Con respecto a las técnicas de almacenamiento, los avances en películas plásticas con diferentes niveles de permeabilidad a los gases, junto con mejoras en el control atmosférico, han facilitado el desarrollo de atmósferas modificadas (Chiesa et al., 2005).

El uso de atmósfera modificada disminuye la aparición de desórdenes fisiológicos, alteraciones microbianas y deterioros químicos, que son responsables de los cambios en el color del fruto (Villanueva, 2014).

A través de la experimentación numérica y el uso de inteligencia artificial (IA), este estudio permitirá generar un modelo matemático que utilice variables influyentes en los cambios del color en la naranjilla, simulando su comportamiento bajo condiciones de almacenamiento en determinadas atmósferas modificadas y niveles de temperatura.

### **1.3 Objetivos**

#### **1.3.1 Objetivo general**

- Modelar el cambio de color en la naranjilla almacenada en atmósferas modificadas a través de modelos de regresión y redes neuronales para la simulación y predicción de su comportamiento.

#### **1.3.2 Objetivos específicos**

- Evaluar el cambio de color en la naranjilla considerando la concentración de gases, temperatura y tiempo de almacenamiento para la obtención de datos experimentales.
- Generar un modelo representativo del cambio de color mediante *Machine Learning* usando modelos de *Regression Learner* y *Neural net Fitting*
- Crear un sistema de supervisión, control y adquisición de datos aplicando el modelo de inteligencia artificial en la aplicación de *App Designer*.

## **1.4 Hipótesis**

### **1.4.1 Hipótesis alternativa**

El cambio de color de la naranjilla se puede representar con la experimentación numérica en función de la temperatura, concentración de gases y tiempo de almacenamiento.

### **1.4.2 Hipótesis nula**

El cambio de color de la naranjilla no se puede representar con la experimentación numérica en función de la temperatura, concentración de gases y tiempo de almacenamiento.

## CAPÍTULO II

### Marco teórico

#### 2.1 La naranjilla en Ecuador y sus variedades

En Ecuador, el cultivo de naranjilla ocupa alrededor del 0,1 % de la superficie agrícola total, involucrando a aproximadamente mil personas en su producción. Este cultivo se distribuye en 14 provincias, con el 85 % de la producción concentrada en Carchi, Imbabura, Bolívar y Morona Santiago (MAGAP, 2022).

La naranjilla es una planta semisilvestre que se desarrolla en zonas abiertas alteradas por la actividad agropecuaria, especialmente en áreas frescas, sombreadas y con un elevado nivel de humedad, como los sotobosques (Castro y Herrera, 2019).

Por lo general, estas plantas se reproducen desde semillas cosechadas de anteriores cultivos. Aunque diversos países de América del Sur producen naranjilla, su cultivo prevalece en Ecuador y Colombia (Grant, 2019). En Ecuador, se registran cinco variedades de esta: Baeza, Baeza roja, dulce, agria y bola, con ligeras diferencias. Además, algunas plantas con características parecidas podrían confundirse con *Solanum quitoense*, ya que las naranjillas muestran variabilidad en sus rasgos físicos. Entre estas especies similares se encuentran *Solanum hirtum*, *Solanum myriacanthum*, *Solanum pectinatum*, *Solanum sessiliflorum* y *Solanum verrogeneum* (Grant, 2019).

#### 2.2 Naranjilla *Solanum quitoense*

Conocida por su color naranja vivo, su exquisito sabor y peculiar aroma. Tiene forma redonda-ovalada, por dentro está dividida en cuatro compartimentos que se separan mediante particiones membranosas, los cuales están llenos de pulpa de color verde y numerosas semillas diminutas. El epicarpio de la naranjilla, de color naranja cuando está madura, está cubierta por finas y pequeñas espinas, como se muestra en la Figura 1. El

sabor de la pulpa oscila entre ácido e intenso, y se suele utilizar en la elaboración de zumos, mermeladas, cócteles y jaleas (Andrade et al., 2019). La caracterización de la naranjilla se define en la Tabla 1.

Figura 1 *Fruto de Naranjilla*



**Fuente:** (Moreno Guerrero et al., 2013)

Tabla 1 *Taxonomía de la Naranjilla*

<b>Característica</b>	<b>Definición</b>
Reino	Vegetal
Clase	Dicotiledóneas
Sub clase	Metaclamídeas
Orden	Tubiflorales
Familia	Solanacea
Género	<i>Solanum</i>
Especie	<i>quitoense</i>
Época de cosecha	Todo el año
Nombre comercial	Naranjilla, lulo
Variedades	<i>quitoense</i> y <i>septentrionale</i>

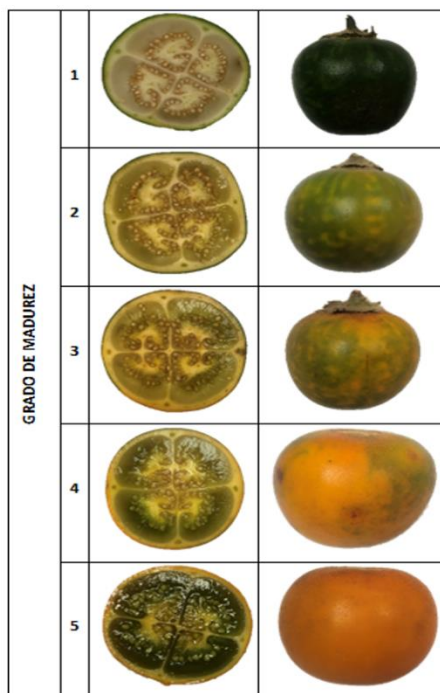
**Fuente:** (Grant, 2019)

### 2.3 Índice de madurez

En la estimación del nivel de madurez de la naranjilla, de manera visual se emplea una escala del 1 al 5 que se basa en la transformación del color del epicarpio. En esta escala, el nivel 1 representa un color verde intenso, lo que indica que la fruta ha alcanzado su madurez fisiológica. El nivel 2 muestra un 25 % de tonalidad amarillo-naranja,

mientras que el nivel 3 refleja un 50 % de esta coloración. El nivel 4 indica un 75 % de amarillo en la cáscara y, por último, el nivel 5 señala que la fruta está completamente madura, con la piel totalmente amarilla, tal como se observa en la Figura 2 (Moreno Guerrero et al., 2013).

Figura 2 *Índice de Madurez de la Naranja*



Fuente: (Moreno Guerrero et al., 2013)

## 2.4 Transporte y conservación de la naranja

Para exportar naranja y garantizar su transporte o almacenamiento por hasta 10 días sin necesidad de refrigeración es fundamental cosechar la fruta cuando su cáscara adquiere un ligero tono anaranjado. En esta fase, las pequeñas espinas que cubren la fruta pueden retirarse fácilmente con un suave frotamiento. La correcta preservación y manejo de alimentos perecederos son cruciales para mantener su calidad y garantizar su consumo seguro. El deterioro de los alimentos frescos es causado principalmente por

microorganismos como bacterias, levaduras y mohos. Por ello, la conservación de los alimentos implica preservar sus características sensoriales, tales como el aroma, sabor y color, mediante distintos métodos o tratamientos (Murcia).

## **2.5 Métodos de conservación**

Hoy en día se emplean diversos métodos avanzados para la conservación de frutas durante su distribución. Uno de los más utilizados es el enfriamiento, el cual ralentiza los procesos bioquímicos y enzimáticos, además de reducir el crecimiento de microorganismos dañinos. Esto se logra a través de la refrigeración y la congelación. También se usan recubrimientos comestibles e invisibles que extienden considerablemente la vida útil del producto. En cuanto al empaque, se aplican técnicas como el envasado al vacío y el envasado en atmósfera controlada, que regulan los niveles de gases dentro del envase para mejorar la preservación (Knauf Industries , 2020).

## **2.6 Técnicas de almacenamiento en envase**

Las tecnologías postcosecha contribuyen a reducir la velocidad de los cambios bioquímicos relacionados con la maduración, aunque no logran detenerlos por completo. Las condiciones de almacenamiento deben ajustarse a las necesidades específicas de cada producto, tomando en cuenta sus características morfológicas, composición y fisiología. En el empaque, se utilizan técnicas avanzadas como las atmósferas controladas y las atmósferas modificadas para prolongar la conservación de productos hortofrutícolas (ITAGRI, 2017).

### **2.6.1 Atmósferas controladas (AC)**

Esta tecnología se fundamenta en la monitorización constante de la temperatura, junto con la regulación precisa de los porcentajes oxígeno y de dióxido de carbono en el ambiente de almacenamiento. Su propósito es desacelerar el proceso de maduración y mantener la frescura de los productos durante más tiempo, asegurando la preservación de

su calidad. Este sistema representa una solución eficaz para el transporte de productos altamente perecederos, especialmente aquellos que requieren ser transportados por vía aérea (Villanueva, 2014).

### **2.6.2 Atmósferas modificadas (AM)**

Este método emplea nitrógeno, ya sea solo o combinado con dióxido de carbono, y reduce el nivel de oxígeno a concentraciones generalmente inferiores al 1%. La atmósfera modificada se obtiene mediante la extracción del aire del envase y la posterior introducción de una mezcla específica de estos gases. Con el tiempo, la constitución del ambiente dentro del envase se regula en medida de las necesidades y reacciones del producto almacenado (Villanueva, 2014).

### **2.7 Estandarización de la fruta**

La estandarización, en el contexto de los productos frescos, se puede definir como la práctica comúnmente aceptada de clasificar el producto y ofrecerlo para la venta según criterios de calidad que han sido claramente definidos y son consistentes a lo largo del tiempo y en diferentes lugares (FAO). Antes de implementar las técnicas de empaque, es necesario definir puntos iniciales para que no existan inconsistencias o distintas reacciones de los alimentos hasta el momento del consumo. A través de la estandarización se define y mantienen criterios y normas para la producción y comercialización de la fruta, estos incluyen aspectos como su tamaño, forma, color y grado de madurez. Este proceso contribuye a garantizar una consistencia en la calidad y apariencia de las frutas, lo que resulta favorable para los productores y consumidores al promover la simplificación del comercio y potenciar la eficacia dentro de la cadena de suministro, los estándares pueden ser establecidos por entidades gubernamentales, acuerdos comerciales internacionales o asociaciones industriales (Fang y Minato, 2021).



### **2.7.1 El color como indicador**

El color es un factor clave en la evaluación de los productos alimenticios, particularmente los de fuente vegetal, ya que está vinculado a su estado de madurez. Este atributo se origina a partir de la interpretación de la energía radiante, percibida visualmente cuando el ojo humano se ve estimulado por la luz que el alimento refleja. Los objetos interactúan con la luz de manera diferente, en función de sus propiedades físicas: la estructura y la composición. El color que se percibe en un objeto es el resultado de las longitudes de onda de la luz que el objeto refleja, ya que las longitudes de onda que son absorbidas no pueden ser vistas. Cuando la luz atraviesa un objeto, éste se vuelve transparente o invisible para nuestra visión (Mathias y Kong Ah, 2014).


La retina de nuestros ojos posee células sensoriales denominadas fotorreceptores, los cuales se clasifican en: bastones y conos. Los bastones se estimulan en escenarios de baja luminosidad, facilitando una percepción de los colores blanco y negro y diferentes tonalidades de gris, lo que nos ayuda a distinguir el contraste. Por su parte, los conos funcionan bajo iluminación intensa y permiten la percepción de los colores. Existen 3 tipos de conos: unos responden a la luz roja (R) con longitudes de onda entre 700 y 770 nm, otros a la luz verde (G) en el rango de 495 a 570 nm, y otros a la luz azul (B) entre 400 y 475 nm. Esta diferenciación fundamenta el sistema de codificación de colores RGB (Rojo, Verde, Azul) (Mathias y Kong Ah, 2014).

### **2.7.2 Modelo de color RGB**

El modelo de color RGB emplea los elementos: rojo (R), verde (G) y azul (B) para determinar la intensidad de cada color en un tono específico (Figura 3). En una imagen de 24 bits, cada componente puede tener un valor que oscila entre 0 y 255. En imágenes con una mayor profundidad de bits, como las de 48 bits, este rango de valores se amplía. La unión de estos valores genera un color específico. En modelos de color aditivos como

el RGB, los colores se generan mediante la emisión de luz. Este modelo es frecuentemente utilizado en pantallas, ya que las luces roja, verde y azul se mezclan de diferentes maneras para generar una amplia variedad de colores. Cuando estas tres luces se armonizan a su máxima intensidad, se obtiene como resultado el blanco. Aunque los contrastes resultantes siguen siendo rojo, verde y azul en teoría, los píxeles en la pantalla están tan cercanos que el ojo humano no puede distinguirlos individualmente. Un valor de 0 en cada componente representa la ausencia de luz, lo cual se percibe como negro (Corel, 2012).

*Figura 3 Representación visual del sistema RGB*



Fuente: (Corel, 2012)

Actualmente, se usan varias herramientas de medición de color de forma objetiva y precisa, estas se introducen cada vez más en la industria alimenticia, incluso empleando tecnologías de visión artificial a través de imágenes y aparatos digitales, que no es una técnica invasiva para el alimento, permitiendo una inspección completa de la producción, asegurando su inocuidad y calidad (Indrajeet et al., 2021).

Es posible estandarizar las frutas a través de la captura de fotografías o imágenes digitales y una evaluación de su color. Las tecnologías de procesamiento de imágenes permiten analizar de manera precisa el color de la fruta. Mediante el desarrollo de algoritmos y sistemas de visión por computadoras, se puede identificar y clasificar automáticamente la fruta según su color, lo que facilita el proceso de estandarización de acuerdo a los estándares predefinidos (Indrajeet et al., 2021).

## **2.8 Procesamiento digital de imagen**

Implica una serie de etapas que comienzan con la captura de imágenes a través de dispositivos conectados a un sistema informático, con el propósito de almacenarlas, transferirlas o procesarlas posteriormente. Dado el nivel de cálculos complejos necesarios, el uso de computadoras es esencial. Las imágenes digitales se generan como datos numéricos que representan la información visual obtenida por equipos como cámaras y escáneres. A través de software especializado, se pueden realizar operaciones como la mejora de la calidad, la identificación de contornos, la manipulación de colores y texturas, entre otras (Pérez y Valente., 2018).

### **2.8.1 Imágenes digitales y su clasificación**

Una imagen puede entenderse como una representación visual compuesta por pequeños puntos o píxeles, que son interpretados como una función de dos dimensiones (X, Y). Cada uno de estos puntos corresponde a un nivel específico de intensidad de luz en una ubicación determinada dentro de la imagen. Los niveles de brillo suelen oscilar entre 0 y 1, lo que genera diferentes tonalidades en la visualización. La manipulación de la información visual en imágenes digitales se realiza a través de dos enfoques principales: imágenes vectoriales y Ráster (o de mapa de bits), cada uno de los cuales define cómo se almacena y procesa la imagen. Según su formato y estructura, las imágenes digitales pueden clasificarse en diversas categorías (García, 2008). :

- Las imágenes vectoriales mantienen su claridad y definición al cambiar de tamaño, ya que no dependen de la resolución. Esto es posible porque cada punto en la imagen se describe mediante ecuaciones matemáticas que definen la relación entre los puntos que componen la figura.
- Por otro lado, las imágenes Ráster son dependientes de la resolución, lo que sugiere que al agrandarlas perderán nitidez, mostrando bordes pixelados. Se componen de una cuadrícula de píxeles, cada uno con un valor de color específico. Aunque pueden representar una gran variedad de tonos, son más adecuadas para fotos y representaciones realistas. Los formatos como TIFF, BMP, GIF, JPEG y PNG son compatibles con la mayoría de los navegadores.

