

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



MODELADO DE PÉRDIDA DE FIRMEZA DE KIWI (*Actinidia deliciosa*)
DURANTE EL ALMACENADO EN ATMÓSFERAS MODIFICADAS

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO EN
INGENIERO EN AGROINDUSTRIA

AUTOR:

DAVID SEBASTIÁN ANDRADE CUMBAJÍN

DIRECTOR:

ING. JUAN CARLOS DE LA VEGA QUINTERO

Ibarra – Ecuador
2025



UNIVERSIDAD TÉCNICA DEL NORTE
BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN
A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA DE IDENTIDAD:	1004682652		
APELLIDOS Y NOMBRES:	Andrade Cumbajín David Sebastián		
DIRECCIÓN:	Hacienda Tababuela, km 11 vía Tulcán		
EMAIL:	dsandradec@utn.edu.ec		
TELÉFONO FIJO:		TELÉFONO MÓVIL:	0989348533

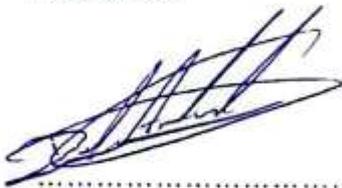
DATOS DE LA OBRA	
TÍTULO:	MODELADO DE PÉRDIDA DE FIRMEZA DE KIWI (<i>Actinidia deliciosa</i>) DURANTE EL ALMACENADO EN ATMÓSFERAS MODIFICADAS
AUTOR (ES):	Andrade Cumbajín David Sebastián
FECHA: DD/MM/AAAA	30/06/2025
SOLO PARA TRABAJOS DE GRADO	
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO
TÍTULO POR EL QUE OPTA:	Ingeniero en Agroindustrias
ASESOR /DIRECTOR:	Ing. Juan Carlos de la Vega Quintero

2. CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrollo, sin los derechos de autores terceros, por lo tanto, la obra es original y 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 30 días del mes de junio del 2025

EL AUTOR



Andrade Cumbajín David Sebastián

C.I.: 1004682652

ACEPTACIÓN

CERTIFICACIÓN DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

Ibarra, 30 de junio de 2025

Ing. Juan Carlos de la Vega Quintero MSc.

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 pertinentes.



Ing. Juan Carlos de la Vega Quintero MSc.

C.C: 1002958856

PRESENTACIÓN

Yo, Andrade Cumbajín David Sebastián como autor de la Tesis Titulada “**Modelado de pérdida de firmeza de kiwi (*Actinidia deliciosa*) durante el almacenado en atmósferas modificadas**”, me hago responsable de los resultados, discusión, conclusiones y demás parte de la investigación; y pongo este documento como fuente de apoyo para consultas dirigidas a todos los estudiantes.

AGRADECIMIENTO

Manifiesto mi más sincero agradecimiento a Dios, por haberme bendecido constantemente con salud, inteligencia y motivación durante toda esta etapa.

A la Universidad Técnica del Norte, por haberme acogido y permitido crecer académicamente en sus instalaciones y darme la oportunidad de formar mi carrera.

A mi tutor de tesis, el Ing Juan Carlos De La Vega Quintero, por su invaluable apoyo profesional, cuya guía y paciencia fueron fundamentales para la correcta ejecución de esta investigación. Al Ing Juan Guamán, por su valioso aporte como mi asesor en el desarrollo de este proyecto.

A mi familia, especialmente a mis abuelitos y padres, que supieron ofrecerme apoyo incondicional. A mi tío, por haberme compartido su hogar durante todo el transcurso de mi formación profesional.

A mi amigo Tito Arévalo que me ayudó en momentos difíciles.

A mi amada, Jhoanna, por estar a mi lado y apoyarme en este largo camino, gracias por tu amor sincero y tu ayuda durante toda esta etapa.

A todos que de alguna manera supieron contribuir y fueron parte de esta meta, gracias.

DEDICATORIA

A Dios, por iluminar mi camino, darme la vida y la fuerza para superarme cada día. Por abrir mi entendimiento y permitirme alcanzar la meta de ser un profesional. A mis padres y abuelitos que han sido mi eterna ayuda desde siempre.

ÍNDICE DE CONTENIDO

AGRADECIMIENTO	v
DEDICATORIA.....	vi
ÍNDICE DE FIGURAS.....	x
ÍNDICE DE TABLAS	xi
ÍNDICE DE ANEXOS	12
CAPÍTULO I.....	15
INTRODUCCIÓN.....	15
1.1 Antecedentes	15
1.2 Definición del problema	16
1.3 Justificación	17
1.4 Objetivos.....	18
1.4.1 Objetivo general	18
1.4.2 Objetivos específicos.....	18
1.5 Hipótesis	18
1.5.1 Hipótesis alternativa	18
1.5.2 Hipótesis Nula	18
CAPÍTULO II.....	19
2 MARCO TEÓRICO.....	19
2.1 El origen del kiwi.....	19
2.2 Variedades y propiedades	19

2.3	El kiwi en Ecuador.....	20
2.4	Métodos de conservación alimentaria.....	21
2.4.1	Atmosferas controladas	21
2.4.2	Atmosferas modificadas	22
2.5	Determinación de errores en medidas directas	22
2.6	Medición de firmeza en frutas	22
2.7	MATLAB.....	23
2.7.1	Técnicas de inteligencia artificial	24
2.8	App designer	27
2.9	Métodos estadísticos de validación.....	28
CAPÍTULO III		30
3	METODOLOGÍA	30
3.1	Tipo de investigación.....	30
3.2	Ubicación del lugar	30
3.3	Materiales, equipos y software	31
3.4	Métodos, técnicas e instrumentos de investigación	31
3.4.1	Estandarización de la materia prima.....	31
3.4.2	Sólidos solubles	33
3.4.3	Acidez titulable.....	33
3.4.4	Almacenaje con atmósferas modificadas	34
3.4.5	Determinación de firmeza	34
3.4.6	Análisis de datos.....	35

3.5	Regression learner.....	35
3.6	Neural Net Fitting	36
3.7	Indicadores de representación.....	37
3.8	Validación del modelo de representación	38
3.9	App Designer	40
CAPÍTULO IV		41
4	RESULTADOS Y DISCUSIÓN.....	41
4.1	Efecto de la concentración de gases, temperatura y tiempo en el cambio de firmeza en los frutos.....	41
4.2	Modelo representativo del cambio de firmeza mediante inteligencia artificial. 42	
4.3	Generación del sistema de supervisión, control y adquisición de datos mediante IA.....	47
CAPÍTULO V.....		52
1.	CONCLUSIONES Y RECOMENDACIONES.....	52
1.1	Conclusiones	52
1.2	Recomendaciones	52
REFERENCIAS		54
ANEXOS		57

ÍNDICE DE FIGURAS

Figura 1. Agrupación en cluters y detección de patrones en los datos.	25
Figura 2. Arquitectura típica de una red neuronal	26
Figura 3. Ejemplo de red con múltiples capas convolucionales.....	27
Figura 4. Ejemplo de una red neuronal totalmente conectada.....	37
Figura 5. Gráfico de bigotes de variables del estudio de firmeza del kiwi.....	42

ÍNDICE DE TABLAS

Tabla 1. Principales variedades y propiedades de la especie Actinidia Deliciosa.	20
Tabla 2. Categorías de algoritmos de aprendizaje supervisado.....	24
Tabla 3. Métricas para medir la eficacia de los modelos.....	28
Tabla 4. Ubicación de la experimentación.	30
Tabla 5. Materiales, equipos y software que su utilizarán en la experimentación.	31
Tabla 6. Medidas necesarias para porcentajes de dispersión.....	33
Tabla 7. Condiciones de almacenamiento por lotes.	34
Tabla 8 Redes convolucionales para el entrenamiento del sistema de supervisión.....	39
Tabla 9. Estandarización de la materia prima.....	41
Tabla 10 Entrenamiento de modelos en Regression Learner	43
Tabla 11 Validación de modelos en Regression Learner	44
Tabla 12. Entrenamiento con Neural Net Fitting.	45
Tabla 13. Validación en Neural Net Fitting	46
Tabla 14. Eficiencia del modelo de clasificación en base a diferentes métricas.	47
Tabla 15. Variables evaluadas en periodo de prueba.	50

ÍNDICE DE ANEXOS

Anexo 1. Características de empaque.....	57
Anexo 2. Gráfico de regresión del mejor modelo representativo de pérdida de firmeza.	59
Anexo 3. Informe de entrenamiento de la red neuronal utilizada para el sistema de supervisión.....	59
Anexo 4. Prueba del sistema de supervisión y adquisición de datos.....	60
Anexo 5. Matriz de cofusión de la validación del sistema de supervisión y adquisición de datos.....	60
Anexo 6. Revisión del funcionamiento del modelo propuesto para describir la pérdida de firmeza.	61

RESUMEN

El kiwi (*Actinidia deliciosa*) es una fruta altamente perecedera, cuya pérdida de firmeza está influenciada por variables como la temperatura y la concentración de gases durante su almacenamiento. Este trabajo está orientado a evaluar la pérdida de firmeza del kiwi utilizando atmósferas modificadas y desarrollar un modelo predictivo mediante inteligencia artificial. La metodología incluyó la estandarización de materia prima, almacenamiento en condiciones con diferentes combinaciones de temperatura (de 2°C a 18°C), niveles de oxígeno y dióxido de carbono, y medición de firmeza mediante un texturómetro. Los datos obtenidos fueron procesados con herramientas de MATLAB, particularmente con Regression Learner y Neural Net Fitting, utilizando redes neuronales y validación estadística para generar el modelo más representativo. Los resultados mostraron que el modelo con el algoritmo Best Scaled Conjugate Gradient (SCG), con una configuración de 5 neuronas en su capa oculta fue el más robusto, alcanzando un coeficiente de determinación (R^2) de 0.79 en validación. Al mismo tiempo, la red neuronal Resnet50 presentó una precisión global del 70,52%, que en comparación con Googlenet y Resnet18 fue más elevada, por lo cual fue seleccionada para el desarrollo del sistema de supervisión y adquisición de datos. En conclusión, las atmósferas modificadas junto con el modelado por redes neuronales demostraron ser una herramienta eficiente para predecir el comportamiento de la firmeza del kiwi durante el almacenamiento, optimizando el tiempo y costos en estudios experimentales futuros.

Palabras clave: Inteligencia artificial, modelo matemático, atmosferas modificadas, redes neuronales.

ABSTRACT

Kiwi fruit (*Actinidia deliciosa*) is highly perishable, and its firmness loss is influenced by variables such as temperature and gas concentrations during storage. This study aimed to evaluate firmness degradation in kiwi using modified atmospheres and to develop a predictive model through artificial intelligence. The methodology involved standardizing the raw material, storing the fruit under different combinations of temperature (ranging from 2°C to 18°C), oxygen and carbon dioxide levels, and measuring firmness with a texture analyzer. The collected data were processed using MATLAB tools, particularly Regression Learner and Neural Net Fitting, applying neural networks and statistical validation to generate the most representative model. Results showed that the Best Scaled Conjugate Gradient (SCG) algorithm with a configuration of five hidden layer neurons produced the most robust model, achieving a determination coefficient (R^2) of 0.79 during validation. Additionally, the ResNet50 neural network achieved an overall accuracy of 70.52%, outperforming GoogLeNet and ResNet18, and was thus selected for the development of the data acquisition and monitoring system. In conclusion, modified atmospheres combined with neural network modeling proved to be an effective tool for predicting kiwi firmness behavior during storage, optimizing time and costs in future experimental studies.

Keywords: Artificial intelligence, mathematical model, modified atmospheres, neural networks.

CAPÍTULO I

INTRODUCCIÓN

1.1 Antecedentes

Guarda (2003), en su trabajo de optimización de la atmósfera modificada en kiwi variedad Hayward experimentó con distintos niveles de oxígeno y dióxido de carbono en las condiciones atmosféricas, al tiempo que evaluaba la calidad a largo plazo del kiwi durante su almacenamiento. Los resultados indicaron que la atmósfera óptima para preservar la calidad del kiwi durante seis meses de almacenamiento consistía en un 2% de oxígeno y un 5% de dióxido de carbono.

Según el estudio realizado por Ramírez (2003), donde se evaluó los cambios físicos del kiwi *Actinidia deliciosa* almacenado con y sin envase en un ambiente con refrigeración y a temperatura ambiente; se pudo determinar que las muestras con envase y refrigeración fueron las más adecuadas, dando como resultado una reducción significativa de pérdida de agua de 0.8259 g/día a 0.2357 g/día en comparación con las muestras sin envase y a temperatura a nivel ambiental, considerando la pérdida de peso como causa principal en la alteración de la firmeza y textura de las muestras.

