



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 APLICADA AL CAMBIO DE FIRMEZA DE
AGUACATE *Persea americana* Hass EN ALMACENAMIENTO EN FRÍO”**

Trabajo de titulación previo a la obtención del título de Ingeniero Agroindustrial

Línea de investigación: Gestión, producción, productividad, innovación y desarrollo socio económico.

Autor: Diego Fernando Arias Yépez

Director: Ing. Juan Carlos De la Vega Quintero

Ibarra – 2025

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:	1004963052		
APELLIDOS Y NOMBRES:	Arias Yépez Diego Fernando		
DIRECCION:	Ibarra, argentina 4-51 y brasil		
EMAIL:	dfariasy@utn.edu.ec/ariasdiego020@gmail.com		
TELÉFONO FIJO:		TELF. MOVIL	0963312806

DATOS DE LA OBRA	
TITULO:	EXPERIMENTACIÓN NUMÉRICA APLICADA AL CAMBIO DE FIRMEZA DE AGUACATE <i>Persea americana</i> Hass EN ALMACENAMINETO EN FRÍO
AUTOR (ES):	Arias Yépez Diego Fernando
FECHA: AAAAMMDD	2025/01/24
SOLO PARA TRABAJOS DE TITULACIÓN	
CARRERA/PROG RAMA:	<input checked="" type="checkbox"/> GRADO <input type="checkbox"/> POSGRADO
TÍTULO POR EL QUE OPTA:	Ingeniero en Agroindustrias
DIRECTOR:	Ing. Juan Carlos de la Vega Quintero

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 24 días, del mes de Enero de 2025

EL AUTOR:



Firma.....

Nombre: Arias Yépez Diego Fernando

**CERTIFICACIÓN DIRECTOR DEL TRABAJO DE INTEGRACIÓN
CURRICULAR**

Ibarra, 24 de Enero de 2025

Ing. Juan Carlos De la Vega Quintero

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.

(f)
Ing. Juan Carlos de la Vega Quintero
C.C.: 1002958856

APROBACIÓN DEL COMITÉ CALIFICADOR

El Comité Calificado del trabajo de Integración Curricular ‘Experimentación numérica aplicada al cambio de firmeza de aguacate *persea americana* Hass en almacenamiento en frío” elaborado por Arias Yépez Diego Fernando, previo a la obtención del título del Ingeniero en Agroindustrias, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte:

(f):.....

Ing. Juan Carlos de la
Vega Quintero
C.C.: 1002958856

(f):.....

Ing. Juan Fernando
Guamán Tabango
C.C.: 1002992244

DEDICATORIA

A Dios, por guiar mi camino y darme la fortaleza para superar cada obstáculo.

A mis padres, por su amor incondicional, sus consejos sabios y por enseñarme el valor del esfuerzo y la perseverancia. Este logro es tan suyo como mío. A mi familia, por su apoyo constante y por creer en mí en cada paso del camino. A mis amigos, quienes con su compañía y palabras de aliento hicieron que este viaje fuera más llevadero. Y, finalmente, a todas aquellas personas que de una u otra manera me inspiraron y me impulsaron a no rendirme.

Con todo mi corazón, dedico este trabajo a ustedes.

AGRADECIMIENTO

En primer lugar, agradezco a Dios por darme la fuerza, salud y sabiduría para culminar esta etapa de mi vida. A mis padres, cuyo amor y sacrificio incondicional han sido el pilar fundamental de mi vida, en especial a mi madre. Gracias por ser mi mayor inspiración y por apoyarme en cada decisión que he tomado. A mi familia, por sus palabras de ánimo y su paciencia en los momentos difíciles. Su apoyo fue esencial para alcanzar este logro.

A mi director de tesis, Ing. Juan Carlos De la Vega, por su guía, dedicación y valiosos consejos durante el desarrollo de este trabajo. Su orientación ha sido clave para la realización de esta investigación. A mi asesor, Ing. Juan Guamán, por sus aportes en este estudio al igual que su guía y enseñanzas. A mis profesores, por compartir su conocimiento y por inculcarme el amor por el aprendizaje.

A mis compañeros y amigos, quienes con su apoyo, amistad y colaboración hicieron de este viaje académico una experiencia inolvidable.