## **2.8.2 Tipos de imágenes digitales**

Según García (2008), dentro del tratamiento digital de imágenes existen cuatro tipos principales:

1. Imágenes en escala de grises: A través una variedad de los tonos de gris. Con imágenes de 8 bits, es posible representar 256 tonos diferentes de gris.

2. Imágenes RGB (Rojo-Verde-Azul): Usan tres canales para mostrar los tonos en la pantalla, cada uno tiene profundidad de 8 bits de color, sumando un total de 24 bits de color por píxel. Esta configuración permite reproducir 16,7 millones de colores siendo afín con formatos como JPG, BMP y PNG.


3. Imágenes binarias: Con profundidad de color de 1 bit, lo que significa que cada píxel se representa con uno de los valores de color disponibles, generalmente blanco y negro.

4. Imágenes indexadas: Limitan la cantidad de colores en la imagen a un máximo de 256. Al disminuir la cantidad de colores, se disminuye el tamaño del archivo, ya que

se elimina parte de la información del color. Este tipo de imágenes es compatible con formatos como GIF y PNG-8 y es ampliamente utilizado en diversas aplicaciones multimedia.

Además, algunas imágenes tienen una profundidad de píxel de 32 bits, lo que implica un byte adicional en comparación con las imágenes de 24 bits. Este byte extra se utiliza para almacenar datos sobre la transparencia de la imagen, denominado máscara o canal alfa, que contiene diversos valores que indican los niveles de claridad. La Figura 4 presenta ejemplos de estas tipologías de imágenes.

*Figura 4 Tipos de Imágenes Digitales; (a) RGB; (b) Indexada; (c) Escala de Grises; (d) Binaria*



Fuente: (García, 2008)

### **2.8.3 Captura y digitalización de imágenes**

La adquisición de imágenes consiste en obtener representaciones visuales del entorno, y puede llevarse a cabo utilizando métodos tradicionales de fotografía con materiales químicos o mediante dispositivos electrónicos como cámaras digitales. Existen

muchas cámaras digitales en el mercado, que varían en diseño, tamaño y especificaciones.

Al seleccionar una cámara, es importante considerar varios factores, tales como:

- Resolución: La cantidad de píxeles que componen las imágenes.
- Capacidad de almacenamiento: La cantidad de memoria disponible para guardar una gran cantidad de imágenes.
- Compresión de archivos: La capacidad de la cámara para ajustar el nivel de compresión de las imágenes, lo cual afecta el espacio de almacenamiento necesario.
- Sistema de transferencia: La eficiencia del método para transferir imágenes desde la cámara a otros dispositivos, como una computadora.

#### **2.8.4 Digitalización**

Este proceso implica convertir una imagen desde un formato analógico a un formato digital, transformándola en una serie de píxeles. Cada píxel es una unidad básica que proporciona información sobre el color, el brillo y la ubicación en la imagen. En imágenes a color, esta información se refiere a la intensidad de cada componente en un esquema de color específico, como son CMYK o RGB. Se digitaliza en dos etapas fundamentales: muestreo y cuantización (García, 2008).

El muestreo consiste en capturar la imagen y organizarla en una matriz con un número definido de filas y columnas, lo que influye en el tamaño y en el valor del brillo de cada píxel. Por otro lado, la cuantización implica darle valores a los píxeles de la matriz, que representan la magnitud de la variable física en cada punto de la imagen. En términos visuales, el valor más bajo en el rango se asocia con el negro y el más alto con el blanco, con una mayor cantidad de valores intermedios permitiendo una representación

más detallada de los matices. Hoy, existen múltiples herramientas de programación que facilitan el proceso de digitalización de imágenes.

## **2.9 *Machine Learning***

MATLAB proporciona un entorno completo que incluye un lenguaje de programación propio y una plataforma destinada a la elaboración de aplicativos que abarcan análisis numérico, operaciones matriciales, procesamiento de señales y representación gráfica.

En esta plataforma se encuentra la función de *Machine Learning* la cual permite a las computadoras aprender a partir de un banco de datos. El propósito fundamental es desarrollar modelos que permitan identificar patrones estructurales en los datos, para ayudar en el proceso de toma de decisiones o realizar predicciones basadas en esa información (Cuevas et al., 2021). La efectividad de esta herramienta aumenta cuando se tiene acceso a extensos volúmenes de datos. y está diseñada principalmente para realizar tareas de clasificación o regresión con aplicaciones que usan conjuntos de datos extensos, como lo son *Regression Learner* y Redes Neuronales.

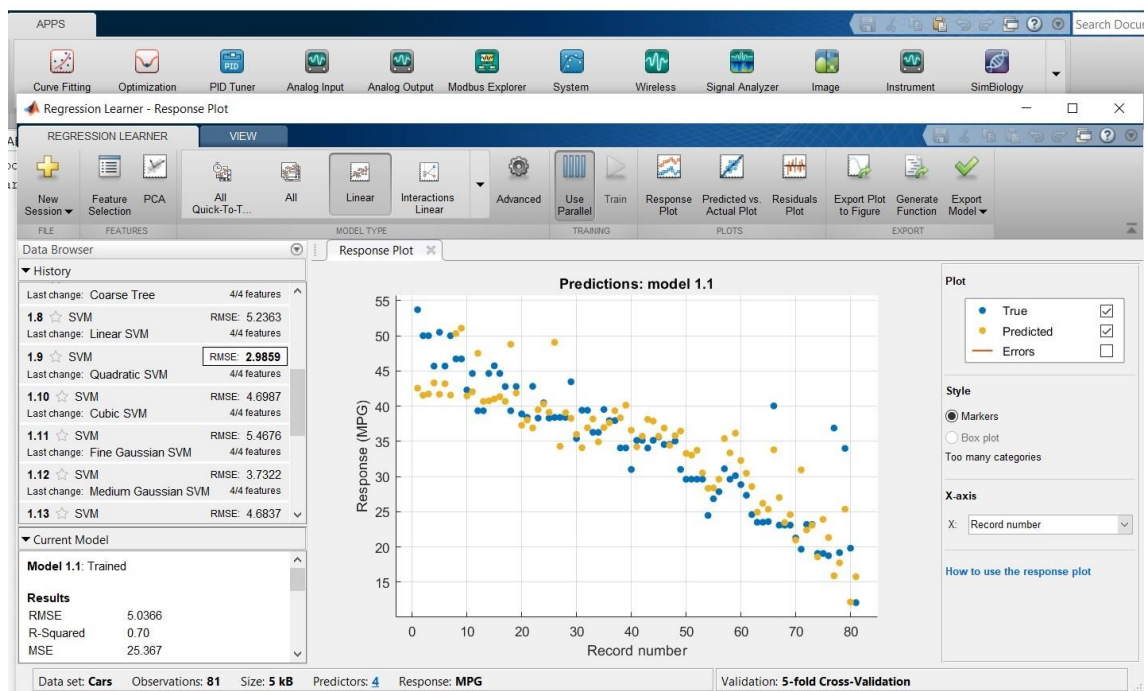
## **2.10 *Regression Learner***

La regresión es una técnica usada en muchos campos que necesitan de la predicción, como las finanzas, evalúa la relación entre variables dependientes e independientes creando algoritmos de regresión de manera interactiva (Anish, 2022).

La herramienta *Regression Learner* es ampliamente utilizada para entrenar modelos predictivos mediante diversas técnicas, entre estas: regresión lineal, árboles de decisión, regresión lineal gaussiana y máquinas de soporte vectorial (SVM), entre otras (Figura 5). También permite trabajar con modelos basados en conjuntos, que combinan varios modelos para mejorar la precisión. Además, facilita el análisis completo de un

conjunto de datos, la selección adecuada de las características más relevantes, y la definición de estrategias de evaluación, lo que ayuda a extraer información valiosa en el entrenamiento de los modelos. Una vez que se haya entrenado un modelo con éxito, es posible guardarlo en el espacio de trabajo de MATLAB para aplicarlo posteriormente en otros conjuntos de datos, permitiendo su reutilización en nuevos escenarios predictivos. Esta flexibilidad hace que *Regression Learner* sea una herramienta útil en la creación de modelos ajustados y precisos para diversas aplicaciones (Anish, 2022).

Figura 5 Técnicas de regresión en MATLAB



Fuente: (Anish, 2022)

## 2.11 Redes neuronales


Hoy en día, las redes neuronales son una herramienta tecnológica clave, ya que aportan significativamente en la solución de problemas asociados al aprendizaje predictivo, especialmente en la planificación de la producción para satisfacer la demanda esperada (Castañeda et al., 2022).



Una red neuronal se define como un modelo matemático que se compone por distintas cantidades de elementos que se organizan en varios niveles. Artificialmente, son redes conectadas de forma masiva inicialmente con elementos simples, que suelen ser versátiles a la adaptación, estos elementos se organizan de manera jerárquica, interactuando unas con otras, de modo similar en el que actúan las neuronas biológicas (Matich, 2001).

Las redes neuronales artificiales se componen de elementos básicos, que se muestran en la Figura 6. Las neuronas se conectan formando distintos números de capas que pueden variar dependiendo de la necesidad, los datos se introducen en la red a través de una capa de entrada y, posteriormente, son procesados en capas ocultas y los resultados se arrojan en la conocida capa de salida.

Figura 6 Esquema de una red neuronal conectada



Fuente: (Matich, 2001)

Tanto los modelos de *Regression Learner* como los de Redes neuronales, pueden ser integrados en aplicaciones desarrolladas en *App Designer* de MATLAB, pues los modelos entrenados en este entorno se exportan a otro espacio de trabajo para crear aplicaciones interactivas.

## **2.12 *App Designer***

*App Designer* está diseñada para el desarrollo profesional de aplicaciones. Esta herramienta incluye un gestor de diseño de cuadrículas, lo cual simplifica la organización de la interfaz de usuario. También ofrece características automáticas de ajuste que permiten que la aplicación se adapte a diferentes tamaños de pantalla. Este espacio facilita la distribución de aplicaciones mediante la creación de archivos empaquetados directamente desde la barra de herramientas, o permite la generación de aplicaciones independientes, tanto para la web como para escritorio (Mathworks, s.f.). Desarrollar aplicaciones en *App Designer* abarca dos aspectos fundamentales. El primero es el código, que es esencial para ejecutar todas las funciones y asegurar el correcto funcionamiento de la aplicación. El segundo es el aspecto visual, que aunque no es tan crucial para la funcionalidad como el código, es crucial para maximizar la satisfacción del usuario y mejorar el diseño general de la aplicación (Vivar, 2019).

*App Designer* proporciona una variedad de componentes para el desarrollo de aplicaciones, destacándose por su capacidad para crear aplicaciones autónomas tanto para escritorio como para la web. Ofrece ventajas como la interacción entre componentes, la definición del comportamiento de la aplicación, el diseño de la interfaz de usuario y la facultad de compartir aplicaciones dentro del entorno de MATLAB.

## **2.13 Modelos estadísticos de validación**

La validación tiene como objetivo garantizar que un modelo sea apropiado para su uso previsto, mientras que la evaluación depende de los objetivos que se quieren alcanzar con dicho modelo. Ambos procesos buscan confirmar que un modelo o teoría represente de manera precisa un fenómeno específico, y proporcionan información crucial para que los usuarios decidan si aceptan o rechazan el modelo

En el análisis estadístico de datos, existen múltiples aplicaciones, lo que conlleva diversas formas de validar un modelo. La selección del método de validación dependerá principalmente de aquello que se desee evaluar para comprobar la calidad y eficacia del modelo (Hernández, 2019).

- El MSE (Error Cuadrático Medio) representa la media de los errores al cuadrado entre las predicciones realizadas y los valores verdaderos. Esta medida castiga los errores más grandes y se presenta en unidades cuadráticas de la variable de interés (Castellon, 2023).

- El coeficiente de determinación  $R^2$  es una medida que se utiliza para evaluar el modelo, reflejando la proporción de la variabilidad total de la variable dependiente que es explicada por este. Este coeficiente varía entre 0 y 1, donde un valor más cercano a 1 indica un mejor ajuste del modelo (Castellon, 2023).

- Una matriz de confusión (Figura 7), es un recurso clave para medir el rendimiento en modelos de clasificación en el ámbito del aprendizaje automático. Esta matriz proporciona un desglose detallado del rendimiento al mostrar cuántas predicciones fueron correctas e incorrectas en cada categoría, desglosándolas en verdaderos negativos (TN), verdaderos positivos (TP), falsos negativos (FN) y falsos positivos (FP). Gracias a esto, es posible analizar los errores de clasificación y obtener información sobre el comportamiento del modelo, lo que contribuye a mejorar su capacidad predictiva (Bhandari, 2024).

Técnicamente, una matriz de confusión tiene una estructura de  $N \times N$ , donde  $N$  corresponde al número total de clases objetivo en el problema de clasificación. Al comparar los valores verdaderos con los valores predichos por el algoritmo, se obtiene una perspectiva completa de su desempeño. Además de calcular la exactitud y la tasa de

error, este análisis permite evaluar otras métricas esenciales como la precisión, la recuperación y el F1-score, lo que facilita la interpretación de los tipos de error cometidos, incluyendo los errores de tipo I y II (falsos positivos y negativos) (Bhandari, 2024).

*Figura 7 Esquema general de una matriz de confusión*

		Valores reales (Actual Values)	
		Positivo	Negativo
Valores predichos (Predicted Values)	Positivo	Verdadero positivo	Falso positivo
	Negativo	Falso negativo	Verdadero negativo

Fuente: (Scientest, 2024)

## CAPÍTULO III

### Materiales y métodos

#### 3.1 Tipo de investigación

Este estudio es de tipo cuantitativo puesto que se requirió entender las relaciones de causa y efecto, probar y confirmar hipótesis mediante un análisis numérico con métodos aproximados y herramientas de inteligencia artificial. El alcance de este estudio fue exploratorio, ya que se profundizó en el fenómeno del color, del cual no se ha encontrado suficiente información en las que se relacione con modelamientos matemáticos, específicamente en la naranjilla.

#### 3.2 Ubicación del lugar de estudio

Para la fase experimental, se trabajó en la ciudad de Ibarra, con el uso del laboratorio de análisis experimentales e innovación, ubicado en la Facultad de Ingeniería en Ciencias Agropecuarias y Ambientales (FICAYA) de la Universidad Técnica del Norte (UTN), cuyas coordenadas GPS son: (0.3578925, -78.1115525270077); además del laboratorio de análisis microbiológicos ubicado en el Campus Antiguo Hospital San Vicente de Paul – UTN (0,3466948, -78,1139).

#### 3.3 Materiales, equipos y software

Para conseguir los objetivos de esta investigación, se requirieron varios equipos y materiales, los cuales se describen en la Tabla 2.

*Tabla 2 Equipos, Materiales, Insumos y Reactivos*

Equipos	Materiales	Insumos	Reactivos	Software
Refractómetro digital	Soporte universal	Naranjilla	Hidróxido de sodio (NaOH) solución 0,1N	Microsoft Word.