Espinosa (2016), describe que un modelo matemático se puede usar para predecir cambios fisiológicos de la fruta durante el almacenamiento, dependiendo de componentes como la temperatura, contenido gaseoso y el tipo de empaque. El modelo se validó empacando frutos de feijoa en diferentes tipos de atmósferas modificadas y midiendo los cambios de peso, firmeza y color a lo largo del tiempo. El artículo concluye que el uso de los empaques con atmósferas modificadas puede ayudar a reducir el deterioro de los productos frescos durante el almacenamiento.

Chorlango (2023), desarrolló un modelo computacional para representar la fermentación alcohólica de la savia extraída del agave azul (*Agave americana*), donde se analiza la implementación de modelos matemáticos y software de simulación como MATLAB y Simulink para predecir la cantidad de producto generado durante el proceso de fermentación. En la investigación se pudo verificar que la aplicación de software de simulación puede ser una herramienta clave para la optimización y automatización de bioprocesos y además los resultados pueden ser validados mediante datos experimentales de campo.

1.2 Definición del problema

El consumo global de kiwi *Actinidia deliciosa* ha experimentado un incremento atribuido a su extraordinario sabor y a sus ampliamente reconocidas propiedades nutricionales. Este comportamiento se manifiesta en el mercado, siendo las preferencias del consumidor por las propiedades organolépticas un factor determinante para la conservación de estas cualidades (Martínez, 2011). La temperatura y la composición atmosférica de almacenamiento son componentes clave que influyen directamente en el proceso de ablandamiento de la fruta (Guarda, 2003). De aquí la necesidad de aplicar nuevas tecnologías como atmósferas modificadas o controladas.

La pérdida de firmeza puede disminuir con la aplicación de atmósferas modificadas, puesto que este sistema se encarga de modificar los niveles de gases, de manera especial oxígeno y dióxido de carbono en el entorno de las cámaras de almacenamiento (Guarda, 2003). Sin embargo, la concentración de los gases puede favorecer como perjudicar la textura o firmeza de la fruta.

Hay que considerar muchos aspectos que intervienen en el sistema de atmósferas modificadas, siendo posible relacionarlos mediante un modelo matemático, mismo que permite simular cualquier cambio existente dentro del sistema. Aspecto mediante el cual

es posible predecir el comportamiento del producto envasado durante un periodo de almacenaje dejando de lado la dependencia de análisis experimentales de laboratorios que además se traducen en inversiones económicas y de tiempo. El problema es que este modelamiento presenta escasa información, pues existen pocas referencias cuando se intenta abordar este tema.

1.3 Justificación

En las frutas frescas es necesario tener un gran control de la manipulación y distribución debido a su carácter perecedero, con la finalidad de reducir pérdidas postcosecha. Seleccionar de manera adecuada las condiciones de almacenamiento y distribución ayudan a la reducción de la tasa de deterioro del producto. Generalmente para verificar el comportamiento un producto frente a diferentes factores es necesario realizar una experimentación a nivel de laboratorio.

Realizar una experimentación trae consigo una inversión económica y demanda de tiempo, que se puede evitar con uso de herramientas que podrían ayudar a predecir los cambios en las propiedades del producto almacenado, permitiendo conocer su comportamiento si se requiere realizar una variación en los parámetros que influyen directamente con su deterioro (Espinosa, 2016).

Al no existir suficiente información acerca de modelos representativos centrados en comportamientos biológicos como es la pérdida de firmeza en frutas durante su almacenamiento, éste estudio será una base para futuras investigaciones permitiendo guiar o seleccionar diferentes factores representativos que afectan directamente el cambio de textura del kiwi haciendo que el modelo sea cada vez más preciso.

1.4 Objetivos

1.4.1 Objetivo general

Modelar la degradación de firmeza del kiwi *Actinidia deliciosa* durante su almacenamiento en atmósferas modificadas.

1.4.2 Objetivos específicos

- Evaluar la firmeza del kiwi considerando la concentración de gases, temperatura y tiempo de almacenamiento para la obtención de datos experimentales.
- Generar un modelo representativo del cambio de firmeza mediante inteligencia artificial.
- Crear un sistema de supervisión, control y adquisición de datos aplicando el modelo de IA.

1.5 Hipótesis

1.5.1 Hipótesis alternativa

Ha: El cambio de firmeza del kiwi se puede representar en un modelo matemático en función de las condiciones de almacenamiento como la concentración de gases, temperatura y tiempo.

1.5.2 Hipótesis Nula

Ho: El cambio de firmeza del kiwi no se puede representar en un modelo matemático en función de las condiciones de almacenamiento como la concentración de gases, temperatura y tiempo.

CAPÍTULO II

2 MARCO TEÓRICO

2.1 El origen del kiwi

Originario de China, comúnmente denominado kiwi (*Actinidia deliciosa*), crece de manera silvestre específicamente al suroeste de este país, sin embargo, alrededor del año 1928 a partir de un cruce se obtuvo un nuevo ejemplar denominado “Hayward”, que tiene características como: forma ovalada, sabor predominante, gran capacidad de conservación. A partir de este momento varios horticultores decidieron introducir esta fruta en sus países (García Rubio y otros, 2015).

En 1934 Jim Mac Loughlin obtuvo el primer cultivo comercial en Nueva Zelanda, donde su comercialización tuvo muy buena acogida en el mercado nacional. También logró buenos resultados en cuanto al comercio internacional en el año 1952 al exportar a mercados de Europa y Estados Unidos. En 1959 la fruta se conservó con el nombre kiwi a causa de las exportaciones y su relación con el pájaro icónico de Nueva Zelanda (García Rubio y otros, 2015).

2.2 Variedades y propiedades

Según García Rubio y otros (2015), las variedades de esta fruta se agrupan de acuerdo a su especie entre las cuales destacan el kiwi verde (*Actinidia deliciosa*), kiwi amarillo (*actinidia chinensis*) y el baby kiwi (*A.arguta* y *A. kolomikta*).

- **Kiwi verde (*Actinidia deliciosa*)**

Se considera la especie con mayor extensión en términos de cultivo a nivel global según García Rubio y otros (2015), se caracteriza por su interior con tonalidad verde intenso y

un distintivo gusto acidificado. Al momento de consumo, presenta un contenido de azúcar que oscila entre 12 y 14° Brix, siendo además una fuente rica en minerales y vitaminas, destacando especialmente su contenido de vitamina C. Se detallan las variedades más comunes de esta especie con sus propiedades en la tabla 1.

Tabla 1. Principales variedades y propiedades de la especie Actinidia Deliciosa.

Variedad	Propiedades
Hayward	<ul style="list-style-type: none"> • Fruto de 100 g aprox • Forma elipsoidal • Piel color marrón • Vellosoidad fina • Pulpa color verde brillante
Hayward, CLON 8	<ul style="list-style-type: none"> ○ Fruto de 120 g aprox ○ Menor producción ○ Más resistente a las heladas
Top Star	<ul style="list-style-type: none"> • Muy productiva • Sin vellosoidad • Vegetación compacta
Summer kiwi	<ul style="list-style-type: none"> ○ Fruto de 85 g aprox ○ Menor acidez y mayor dulzor
Bruno	<ul style="list-style-type: none"> • Fruto de 60-70 g aprox • Piel color marrón • Gran contenido de vitamina C

Fuente: García Rubio y otros, (2015).

2.3 El kiwi en Ecuador

Desde finales de los años noventa, Ecuador ha experimentado un notorio auge en la producción de kiwi, impulsando el desarrollo de esta fruta exótica por sus atributos medicinales y nutritivos. La preferencia por suelos francos arenosos, sin cloruros, con un pH entre 6 y 7, ha sido clave para el cultivo exitoso. Gracias a la biodiversidad y fertilidad del país, la cosecha y producción del kiwi se han establecido favorablemente en diversos sectores de la industria y comercio nacional (GAD Parroquial Rural De Huachi Grande, 2017).

En términos de exportación, Ecuador ha enviado kiwis a mercados internacionales durante la última década, con destinos como Holanda, Canadá y Bélgica, con un promedio anual de alrededor de 12 toneladas. Aunque se han presentado fluctuaciones, las exportaciones reflejan la posición favorable de Ecuador en la producción y comercio de kiwis a nivel global (GAD Parroquial Rural De Huachi Grande, 2017).

2.4 Métodos de conservación alimentaria

El cuidado de los alimentos para su conservación ha sido una práctica fundamental para asegurar su comestibilidad a lo largo del tiempo. Aunque los métodos contemporáneos difieren significativamente de los utilizados en el pasado, los conocimientos transmitidos por nuestros ancestros han sentado los cimientos de nuestra comprensión actual en este ámbito. Existen varios métodos de conservación, sin embargo, la atmosfera modificada y atmosfera controlada son excelentes técnicas que generan muy buenos resultados (Ospina Meneses & Cartagena, 2008).

2.4.1 Atmosferas controladas

Según De la Vega y otros (2017), las atmósferas controladas representan entornos donde se ajustan los niveles de oxígeno, dióxido de carbono y otros elementos con el propósito de preservar productos, incluyendo frutas y alimentos. La alteración de la atmósfera tiene el potencial de retrasar el proceso de maduración, prevenir daños por frío y prolongar la duración de los productos.

Investigaciones han corroborado que la tecnología de atmósferas controladas no solo mejora la conservación de alimentos, sino que también preserva las propiedades nutraceuticas de las frutas y reduce los costos energéticos, convirtiéndola en una herramienta prometedora con diversas aplicaciones en la industria (De la Vega y otros, 2017).

2.4.2 Atmosferas modificadas

La estrategia de conservación mediante atmósfera modificada se basa en el empaquetado de productos alimenticios con elementos que poseen propiedades que limitan la dispersión de gases. En estos envases, se altera la composición del ambiente gaseoso con el objetivo de mitigar la respiración, limitar el desarrollo microbiano y reducir la degradación enzimática, con la finalidad de extender el tiempo de vida del producto (Ospina Meneses & Cartagena, 2008).

La creación de atmósferas específicas, ricas en CO₂ y con bajos niveles de O₂, según las necesidades del alimento, favorece a la reducción de la respiración, asegurando las propiedades fisicoquímicas, organolépticas y microbiológicas durante períodos más prolongados.

2.5 Determinación de errores en medidas directas

Para establecer el valor preciso de una magnitud, es esencial llevar a cabo múltiples mediciones y calcular su promedio. Si el porcentaje de dispersión es igual o inferior al 2%, se considera el valor promedio como el valor real y la sensibilidad del instrumento como el error absoluto. En el caso de que el porcentaje de dispersión supere este umbral, es necesario realizar mediciones adicionales y calcular el error de dispersión. El error absoluto se establece como el valor más alto entre el error de dispersión y la sensibilidad del instrumento

2.6 Medición de firmeza en frutas

Las prácticas habituales para evaluar la firmeza en frutas implican la utilización de diversos dispositivos y métodos. Entre las técnicas comúnmente empleadas para medir la firmeza, según Valero y Ruiz Altisent (2000), se encuentran la compresión, penetración,

punción y deformación, las cuales requieren instrumentos como durómetros, penetrómetros, texturómetros y refractómetros como se detalla a continuación:

- **Penetrómetros:** Estos instrumentos se emplean para evaluar la firmeza o consistencia de las frutas, existiendo versiones manuales y digitales que aplican presión sobre la fruta para realizar la medición.
- **Texturómetro de laboratorio:** Conectado a un computador, este equipo posibilita realizar pruebas de penetración, compresión y otras técnicas para evaluar la firmeza de las frutas.
- **Durómetros medidores de deformación:** Estos dispositivos operan desplazando una pequeña bola o cilindro sobre la fruta al ser sometidos a presión, siendo especialmente adecuados para frutas de pulpa blanda, destacando por su tamaño compacto y precio asequible.
- **FT7, Firmtech 7:** Una unidad autónoma con capacidad de transmisión de datos a PC o portátil mediante USB, optimizada para cerezas, arándanos y otros frutos rojos. Incluye un plato giratorio para cerezas y una sonda plana para medición, así como platos especiales destinados a ciruelas y arándanos.

2.7 MATLAB

MATLAB, acrónimo de (Matrix Laboratory), se presenta como un recurso de software diseñado para llevar a cabo cálculos científicos y tecnológicos avanzados mediante la representación numérica por medio de estructuras matriciales. Este programa incorpora un conjunto versátil y completo de bibliotecas y comandos de alto nivel que permiten realizar simulaciones en diversos campos científicos y tecnológicos (Reinoso García y otros, 2018).