A Jocelyn por su amor, comprensión y constante motivación. Gracias por estar a mi lado en cada paso de este camino y por ser mi compañera en esta aventura. Este logro no habría sido posible sin tu apoyo incondicional.

RESUMEN

La maduración y conservación postcosecha del aguacate se prolongan cuando se disminuye la actividad respiratoria y se reduce la tasa de transpiración, mediante el almacenamiento a bajas temperaturas. En este estudio, se utilizó aguacate de la variedad Hass cosechado en Imbabura (Cotacachi), almacenado a diferentes temperaturas (2°C, 6°C, 10°C, 14°C, 18°C) durante un período de 15 días para obtener datos experimentales sobre el cambio de firmeza medidos mediante un texturómetro. Se recolectaron datos, los cuales se sometieron a un proceso de aleatorización para eliminar datos atípicos y se entrenaron mediante técnicas de aprendizaje automático utilizando Matlab, específicamente los programas de regresión integrados como Regression Learner y Neural Net Fitting. El objetivo fue modelar la relación entre la temperatura y el tiempo de almacenamiento en relación con el cambio de firmeza del aguacate. Este modelo permitió crear un programa predictivo para el comportamiento postcosecha del aguacate, proporcionando a los productores información para comercializar el producto en condiciones óptimas, mejorando así su rentabilidad y satisfaciendo las expectativas del consumidor.

Palabras clave: Aprendizaje máquina, firmeza, regresión, refrigeración, 5texturómetro, predicción, modelado

ABSTRACT

Avocado ripening and postharvest conservation are prolonged when respiratory activity is decreased and transpiration rate is reduced by storage at low temperatures. In this study, Hass avocados harvested in Imbabura (Cotacachi) and stored at different temperatures (2°C, 6°C, 10°C, 14°C, 18°C) for a period of 15 days were used to obtain experimental data on the change in firmness measured by means of a texturometer. Data were collected and subjected to a randomization process to eliminate outliers and trained by machine learning techniques using Matlab, specifically integrated regression programs such as Regression Learner and Neural Net Fitting. The objective was to model the interaction between temperature and storage time in relation to avocado firmness change. This model allowed the creation of a predictive program for avocado postharvest behavior, providing growers with information to market the product under optimal conditions, thus improving their profitability and satisfying consumer expectations.

Keywords: machine learning, firmness, regression, cooling, texturometer, prediction, modeling

LISTA DE SIGLAS

AIC. Criterio de Información de Akaike

IA. Inteligencia Artificial.

INEN. Servicio Ecuatoriano de Normalización

LM. Levenberg-Marquardt

MSE. Error cuadrático medio

RNA: Redes neuronales artificiales

RMSE. Desviación estándar de los valores residuales

R². Coeficiente de determinación

SCG. Best Scaled Conjugated Gradient

INDICE DE CONTENIDOS

INDICE DE CONTENIDOS	8
CAPÍTULO 1.....	12
INTRODUCCION	12
1.1. PROBLEMA	12
1.2. Justificación.....	14
1.3. Objetivos.....	15
1.3.1. Objetivo General.....	15
1.3.2. Objetivos específicos.....	15
1.4. Hipótesis.....	15
CAPÍTULO II	16
MARCO TEÓRICO.....	16
2.1. El Aguacate.....	16
2.1.1. Taxonomía.....	16
2.1.2. Maduración	17
2.2. Características fisicoquímicas del aguacate	19
2.2.1. Índice de Madurez	19
2.2.2. Acidez titulable	19
2.2.3. Sólidos solubles	20
2.2.4. Firmeza	21

2.2.5 Estandarización.....	21
2.3. Conservación.....	22
2.3.1. Almacenamiento en frío.....	23
2.4. Inteligencia Artificial.....	24
2.4.1. Matlab.....	24
2.4.2. Redes neuronales artificiales (RNA).....	25
2.4.3. Neuronal Net Fitting.....	25
2.4.4. Regression learner.....	26
2.5. Validación.....	28
2.6. App Designer.....	28
CAPÍTULO III.....	30
METODOLOGÍA.....	30
3.1. Tipo de investigación.....	30
3.2. Ubicación del experimento o del área experimental.....	30
3.3. Métodos, técnicas e instrumentos.....	31
3.4 Evaluar la firmeza del aguacate, considerando temperatura y tiempo de almacenamiento para la obtención de datos experimentales.....	32
3.4.1. Estandarización.....	32
3.4.2. Almacenamiento y toma de datos.....	36
3.4.3. Determinación de firmeza.....	37