Balanza digital Scale	Bureta de vidrio (25-50ml)	de	Fenolftaleína al 1%	Microsoft Excel
Refrigeradora	Probeta 100ml	de	Agua destilada	Plataforma de programación MATLAB
Controladores	Frasco Erlenmeyer 250ml	de		
Medidor de pH (potenciómetro) Cámara digital	Vaso de precipitación	de		

---

### 3.4 Métodos, técnicas e instrumentos

A continuación, se describen los instrumentos de investigación, los procedimientos y las metodologías utilizadas para obtener los datos y alcanzar los objetivos de este estudio.

#### 3.4.1 Evaluación del cambio de color en la naranjilla considerando la concentración de gases, temperatura y tiempo de almacenamiento

Para cumplir con el primer objetivo, se consideraron las condiciones iniciales de la fruta, comenzando con la estandarización de la materia prima basada en el índice de madurez. Para la obtención de datos se utilizó naranjilla con un índice de madurez específico: 2 (ver Figura 2), asegurándose de que la fruta no presentara daños ni golpes, ni estuviera en su etapa de senescencia.

##### 3.4.1.1 Estandarización

Se analizó el índice de madurez a través de la ecuación 1, a partir de un mínimo de 3 muestras para obtener un promedio menor al coeficiente de variación, esto con el fin

de trabajar con el mismo índice de madurez en todas las unidades experimentales. En la obtención de datos estandarizados, se midieron las variables siguiendo la guía de la normativa NTE INEN 2 303:2009. En la Tabla 3 se detalla los requisitos de la naranjilla fresca, en este trabajo se estudiará la denominada Naranjilla Híbrido Puyo.

*Tabla 3 Propiedades físico-químicas a Evaluar.*

	Madurez fisiológica		Madurez comercial		Método de ensayo
	Min	Máx	Min	Máx	
<b>Acidez titulable%(ácido cítrico)</b>					<b>NTE INEN 381</b>
Naranjilla híbrido Puyo	1,8	-	-	<1,8	
Naranjilla jugo	2,4	-	-	<2,4	
<b>Sólidos solubles totales, °Bx</b>					<b>NTE INEN 380</b>
Naranjilla híbrido Puyo	-	8,0	> 8,0	-	
Naranjilla jugo	-	6,0	> 6,0	-	
<b>Índice de madurez(°Bx/acidez)</b>					<b>Ver 8.3</b>
Naranjilla híbrido Puyo	-	4,5	>4,5	-	
Naranjilla jugo	-	2,5	>2,5	-	

Fuente: (NTE INEN 2 303, 2009)

- Determinación del índice de madurez

A través de los sólidos solubles totales (%Brix) y la máxima acidez titulable, aplicando la ecuación (1)

**Índice de madurez** (1)

$$= \frac{\text{solidos solubles totales}(\%Brix)}{\text{acidez total}(\%)}$$

- Determinación de la acidez titulable

Siguiendo la normativa presentada, usando un titulador se realizó por triplicado de solución de agua destilada 80 ml con 10 g de pulpa en un vaso de precipitado al que se le añadieron tres gotas de fenolftaleína. Seguido, se añadió el NaOH 0.1N hasta que la pulpa cambie de color ligeramente, finalmente se anotaron los mililitros de hidróxido de sodio gastado en el viraje de color, con este dato se aplica la ecuación (2).

$$\mathbf{Acidez\ total = Vx\ 2xF} \quad (2)$$

Donde:

A= Porcentaje de acidez titulable expresado como gramos de ácido cítrico por cada 100 gramos de fruta.

V= Cantidad de solución de NaOH 0.1N utilizada durante el proceso de titulación.

F= factor de acidez del ácido cítrico (0.064).

- Determinación de sólidos solubles totales

Mediante un refractómetro, se tomaron tres medidas de la misma muestra, cada una con una gota de la pulpa, tomando finalmente la media de los tres valores.

- Determinación de errores en medidas directas

En este estudio se realizaron múltiples cálculos de una misma magnitud, con la finalidad de validar los resultados acertadamente. Para ello, fue necesario trabajar en función de la dispersión de estos resultados, se evaluó la conveniencia de incrementar el número de mediciones. Para tomar una decisión, se realizaron tres mediciones de la magnitud en cuestión. ( $X_1$ ,  $X_2$  y  $X_3$ ) y se calcula el valor medio de estas, hallándose la dispersión total D, luego se obtiene el tanto por ciento de dispersión T, como se presenta en la ecuación 3:



$$T = \frac{D}{X_n} \quad (3)$$

Si D no es mayor que el valor de la sensibilidad (S) del aparato, se considera como estimación del valor real de la magnitud el promedio de las tres mediciones, y se utiliza la sensibilidad como el error absoluto, entonces:

$$X_3 \pm S$$

Si el valor de D supera a S, se opta por incrementar el número de mediciones de la magnitud. Este aumento está determinado por el valor del porcentaje de dispersión T, detallado en la Tabla 4.

*Tabla 4 Condicionamiento por el Porcentaje de Dispersión T.*

<b>Porcentaje de dispersión (T)</b>	<b>Nº total de medidas necesarias</b>	<b>Ecuación</b>
$T_3 \leq 2\%$	3	$\Delta x = S$
$2\% < T_3 \leq 8\%$	6	$\Delta x = \max(D_6/6, S)$
$8\% < T_6 \leq 15\%$	15	$\Delta x = \left(\frac{\sum(X_i - X_n)^2}{N}\right)^{1/2}$
$15\% < T_{15}$	50	$\Delta x = \left(\frac{\sum(X_i - X_n)^2}{N}\right)^{1/2}$

Fuente: (Posadas, 2010)

### **3.4.1.2 Almacenamiento con atmósferas modificadas**

Con la materia prima estandarizada, la fruta se envasó en fundas de polietileno de baja densidad para su posterior inyección de gases, tomando una unidad experimental de aproximadamente 160 g (tres naranjillas). En este estudio, se requirieron un mínimo de

100 datos experimentales y se trabajó por duplicado, por lo que se almacenaron más de 200 muestras. Respecto al tiempo de duración del experimento, Bonilla (2010) menciona que la naranjilla puede resistir hasta 52 días si se almacena en buenas condiciones, pero se recomienda no exceder los 40 días a la temperatura de 7°C. Sin embargo, con el fin de obtener un modelo más amplio y eficiente, los datos fueron medidos con temperaturas controladas entre 2 a 18°C en intervalos de 4, las temperaturas definidas fueron: 2, 6, 10, 14 y 18 °C.

Según Ospina y Meneses (2008), se ha observado que en el rango de 2-5% de O<sub>2</sub> y 3-8% de CO<sub>2</sub> las concentraciones son las más eficaces para ampliar el proceso de degradación de la clorofila y disminuir los síntomas de daño por frío, pero para un modelado más amplio se tomaron valores fuera de este rango. En la Tabla 5, se detallan las temperaturas y concentraciones con las que se realizaron 15 tratamientos en la fase experimental.

*Tabla 5 Factores en Estudio para cada tratamiento aplicado.*

<b>Temperatura (°C)</b>	<b>O<sub>2</sub> %</b>	<b>CO<sub>2</sub> %</b>
2	13	6
18	10	7
2	8	8
6	16	10
6	6	6
14	16	10
14	4	6
14	11	10
10	4	6
18	15	12
18	5	11
2	15	12
6	11	9
10	8,5	8,5
10	11	9

### **3.4.1.3 Medición de color**

La obtención de los datos experimentales del color de la fruta, se realizó tomando mediciones cada dos días durante 16 días de almacenamiento en las condiciones especificadas para cada tratamiento. Para iniciar con el procedimiento, los empaques fueron abiertos y con ayuda de una cámara digital, se capturaron varias imágenes de cada naranjilla desde distintos ángulos, posteriormente, estas fotografías fueron procesadas en la aplicación de “RGB color detector”, esta es una herramienta que permite identificar los valores numéricos de color en una imagen. Como su nombre lo indica, la aplicación muestra las coordenadas de color correspondientes al modelo “RGB” (rojo, verde, azul), estos valores pueden encontrarse entre 0 y 255, por ejemplo: (255, 0, 0) es el valor del color rojo.

Se calcularon los valores RGB de cada fotografía y se promediaron para identificar el color predominante de las naranjillas en cada día del tratamiento. Este procedimiento se repitió en cada medición para alcanzar un mínimo de 100 datos experimentales, necesarios para el modelado del sistema. El sistema se formó a partir de los cambios de color en la fruta, los cuales fueron influenciados por las variaciones de las concentraciones de los gases dentro de los empaques, así como la temperatura y el tiempo de almacenamiento.

### **3.4.2 Generación de un modelo representativo del cambio de color mediante inteligencia artificial**

Se utilizó el software MATLAB, en la cual se encuentra la herramienta de *Machine Learning*. Esta tiene como objetivo realizar tareas de clasificación o regresión con un conjunto significativo de datos. Las aplicaciones incluidas en este estudio fueron *Regression Learner* y *Neural Net Fitting*.

## **Modelamiento en *Regression Learner***

Con los datos obtenidos, se trabajó con la aplicación de *Regression Learner*, de MATLAB, esta cuenta con 19 modelos de regresión lineal que crean, entrenan y validan modelos de regresión con el fin de predecir valores dependientes a partir de conjuntos de datos de entrada independientes, en este caso, predictoras.

Para iniciar con el modelamiento, se descartaron los datos atípicos mediante un diagrama de caja y bigotes, los datos restantes fueron aleatorizados y divididos en porcentajes de 70 % y 30% para entrenamiento y validación respectivamente. Los valores se trabajaron con el método *bootstrap*, esta es una técnica de simulación que emplea el remuestreo para estimar desviaciones estándar de un estadístico y definir intervalos de confianza (Carmona, 2023). Se dividieron los 100 datos en 3 conjuntos más pequeños. Cada conjunto de datos fue entrenado y se evaluó su efectividad recopilando los indicadores de representación:  $R^2$  y MSE.

### **Consideraciones para $R^2$ (coeficiente de determinación):**

Muestra el porcentaje de la variabilidad total de la variable de estudio que es explicado por el modelo. El valor de  $R^2$  oscila entre 0 y 1; los valores más elevados denotan un fuerte ajuste, mientras que los valores más bajos reflejan un ajuste débil (Madrigal, 2022).

$-R^2 < 0,5 \rightarrow$  Ajuste débil

$-0,5 \leq R^2 \leq 0,8 \rightarrow$  Ajuste moderado

$-R^2 > 0,8 \rightarrow$  Ajuste fuerte

Se formula como la ecuación 4:

$$R^2 = 1 - \frac{SCE}{SCT} \quad (4)$$

Donde:

SCE= suma de cuadrados debida al error

$$SCE = \sum (Y_i - \bar{Y}_i)^2 \quad (5)$$

SCT= Suma total de cuadrados

$$SCT = \sum (Y_i - \hat{y})^2 \quad (6)$$

### **Consideraciones para MSE:**

Expresa la distancia al cuadrado entre los valores verdaderos y los estimados. Se eleva al cuadrado para evitar la cancelación de valores negativos y para dar mayor significancia a los valores atípicos. Esto genera un gradiente suave para aquellos errores mínimos, lo cual es beneficioso para que los algoritmos de optimización determinen los valores óptimos de los parámetros (Madriral, 2022).

- El MSE nunca puede ser negativo, ya que los errores se calculan al cuadrado.
- El valor del error puede oscilar entre cero e infinito.
- El MSE crece de manera exponencial cuando el error aumenta.
- Un modelo eficaz presentará un valor de MSE que se acerque más a cero.

Se formula como la ecuación 7:

$$MSE = \frac{\sum(Y_i - P_i)^2}{n} \quad (7)$$

Donde:

$Y_i$ = valor observado

$P_i$ = valor predicho correspondiente

$N$ = número de observaciones

### **Modelamiento con *Neural Net Fitting***

Esta aplicación divide los datos ingresados automáticamente, para trabajar el entrenamiento y la validación al mismo tiempo; en esta investigación, se utilizaron 2 algoritmos con los que se desarrollan las redes neuronales, estas son: *Best Levenberg-Marquardt* y *Best Scaled Conjuhated Gradient*. Se inició el modelamiento con 5 neuronas, en cada iteración se aumentaron 5 más hasta llegar a las 100 capas. Se contabilizaron 40 modelos en total. Para conocer la eficiencia de los modelos, también se tomó en consideración los indicadores de representación  $R^2$  y MSE dados por la misma aplicación.

### **Validación de los modelos para la selección del mejor representante del sistema**

Como se mencionó, el 30% de los datos separados inicialmente fueron utilizados para la validación de los modelos, se tomó en cuenta que con la técnica de redes neuronales en *Neural Net Fitting*, la validación y sus respectivos indicadores fueron calculados automáticamente. Específicamente en los modelos de regresión con *Regression Learner*, este proceso se realizó manualmente, los algoritmos de entrenamiento fueron exportados y empleados para realizar predicciones, una vez

obtenidos estos datos, se realizó una comparación para determinar los indicadores de representación.

Finalmente, el mejor modelo de entrenamiento, no siempre es el mejor de validación, por lo que todos los modelos fueron comparados, tomando como referencia los indicadores de representación.

### **3.4.3 Creación de un sistema de supervisión, control y adquisición de datos aplicando el modelo de IA**

Para el cumplimiento de este objetivo, se trabajó en MATLAB con la herramienta de *App Designer*, la cual permite crear apps de manera profesional proporcionando un gestor de diseño de cuadrículas para estructurar la interfaz de usuario y características automáticas de reordenación que permiten a la aplicación identificar y adaptarse a modificaciones en el tamaño de la pantalla (Mathworks, s.f.).

En este estudio se recopilaron todos los datos relevantes que contribuyen al cambio de color de la naranjilla durante su almacenamiento, bajo condiciones controladas y específicas para cada tratamiento. Para analizar esta variación, se emplearon imágenes digitalizadas obtenidas en el primer objetivo, las cuales fueron procesadas mediante algoritmos de redes neuronales pre configurados y disponibles en el entorno de trabajo. El objetivo fue identificar un modelo que mostrara una eficiencia aceptable, determinada por matrices de confusión, para que sea representativa y estadísticamente significativa del sistema, basándose en la base de datos generada.

La aplicación desarrollada buscó incorporar la capacidad de ingresar datos gráficos, es decir, imágenes capturadas directamente a través de una cámara conectada al dispositivo, facilitando el análisis visual. Además, se habilitó la posibilidad de ingresar parámetros clave como la concentración de gases, la temperatura y el tiempo de

almacenamiento, lo que permite al usuario seguir el proceso de forma más precisa mediante una simulación predictiva. De esta forma, los exportadores cuentan con una herramienta práctica y eficiente que les permite prever el estado de su producto al llegar a su destino, reduciendo la necesidad de experimentación directa que podría conllevar pérdidas económicas.

## CAPÍTULO IV

### Resultados y discusión

#### 4.1 Datos obtenidos del análisis de cambio de color en la naranjilla dadas distintas condiciones de almacenamiento.

La dispersión total de los resultados de los lotes estandarizados fue menor al 2%, por lo cual, tres mediciones fueron suficientes. Se obtuvieron resultados muy cercanos con respecto al índice de madurez, asegurando que la fruta con la que se trabajó estuvo bajo las mismas condiciones iniciales, dichos resultados se ven reflejados en la Tabla 6.