2.7.1 Técnicas de inteligencia artificial

MATLAB proporciona un entorno interactivo altamente accesible que facilita la construcción de algoritmos y manejo dinámico de flujo de datos, y la visualización de manera cómoda y sencilla. En cuanto al análisis de datos, el programa ofrece diversas técnicas de inteligencia artificial, como Machine Learning, Deep Learning, Image Acquisition Toolbox, utilizando enfoques como el aprendizaje supervisado y no supervisado (MathWorks, 2024).

- **Aprendizaje supervisado**

El enfoque más común en Machine Learning es el aprendizaje supervisado, que emplea un conjunto de datos de entrenamiento previamente conocido para instruir a los algoritmos en la realización de predicciones. Este conjunto, compuesto por datos de entrada etiquetados con respuestas conocidas, se emplea para desarrollar conexiones entre las características y las respuestas, capacitando al algoritmo para realizar predicciones en relación con nuevos conjuntos de datos. Estos algoritmos se pueden dividir en dos categorías como lo indica la tabla 2 (MathWorks, 2024).

Tabla 2. Categorías de algoritmos de aprendizaje supervisado.

Categoría	Tipos de algoritmos
Clasificación	Regresión logística, Support vector machine (SVM), redes neuronales, clasificador de Naïve Bayes, árbol de decisión, análisis discriminante, K vecinos más cercanos (kNN), clasificación de ensembles.
Regresión	Regresión lineal, regresión no lineal, modelo lineal generalizado, árbol de decisión, redes neuronales, regresión con procesos gaussianos, regresión con support vector machines, regresión con ensembles.

Fuente: MathWorks, (2024).

- **Aprendizaje no supervisado**

El aprendizaje no supervisado se centra en revelar patrones latentes o estructuras inherentes en los datos, siendo utilizado para extraer conclusiones en función de una colección de datos que carecen de respuestas previamente catalogadas. La técnica principal en este enfoque es la agrupación en clusters como se muestra en la figura 1, comúnmente empleada en análisis exploratorio de datos para descubrir patrones o grupos ocultos. Este método encuentra aplicaciones en múltiples áreas, como la evaluación de cadenas de material genético, análisis de tendencias de consumo y detección y clasificación de elementos u objetos (MathWorks, 2024).

Figura 1. Agrupación en cluters y detección de patrones en los datos.



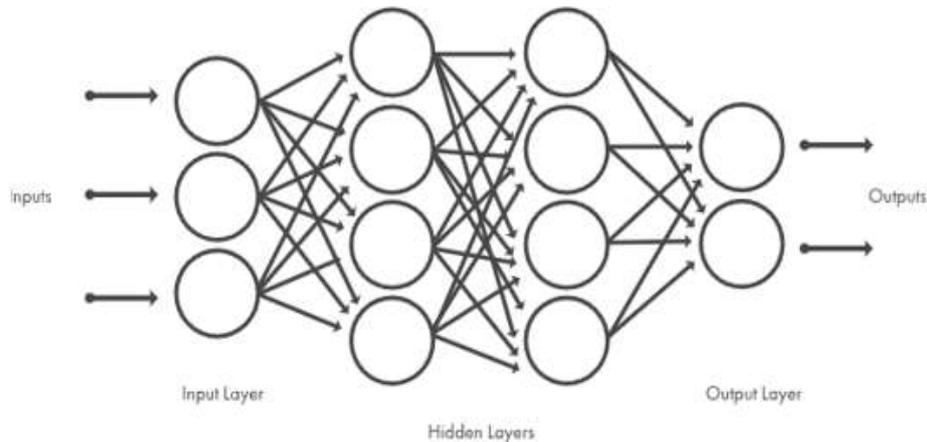
Fuente: Mathworks, (2024)

- **Redes neuronales artificiales**

Una red neuronal, modelada según la interconexión de neuronas cerebrales, es un sistema computacional con capas de nodos entrelazados (figura 2). Gracias a su capacidad de aprendizaje, puede identificar patrones, clasificar datos y prever futuros eventos mediante el entrenamiento con ejemplos. Estas redes descomponen las entradas en capas abstractas

y se entrenan para reconocer patrones en voz o imágenes, ajustando automáticamente la importancia de las conexiones según una regla de aprendizaje hasta lograr una ejecución precisa de la tarea (MathWorks, 2024).

Figura 2. Arquitectura típica de una red neuronal



Fuente: Mathworks, (2024).

- **Image Acquisition Toolbox**

Es una colección de funciones que amplían la capacidad del entorno de computación numérica MATLAB. Image Acquisition Toolbox admite una amplia gama de operaciones de adquisición de imágenes, desde captadores de fotogramas de nivel profesional hasta cámaras web basadas en USB. La caja de herramientas le permite conectarse y configurar su hardware, obtener una vista previa de un vídeo y transmitir imágenes directamente a MATLAB para su análisis y visualización. Muchas de las funciones de la caja de herramientas son archivos M de MATLAB (MathWorks, 2024).

- **Deep learning**

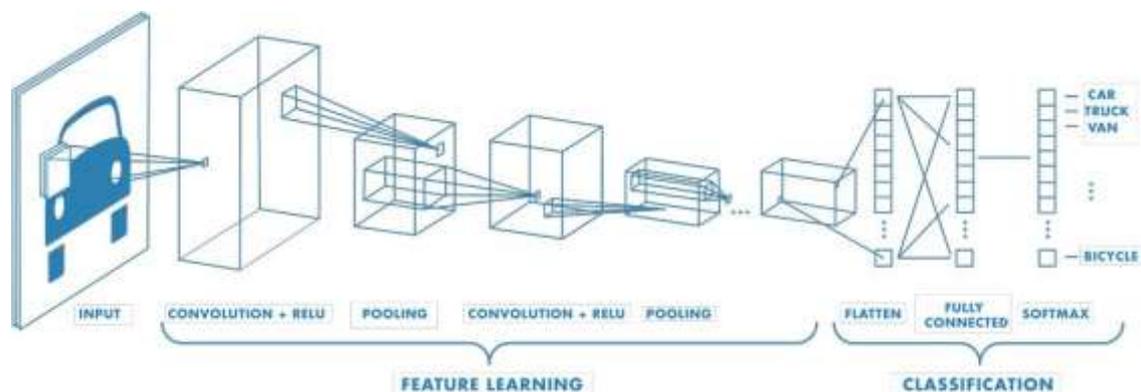
En esta herramienta es útil usar transferencia de aprendizaje debido a que permite que una red neuronal adquiera conocimientos de una nueva tarea de manera más eficiente, utilizando un menor número de imágenes de entrenamiento. La principal ventaja de la

transferencia de aprendizaje radica en que la red que ha sido entrenada previamente ya posee un conjunto de características valiosas que pueden ser aprovechadas para una variedad de tareas similares (MathWorks, 2024).

- **Redes neuronales convolucionales**

Este tipo de redes se caracterizan por aplicar una serie de filtros a las imágenes de entrada y la salida del filtro se considera como entrada para la siguiente capa (figura 3), de tal forma que en cada capa los filtros sean más complejos hasta llegar a características que permitan clasificar a un objeto (MathWorks, 2024).

Figura 3. Ejemplo de red con múltiples capas convolucionales.



Fuente: Mathworks, (2024).

2.8 App designer

App Designer constituye un entorno diseñado para la creación de aplicaciones en MATLAB®, simplificando la tarea de diseñar los elementos gráficos de un módulo de interacción mediante la incorporación de un conjunto integral de componentes. Este incluye una variedad completa de elementos que posibilitan la construcción de paneles de control e interfaces gráficas, haciendo posible la organización de componentes y el desarrollo del sistema de interacción de la aplicación (MathWorks, 2024).

2.9 Métodos estadísticos de validación

La validación es de gran importancia debido a que ayuda a medir el rendimiento de modelos de clasificación o regresión, haciendo posible la relación de datos conocidos con predicciones obtenidas por el modelo. Según Encina y otros (2023), para la validación son necesarios criterios estadísticos objetivos como las siguientes métricas: coeficiente de determinación, error cuadrático medio.

- **Coeficiente de determinación (R^2)**

Encina y otros (2023), mencionan que representa la cantidad de variación de la variable dependiente que el modelo lineal puede justificar. Esta estimación, sin dimensiones, indica que, independientemente del rango de valores, el coeficiente R cuadrado estará en un intervalo de valores entre -1 y 1. Se determina mediante la ecuación de la tabla 5.

- **Error cuadrático medio (MSE)**

La métrica en cuestión evalúa la discrepancia cuadrática media entre los valores originales y los esperados en una compilación de observaciones, esencialmente cuantificando la variabilidad de los valores predichos (Encina y otros, 2023). Su ecuación se presenta en la tabla 3.

Tabla 3. Métricas para medir la eficacia de los modelos.

Denominación	Fórmula	Definición
MSE	$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2$	N = Total de datos de entrenamiento. y_i = Valor predicho por el modelo. \hat{y} = Valor real.
R^2	$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2}$	\bar{y} = Promedio de valores reales.

Fuente: (Encina y otros, 2023).

- **Matrices de confusión**

A través de un modelo de clasificación se puede determinar la categoría a la que pertenece una nueva instancia, basándose en patrones identificados previamente en datos históricos. En un escenario binario, las categorías suelen representarse como "Positiva" y "Negativa".

La precisión o exactitud mide el desempeño del modelo calculando la relación entre el número de aciertos y el total de casos analizados.

Aunque este indicador es útil por su simplicidad, puede no reflejar a detalle la naturaleza de los errores cometidos. Para abordar esta limitación, es esencial recurrir a una matriz de confusión, misma que organiza las predicciones en una tabla $n \times n$ donde Las filas corresponden a las clases reales, mientras que las columnas indican las categorías predichas por el modelo. Esto facilita la evaluación de los errores generados.

Por ejemplo, si se diseña un modelo para clasificar setas como venenosas o comestibles, las clases reales serían P (venenosa) y N (comestible), mientras que las predicciones del modelo podrían ser S (sí, venenosa) o N (no, comestible). La matriz de confusión permite visualizar las coincidencias y errores, ayudando a identificar áreas de mejora en el modelo (Recuero, 2018).

CAPÍTULO III

3 METODOLOGÍA

Este capítulo describe el procedimiento metodológico seguido para alcanzar los objetivos de la investigación, incluyendo las técnicas utilizadas en la recolección, procesamiento e interpretación de los datos.

3.1 Tipo de investigación

La ruta de investigación de este estudio es de tipo cuantitativa con un alcance exploratorio. Esto debido a que la investigación presenta características plenas de un método cuantitativo como lo es la inferencia generalizable, relación entre variables y recolección y análisis de datos (Cárdenas, 2018).

3.2 Ubicación del lugar

Gran parte de la fase experimental de este proyecto ejecutó en los laboratorios de Análisis Experimental e Innovación y Análisis Físicoquímicos y Microbiológicos de la Universidad Técnica del Norte, ubicados en la ciudad de Ibarra. En la tabla 4 se detallan las particularidades del sitio donde se llevó a cabo el estudio.

Tabla 4. Ubicación de la experimentación.

Localización	Descripción
Provincia	Imbabura
Cantón	Ibarra
Lugar	Laboratorio de Análisis Experimental e Innovación
Altitud	2256 m.s.n.m
HR. Promedio	73%
Precipitación	550,3 mm/año
Temperatura media	18 °C

Fuente: INAMHI, (2020).

3.3 Materiales, equipos y software

Los materiales, equipos, insumos, reactivos y software que se utilizaron en el proceso de investigación se detallan en la tabla 5.

Tabla 5. Materiales, equipos y software que su utilizarán en la experimentación.

Materiales	Equipos	Insumos	Reactivos	Software
Bureta de vidrio	Refractómetro digital	Kiwi	Hidróxido de sodio (NaOH) solución 0,1N	Microsoft Word
Probeta	Balanza digital Scale		Fenolftaleína al 1%	Microsoft Excel
Frasco Erlenmeyer	Refrigerador		Agua destilada	Plataforma de programación MATLAB
Vaso de precipitación	Texturómetro Cámara			

3.4 Métodos, técnicas e instrumentos de investigación

A fin de evaluar la firmeza del kiwi considerando la concentración de gases, temperatura y tiempo de almacenamiento para la obtención de datos experimentales, se procedió inicialmente a estandarizar la materia prima, luego al embalaje en atmosferas modificadas y posterior almacenado. Todo lo anterior se describe a continuación.

3.4.1 Estandarización de la materia prima

Al seleccionar la fruta para la experimentación fue necesario determinar el índice de madurez para obtener una población específica. Se realizó mediante la ecuación 1.