*Tabla 6 Estandarización de la Materia Prima*

<b>Lote</b>	<b>°Brix</b>	<b>Acidez Titulable</b>	<b>Índice De Madurez</b>	<b>Dispersión Total (%)</b>
1	7,36	29,46	0,20	0,18
2	6,57	29,71	0,17	0,09
3	6,57	29,71	0,17	0,21
4	6,77	28,83	0,18	0,06
5	5,98	28,78	0,16	0,04
6	5,36	25,00	0,16	0,20

Durante el almacenamiento en los distintos tratamientos, los datos numéricos recopilados mostraron que la desviación estándar y el coeficiente de variación se mantuvieron controlados. Estos valores no superaron el límite establecido de 10, lo que indica que el nivel de error estuvo dentro de los parámetros aceptables. En la Tabla 7 se refleja la manera en la que fueron recopilados los datos, la concentración inicial de CO<sub>2</sub> y de O<sub>2</sub>, además de la temperatura para cada tratamiento, también se muestra de manera



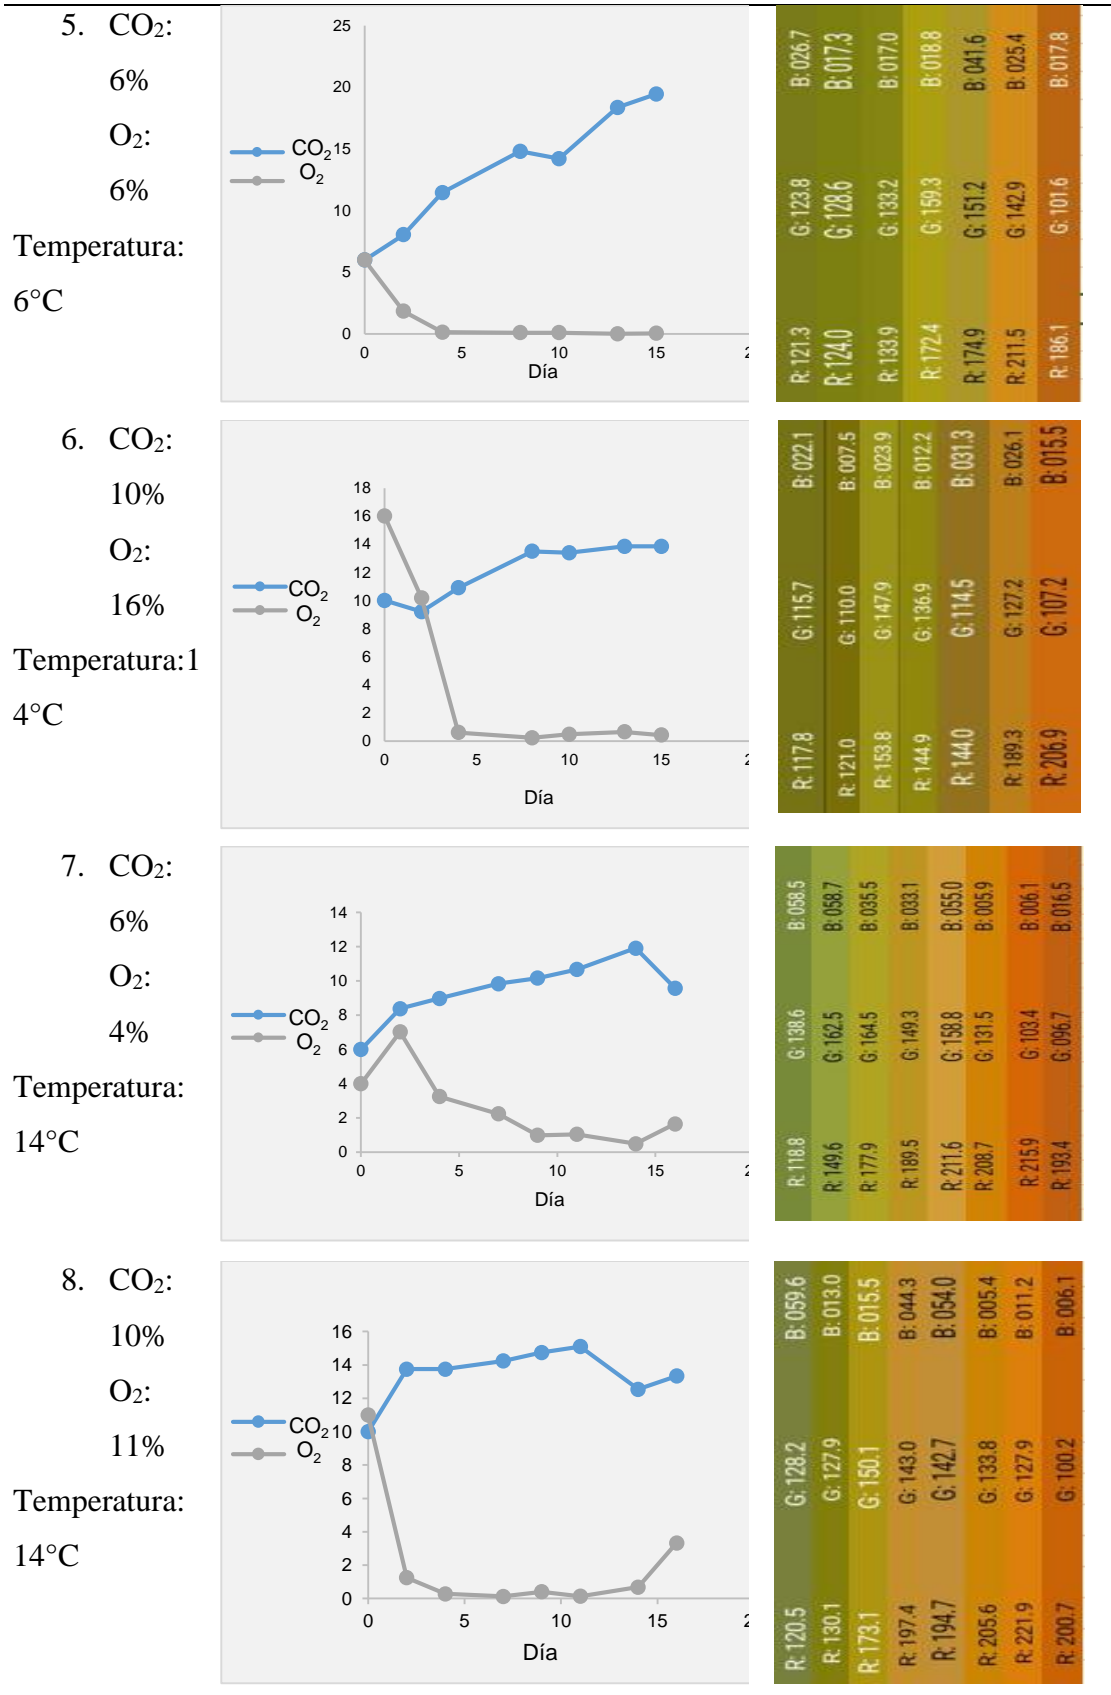
gráfica la variación de los gases durante el tratamiento, en estas gráficas se puede observar la disminución del O<sub>2</sub> y el aumento de CO<sub>2</sub> de inicio a fin de la experimentación. En el proceso de respiración, los carbohidratos se descomponen en componentes básicos para generar la energía requerida para desarrollar los procesos celulares, manteniendo vivas las células y el organismo. Durante este proceso, se utiliza oxígeno y se producen agua, dióxido de carbono y energía (Silva, 2008).

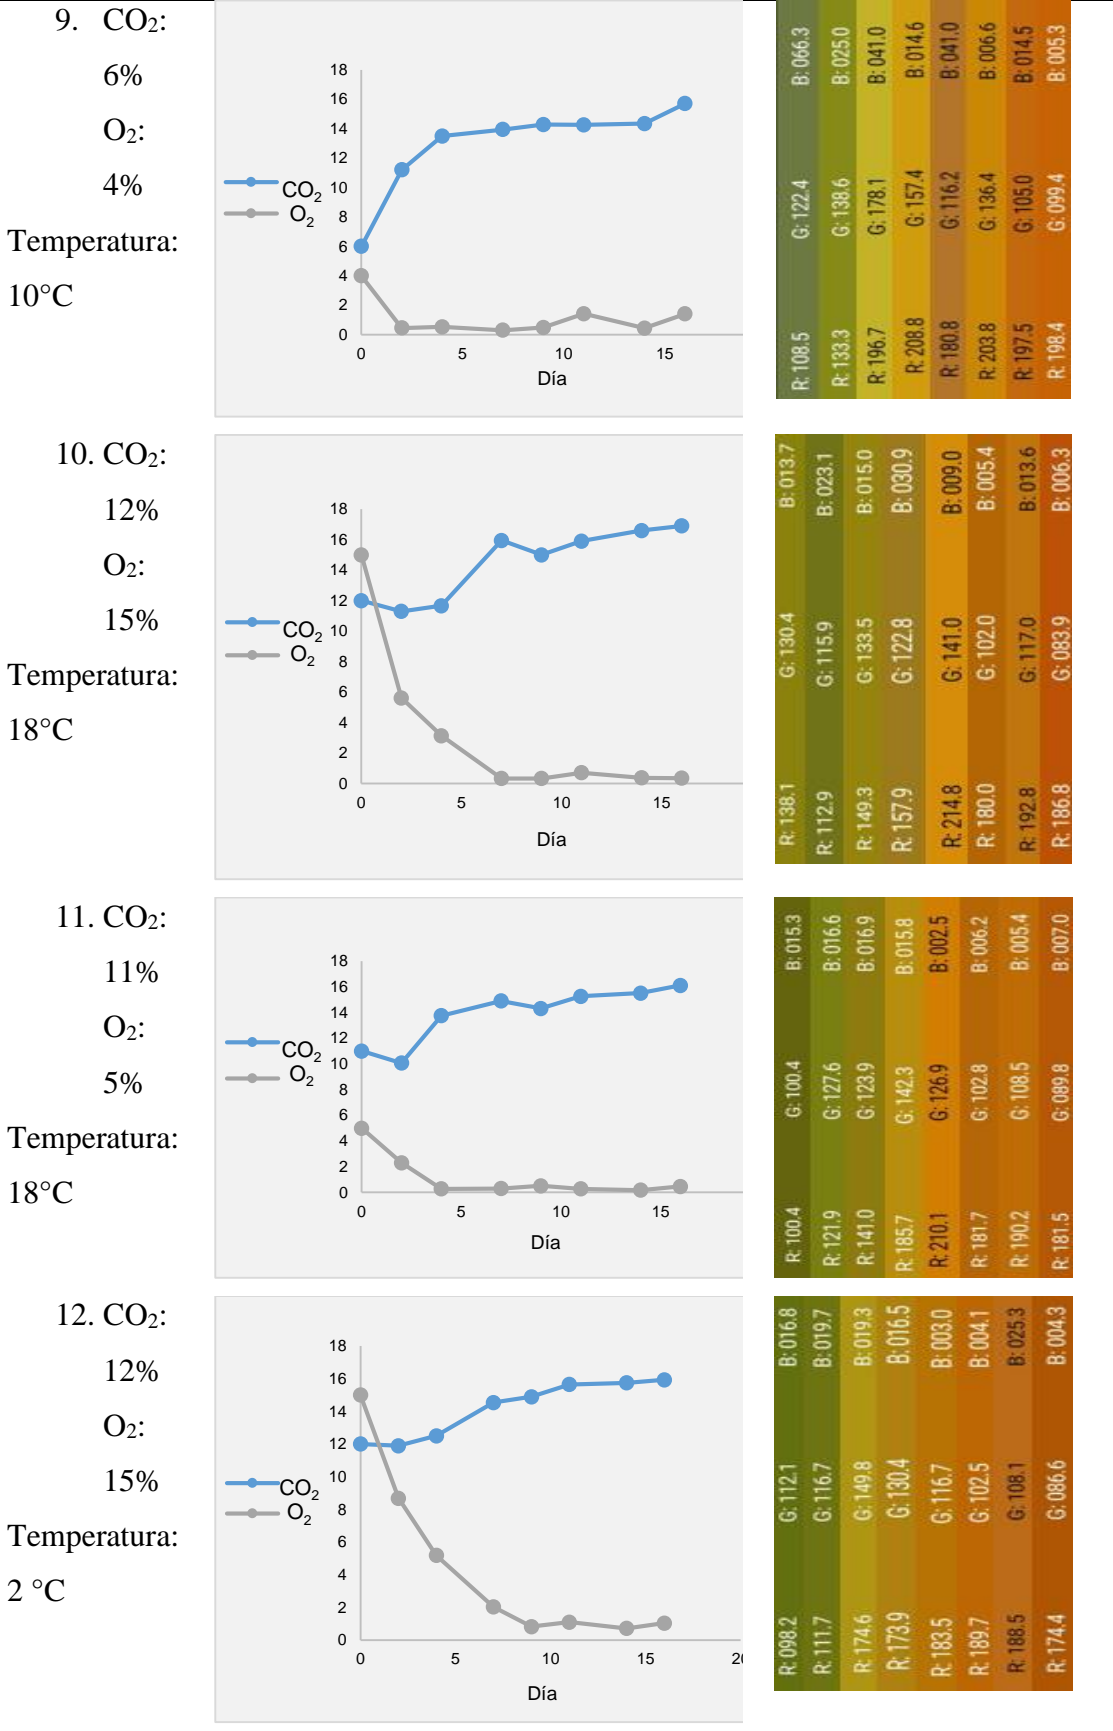
La naranjilla es un fruto cuya tasa respiratoria es más baja que otros frutos climatéricos, sin embargo, esta condición si se ve reflejada, según un estudio realizado por Andrade y Fuertes (2021), se observó un incremento gradual en la respiración de la fruta en función del tiempo de maduración, esto se traduce en una mayor producción de etileno, razón por la cual la concentración de CO<sub>2</sub> va en acenso y la de O<sub>2</sub> desciende.

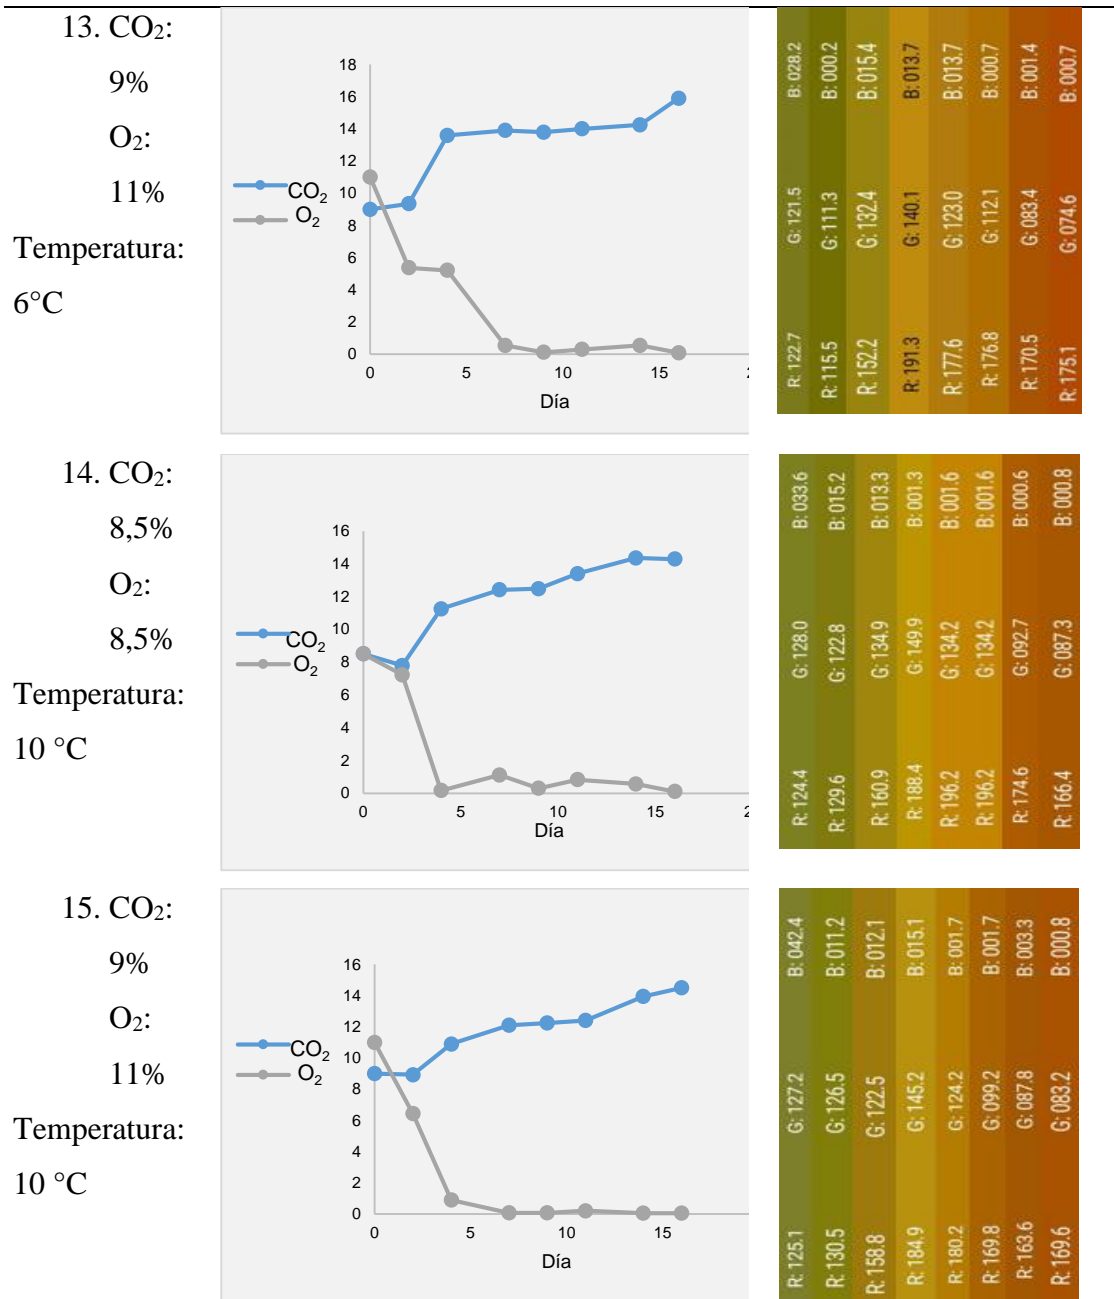
Además, se presentan gráficos que detallan la variación del color en coordenadas RGB. Se observa que el cambio de color en todos los tratamientos sigue un patrón consistente, sin importar las condiciones específicas de almacenamiento. Este cambio va desde un tono verde hasta un naranja. Los cambios en el color se deben principalmente a la degradación de la clorofila a través de procesos enzimáticos, lo que lleva a la formación de carotenoides, los cuales son responsables de los pigmentos asociados con la madurez (Andrade et al., 2021). Finalmente, los impactos de la generación de etileno durante la respiración, causan un amarillamiento o pérdida de coloración verde (Silva, 2008).

Tabla 7 Recopilación de datos

Tratamiento	Variación de gases (%)	Variación de color (RGB)
1. CO <sub>2</sub> : 6% O <sub>2</sub> : 13% Temperatura: 2 °C		
2. CO <sub>2</sub> : 7% O <sub>2</sub> : 10% Temperatura: 18 °C		
3. CO <sub>2</sub> : 8% O <sub>2</sub> : 8% Temperatura: 2 °C		
4. CO <sub>2</sub> : 10% O <sub>2</sub> : 16% Temperatura: 6 °C		



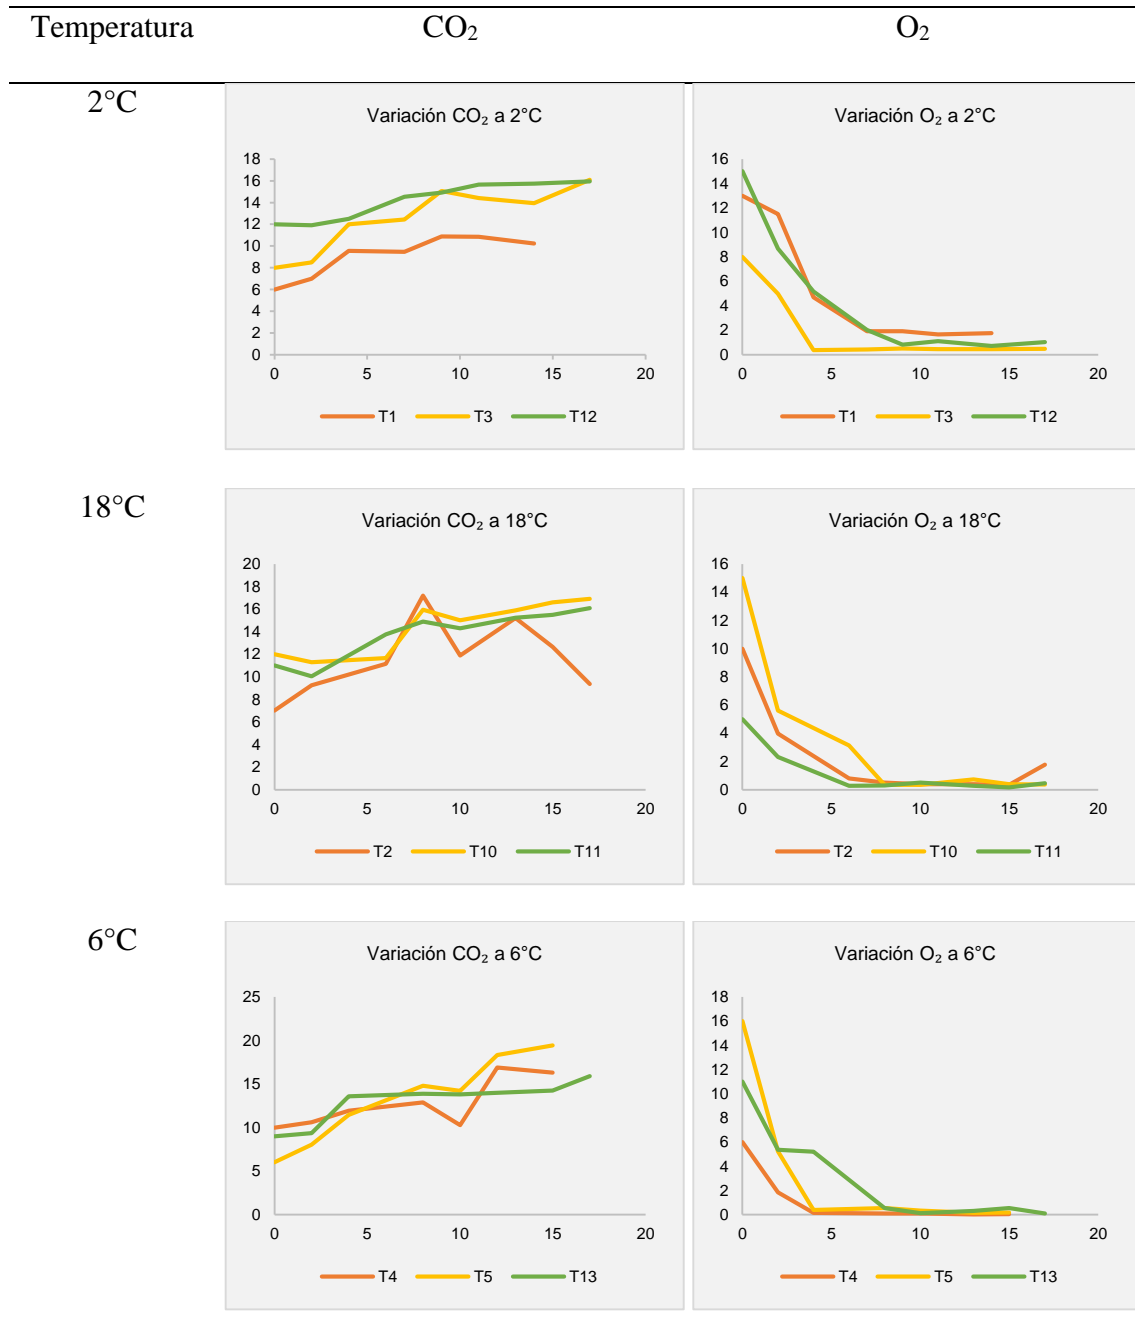




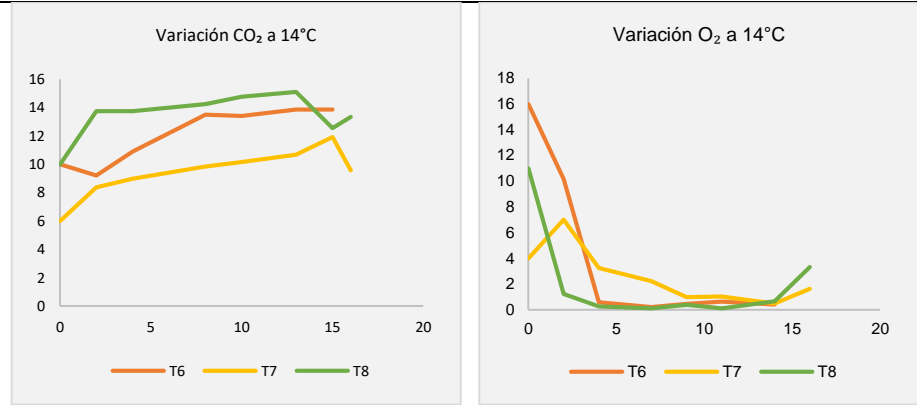
Como se detalló anteriormente, se llevaron a cabo experimentos con cinco temperaturas diferentes, distribuidas en 15 tratamientos en total. Cada tratamiento presentó variaciones en las concentraciones iniciales de los gases a lo largo del tiempo (días). A continuación, se muestra de manera gráfica el cambio en las concentraciones de

CO<sub>2</sub> y O<sub>2</sub> respectivamente (Tabla 8), agrupados por temperatura y número de tratamiento (T1,T2,T3...) en los que fue aplicada.

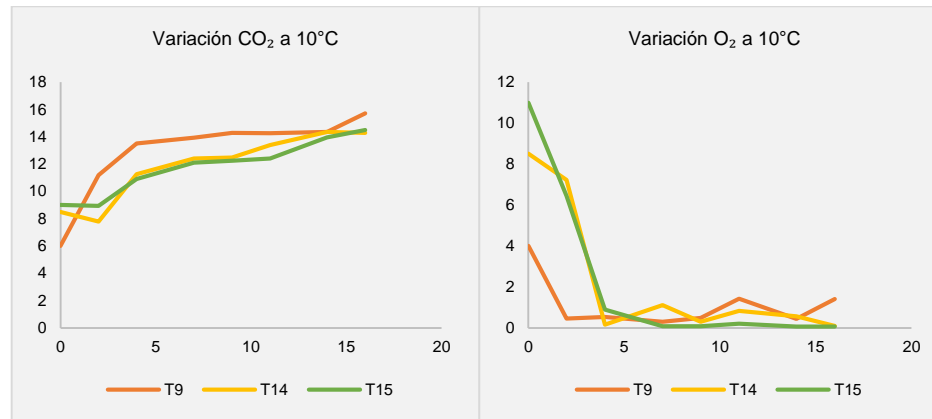
Tabla 8 Variación de gases por temperatura



14°C



10°C



#### 4.2 Modelo representativo del cambio de color mediante inteligencia artificial

Se contó con 19 modelos de regresión lineal en la aplicación de *Regression Learner*. A través de los datos divididos para el entrenamiento y la validación respectivamente, se evaluaron los indicadores de representación  $R^2$  y MSE. Sin embargo, no se obtuvieron resultados significativos para MSE que faciliten la elección de un modelo, por lo que se adjuntó el cálculo de otros indicadores, estos son: RMSE y AIC. Pese a estos resultados, el mejor modelo de entrenamiento no fue el mejor modelo para validación, pues se produjo un sobreajuste en los datos debido a que no se trabajó con la opción de validación cruzada, esto por la naturaleza de los datos del color, que en coordenadas RGB, varían notablemente para cada color en específico. En la Tabla 9, se presenta de manera resumida de los resultados de dichos procesos.

Tabla 9 Entrenamiento de datos con Regression Learner

#Modelo	Modelos de regresión lineal	R <sup>2</sup>	MSE	RMSE	AIC
1	Linear regression-linear	0,44	265,77	16,13	433,33
2	Linear regression-interactions linear	0,65	160,77	12,60	394,63
3	Linear regression-robust linear	0,36	277,43	16,53	437,68
4	Linear regression-stepwise linear	0,51	232,17	15,08	422,01
5	Tree-fine tree	0,64	182,20	12,97	400,72
6	Tree-medium tree	0,26	368,60	18,90	456,99
7	Tree-coarse tree	0,00	549,57	22,65	482,45
8	Svm-linear svm	0,37	293,33	16,97	441,54
9	Svm-quadraticsvm	0,58	185,30	13,55	406,69
10	Svm-cubic svm	0,71	133,40	11,49	380,10
11	Svm-fine gaussian svm	0,83	73,20	8,17	334,73
12	Svm-medium gaussian svm	0,61	173,20	13,03	401,39
13	Svm-coarse gaussian svm	0,30	336,33	18,10	451,37
14	Esemble-boosted trees	0,54	221,53	14,67	418,79
15	Esemble-bagged trees	0,42	273,90	16,30	435,36
16	Gaussian process-squared	0,71	153,07	11,38	384,38
17	Gaussian process-matern	0,72	142,67	10,94	378,67
18 <sup>a</sup>	Gaussian process-exponential	0,94	36,87	4,24	200,96
19	Gaussian proces-rational	0,71	130,87	10,25	375,86

a: Modelo representativo respecto a los indicadores de representación para la fase de entrenamiento.

Para validar los modelos (Tabla 10), también se realizaron los cálculos de RMSE y AIC como indicadores adicionales, en esta etapa, el mejor modelo fue el número 15, pues este arrojó predicciones más cercanas a los valores reales de color. Hay que tomar en cuenta que en este caso, el valor del coeficiente de determinación es bajo. Un modelo con un R<sup>2</sup> menor a 0,50 posee una capacidad limitada para interpretar la variabilidad de los datos, siendo que un modelo con valores mayores a este, se considerarían fiables para las previsiones futuras (Blog, 2019). Según Palma (2022), se considera que la diferencia de esta proporción se debe a la variación individual y puede explicarse por otros factores que no se tuvieron en cuenta en el análisis. En tanto, al conocer los indicadores



representativos del mejor modelo de validación, se determinó que pudieron existir factores influyentes en el cambio de color que no fueron tomados en cuenta para el modelamiento, razón por la que no se obtuvo una eficiencia mayor.