Índice de madurez

$$= \frac{\text{Solidos solubles totales (\%Brix)}}{\text{Acidez total (\%)}} \quad (1)$$

Al ser el índice de madurez una magnitud desconocida se presentó el error asociado a esta. Para esto fue necesario realizar varias medidas para obtener el porcentaje de dispersión, que se define como la ecuación 2. También se presentan las fórmulas para las variables que influyen en el porcentaje de dispersión en la ecuación 3 y 4.

$$T = \frac{D}{\bar{x}} \quad (2)$$

$$D = x_{\text{máximo}} - x_{\text{mínimo}} \quad (3)$$

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (4)$$

Donde:

T= Porcentaje de dispersión.

D= Dispersión total de n medidas.

\bar{x} = Promedio de medidas.

n = Total de medidas.

Para considerar el valor verdadero del índice de madurez como la media de n medidas y el error absoluto como la media de n medidas \pm la sensibilidad del aparato se debe cumplir que la dispersión tendrá que ser menor o igual a la sensibilidad del aparato de medida. Si el porcentaje de dispersión se incrementa habrá que aumentar las mediciones. En este caso se tomaron medidas en base a la tabla 6. Para todos los casos mostrados en la tabla 6 la estimación del valor verdadero fue la media de todas las muestras.

Tabla 6. Medidas necesarias para porcentajes de dispersión.

Porcentaje de dispersión para las i muestras (T_i)	Nº total de medidas necesarias	Error absoluto
$T_3 \leq 2\%$	3	$\Delta x = S$
$2\% < T_3 \leq 8\%$	6	$\Delta x = \max\left(\frac{D_6}{6}, S\right)$
$8\% < T_6 \leq 15\%$	15	$\Delta x = \left[\frac{\sum(x_i - \bar{x}_n)^2}{N}\right]^{1/2}$
$15\% < T_{15}$	50	$\Delta x = \left[\frac{\sum(x_i - \bar{x}_n)^2}{N}\right]^{1/2}$

3.4.2 Sólidos solubles

Para realizar la medición de este parámetro se utilizó un refractómetro digital (como lectura directa) de la fracción de masa de sólidos solubles (Brezmes Llecha, 2002).

3.4.3 Acidez titulable

Para la determinación de este criterio se tuvo presente la normativa NTE INEN- ISO 750 (INEN 2013), donde se emplea el método de rutina en el cual se titula una solución del zumo de la fruta en presencia de fenolftaleína, con hidróxido de sodio como neutralizador al 0,1 N. Luego se obtendrá la acidez total mediante la ecuación 5.

$$\text{Acidez total} = V \times 2 \times F$$

(5)

Donde:

A= Acidez titulable en porcentaje de ácido específico (g ácido cítrico / 100g de fruta).

V= volumen de solución de NaOH 0,1N empleado en la titulación.

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

3.4.4 Almacenaje con atmósferas modificadas

Una vez estandarizada la materia prima, la fruta se envasó con empaques blandos de polietileno de baja densidad con una unidad experimental de alrededor de 200 g (3 frutos), las especificaciones de las fundas se encuentran en el anexo 1. Se pretendió alcanzar 100 datos experimentales (cada uno por duplicado) los cuales se desarrollaron siguiendo la metodología de López Eusebio (2018). Que en su estudio usó como rango de almacenamiento óptimo de refrigeración 0 a 5 °C y los niveles de gases fue de 2% O₂ y 5% CO₂. En la presente investigación con el propósito de obtener un modelo robusto y eficiente, se midieron datos entre 2 a 18°C y diferentes concentraciones de gases mismas que se detallan en la tabla 7. Se considera estos factores a fin de gestionar el tiempo de experimentación y disponibilidad de los equipos.

Tabla 7. Condiciones de almacenamiento por lotes.

Lotes	Temperatura (°C)	O ₂ (%)	CO ₂ (%)
1	2	13	6
2	18	10	7
3	2	8	8
4	6	16	10
5	6	6	6
6	14	16	10
7	14	4	6
8	14	11	10
9	10	4	6
10	18	15	12
11	18	5	11
12	2	15	12
13	6	11	9
14	10	8,5	8,5
15	10	11	9

3.4.5 Determinación de firmeza

Se realizó mediante lectura directa del texturómetro Shimadzu EZ-SX con el que cuenta el laboratorio de análisis físico químico y microbiológico de la universidad. Fue necesario

tomar lectura de dos unidades experimentales y su promedio se consideró como dato experimental. La medición de este parámetro sirvió para cada una de las combinaciones de las condiciones expresadas en la tabla 9 luego de 15 días de almacenamiento por cada temperatura.

3.4.6 Análisis de datos

En el desarrollo del modelo representativo del cambio de firmeza, luego de estandarizada la materia prima y obtenidos los datos experimentales, se procedió a analizar estos últimos mediante métodos de inteligencia artificial con técnicas de aprendizaje supervisado, debido a que trabaja con dos tipos de grupos de datos (entrada y salida) ambos conocidos y los entrena con modelos de regresión para producir predicciones a partir de datos nuevos no entrenados. (MathWorks, 2024). Antes de entrenar se descartaron datos atípicos debido a que los modelos son sensibles a estos. También se trabajó una aleatorización para seleccionar el 70% para entrenar los diferentes modelos de regresión y el 30% restante para validarlos.

Para entrenar el 70% de datos aleatorizados se empleó el método Bootstrap, el cual minimiza la posibilidad de sobreajuste de resultados e incrementa la estabilidad y precisión del modelo de regresión. Este modelo plantea un muestreo con remplazamiento de datos en un conjunto de muestras para luego entrenar diferentes modelos y conseguir un promedio de indicadores de representación de todas las muestras (Ceballos, 2015). En esta investigación se pretendió dividir los datos experimentales en 3 conjuntos, que luego fueron entrenados por cada uno de los modelos que ofrece las aplicaciones de *Regression Learning* y *Neural Net Fitting* de MATLAB.

3.5 Regression learner

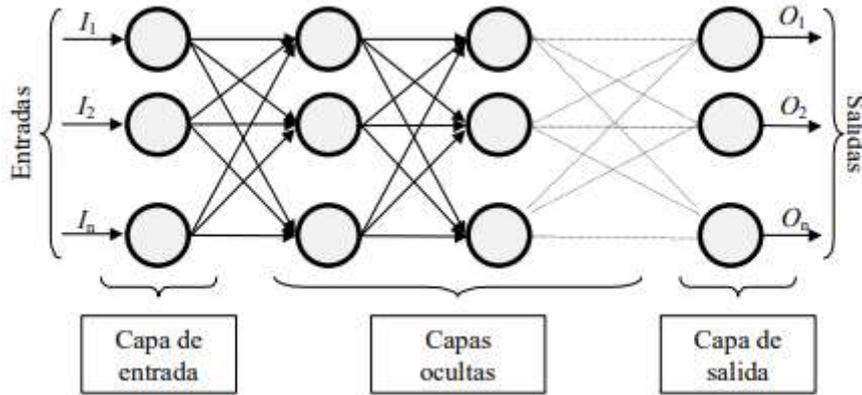
En el uso de la aplicación de *Regression Learning*, los datos reservados para el entrenamiento se dividieron en 3 conjuntos para seguir las indicaciones del método *Bootstrap*. Los 3 conjuntos se entrenaron para cada uno de los modelos que ofrece la aplicación, que se describen a continuación (MathWorks, 2024):

- Modelos de regresión lineal.
- Árboles de regresión.
- Máquinas de vectores de soporte.
- Modelos de regresión lineal entrenados eficientemente.
- Modelo de regresión del proceso gaussiano.
- Modelos de aproximación del kernel.
- Conjuntos de árboles.
- Redes neuronales.

3.6 *Neural Net Fitting*

Este tipo de modelo el cual usa redes neuronales puede reconocer patrones y clasificar datos para pronosticar una salida requerida. Su funcionamiento en general se basa en una capa de entrada, una o múltiples capas ocultas y una capa de salida, todas conectadas mediante neuronas. En la figura 4 se evidencian los elementos que integran una red neuronal (Matich, 2001).

Figura 4. Ejemplo de una red neuronal totalmente conectada.



Fuente: Matich, (2001).

En esta investigación se utilizó la aplicación de *Neural Net Fitting* que ofrece MATLAB, que, a diferencia de la aplicación explicada en la sección anterior, puede entrenar y validar al mismo tiempo. Por lo que, en este caso, se dividieron los datos experimentales en 3 conjuntos sin hacer la división previa de datos de entrenamiento y validación. Luego de ingresar los datos por conjunto, se colocaron en el software la configuración de la red, la cual permite modificar el número de neuronas de la capa o capas ocultas. Se inició con 5 neuronas en la capa oculta y se aumentaron 5 neuronas por cada iteración hasta alcanzar 100 y seleccionar aquella que represente en mejor medida el sistema de estudio (lo cual se determinó con indicadores de representación que se detallan en una sección posterior). Es importante mencionar que agregar demasiadas capas puede ocasionar un sobreajuste a los datos dando como resultado un modelo ineficiente en la resolución de nuevos problemas.

3.7 Indicadores de representación

Para poder reconocer y seleccionar el modelo que representa en mayor medida los datos experimentales del sistema de estudio se utilizaron dos indicadores de representación, el error cuadrado medio (MSE, acrónimo en inglés) y el coeficiente de determinación (R^2)

cuyas ecuaciones se muestran en la tabla 5 (Encina y otros, 2023). El valor de MSE igual a 1 representa una diferencia absoluta entre los valores proyectados por el modelo y los observados en la realidad, debido a esto es ideal obtener valores bajos donde 0 sería lo ideal. Por otro lado, los valores de R^2 también se encuentran entre 0 a 1 pero su valor se interpreta de la siguiente manera (Sosa, 2021):

- $R^2 < 0$: existe una correlación negativa entre variables.
- $R^2 > 0$: se presenta una correlación positiva entre variables.
- $R^2 = 1$: se observa una correlación positiva perfecta entre variables.
- $R^2 = 0$: No existe correlación entre variables.

Se determinó el MSE y R^2 para cada uno de los 4 conjuntos de datos por cada modelo. Posteriormente se estableció el promedio de cada uno de los indicadores, y estos últimos valores fueron los que se utilizaron para decidir cuál modelo es el más representativo durante el periodo de entrenamiento.

3.8 Validación del modelo de representación

En la sección de validación también se obtuvieron los indicadores de representación, pues es importante mencionar que los algoritmos podrían presentar un buen desempeño durante el periodo de entrenamiento, pero no en validación, por esto es fundamental volver a determinar los indicadores de todos los modelos generados en la etapa de entrenamiento (Ceballos, 2015). Los indicadores de representación para la validación de los modelos generados por la aplicación de *Neural Net Fitting* son automáticamente calculados. Es por ello por lo que no se hace la división de los datos en conjunto de entrenamiento y de validación. Sin embargo, para los modelos generados con la aplicación de *Regression Learner*, fue necesario primero, exportar cada modelo, predecir las variables de salida con los modelos extraídos y junto con los datos experimentales de

la variable de respuesta, determinar manualmente los indicadores de representación. En este caso si se trabajó el 30% de los datos experimentales asignados para la validación.

Una vez obtenido todos los indicadores, se compararon todos los modelos y aquel que presentó los mejores valores se seleccionó como aquel que representa el sistema de estudio. Sin embargo, si no se consigue un modelo que represente de manera precisa el sistema en el entrenamiento y en la validación, se debería seleccionar aquel que se acerque más a esta condición.

Creación del sistema de supervisión

Durante el periodo de almacenamiento, además de medir las variables predictoras y de interés, fue necesario capturar fotografías de la fruta por cada medición realizada, para la adquisición de la base de datos necesaria para el entrenamiento con 3 tipos de redes convolucionales (Tabla 8). Para todas las redes es indispensable que las imágenes de entrada tengan un tamaño de 224 por 224.

Tabla 8 Redes convolucionales para el entrenamiento del sistema de supervisión.

Red convolucional	Capas de profundidad
Googlenet	22
Resnet18	18
Resnet50	50

(MathWorks, 2024).

La eficiencia del modelo de clasificación se realizó en base al porcentaje de predicciones correctas, mediante una matriz de confusión.

3.9 *App Designer*

Una vez elegido el método representativo del sistema, se empleó el código del algoritmo para integrarlo en el entorno de *App Designer*. Esta herramienta permite a los usuarios crear aplicaciones profesionales e interactivas, con una apariencia visual atractiva, a través de la asignación de sistemas visuales de una interfaz gráfica de usuario y el desarrollo del funcionamiento de la aplicación (MathWorks, 2024).

Según Math Works (2024), *App Designer* proporciona dos tipos de vistas para la creación de una aplicación:

Design View: facilita una variedad de componentes para el diseño de funciones interactivas. Cualquier tipo de configuración entre aspectos que se realice en esta ventana también se mostrará en la *code view* en forma de código.