*Tabla 10 Validación de datos con Regression Learner*

#Modelo	Modelos de regresión lineal	R <sup>2</sup>	MSE	RMSE	AIC
1	Linear regression-linear	0,26	408,62	19,66	212,08
2	Linear regression-interactions linear	0,31	388,17	19,23	210,82
3	Linear regression-robust linear	0,27	398,4	19,45	211,46
4	Linear regression-stepwise linear	0,27	403,23	19,5	211,44
5	Tree-fine tree	0,31	392,67	19,28	210,87
6	Tree-medium tree	0,31	375,8	18,84	209,01
7	Tree-coarse tree	0,23	417,4	19,75	211,87
8	Svm-linear svm	0,25	432,27	20,15	213,49
9	Svm-quadraticsvm	0,28	423,67	20,13	214,31
10	Svm-cubic svm	0,11	757,8	26,35	231,63
11	Svm-fine gaussian svm	0,21	496,47	21,09	214,99
12	Svm-medium gaussian svm	0,34	362,2	18,58	208,41
13	Svm-coarse gaussian svm	0,25	403,1	19,5	211,3
14	Esemble-boosted trees	0,29	440,57	20,2	212,97
15 <sup>a</sup>	Esemble-bagged trees	0,45	280,17	16,42	199,94
16	Gaussian process-squared	0,34	345,07	18,09	206,17
17	Gaussian process-matern	0,34	343,4	18,05	206,05
18	Gaussian process-exponential	0,37	325,07	17,6	204,47
19	Gaussian proces-rational q	0,34	346,03	18,12	206,31

a: Modelo representativo respecto a los indicadores de representación para la fase de validación.

Respecto al modelamiento con redes neuronales, se calcularon los indicadores de representación cada 5 neuronas en la aplicación *Neural Net Fitting*, aquí se trabajó con 2 algoritmos de aprendizaje: *Best Levenberg-Marquardt* y *Best Scaled Conjuhated Gradient*, ambos ejecutados de la misma manera y tomando sus indicadores de representación. En el entrenamiento (Tabla 11 y 12) se obtuvieron mejores resultados con el primer algoritmo, pues en este se obtuvo un coeficiente de determinación muy bueno,

indicando un ajuste perfecto haciéndolo un modelo confiable para las predicciones futuras; el resultado de MSE con este algoritmo también fue muy aceptable, indicando que las predicciones coincidirían con los valores reales, sin embargo, al igual que con *Regression Learner*, el mejor modelo de entrenamiento no fue el mejor para la validación.

*Tabla 11 Entrenamiento de datos con Best Levenberg-Marquard (BLM) en Neural Net Fitting*

Número de neuronas	R <sup>2</sup>	MSE	RMSE	AIC
5	0,97	240	15,5	624,8
10	0,98	109	10,4	534,8
15	0,98	116	10,8	541,9
20	0,95	424	20,6	689,7
25	0,99	47	6,9	438,9
30	0,98	84	9,2	505,1
35	0,98	187	13,7	596,3
40	0,99	33	5,7	398,6
45	0,99	64	8,0	474,1
50	0,97	213	14,6	611,2
55	0,98	56	7,5	458,9
60	0,99	24	4,9	362,3
65	0,99	7	2,6	221,8
70	0,99	1	1,0	0,0
75 <sup>a</sup>	0,99	1	1,0	0,0
80	0,99	45	6,7	434,0
85	0,98	87	9,3	509,1
90	0,98	125,7	11,2	551,1
95	0,99	2	1,4	79,0
100	0,99	3	1,7	125,2

a: Modelo representativo respecto a los indicadores de representación para la fase de entrenamiento.

*Tabla 12 Entrenamiento de datos con Best Scaled Conjugated Gradient (SCG) en Neural Net Fitting*

Número de neuronas	R <sup>2</sup>	MSE	RMSE	AIC
5	0,96	280	16,7	642,4
10	0,97	215	14,7	612,3
15	0,97	198	14,1	602,9
20	0,96	240	15,5	624,8

25	0,97	241	15,5	625,3
30	0,95	454	21,3	697,5
35	0,86	1476	38,4	831,9
40	0,97	198	14,1	602,9
45	0,95	434	20,8	692,3
50	0,98	156	12,5	575,7
55	0,98	143	12,0	565,8
60	0,98	194	13,9	600,5
65	0,98	1107	33,3	799,1
70	0,99	108	10,4	533,8
75	0,97	218	14,8	613,8
80	0,99	84	9,2	505,1
85	0,97	302	17,4	651,0
90	0,98	133	11,5	557,5
95	0,98	168	13,0	584,1
100 <sup>a</sup>	0,99	31	5,6	391,5

a: Modelo representativo respecto a los indicadores de representación para la fase de entrenamiento.

La Tabla 13 muestra los resultados de la validación en redes neuronales con los dos algoritmos mencionados, en este caso, ambos algoritmos coinciden en el número de neuronas con las que se obtienen mejores valores de los indicadores representativos, al igual que en el entrenamiento, los valores de  $R^2$  son muy buenos, pese a esto, los valores obtenidos en MSE no se ven tan cercanos a cero, esto se puede dar debido a la naturaleza de las variables de salida.

Tabla 13 Validación de datos con Neural Net Fitting

Número de neuronas con LM					Número de neuronas con SCG				
	$R^2$	MSE	RMSE	AIC		$R^2$	MSE	RMSE	AIC
5	0,97	264	16,2	635,7	5	0,96	340	18,4	664,5
10	0,95	270	16,4	638,2	10	0,94	602	24,5	729,6
15	0,93	731	27,0	751,8	15	0,95	440	21,0	693,9
20	0,91	988	31,4	786,1	20	0,96	356	18,9	669,7
25	0,91	869	29,5	771,5	25	0,95	489	22,1	705,9
30	0,88	1785	42,2	853,5	30	0,91	861	29,3	770,4
35	0,86	1158	34,0	804,2	35	0,83	1314	36,2	818,6
40	0,81	1796	42,4	854,2	40	0,82	1645	40,6	844,2
45	0,9	1295	36,0	817,0	45	0,93	679	26,1	743,4
50	0,89	1114	33,4	799,8	50	0,93	769	27,7	757,5
55	0,89	1247	35,3	812,6	55	0,94	664	25,8	740,8

60	0,83	2226	47,2	878,7	60	0,91	1532	39,1	836,1
65	0,91	1051	32,4	793,2	65	0,86	2184	46,7	876,5
70	0,81	2062	45,4	870,0	70	0,91	1306	36,1	817,9
75	0,88	1236	35,2	811,6	75	0,86	1458	38,2	830,5
80	0,81	3607	60,1	933,7	80	0,9	1425	37,7	827,9
85	0,78	2171	46,6	875,9	85	0,77	2741	52,4	902,4
90	0,79	2906	53,9	909,1	90	0,86	2050	45,3	869,3
95	0,89	1319	36,3	819,0	95	0,84	2264	47,6	880,6
100	0,81	2366	48,6	885,7	100	0,88	1311	36,2	818,4

Nota: se observa que con ambos algoritmos, los mejores resultados se obtienen al trabajar con 5 neuronas, sin embargo, los valores del algoritmo LM tienen mayor aceptabilidad

Para entender por qué el error cuadrático medio (MSE) puede ser elevado en ciertos contextos, es crucial considerar la naturaleza de las variables involucradas. En el caso de las coordenadas de color RGB, los valores varían entre 0 y 255 para cada componente (rojo, verde y azul). Esto implica que las diferencias absolutas entre los valores predichos y los reales pueden ser considerables. Al operar estas diferencias y promediarlas, se obtiene un MSE elevado. En el caso de los valores RGB, su amplio rango hace que incluso pequeñas discrepancias resulten en un MSE significativo. Además, el MSE impone una mayor penalización a los errores elevados, dado que las diferencias son elevadas al cuadrado. Por lo tanto, es natural esperar un MSE alto al trabajar con datos RGB debido a su amplio rango y la sensibilidad del MSE a diferencias mayores (Frost, 2019). Para determinar el mejor modelo, se tomó entonces el valor más próximo a cero para el MSE y el más cercano a 1 para  $R^2$ .

Se hizo una comparación de los resultados de los mejores algoritmos tanto de regresión como de redes neuronales, priorizando a los algoritmos de validación como el modelo más representativo del sistema por las siguientes razones:

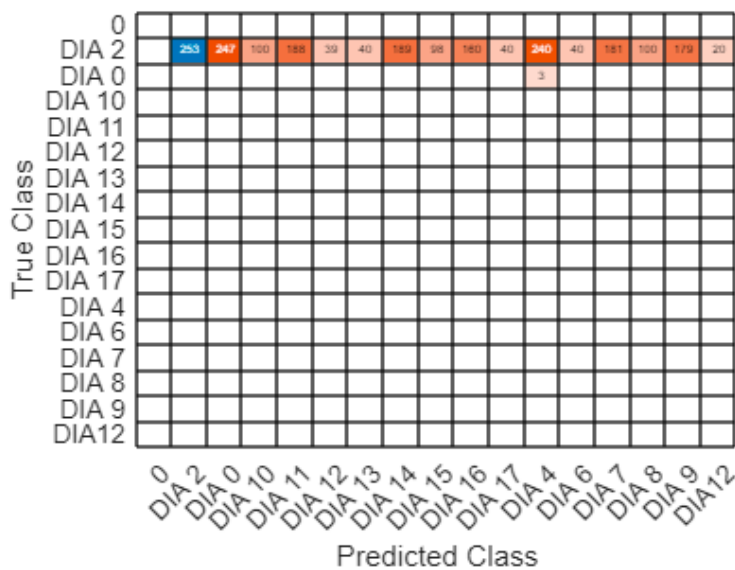
- El conjunto de validación actúa como un conjunto independiente e imparcial para comprender el rendimiento de distintos algoritmos entrenados (Wilber y Werness, 2020).
- Se prioriza la validación sobre el entrenamiento para prevenir el sobreajuste, ya que el modelo puede capturar particularidades específicas de las muestras de entrenamiento, reduciendo la eficacia en datos nuevos. Martin (2024) subraya la importancia de realizar una "prueba a ciegas" al final del desarrollo para asegurar la efectividad del modelo. Durante el desarrollo, se utiliza un conjunto de validación para iterar y ajustar hiperparámetros, mejorando el ajuste del modelo a los datos y sirviendo como medida de la precisión real en escenarios de prueba. Por estas razones, es esencial contar con un conjunto de validación durante el desarrollo del modelo.
- Un modelo que rinde bien en el conjunto de validación es más robusto y confiable. Es menos probable que dependa de las particularidades de los datos de entrenamiento y más probable que identifique las verdaderas relaciones subyacentes en los datos.

#### **4.3 Sistema de supervisión, control y adquisición de datos aplicando el modelo de IA**

Se planeó trabajar con la base de datos de imágenes digitalizadas obtenidas en el objetivo 1, utilizando un algoritmo proporcionado por MATLAB (googlenet) para identificar el cambio de color durante los tratamientos y determinar el porcentaje de eficiencia del modelo a través de una matriz de confusión. Los resultados no fueron significativos, en la Figura 8 se presenta el resultado de la validación con una matriz de confusión para este algoritmo, con el que se obtuvo un 11,95% de efectividad. En esta matriz se refleja un sesgo fuerte del modelo, sugiriendo que está teniendo dificultades

para diferenciar correctamente entre diferentes clases, en este caso, días. La mayor parte de las predicciones se concentran en los primeros días, pero con pocos datos correctamente clasificados en los demás, lo que llevó a la inclusión de dos algoritmos adicionales: resnet50 y resnet101. Sin embargo, estos modelos también mostraron una eficacia limitada (menos del 20%).

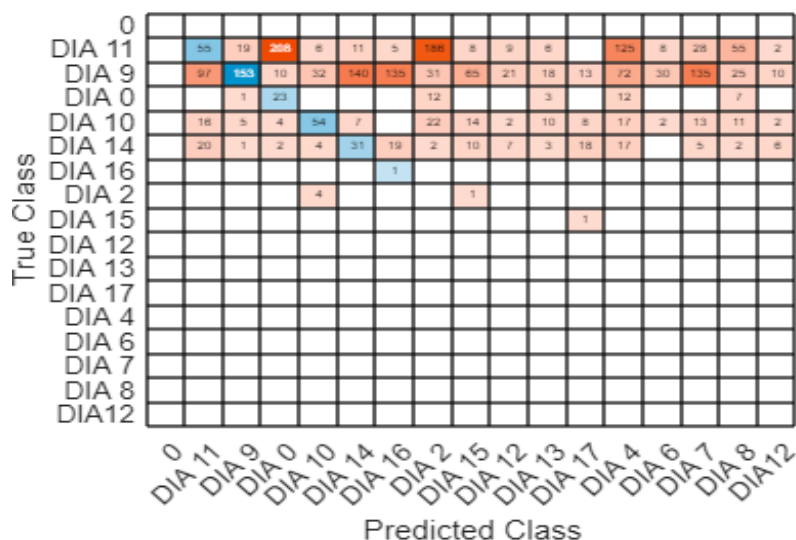
Figura 8 Matriz de confusión del algoritmo googlenet



En la Figura 9, se muestra la matriz de confusión obtenida como resultado del algoritmo “resnet50” con el que se obtuvo un alcance de 19,08%. La matriz muestra una concentración de predicciones correctas en dos clases: día 0 y día 14, en ambos casos el modelo tiene 259 aciertos, sin embargo, para las demás clases, el rendimiento es deficiente. El modelo podría estar sobre ajustado a esas dos clases específicas teniendo dificultades para generalizar bien a las demás.



Figura 10 Matriz de confusión del algoritmo resnet101



Los bajos resultados en las matrices de confusión al intentar detectar cambios en el color de la fruta durante su almacenamiento pueden estar influenciados por varios aspectos. En primer lugar, las modificaciones en el color de la naranjilla a lo largo del tiempo pueden ser extremadamente sutiles, lo que dificulta su captura precisa en imágenes digitales debido a variables como la iluminación, la resolución de la cámara, o las limitaciones del modelo de aprendizaje automático utilizado (Xiao et al., 2023).


Adicionalmente, los modelos de clasificación pueden tener problemas al distinguir entre colores que son muy similares dentro del espectro RGB, lo cual aumenta la probabilidad de falsos positivos o negativos. Como resultado, estas pequeñas variaciones en color podrían ser interpretadas incorrectamente, lo que reduce la precisión general del modelo y se refleja en un bajo rendimiento en la matriz de confusión (Xiao et al., 2023).

Debido a esto, se decidió continuar con el modelo seleccionado como el más representativo en el objetivo 2, en la Figura 11 se presenta la gráfica de regresión obtenida de este modelo, evaluando la relación entre las salidas reales y las predichas, incluyendo



una línea de regresión y valor de coeficiente de regresión (R). En entrenamiento, validación y prueba los valores son muy cercanos a 1.

Figura 11 Gráfica de regresión del modelo de Neural Net Fitting con 5 neuronas del algoritmo LM



Este modelo permitió la creación de la aplicación (Figura 12), aunque no fue posible incluir la función de visualización de predicción de color, es decir, opciones en el menú para que se pudieran ingresar datos fotográficos en tiempo real; se mantuvieron los campos para trabajar con datos numéricos de almacenamiento, que constan de: temperatura, día, concentración de CO<sub>2</sub> y O<sub>2</sub>, obteniendo como salida el color en coordenadas RGB y una gráfica que muestra el alcance de cada color en el intervalo de 0 a 255, propio de este espacio de color.

Figura 12 Aplicación creada en App Designer



## CAPÍTULO V

### Conclusiones y recomendaciones

#### 5.1 Conclusiones

- Los resultados indicaron un cambio de color en la naranjilla similar en todos los tratamientos, sin diferencias significativas relacionadas con las concentraciones de CO<sub>2</sub> y O<sub>2</sub>. No obstante, el tiempo de almacenamiento fue el factor más influyente en la evolución del color, demostrando que, más allá de las variaciones en los gases, el tiempo es el principal determinante en la alteración visual del fruto.
- Aunque se aplicaron metodologías para desarrollar un modelo predictivo preciso, los indicadores mostraron que los modelos no lograron predecir el cambio de color en la naranjilla de manera completamente realista, por lo que la hipótesis nula es aceptada. Esto podría deberse a factores no considerados en el experimento. No obstante, se seleccionó el modelo con los mejores parámetros de ajuste y precisión, considerándolo el más representativo dentro de las limitaciones.
- Se desarrolló una aplicación basada en el mejor modelo obtenido para predecir el cambio de color en la naranjilla. Sin embargo, no se logró implementar una supervisión visual en tiempo real debido a la falta de un algoritmo eficiente para procesar imágenes. Como alternativa, la aplicación permite ingresar los datos de almacenamiento de forma numérica y generar una predicción del color. Aunque no se logró la supervisión gráfica, el sistema ofrece una herramienta útil para predecir el estado visual del fruto mediante datos cuantitativos.

#### 5.2 Recomendaciones

- Incluir más variables experimentales: Para aumentar la exactitud en la predicción del cambio de color en la naranjilla, se recomienda considerar

factores adicionales que pueden influir en el proceso de descomposición, como la composición de etileno, la humedad relativa y la exposición a la luz. Estos factores podrían proporcionar una visión más completa de las condiciones de almacenamiento óptimas.

- Optimización de algoritmos de procesamiento de imágenes: Dado que no se logró implementar un sistema de supervisión visual en tiempo real, se sugiere continuar investigando y desarrollando algoritmos más eficientes para el procesamiento de imágenes. Esto podría permitir una evaluación automática y visual del cambio de color, mejorando la aplicabilidad del sistema en tiempo real y facilitando su uso práctico.

- Validación en otros productos agroindustriales: Se recomienda validar el modelo y la aplicación desarrollada en otros productos perecederos. Esto permitiría evaluar la aplicabilidad y adaptabilidad del sistema en diferentes contextos agroindustriales y ajustarlo a diversas dinámicas de degradación que contribuyen al cambio de color.

## Referencias

- Andrade, Fuertes, & Figueroa. (2021). Evaluación fisicoquímica y antioxidante de naranjilla (*Solanum quitoense* Lam.) durante la maduración. *Revista Iberoamericana de Tecnología Postcosecha*.
- Andrade, M., Moreno, C., Bravo, J., Guijarro, M., Monar, V., Cevallos, C., & Concellón, A. (2019). Efecto del estado de madurez sobre la calidad de tres variedades de naranjilla (*Solanum quitoense* Lam). *Revista Iberoamericana de Tecnología Postcosecha*, 17(2). [https://doi.org/https://www.researchgate.net/publication/330599333\\_Efecto\\_del\\_estado\\_de\\_Madurez\\_sobre\\_la\\_calidad\\_de\\_tres\\_variedades\\_de\\_naranjilla\\_Solanum\\_quitoense\\_Lam](https://doi.org/https://www.researchgate.net/publication/330599333_Efecto_del_estado_de_Madurez_sobre_la_calidad_de_tres_variedades_de_naranjilla_Solanum_quitoense_Lam)
- Anish, Y. (18 de Febrero de 2022). *Matlab Helper*. Matlab Helper: <https://matlabhelper.com/blog/matlab/regression-learner-app/>
- Bhandari, A. (2024). Confusion Matrix in Machine Learning. *Analytics Vidhya*.
- Blog, M. (2019). Análisis de Regresión: ¿Cómo Puedo Interpretar el R-cuadrado y Evaluar la Bondad de Ajuste? *Minitab*.
- Bonilla, D. (2010). *Evaluación de dos índices de cosecha y tipos de empaque del fruto de naranjilla (Solanum quitoense Lam.) HÍBRIDO INIAP Palora, bajo dos condiciones de almacenamiento en el cantón Cevallosde la provincia de Tungurahua*. Cevallos.
- Carmona, F. (21 de febrero de 2023). *Bootstrap*. Bootstrap: <https://www.ub.edu/cursosR/files/bootstrap.html>
- Castañeda, A., Polo, B., & Vega, F. (2022). Redes neuronales artificiales: una medición de aprendizajes de pronóstico como demanda potencial. *SciELO*, Vol. 27(118).
- Castellon, N. (Junio de 2023). *Linkedin*. Linkedin: [https://es.linkedin.com/posts/naren-castellon-1541b8101\\_las-m%C3%A9tricas-mae-mse-rmse-r2-y-mape-son-activity-7071597115369500672-c7SE?trk=public\\_profile\\_like\\_view](https://es.linkedin.com/posts/naren-castellon-1541b8101_las-m%C3%A9tricas-mae-mse-rmse-r2-y-mape-son-activity-7071597115369500672-c7SE?trk=public_profile_like_view)
- Castro, W., & Herrera, L. (2019). *La naranjilla (Solanum quitoense Lam.) en Ecuador*. Feijóo.
- Chiesa, A., Trincherro, G., Fraschina, A., & Mónaco, E. (2005). Selección de películas poliméricas. *Revista de Investigaciones Agropecuarias*.
- Corporation, C. (2012). *Corel Corporation*. Corel Corporation : [https://product.corel.com/help/CorelDRAW/540240626/Main/ES/Doc/wwhelp/wwhelp.pl/common/html/wwhelp.htm?context=CorelDRAW\\_Help&file=CorelDRAW-Understanding-color-models.html](https://product.corel.com/help/CorelDRAW/540240626/Main/ES/Doc/wwhelp/wwhelp.pl/common/html/wwhelp.htm?context=CorelDRAW_Help&file=CorelDRAW-Understanding-color-models.html)

- Cuevas, E., Avalos, O., Díaz, P., Valdivia, A., & Pérez, M. (2021). *Introducción Al Machine Learning con MATLAB*. Alfaomega – Marcombo.
- Fang, Y., & Minato, W. (2021). A Review on the Modified Atmosphere Preservation of Fruits. *Agriculture*.
- FAO. (s.f.). Estandarización y control de calidad. *Food and Agriculture Organization*.
- Frost, J. (2019). Statistics by Jym. *Statistics by Jym*.
- García. (2008). *Visión artificial y procesamiento digital de imágenes usando Matlab*. Ibarra.
- García, Y., García, A., Hernández, A., & Pérez, J. (2011). Estudio de la variación del Índice de Color durante. *Revista Ciencias Técnicas Agropecuarias*.
- Gómez, F., Trejo, L., García, C., & Cadeña, J. (2014). Lulo (*Solanum quitoense* [Lamarck.]) como cultivo novedoso en el paisaje agroecosistémico mexicano. *SciELO*.  
[https://doi.org/https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S2007-09342014001301741](https://doi.org/https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-09342014001301741)
- Grant, A. (1 de Enero de 2019). *Gardening*. Gardening:  
<https://www.diversegarden.com/edible/fruits/naranjillas/different-varieties-of-naranjilla.htm>
- Hernández, Y. (2019). Validación de modelos en el análisis de datos estadísticos. *BESH*.
- Indrajeet, K., Jyoti, R., Noor, M., & Shahnawaz, H. (2021). Sistema de visión artificial en la industria alimentaria. *Hindawi*.
- INEN. (2009). *INEN*. INEN: <https://archive.org/details/ec.nte.2303.2009/page/n1/mode/2up>
- ITAGRI. (2017). Atmósferas Controladas y Modificadas en Postcosecha. *ITAGRI*(13).
- Knauf Industries* . (16 de Marzo de 2020). Knauf Industries : <https://knauf-industries.es/metodos-de-conservacion-para-productos-frescos-las-cajas-de-eps/#metodos-de-conservacion-de-frutas-y-hortalizas-durante-la-distribucion>
- Madrigal, E. (2022). Métricas de precisión más comunes para modelos de regresión. *growup*.
- MAGAP*. (Mayo de 2022). *MAGAP*: <https://fliphtml5.com/ijja/bntq>
- Martin, E. (2024). ML: entrenar, validar y probar. *Baeldung*.
- Mathias, R., & Kong Ah, H. (2014). El color en los alimentos un criterio de calidad medible. *AGROSUR*. <https://doi.org/10.4206>

- Mathworks*. (s.f.). Designer, MATLAB App: <https://la.mathworks.com/videos/app-designer-overview-1510748719083.html>
- Matich, D. (Marzo de 2001). [https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monografias/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monografias/matich-redesneuronales.pdf)
- MATLAB. (s.f.). *Mathworks.com*. Mathworks.com: <https://la.mathworks.com/products/image-acquisition.html#:~:text=Image%20Acquisition%20Toolbox%20proporciona%20funciones,la%20adquisici%C3%B3n%20en%20futuras%20sesiones>.
- MATLAB. (s.f.). *MathWorks.com*. MathWorks.com: <https://la.mathworks.com/discovery/roc-curve.html>
- Medina, Espinosa, & Balaguera. (2023). Fisiología y bioquímica del fruto de naranjilla (*Solanum quitoense* Lam) durante. *Agronomía Colombiana* .
- Moreno Guerrero, C., Andrade Cuvi, M. J., Concellón, A., & Díaz Navarrete, G. (2013). Estudio de la capacidad antioxidante durante el almacenamiento refrigerado de la naranjilla (*Solanum quitoense*) tratada con radiación UV-C. *Iberoamericana de Tecnología*, 126.
- Murcia, U. d. (s.f.). *ADYV*. adyv: <https://www.um.es/web/adyv/diversidad/salud-comunitaria/nutricion/Conservacion-alimentos>
- Options, C. R. (s.f.). MATLAB. MATLAB: <https://la.mathworks.com/help/stats/choose-regression-model-options.html#bvmnwhd-1>
- Orlando, I., Ruiz, U., Loeza, J., & Hernandez, Z. (2023). Procedimiento para obtener modelos lineales de cinética de color en frutas. *Scielo*. <https://doi.org/1405-5546>
- Ospina Meneses, S. M. (2008). La atmósfera modificada: una alternativa para la conservación de los alimentos. *Revista Lasallista de Investigación*, 114.
- Palma, P. (2022). Analisis critico del coeficiente de determinación(R<sup>2</sup>), como indicador de la calidad de modelos lineales y no lineales. *ESPOL-FCNM JOURNAL*.
- Pérez, P., & Valente., M. (2018). *FAMAF*. FAMAF: <https://www.famaf.unc.edu.ar/~pperez1/manuales/cim/cap2.html>
- Phillips, K. (2024). A Beginner's Guide to Color Measurement. *HunterLab*.
- Phillips, K. (26 de Enero de 2024). *HunterLab*. <https://doi.org/https://www.hunterlab.com/blog/a-guide-to-color-measurement/>
- Posadas, A. (2010). <https://w3.ual.es/~aposadas/TeoriaErrores.pdf>

- Productor, E. (2023). *Altos costos de producción comprometen el cultivo de mango*. Elproductor.com.
- Scientest. (2024). ¿Cómo aprovechar el rendimiento de la matriz de confusión? *Scientest*.
- Silva, E. (2008). Respiración y etileno y su relación con el manejo poscosecha. *eOrganic*.
- Villanueva, R. (2014). *Conservación de mango*. Nuevo Chimbote: UNS.
- Vivar, L. T. (2019). "Desarrollo de app en Matlab para rehabilitación de espasticidad con ayuda del robot colaborativo KUKA LBR IIWA". [https://e-archivo.uc3m.es/bitstream/handle/10016/30457/TFG\\_Laura\\_Toledano\\_Vivar.pdf?sequence=1&isAllowed=y](https://e-archivo.uc3m.es/bitstream/handle/10016/30457/TFG_Laura_Toledano_Vivar.pdf?sequence=1&isAllowed=y).
- Wilber, J., & Werness, B. (30 de Diciembre de 2020). *MLU*. MLU: <https://mlu-explain.github.io/train-test-validation/>
- Wills, R. M. (2007). Postharvest: An introduction to the physiology and handling of fruit, vegetables and ornamentals. *UNSW Press*. <https://doi.org/https://worldveg.tind.io/record/47023>
- Xiao, F., Haibin, R., & Xu, Y. (2023). Fruit Detection and Recognition Based on Deep Learning for Automatic Harvesting: An Overview and Review. *Agronomy*.



Anexos

Anexo 1. Especificaciones del empaque



<b>PRODUCTOS PARAISO DEL ECUADOR</b>					
<b>DIVISION POLIETILENO</b>					
<b>CERTIFICADO DE CALIDAD DEL PRODUCTO</b>					
<b>CLIENTE</b>	<b>ECOPACIFIC</b>	<b>FECHA</b>	<b>2 de enero de 2018</b>		
<b>CANTIDAD</b>	<b>60.000</b>	<b>CODIGO</b>	<b>4394.07</b>		
<b>FUNDAS POR BULTO</b>	<b>4.000</b>	<b>TIPO DE FUNDA</b>			
<b>FUNDAS POR PAQUETE</b>	<b>15</b>	<b>TRADICIONAL TRANSPARENTE</b>			
<b>NÚMERO DE LOTE</b>	<b>21217</b>				
<b>USO</b>	<b>EMPAQUE PRODUCTO TERMINADO REFERENCIA SAMBO PICADO</b>				
<b>MATERIAL</b>		<b>POLIETILENO DE BAJA DENSIDAD</b>			
		<b>ESPECIFICACIONES DE MEDIDAS</b>			
		<b>PARAMETRO</b>	<b>MEDIDA</b>	<b>TOLERANCIA</b>	<b>REVISADO</b>
		ANCHO	7,00 "	±5 %	/
		LARGO	10,00 "	±8 %	/
		ESPESOR	3,60 mils	±10 %	/
		FUELLE LATERAL	--	--	--
		FUELLE FONDO	--	--	--
		LENGUETA	--	--	--
<b>COLORES DE IMPRESIÓN</b>					
<b>ANVERSO</b>			<b>REVERSO</b>		
<b>CÓLOR</b>	<b>REVISADO</b>	<b>CÓLOR</b>	<b>REVISADO</b>		
1 NEGRO	/	1 BLANCO	/		
2 BLANCO	/	2 NEGRO	/		
3 NARANJA 190C	/	3 VERDE 349C	/		
4 NARANJA161C	/	4	/		
5 VERDE 349C	/	5	/		
6	/	6	/		
<b>PROPIEDADES DEL PRODUCTO</b>					
<b>ESPECIFICACION</b>		<b>REVISADO</b>			
RESISTENCIA LONGITUDINAL		/			
RESISTENCIA TRANSVERSAL		/			
CARGA DE RUPTURA		/			
BLOQUEO DE MATERIAL		/			
TRATADO SUPERFICIAL DE MATERIAL		/			
ADHERENCIA DE LA TINTA		/			
RESISTENCIA DE SELLOS		/			
<p>Los materiales usados en la fabricación de este empaque, se encuentran dentro de la lista positiva y cumplir con las regulaciones FDA "Food and drugs administration" aptos para estar en contacto con alimentos según: FDA 21CFR parte177 §1826 FDA; 21 CFR 177.1625(c) 3.2(a) FDA; 21CFR parte175 §208 y § 220, parte 176 §125,180,205, 249 y 176(c) y que son utilizados para la elaboración de empaques para alimentos de consumo humano.</p>					
<b>CONDICIONES DE ALMACENAMIENTO</b>					
<p>Los paquetes deben almacenarse en bodegas o depósitos cerrados con techo en buen estado, ventilados, evitando condiciones adversas de humedad, exposición al sol o a la lluvia y excesivo calor. Deben estar aislados de materiales aromáticos, químicos y vapores. Evitar contaminación por plagas y polvo. Un período largo de almacenamiento puede causar alteraciones en las características y especificaciones técnicas del material.</p>					
<p>El lote al que se hace referencia es el presente certificado cumple con las especificaciones de calidad establecidas, por lo que se LIBERA para su uso comercial como empaque de alimentos.</p>					