Code View: ofrece la vista del código del funcionamiento de la App. Para cada función que se agregó se podrá editar partes del código para mejorar su interacción. Existen secciones del código no editables debido a que éstas son generadas y administradas con *App Designer*. En este apartado se asociaron los eventos disponibles dentro de *App Designer* para relacionar con los componentes creados.

Luego de relacionar el código con componentes y mejorar el comportamiento de la aplicación se guardó y ejecutó. Para probar la aplicación es necesario ingresar datos de entrada y verificar que la App realice predicciones de una manera adecuada. Se esperó poder exportar la app como un instalador para que se pueda ejecutar como una app de escritorio o directamente desde la web mediante un navegador.

CAPÍTULO IV

4 RESULTADOS Y DISCUSIÓN

4.1 Efecto de la concentración de gases, temperatura y tiempo en el cambio de firmeza en los frutos.

El porcentaje de dispersión observado fue menor a 2% en todos los lotes. Esto es un indicativo de que se puede considerar a esta variable como una magnitud estándar (Tabla 9).

Tabla 9. Estandarización de la materia prima

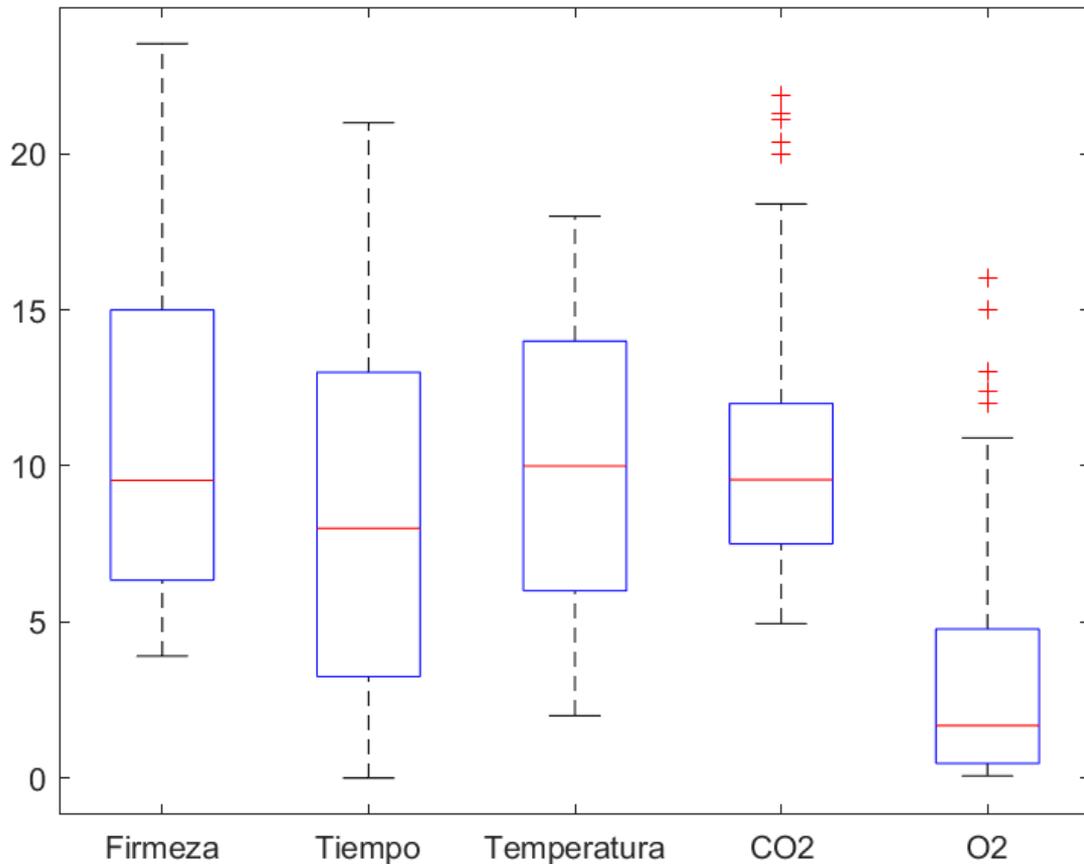
Lotes	SS (°Brix)	Acidéz T	I Maduréz	Dispersión (%)
1, 2, 3	12,30	1,34	9,18	0,17
4, 5, 6	12,59	1,28	9,84	0,04
7, 8, 9	8,27	1,10	7,52	0,05
10, 11, 12	9,37	1,23	7,79	0,01
13, 14, 15	10	1,25	8,01	0,08

En base al porcentaje de dispersión, se pudo considerar que la fruta con la que se trabajó estuvo bajo las mismas condiciones de madurez, además las prácticas adecuadas de transporte y almacenamiento después de la cosecha también influyeron en la conservación de las características del fruto, como lo explican García Rubio y otros, (2015).

La fruta luego de haber sido estandarizada se almacenó bajo las condiciones de la tabla 9. Los valores de firmeza obtenidos posterior al periodo de almacenamiento estuvieron en un rango donde el mínimo fue de 3,91 N y el máximo de 23,53 N. Este rango amplio de valores permite tener una mayor eficiencia del modelo predictivo en cuanto a la robustez de este.

Por otro lado, mediante el gráfico de cajas y bigotes de las variables del estudio (figura 5), se pudo evidenciar que existen datos atípicos para las variables de CO₂ y O₂.

Figura 5. Gráfico de bigotes de variables del estudio de firmeza del kiwi.



Camargo Rodríguez & Alfonso Ortiz, (2020) mencionan que es necesario realizar un pretratamiento de los datos tanto para las variables independientes como para las dependientes, sin embargo, en esta investigación es esencial que los rangos de las variables relacionadas con el proceso sean amplios, por lo tanto, es preciso conservar los valores atípicos en estas variables, con el fin de modelar el comportamiento del sistema aun en condiciones extremas.

4.2 Modelo representativo del cambio de firmeza mediante inteligencia artificial.

La aplicación del Regression Learner no permitió la obtención de un modelo estadísticamente significativo. El valor de R^2 más alto que se obtuvo mediante esta metodología fue 0.21 (Tabla 10).

Tabla 10 Entrenamiento de modelos en Regression Learner

N.º	Modelo	R^2	MSE	RMSE
1	Linear	0,02	34,54	5,83
2	Interactions Linear	-3,53	158,08	11,60
3	Robust Linear	-0,03	36,78	6,01
4	Stepwise Linear	0,09	31,01	5,56
5	Fine Tree	0,19	24,88	4,93
6	Medium Tree	0,00	35,50	5,91
7	Coarse Tree	0,00	35,50	5,91
8	Linear SVM	0,08	31,37	5,59
9	Quadratic SVM	-0,04	35,66	5,95
10	Cubic SVM	-0,19	40,56	6,36
11	Fine Gaussian SVM	0,02	33,97	5,81
12	Medium Gaussian SVM	0,11	29,57	5,43
13	Coarse Gaussian SVM	0,06	32,76	5,70
14	Boosted Trees	0,21	26,25	5,12
15	Bagged Trees	-0,10	39,46	6,21
16	Squared Exponential GPR	0,17	28,01	5,28
17	Matern 5/2 GPR	0,19	27,41	5,23
18	Exponential GPR	0,20	26,99	5,19
19	Rational Quadratic GPR	0,18	27,97	5,28

Los indicadores de representación indican una baja correlación y errores elevados, sin embargo, hay que tomar en cuenta que un modelo de entrenamiento no tiene que ser necesariamente efectivo, dado que es necesario realizar la validación de estos. Para la etapa de validación se seleccionó el 30% de los datos totales. La tabla 11 muestra un resumen de los indicadores obtenidos en la etapa de validación.

La metodología de Bootstrap no fue suficiente para corregir ciertos sesgos que pueden existir cuando se trabaja con una baja cantidad de datos, por lo tanto, es esencial contar con un tamaño mínimo de muestra, tal como lo describen Van Der Schaaff y otros, (2012) en su investigación donde explican que se ha comprobado que se logra más de la mitad

del poder predictivo potencial con alrededor de 200 observaciones, mientras que con menos de 32, el poder predictivo real disminuye considerablemente de forma rápida.

Tabla 11 Validación de modelos en Regression Learner

Modelo	R ²	MSE	RMSE
Linear	0,34	23,37	4,83
Interactions Linear	0,39	20,97	4,58
Robust Linear	0,35	24,72	4,97
Stepwise Linear	0,30	24,05	4,90
Fine Tree	0,23	30,26	5,50
Medium Tree	0,27	24,23	4,92
Coarse Tree	0,15	28,77	5,36
Linear SVM	0,35	31,76	5,64
Quadratic SVM	0,30	28,57	5,35
Cubic SVM	0,28	29,39	5,42
Fine Gaussian SVM	0,29	28,02	5,29
Medium Gaussian SVM	0,30	29,36	5,42
Coarse Gaussian SVM	0,37	33,11	5,75
Boosted Trees	0,26	28,64	5,35
Bagged Trees	0,12	29,37	5,42
Squared	0,35	22,57	4,75
Exponential GPR	0,39	21,55	4,64
Matern 5/2 GPR	0,44	20,65	4,54
Rational Quadratic GPR	0,35	22,57	4,75

Los valores obtenidos para los modelos de validación no fueron significativos para el sistema por lo que fue necesario entrenar y validar en la aplicación *Neural Net Fitting*, en la que se trabajó con dos algoritmos *Best Levenberg-Marquard (BLM)* y *Best Scaled Conjuhated Gradient (SCG)*. Las configuraciones usadas para el entrenamiento y validación estuvieron en el rango de 5 hasta 100 neuronas, en un intervalo de 5. En la tabla 12 se ponen en evidencia los indicadores de entrenamiento para cada algoritmo.

Tabla 12. Entrenamiento con Neural Net Fitting.

# de neuronas	BLM			SCG		
	R2	MSE	RMSE	R2	MSE	RMSE
5	0,58	30,85	5,20	0,62	19,41	4,40
10	0,77	13,16	3,60	0,69	17,26	4,10
15	0,87	15,08	3,40	0,69	16,87	4,10
20	0,72	19,08	3,60	0,89	8,80	2,90
25	0,75	22,71	4,40	0,69	21,05	4,30
30	0,35	182,79	12,70	0,81	11,37	3,30
35	0,83	12,88	2,70	0,58	49,73	5,40
40	0,86	10,16	2,70	0,65	24,90	4,30
45	0,88	12,57	3,20	0,49	53,27	7,20
50	0,88	13,85	3,30	0,79	14,29	3,70
55	0,94	3,90	1,60	0,60	26,53	5,10
60	0,76	37,76	5,00	0,73	14,79	3,60
65	0,93	5,33	1,90	0,81	13,04	3,50
70	0,93	4,34	1,30	0,46	106,39	7,90
75	0,90	8,04	2,80	0,62	32,59	5,10
80	0,89	4,69	1,30	0,43	70,45	8,30
85	0,92	4,07	1,60	0,79	13,49	3,60
90	0,96	3,84	1,40	0,73	15,41	3,90
95	0,93	3,54	1,50	0,80	19,03	3,70
100	0,98	0,78	0,70	0,47	33,82	5,80

En el entrenamiento con algoritmos de *Neural Net Fitting* se obtuvo indicadores con valores que muestran mejores resultados en comparación a los modelos de *Regression Learner*, con valores de R^2 de 0,98 y 0,89 para BLM y SCG respectivamente. Sin embargo, para verificar la eficiencia del modelo se debe dar mayor relevancia a los valores de validación. En la tabla 13 se reflejan los indicadores de la etapa de validación.

Tabla 13. Validación en Neural Net Fitting

# de neuronas	LM			SCG		
	R ²	MSE	RMSE	R ²	MSE	RMSE
5	0,65	16,99	4,10	0,79	14,56	3,70
10	0,01	69,01	8,20	0,73	16,04	3,40
15	0,37	42,67	5,70	0,76	13,68	3,70
20	0,10	101,13	9,00	0,67	20,99	4,60
25	0,67	42,76	6,40	0,34	31,49	5,50
30	0,42	76,28	8,30	0,59	19,59	4,40
35	0,27	55,40	6,90	0,27	108,24	9,50
40	0,50	103,74	9,80	0,55	21,98	4,50
45	0,21	272,29	14,80	0,07	82,62	8,50
50	0,43	79,16	8,70	0,07	83,68	8,50
55	-0,19	114,37	10,00	0,09	80,47	8,80
60	0,40	170,01	11,40	0,46	45,70	6,60
65	0,32	75,69	8,30	0,62	44,26	6,50
70	0,07	124,89	10,70	0,54	81,53	8,90
75	0,31	100,74	9,70	0,41	119,64	10,10
80	0,43	219,85	13,70	0,23	106,06	10,10
85	0,55	248,69	15,70	-0,07	72,35	8,40
90	0,09	112,93	9,40	0,31	181,71	13,30
95	0,09	405,54	19,80	0,39	159,98	11,70
100	0,63	146,99	11,50	0,34	209,11	13,40

Al realizar la validación, tanto para el algoritmo de LM, como para SCG, la configuración que mejor resultados mostró fue de 5 neuronas. Aun así, es necesario escoger una sola para representar al sistema, por lo tanto, comparando los indicadores de ambos algoritmos se escogió la de SCG.

Por lo tanto, tiene relación con lo que Lee y otros, (2020) mencionan en su investigación donde indican que el algoritmo SCG resulta valioso para la predicción y simulación de sistemas biológicos, ya que tiene la habilidad de abordar problemas de optimización que muestran características de esparsidad. Esta propiedad es particularmente importante en la modelización de sistemas biológicos, donde los datos pueden ser limitados o solo algunas variables tienen un efecto importante en el resultado del sistema.

4.3 Generación del sistema de supervisión, control y adquisición de datos mediante IA

Los valores que arrojaron diferentes métricas para la evaluación del modelo de clasificación para el sistema de supervisión se detallan en la tabla 14.

Tabla 14. Eficiencia del modelo de clasificación en base a diferentes métricas.

	Googlenet	Resnet 50	Resnet 18
Precisión global (%)	33,07	70,52	65,19
Macro precisión (%)	32,41	70,98	64,98
Macro Recall (%)	31,77	79,74	74,43
Macro F1-Score	0,26	0,69	0,63
Micro precisión (%)	33,08	70,51	65,19
Micro Recall (%)	33,8	70,51	65,19
Micro F1-Score	33,08	0,7051	0,65
Micro Accuracy (%)	-33,84	41,03	30,38
Tiempo de Ejecución Promedio (s)	0,24	0,58	1,79

Referente a la precisión global, que se puede definir como La proporción de imágenes clasificadas correctamente respecto al total de imágenes, en base a la matriz de confusión se entiende como la suma de los verdaderos positivos y verdaderos negativos dividida por el total de casos (Banerjee y otros, 2024).

En cuanto a la macro precisión, se calcula como un promedio de las precisiones para cada clase o clasificador. La precisión para una clase se define como verdadero positivo entre la suma de verdadero positivo y falso positivo (Kumar y otros, 2024).

La macro recall cuantifica la habilidad del modelo para detectar de manera precisa todas las instancias positivas correspondientes a cada clase.. Se puede definir como el promedio de la relación de verdaderos positivos entre verdaderos positivos más falsos negativos (Banerjee y otros, 2024).

El macro F1-Score combina la precisión con el recall de cada clase y se calcula mediante una relación de la precisión multiplicada por el recall, sobre la suma de la precisión y el recall, todo esto multiplicado por 2 (Banerjee y otros, 2024).

La micro precisión calcula globalmente considerando los verdaderos positivos, falsos positivos y falsos negativos. Donde se puede calcular mediante la relación de la sumatoria de verdaderos positivos, entre la sumatoria de verdaderos positivos y falsos positivos (Kumar y otros, 2024)

La micro recall es similar a la micro precisión, pero esta se relaciona con los falsos negativos. Es posible calcular por medio de la relación de la sumatoria de verdaderos positivos, entre la sumatoria de verdaderos positivos y falsos negativos (Kumar y otros, 2024)

En cuanto al micro F1-Score, toma en cuenta tanto la micro precisión como el micro recall y se puede definir como el producto de micro precisión y mico recall sobre la suma de mi micro precisión y micro recall, todo esto multiplicado por 2 (Kumar y otros, 2024).

La micro accuracy considera el total de casos en lugar de calcular la precisión por clase individualmente. Se puede calcular como la relación de la sumatoria de verdaderos positivos entre la sumatoria de verdaderos positivos, falsos positivos, falsos negativos, verdaderos negativos (Kumar y otros, 2024).

El tiempo de ejecución promedio mide cuanto tarda en promedio el algoritmo en ejecutarse (Banerjee y otros, 2024).

En base a los resultados de las métricas para cada una de las redes neuronales, resnet50 posee valores más elevados. Aquí las métricas relacionadas a la precisión se relacionan con la habilidad del algoritmo para prevenir falsos positivos, las recall se enfocan en minimizar los falsos negativos y F1-score para dar un equilibrio entre precisión y recall, en particular para conjuntos de datos desbalanceados, según R y otros, (2022).

Los valores para las métricas macro son superiores para las métricas micro, esto hace referencia a lo que R y otros, (2022) mencionaron en su conferencia, donde explican que las métricas macro son apropiadas para determinar el rendimiento en problemas de clasificación desbalanceada, es decir, cuando se posee una cantidad de muestras diferentes para cada categoría, por lo tanto es evidente que existe un desbalanceo en los conjuntos de datos.

Por otro lado en conjuntos de datos desbalanceados, la precisión puede ser engañosa, ya que un modelo puede predecir correctamente la clase mayoritaria la mayoría del tiempo, pero fallar en identificar la clase minoritaria, por esta razón tal como lo señalan Riyanto y otros (2023), es apropiado evaluar el rendimiento del modelo con F1-Score, debido a que equilibra la precisión y el recall.

En efecto, fue necesario realizar una prueba del programa para verificar la eficiencia en una fase práctica. En este periodo de evaluación se midieron todas las variables del sistema las cuales fueron similares a las de entrenamiento (tabla 15).

Tabla 15. Variables evaluadas en periodo de prueba.

Día	Temperatura	O ₂	CO ₂	Firmeza Exp	Firmeza Clas	MSE	
1	18	8,44	6,61	11,51	13,02	2,28	
3	18	5,68	7,79	9,65	13,02	11,36	
6	18	5,08	6,17	10,66	7,96	7,29	
7	18	1,08	7,79	9,83	7,96	3,50	
8	18	0,95	7,01	8,52	13,02	20,25	
9	18	0,62	9,05	5,91	7,96	4,20	
13	18	1,23	6,39	6,77	8,34	2,46	
14	18	0,82	9,39	5,75	13,02	52,85	
15	18	1,03	6,61	9,39	8,34	1,10	
16	18	2,26	8,07	6,5	9,01	6,30	
19	18	1,73	5,92	4,03	8,34	18,58	
20	18	1,15	6,74	4,98	7,99	9,06	
21	18	1,75	5,67	5,15	8,34	10,18	
22	18	2,84	5,23	5,98	13,02	49,56	
23	18	1,20	6,06	4,22	7,96	13,99	
27	18	4,75	9,12	3,07	7,99	24,21	
R²						0,12	15,4

A pesar de tener resultados semejantes al entrenamiento y métricas que indicaban una eficiencia adecuada, el programa no pudo arrojar valores de firmeza que sean próximos a los reales. Esto sucede debido a las limitaciones que pueden generar las métricas globales en escenarios con clases desbalanceadas, generando clasificaciones en la clase mayoritaria y causando problemas en las minoritarias tal cual lo explica Ferrer, (2022).

Ademas, al realizar un analisis de correlación entre los valores clasificados y reales se pudo evidenciar un R^2 significativamente bajo, que también permite interpretar un bajo desempeño en cuanto a la eficiencia del programa para la clasificación en un campo aplicado.

Cabe considerar, por otra parte la resolución discriminativa del sistema, que por la disponibilidad de insumos no pudo minimizarse, obteniendose así una resolución promedio de 0,22. Aïcha (2024), menciona que los valores cercanos a cero o positivos presentan clases poco separadas lo que genera una clasificación menos precisa. Por lo tanto el modelo muestra baja capacidad de distinción entre diferentes clases.

También es importante tener en cuenta que la resolución de las imágenes de entrenamiento y prueba fueron de 8 y 0,31 mega píxeles respectivamente. Clark & Clark, (2019) señalan que la resolución de las muestras visuales empleadas durante el entrenamiento y evaluación deben ser similares, sin embargo, la resolución en la fase de entrenamiento fue alta y baja en la fase de prueba, por lo cual el modelo no fue capaz de reconocer patrones aprendidos de los datos de entrenamiento.

Por otro lado, la iluminación es un factor importante al momento de obtener la base de datos. Sánchez Cáceres, (2013) sugiere que se debe tener una iluminación uniforme que maximice las características de interés y reduzca posibles variaciones como sombras o reflejos. A pesar de emplear un fondo blanco para las imagenes usadas tanto en el entrenamiento como en la fase de prueba, se pudieron distinguir sombras y contrastes pobres en algunas fotografías, lo que da como resultado errores o sesgos en la eficiencia del sistema, que tiene relación con los resultados expuestos por Herrera y otros, (2016), donde evidenciaron una baja efectividad por problemas de iluminación, utilizando imágenes para un sistema de detección de café.

CAPÍTULO V

1. CONCLUSIONES Y RECOMENDACIONES

1.1 Conclusiones

- Se consiguió evaluar la firmeza en función de la concentración de gases, temperatura y tiempo de almacenamiento, adquiriendo datos experimentales que evidencien los cambios ocurridos dentro del sistema, por lo que fueron adecuados como base de datos para trabajar con modelos de predicción.
- Aunque los modelos de regression learner no fueron tan eficaces, las redes neuronales revelaron que el algoritmo Scaled Conjugated Gradient es práctico para simular procesos biológicos, generando así un modelo capaz de predecir la degradación de firmeza en función de las condiciones de almacenamiento.
- Se logró desarrollar un sistema de supervisión, control y adquisición de datos en base a una red neuronal convolucional. Sin embargo, este sistema no es práctico para la supervisión en tiempo real de la firmeza del kiwi, debido a que presentó baja capacidad de clasificación por factores relacionados con la adquisición de datos visuales.

1.2 Recomendaciones

- Seleccionar un subconjunto de variables adicionales para incrementar el desempeño de los modelos predictivos, tomando en cuenta un análisis de factores que puedan influir significativamente en el proceso de pérdida de firmeza en el kiwi. De modo que estos se adapten a distintas condiciones de almacenamiento, haciendo que las predicciones sean más representativas y aplicables a escenarios agroindustriales reales.

- Para mejorar la precisión en la medición de gases, es aconsejable emplear sensores con alta capacidad de detección que permitan identificar con exactitud los cambios en la composición del aire dentro del empaque. Además, es importante optimizar el sellado de las fundas para prevenir fugas de gases, recomendándose el uso de tecnología de termosellado en materiales con permeabilidad adecuada a las necesidades del fruto, lo que ayudará a prolongar su vida útil.
- Es conveniente tener una organización de imágenes homogénea o balanceada para cada una de las categorías que se desea clasificar, además de incrementar el número de clasificadores para mejorar la separación entre clases y considerar factores que influyan en la adquisición de datos como la iluminación y resolución de fotografías, esto ayudaría a elevar la eficiencia del modelo de clasificación, haciéndolo tanto preciso como exacto.

REFERENCIAS

- Aïcha. (8 de julio de 2024). *Innovatiana*. Clasificación de imágenes: de la teoría a la práctica, todo lo que necesita saber: <https://es.innovatiana.com/post/image-classification-in-ai>
- Ayvar Rios, R. (2024). *DETECCIÓN DE TRAMPAS EN PARTIDAS DE AJEDREZ EN LÍNEA UTILIZANDO CLASIFICADORES DE MACHINE LEARNING*. Lima.
- Banerjee, D., Sharma, N., Chauhan, R., Singh, M., & Kumar, B. (2024). Improving Precision in Rose Leaf Disease Recognition with Integrated CNN and SVM Models. *2024 4th International Conference on Innovative Practices in Technology and Management (ICIPTM)*, (págs. 1-6). <https://doi.org/DOI:10.1109/ICIPTM59628.2024.10563533>
- Brezmes Llecha, J. (2002). *Diseño de una nariz electrónica para la determinación no destructiva del grado de la maduración de la fruta*.
- Camargo Rodríguez, L., & Alfonso Ortiz, K. L. (2020). *Aplicación de modelos predictivos en quiebra corporativa, utilizando técnicas de Machine Learning en empresas Pyme de Colombia en el periodo comprendido entre el 2015-2018*.
- Cárdenas, J. (2018). *Investigación cuantitativa*.
- Ceballos, G. F. (2015). *Estudio de Bootstrapping en Algoritmos de Clasificación*.
- Chorlango, A. J. (2023). *SIMULACIÓN COMPUTACIONAL DEL PROCESO DE FERMENTACIÓN ALCOHÓLICA DE LA SAVIA EXTRAÍDA DEL AGAVE AZUL (Agave americana)*.
- Clark, J. I., & Clark, C. A. (24 de Agosto de 2019). *Deriving a Quantitative Relationship Between Resolution and Human Classification Error*. arXiv: <https://arxiv.org/abs/1908.09183>
- De la Vega, J. C., Cañarejo, M. A., & Pinto, N. S. (2017). Avances en Tecnología de Atmósferas Controladas y sus Aplicaciones en la Industria. Una Revisión. *Información tecnológica*, 28(3).
- Encina, A., Pachecho, M., & Vargas, V. (2023). *Técnicas de Machine Learning para la predicción del caudal efluente de la represa Condorama*.
- Espinosa, D. A. (2016). *Modelado del cambio de propiedades indicativas de calidad en el almacenamiento de feijoa (Acca Sellowiana Berg) utilizando atmósferas modificadas*.
- Ferrer, L. (2022). Analysis and Comparison of Classification Metrics. *ArXiv*. <https://doi.org/https://doi.org/10.48550/arXiv.2209.05355>
- García Rubio, J. C., García González de Lena, G., & Ciordia Ara, M. (2015). *El cultivo del kiwi*. Servicio Regional de Investigación y Desarrollo Agroalimentario (SERIDA).