  
**INSPECCIONADO POR**  
**Control de Calidad**

**PRODUCTOS PARAISO DEL ECUADOR**


**DIVISION POLIETILENO**

**ESPECIFICACIONES TÉCNICAS**

<b>CLIENTE</b>	<b>ECOPACIFIC EMPRESA COMERCIAL DEL PACIFICO S.A</b>
<b>REFERENCIA</b>	<b>SAMBO PICADO</b>

<b>FUNDAS POR PAQUETE</b>	<b>100</b>	<b>TIPO DE EMPAQUE</b>
<b>FUNDAS POR BULTO</b>	<b>4.000</b>	<b>TRADICIONAL TRANSPARENTE</b>
<b>CODIGO</b>	<b>4394.07</b>	

<b>MATERIAL</b>	<b>POLIETILENO EXTRUIDO DE BAJA DENSIDAD</b>
-----------------	--



ESPECIFICACIONES DE MEDIDAS		
PARAMETRO	MEDIDAS	TOLERANCIA
ANCHO	178 mm ( 7,00 ")	± 5%
LARGO	254 mm ( 10,00 ")	± 5%
ESPOSOR	88,9 µ ( 3,50 mils)	± 10%

COLORES DE IMPRESIÓN	
COLORES ANVERSO	COLORES REVERSO
NEGRO	BLANCO
BLANCO	NEGRO
NARANJA 130C	VERDE 349C
NARANJA 151C	
VERDE 349C	

EMPAQUES IMPRESOS utilizamos SISTEMA DE CONTROL DE COLOR X-RITE que garantiza la uniformidad del color y la fidelidad con los colores aprobados por nuestros clientes en cada uno de los lotes de producción fabricados.

PROPIEDADES DEL PRODUCTO		
ESPECIFICACIONES	VALORES	NORMAS
RESISTENCIA AL DESGARRE MD (gf)	600	ASTM D-1922 (F)
RESISTENCIA AL DESGARRE TD (gf)	1.200	ASTM D-1923
RESISTENCIA AL IMPACTO (g)	>600	ASTM D-1709
ESFUERZO DE RUPTURA MD*TD (MPa)	24/26	ASTM D-882
DEFORMACIÓN POR RUPTURA MD*TD (%)	100/150	ASTM D-882
SELLABILIDAD (° C)	100 - 105	PPE -1011

Para valoraciones en nuestros laboratorios aplica Norma ASTM

**REGULACIONES PARA EL CONTACTO CON ALIMENTOS.**

Los materiales usados en la fabricación de esta lámina, se encuentran dentro de la lista positiva y cumplen con las regulaciones FDA "Food and drugs administration" aptos para estar en contacto con alimentos según: FDA:21CFR parte177 §1520 FDA: 21 CFR 177.1520(c) 3.2(a) FDA: 21CFR parte175 §105 y § 320; parte 176 §125,180,200, 210 y 176(c) y que son utilizados para la elaboración de empaques para alimentos de consumo humano. No se permite el uso de material reciclado para este tipo de empaques.

**CONDICIONES DE ALMACENAMIENTO Y VIDA ÚTIL**

Los paquetes deben almacenarse en bodegas o locales cerrados con techo en buen estado, ventilados, evitando condiciones adversas de humedad, exposición al sol o a la lluvia y excesivo calor. Deben estar aislados de materiales aromáticos, químicos y vapores. Evitar contaminación por plagas y polvo. Un período largo de almacenamiento puede causar alteraciones en las características y especificaciones técnicas del material. Teniendo en cuenta el manejo y las condiciones de almacenamiento, el material puede conservar sus propiedades hasta 6 meses, sin embargo recomendamos utilizar dentro de los primeros 4 meses desde su fabricación.

## Anexo 2. Codificación de la aplicación

```

classdef naranjilla1 < matlab.apps.AppBase
    % Properties that correspond to app components
    properties (Access = public)
        UIFigure          matlab.ui.Figure
        UIAxes            matlab.ui.control.UIAxes
        Menu              matlab.ui.container.Menu
        iniciaMenu       matlab.ui.container.Menu
        Panel             matlab.ui.container.Panel
        TemperaturaEditField_2Label matlab.ui.control.Label
        TemperaturaEditField_2 matlab.ui.control.NumericEditField
        diaEditFieldLabel matlab.ui.control.Label
        diaEditField     matlab.ui.control.NumericEditField
        CO2EditFieldLabel matlab.ui.control.Label
        CO2EditField    matlab.ui.control.NumericEditField
        O2EditFieldLabel matlab.ui.control.Label
        O2EditField     matlab.ui.control.NumericEditField
        UITable         matlab.ui.control.Table
        abricamaraButton matlab.ui.control.Button
        capturarButton  matlab.ui.control.Button
        Image           matlab.ui.control.Image
        DatePickerLabel matlab.ui.control.Label
        DatePicker      matlab.ui.control.DatePicker
        Image2          matlab.ui.control.Image
        Image3          matlab.ui.control.Image
    end

    % Callbacks that handle component events
    methods (Access = private)
        % Callback function: CO2EditField, O2EditField,
        % TemperaturaEditField_2, diaEditField, iniciaMenu
        function calcular(app, event)
            T = app.TemperaturaEditField_2.Value
            D = app.diaEditField.Value
        end
    end
end

```

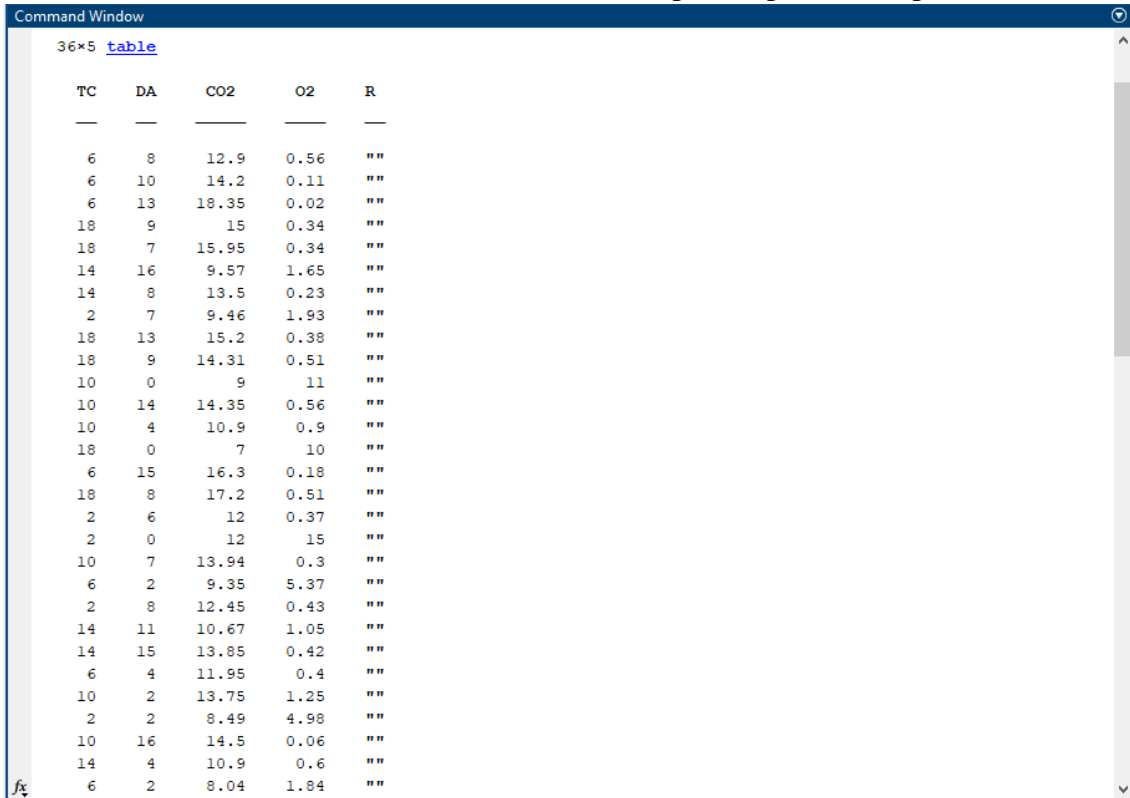
## Anexo 3. Codificación del modelo seleccionado como el mejor del sistema

```

%=====
%function [Y,Xf,Af] = m1N5(X)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Auto-generated by MATLAB, 30-Jul-2024 23:19:21.
%
% [Y] = myNeuralNetworkFunction(X,~,~) takes these arguments:
%
% X = 1xTS cell, 1 inputs over TS timesteps
% Each X{1,ts} = Qx4 matrix, input #1 at timestep ts.
%
% and returns:
%
% Y = 1xTS cell of 1 outputs over TS timesteps.
% Each Y{1,ts} = Qx3 matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.
%
%#ok<*RPMT0>
% ===== NEURAL NETWORK CONSTANTS =====
% Input 1
x1_step1.xoffset = [2;0;6;0.02];
x1_step1.gain = [0.125;0.117647058823529;0.148698884758364;0.125156445556946];
x1_step1.ymin = -1;
% Layer 1
b1 = [-0.078324141309290107316;1.6795858103795548999;-0.34290061701848761899;-0.79427159473438135873;5.261886641762];
IW1_1 = [-0.11407578023739439743 -3.1448245812919366493 0.89817258256693899288 2.5326806989483725552;-0.86456159950];
% Layer 2
b2 = [0.0082660909322712222691;-0.16325819870606714246;-0.44989782499592456677];
LW2_1 = [-0.31653615962470338374 0.17729743755678697981 -0.0070000452749061498059 -0.53636749215381285261 -0.213146];
% Output 1

```

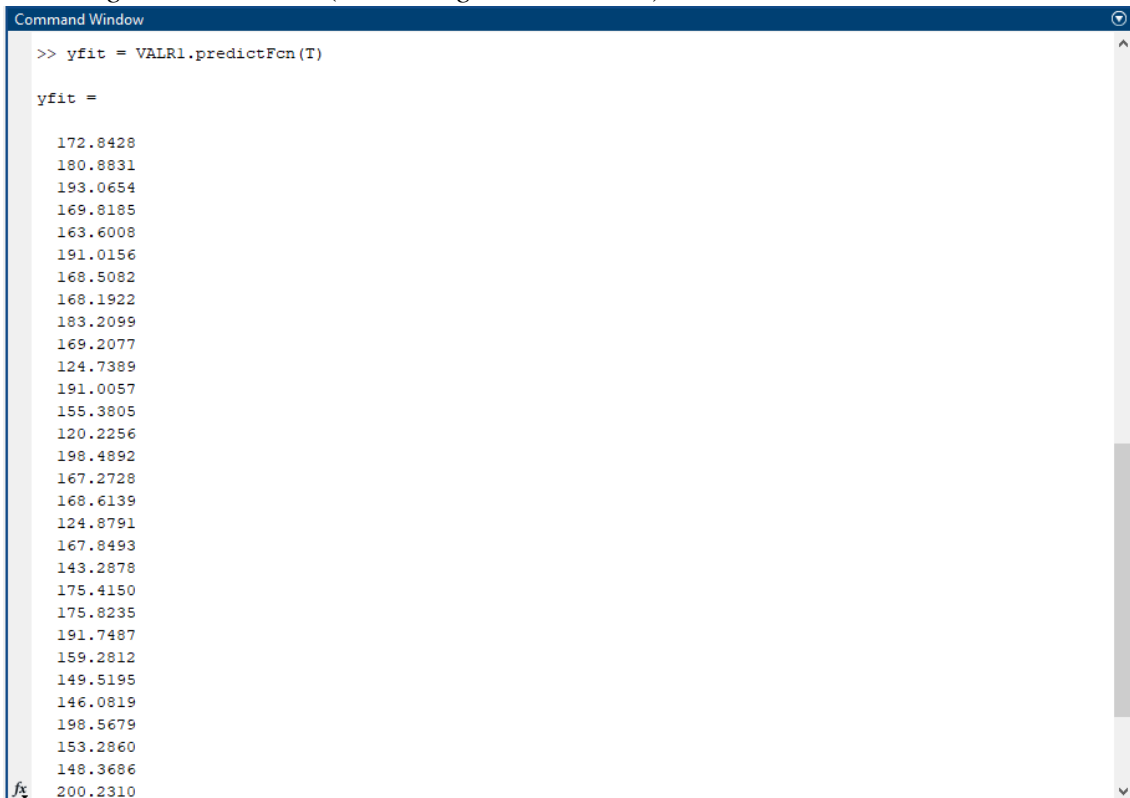
#### Anexo 4. Introducción de datos en MATLAB para el proceso de predicción



36x5 table

TC	DA	CO2	O2	R
6	8	12.9	0.56	""
6	10	14.2	0.11	""
6	13	18.35	0.02	""
18	9	15	0.34	""
18	7	15.95	0.34	""
14	16	9.57	1.65	""
14	8	13.5	0.23	""
2	7	9.46	1.93	""
18	13	15.2	0.38	""
18	9	14.31	0.51	""
10	0	9	11	""
10	14	14.35	0.56	""
10	4	10.9	0.9	""
18	0	7	10	""
6	15	16.3	0.18	""
18	8	17.2	0.51	""
2	6	12	0.37	""
2	0	12	15	""
10	7	13.94	0.3	""
6	2	9.35	5.37	""
2	8	12.45	0.43	""
14	11	10.67	1.05	""
14	15	13.85	0.42	""
6	4	11.95	0.4	""
10	2	13.75	1.25	""
2	2	8.49	4.98	""
10	16	14.5	0.06	""
14	4	10.9	0.6	""
6	2	8.04	1.84	""

#### Anexo 5. Predicción y validación de datos con uno de los modelos entrenados en *regression learner* (Linear regression-linear)



```
>> yfit = VALR1.predictFcn(T)

yfit =

172.8428
180.8831
193.0654
169.8185
163.6008
191.0156
168.5082
168.1922
183.2099
169.2077
124.7389
191.0057
155.3805
120.2256
198.4892
167.2728
168.6139
124.8791
167.8493
143.2878
175.4150
175.8235
191.7487
159.2812
149.5195
146.0819
198.5679
153.2860
148.3686
200.2310
```