- Gobierno Autonomo Descentralizado Parroquial Rural De Huachi Grande. (2017). *Adquisición de plantas de kiwi para los productores agrícolas de la parroquia Huachi Grande, Con el propósito de diversificar la producción y mercados, para el cambio de la matriz productiva.*
- Guarda, N. L. (2003). *Optimización de la Atmósfera Modificada en Kiwi variedad Hayward.* Revista de la Facultad de Agronomía de la Universidad de Buenos Aires. <https://doi.org/10.25237/1516-8992.2019.v44n1.15>
- Herrera, J. C., Medina, S. M., Beleño, K., & Gualdrón, O. E. (2016). Projeto de um sistema automático para seleção de frutas de café utilizando técnicas de visão artificial. *Revista de Ingeniería UIS, 15(1).* <https://doi.org/https://doi.org/10.18273/revuin.v15n1-2016001>
- INAMHI. (2020). *Red de Estaciones Meteorológicas.*
- Instituto Ecuatoriano de Normalización (INEN). (2013). *NTE INEN-ISO 750: Frutas y hortalizas. Determinación de la acidez titulable.* Instituto Ecuatoriano de Normalización.
- Kumar, R., Jain, A., Sharma, V., Das, P., Midha, M., & Singh, M. (2024). Towards Precision Agriculture: A Unified CNN and Random Forest Framework for Jasmine Leaf Disease Recognition. *2024 4th International Conference on Innovative Practices in Technology and Management (ICIPTM).* <https://doi.org/10.1109/ICIPTM59628.2024.10563259>
- Lee, C. H., Rao, B. D., & Garudadri, H. (2020). A Sparse Conjugate Gradient Adaptive Filter. *IEEE Signal Processing Letters, 27,* 1000-1004. <https://doi.org/10.1109/LSP.2020.3000459>
- Lizares Castillo, M. (2017). *Comparación de modelos de clasificación: regresión logística y árboles de clasificación para evaluar el rendimiento académico.*
- López Eusebio, V. E. (2018). *DESARROLLO DE SISTEMA DE MEDICIÓN MULTIPUNTO DE ETILENO, DIÓXIDO DE CARBONO Y OXÍGENO.*
- Martínez, L. (2011). *EVALUACIÓN DE LA CALIDAD DE KIWIS ALMACENADOS EN REFRIGERACIÓN ENVASADOS EN DISTINTAS ATMÓSFERAS MODIFICADAS Y EL USO DE 1-MCP.*
- MathWorks. (2023). *MathWorks.* MathWorks: <https://la.mathworks.com/discovery/machine-learning.html>
- MathWorks. (2024). *MathWorks.* MathWorks.
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones.*
- Ospina Meneses, S. M., & Cartagena, J. R. (2008). La atmósfera modificada: una alternativa para la conservación de los alimentos. *Revista Lasallista de Investigación, 5(2).*
- R, R., Namita, G., & Kulkarni, R. (2022). Image Recognition, Classification and Analysis Using Convolutional Neural Networks. *2022 First International*

Conference on Electrical, Electronics, Information and Communication Technologies (ICEEICT). <https://doi.org/DOI:10.1109/ICEEICT53079.2022.9768474>

- Ramírez Salvador Salas, Z. M. (2003). *EVALUACIÓN DE LOS CAMBIOS FÍSICOS Y DE TEXTURA EN KIWI ALMACENADO EN REFRIGERACIÓN CON Y SIN ENVASE*.
- Ramos, A., Sánchez, P., Ferrer, J. M., Barquín, J., & Linares, P. (2010). *Modelos Matemáticos de Optimización*.
- Recuero, P. (2018). Machine Learning a tu alcance: La matriz de confusión. *Tech*.
- Reinoso García, Ó., Jiménez García, L. M., Payá Castelló, L., Gil Aparicio, A., & Peidró Vidal, A. (2018). *MATLAB: conceptos básicos y descripción gráfica*. Universidad Miguel Hernández.
- Riyanto, S., Sitanggang, I., Djatna, T., & Atikah, T. (2023). Comparative Analysis using Various Performance Metrics in Imbalanced Data for Multi-class Text Classification. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2023.01406116>
- Sánchez Cáceres, V. M. (2013). *Diseño de un sistema de identificación y clasificación por visión artificial*.
- Sosa, E. (2021). *PREDICCIÓN DEL GRADO DE SUPERHIDROFOBICIDAD EN SUPERFICIES MICROTERTURIZADAS, MEDIANTE EL USO DE INTELIGENCIA ARTIFICIAL EN PYTHON*.
- Valero, C., & Ruiz Altisent, M. (2000). Conjunto de técnicas de medida de la calidad y atributos de frutas. *Vida rural*(116), 60-64.
- Van Der Schaaff, A., Xu, C., Van Luijk, P., Veld, A., Langendijk, J., & Schilstra, C. (2012). Multivariate modeling of complications with data driven variable selection: guarding against overfitting and effects of data set size. *Radiotherapy and Oncology: Journal of the European Society for Therapeutic Radiology and Oncology*, 105(1), 115-121. <https://doi.org/10.1016/j.radonc.2011.12.006>

ANEXOS

Anexo 1. Características de empaque.



PRODUCTOS PARAISO DEL ECUADOR																																																																																									
DIVISION POLIETILENO																																																																																									
CERTIFICADO DE CALIDAD DEL PRODUCTO																																																																																									
CLIENTE	ECOPACIFIC	FECHA	2 de enero de 2018																																																																																						
CANTIDAD	60.000	CODIGO	4394.07																																																																																						
FUNDAS POR BULTO	4.000	TIPO DE FUNDA																																																																																							
FUNDAS POR PAQUETE	15	TRADICIONAL TRANSPARENTE																																																																																							
NÚMERO DE LOTE	21217																																																																																								
USO	EMPAQUE PRODUCTO TERMINADO REFERENCIA SAMBO PICADO																																																																																								
MATERIAL		POLIETILENO DE BAJA DENSIDAD																																																																																							
		<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="4" style="text-align: center;">ESPECIFICACIONES DE MEDIDAS</th> </tr> <tr> <th>PARAMETRO</th> <th>MEDIDA</th> <th>TOLERANCIA</th> <th>REVISADO</th> </tr> </thead> <tbody> <tr> <td>ANCHO</td> <td>7,00"</td> <td>±5 %</td> <td>✓</td> </tr> <tr> <td>LARGO</td> <td>10,00"</td> <td>±5 %</td> <td>✓</td> </tr> <tr> <td>ESPESOR</td> <td>3,50 mils</td> <td>±10 %</td> <td>✓</td> </tr> <tr> <td>FUELLE LATERAL</td> <td>--</td> <td>--</td> <td>--</td> </tr> <tr> <td>FUELLE FONDO</td> <td>--</td> <td>--</td> <td>--</td> </tr> <tr> <td>LENGÜETA</td> <td>--</td> <td>--</td> <td>--</td> </tr> </tbody> </table> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="4" style="text-align: center;">COLORES DE IMPRESIÓN</th> </tr> <tr> <th colspan="2" style="text-align: center;">ANVERSO</th> <th colspan="2" style="text-align: center;">REVERSO</th> </tr> <tr> <th>CÓLOR</th> <th>REVISADO</th> <th>CÓLOR</th> <th>REVISADO</th> </tr> </thead> <tbody> <tr> <td>1 NEGRO</td> <td>✓</td> <td>1 BLANCO</td> <td>✓</td> </tr> <tr> <td>2 BLANCO</td> <td>✓</td> <td>2 NEGRO</td> <td>✓</td> </tr> <tr> <td>3 NARANJA 190C</td> <td>✓</td> <td>3 VERDE 349C</td> <td>✓</td> </tr> <tr> <td>4 NARANJA161C</td> <td>✓</td> <td>4</td> <td></td> </tr> <tr> <td>5 VERDE 349C</td> <td>✓</td> <td>5</td> <td></td> </tr> <tr> <td>6</td> <td></td> <td>6</td> <td></td> </tr> </tbody> </table> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">PROPIEDADES DEL PRODUCTO</th> </tr> <tr> <th>ESPECIFICACION</th> <th>REVISADO</th> </tr> </thead> <tbody> <tr> <td>RESISTENCIA LONGITUDINAL</td> <td>✓</td> </tr> <tr> <td>RESISTENCIA TRANSVERSAL</td> <td>✓</td> </tr> <tr> <td>CARGA DE RUPTURA</td> <td>✓</td> </tr> <tr> <td>BLOQUEO DE MATERIAL</td> <td>✓</td> </tr> <tr> <td>TRATADO SUPERFICIAL DE MATERIAL</td> <td>✓</td> </tr> <tr> <td>ADHERENCIA DE LA TINTA</td> <td>✓</td> </tr> <tr> <td>RESISTENCIA DE SELLOS</td> <td>✓</td> </tr> </tbody> </table>		ESPECIFICACIONES DE MEDIDAS				PARAMETRO	MEDIDA	TOLERANCIA	REVISADO	ANCHO	7,00"	±5 %	✓	LARGO	10,00"	±5 %	✓	ESPESOR	3,50 mils	±10 %	✓	FUELLE LATERAL	--	--	--	FUELLE FONDO	--	--	--	LENGÜETA	--	--	--	COLORES DE IMPRESIÓN				ANVERSO		REVERSO		CÓLOR	REVISADO	CÓLOR	REVISADO	1 NEGRO	✓	1 BLANCO	✓	2 BLANCO	✓	2 NEGRO	✓	3 NARANJA 190C	✓	3 VERDE 349C	✓	4 NARANJA161C	✓	4		5 VERDE 349C	✓	5		6		6		PROPIEDADES DEL PRODUCTO		ESPECIFICACION	REVISADO	RESISTENCIA LONGITUDINAL	✓	RESISTENCIA TRANSVERSAL	✓	CARGA DE RUPTURA	✓	BLOQUEO DE MATERIAL	✓	TRATADO SUPERFICIAL DE MATERIAL	✓	ADHERENCIA DE LA TINTA	✓	RESISTENCIA DE SELLOS	✓
ESPECIFICACIONES DE MEDIDAS																																																																																									
PARAMETRO	MEDIDA	TOLERANCIA	REVISADO																																																																																						
ANCHO	7,00"	±5 %	✓																																																																																						
LARGO	10,00"	±5 %	✓																																																																																						
ESPESOR	3,50 mils	±10 %	✓																																																																																						
FUELLE LATERAL	--	--	--																																																																																						
FUELLE FONDO	--	--	--																																																																																						
LENGÜETA	--	--	--																																																																																						
COLORES DE IMPRESIÓN																																																																																									
ANVERSO		REVERSO																																																																																							
CÓLOR	REVISADO	CÓLOR	REVISADO																																																																																						
1 NEGRO	✓	1 BLANCO	✓																																																																																						
2 BLANCO	✓	2 NEGRO	✓																																																																																						
3 NARANJA 190C	✓	3 VERDE 349C	✓																																																																																						
4 NARANJA161C	✓	4																																																																																							
5 VERDE 349C	✓	5																																																																																							
6		6																																																																																							
PROPIEDADES DEL PRODUCTO																																																																																									
ESPECIFICACION	REVISADO																																																																																								
RESISTENCIA LONGITUDINAL	✓																																																																																								
RESISTENCIA TRANSVERSAL	✓																																																																																								
CARGA DE RUPTURA	✓																																																																																								
BLOQUEO DE MATERIAL	✓																																																																																								
TRATADO SUPERFICIAL DE MATERIAL	✓																																																																																								
ADHERENCIA DE LA TINTA	✓																																																																																								
RESISTENCIA DE SELLOS	✓																																																																																								
<p><small>Los materiales usados en la fabricación de este empaque, 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 parte 177 §1826 FDA: 21 CFR 177.1620(c) 2.2(a) FDA: 21CFR parte 178 §106 y § 330, parte 178 §125,180,200, 210 y 170(c) y que son utilizados para la elaboración de empaques para alimentos de consumo humano.</small></p>																																																																																									
CONDICIONES DE ALMACENAMIENTO																																																																																									
<p><small>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 exceso de calor. Deben estar alejados de materiales arriesgados, químicos y vapores. Evitar contaminación por plagas y polvo. Un periodo largo de almacenamiento puede causar alteraciones en las características y especificaciones técnicas del material.</small></p>																																																																																									
<p><small>El lote al que se hace referencia en el presente certificado cumple con las especificaciones de calidad establecidas, por lo que se LIBERA para su uso comercial como empaque de alimentos.</small></p>																																																																																									

INSPECCIONADO POR
Control de Calidad

Quito
 Av. Patria y Av. Amazonas, Ed. Cofec, 6to. Piso.
 Telf: (593-2) 2228018

Guayaquil
 Av. Juan Tarca Morengo Km. 415
 Telf: (593-4) 2658142

PRODUCTOS PARAISO DEL ECUADOR

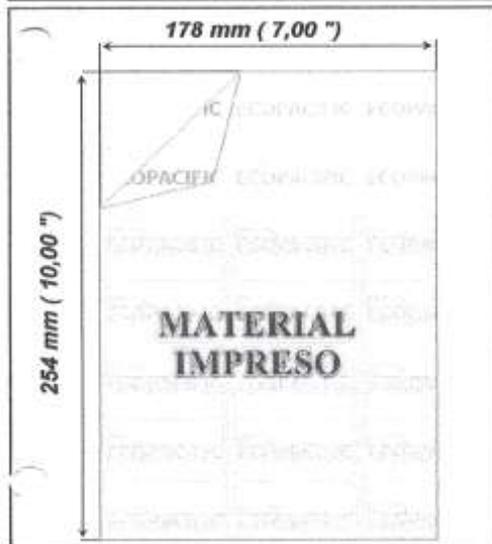
DIVISION POLIETILENO

ESPECIFICACIONES TÉCNICAS

CLIENTE	ECOPACIFIC EMPRESA COMERCIAL DEL PACIFICO S.A
REFERENCIA	SAMBO PICADO

FUNDAS POR PAQUETE	100	TIPO DE EMPAQUE
FUNDAS POR BULTO	4.000	TRADICIONAL TRANSPARENTE
CODIGO	4394.07	

MATERIAL	POLIETILENO EXTRUIDO DE BAJA DENSIDAD
-----------------	--



ESPECIFICACIONES DE MEDIDAS		
PARAMETRO	MEDIDAS	TOLERANCIA
ANCHO	178 mm (7,00 ")	± 5%
LARGO	254 mm (10,00 ")	± 5%
ESPESOR	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-1933 (F)
RESISTENCIA AL DESGARRE TD (gf)	1.200	ASTM D-1933
RESISTENCIA AL IMPACTO (g)	>650	ASTM D-1709
ESFUERZO DE RUPTURA MEDIO (MPa)	24/28	ASTM D-882
DEFORMACIÓN POR RUPTURA MEDIO (%)	100/150	ASTM D-882
SELLABILIDAD (° C)	100 - 105	PPE-1811

Para valoraciones en nuestros laboratorios aplica Norma ASTM

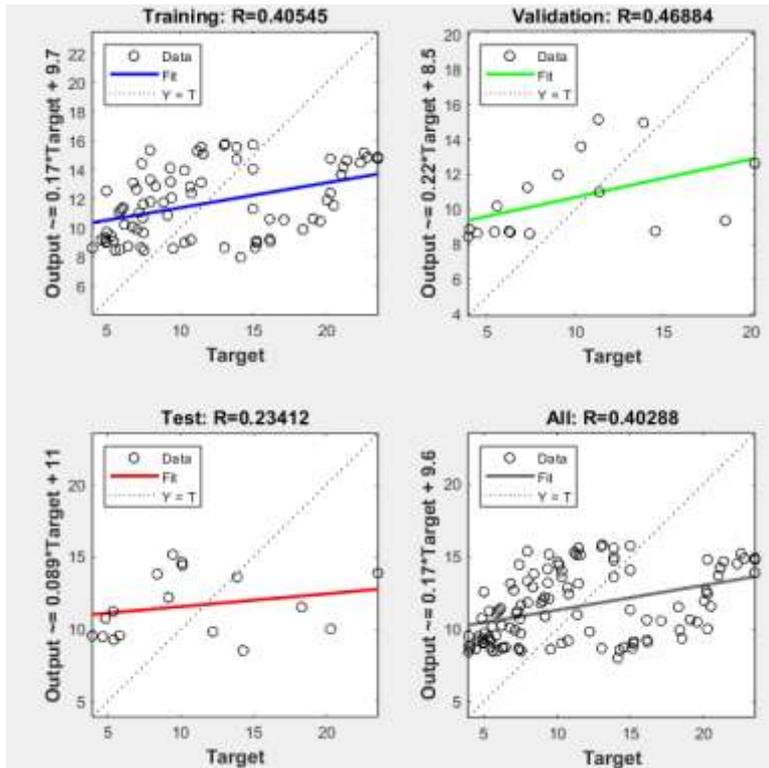
REGULACIONES PARA EL CONTACTO CON ALIMENTOS.

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.

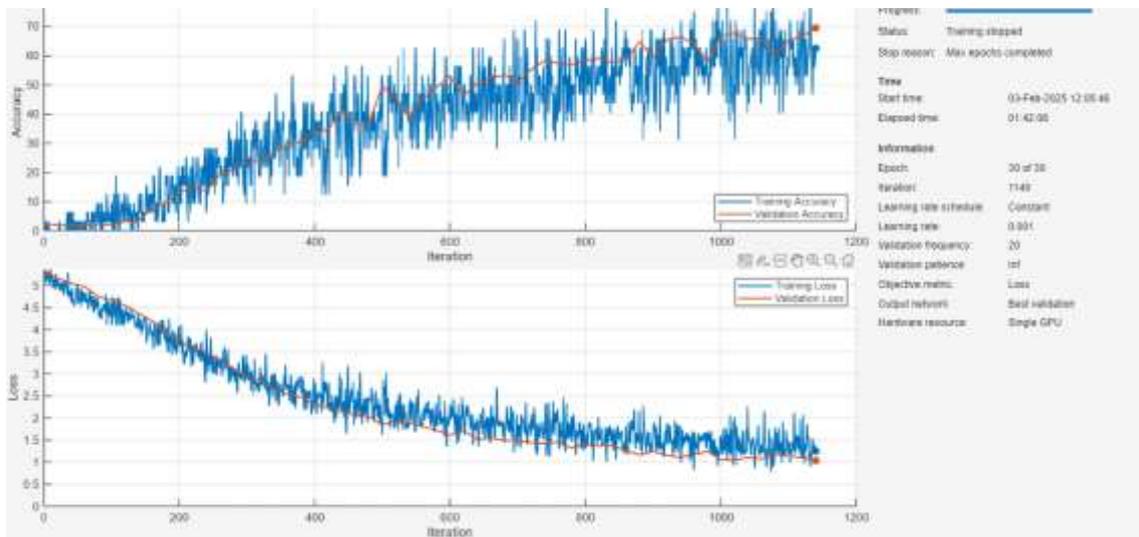
CONDICIONES DE ALMACENAMIENTO Y VIDA ÚTIL

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 periodo 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.

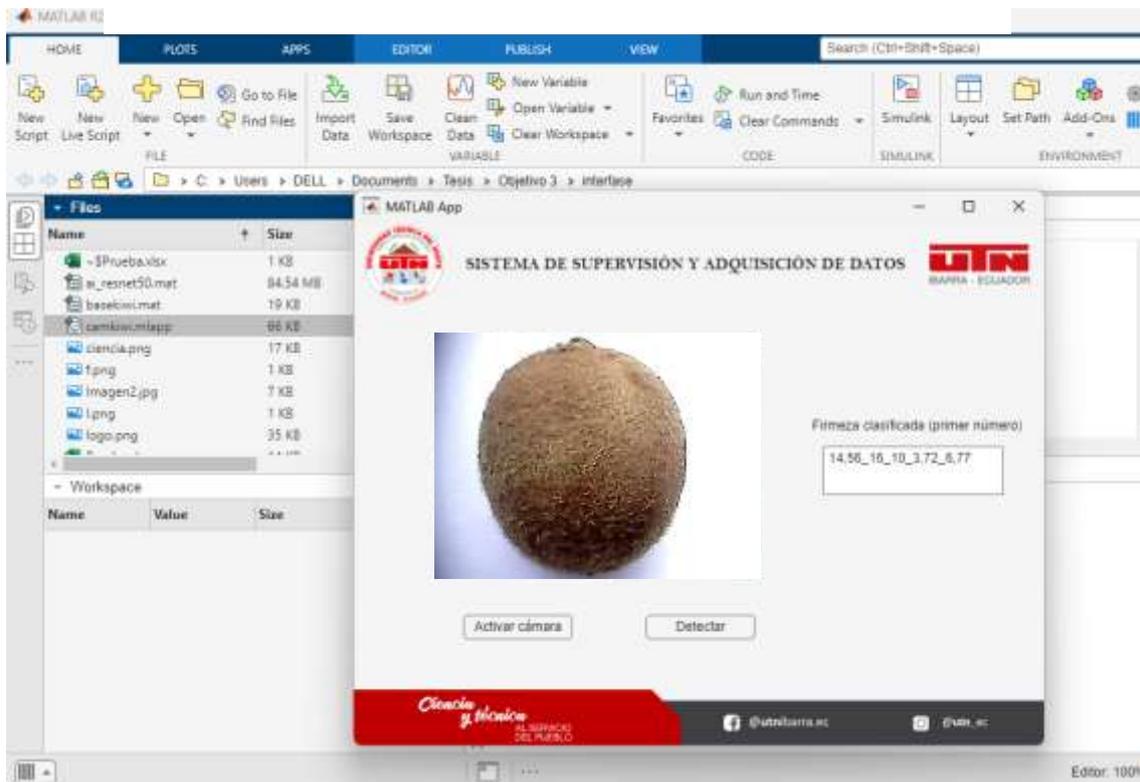
Anexo 2. Gráfico de regresión del mejor modelo representativo de pérdida de firmeza.



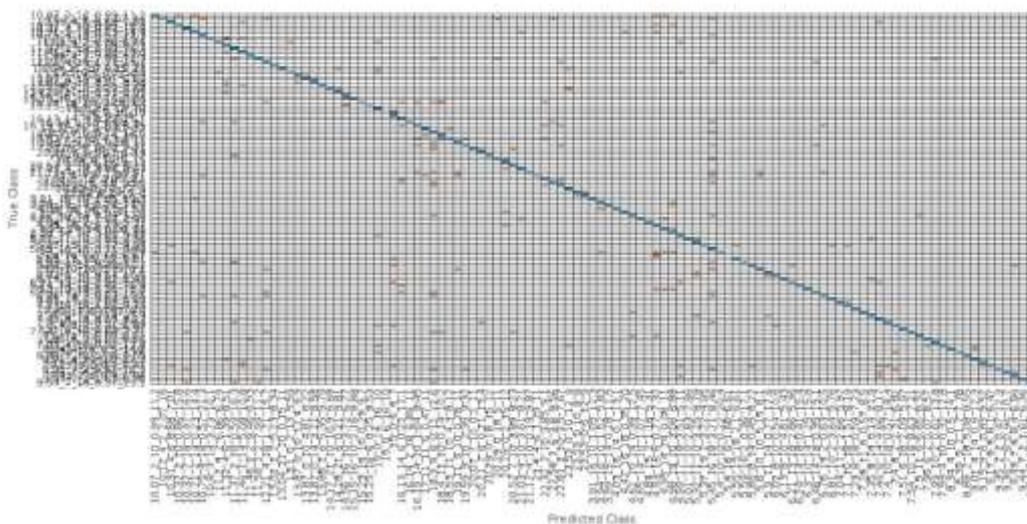
Anexo 3. Informe de entrenamiento de la red neuronal utilizada para el sistema de supervisión.



Anexo 4. Prueba del sistema de supervisión y adquisición de datos.



Anexo 5. Matriz de cofusión de la validación del sistema de supervisión y adquisición de datos.



Anexo 6. Revisión del funcionamiento del modelo propuesto para describir la pérdida de firmeza.