3.5. Generar un modelo representativo del cambio de firmeza mediante inteligencia artificial.....	37
3.5.1. Análisis de datos	38
3.5.2. Uso de la aplicación Regression Learner.....	39
3.5.3. Desarrollo de la técnica Neural Net Fitting	41
3.6. Validación de los modelos para elegir el que mejor se ajuste a los datos.....	42
3.7. Crear un sistema de supervisión, control y adquisición de datos aplicando el modelo de IA.....	43
3.7.1. App Designer	43
CAPÍTULO IV.....	44
RESULTADOS	44
En este capítulo se exponen los resultados obtenidos al evaluar la firmeza del aguacate, considerando temperatura y tiempo de almacenamiento, así como el procesamiento de los datos y la creación del aplicativo.....	44
4.1. Caracterización de la materia prima.....	44
4.2 Generar un modelo representativo del cambio de firmeza mediante inteligencia artificial	47
4.2.1 Validación de modelos matemáticos con diferentes datos a los de entrenamiento	52
4.3 Crear un sistema de supervisión, control y adquisición de datos aplicando el modelo de IA.....	55

	11
CAPÍTULO V	59
CONCLUSIONES Y RECOMENDACIONES.....	59
5.1 Conclusiones.....	59
5.2 Recomendaciones.....	60
BIBLIOGRAFÍA.....	61
ANEXOS.....	66

CAPÍTULO I

INTRODUCCION

1.1. PROBLEMA

El aguacate (*Persea americana* Hass) se trata de una fruta que cuenta con gran popularidad a nivel mundial gracias a su distintivo sabor, textura cremosa y beneficios nutricionales especialmente por su contenido de grasas monoinsaturadas (Morales Leonardo et al., 2016). La variedad Hass se cataloga como la más demandada a nivel global, por su versatilidad en los ámbitos de uso, características y manejo post cosecha. Además, gracias a su ubicación geográfica, Ecuador, se caracteriza por tener condiciones climáticas propicias y las regiones primordiales de producción de aguacate como Carchi, Imbabura, Pichincha, Tungurahua, Azuay y Loja, (Quiguango, 2023).

El aguacate es una fruta climatérica, por lo cual está expuesta a cambios fisicoquímicos y daños por frío, lo que ocasiona descomposición fisiológica (Benítez et al., 2021). Es por ello, que la manipulación postcosecha de frutas se debe concentrar en retardar los procesos de deterioro, como la respiración, transpiración y envejecimiento celular (Mata et al., 2022). Como resultado, se ha implementado diferentes métodos para la conservación como la reducción de oxígeno y temperatura, incorporación de sustancias químicas, regulación del pH y la aplicación de atmósferas controladas o recubrimientos protectores. (Quiguango, 2023).

Con respecto al aguacate, uno de los factores cruciales es su firmeza, ya que está estrechamente vinculada con su nivel de madurez y, por ende, su vida útil. Aunque, se reconoce que esta firmeza dependerá de la temperatura y la duración del almacenamiento. (Huamani, 2017), existe una falta de información detallada que permita establecer una relación precisa entre estas variables. Por consiguiente, se considera imprescindible realizar un estudio para identificar la

viabilidad de preservar las características fisicoquímicas del aguacate a lo largo de períodos específicos de almacenamiento bajo condiciones de refrigeración, con el objetivo de minimizar las pérdidas implicadas.

1.2. Justificación

En Ecuador hay alrededor de 7.000 hectáreas dedicadas al cultivo de aguacate afirma Quiquango (2023). Durante el año 2012 se exportaron 34,352 toneladas de aguacate, generando ingresos por un total de 2.3 millones de dólares, de acuerdo con la información suministrada por el Banco Central del Ecuador (2012). Así mismo, existe información insuficiente que permita conocer y tomar decisiones oportunas con base a métodos y/o técnicas enfocadas a minimizar las pérdidas de aguacate. En consecuencia, se reduce la satisfacción del consumidor, ya que, está ampliamente condicionado por la calidad del producto. Este aumento se logra mediante la implementación de enfoques más eficaces en la conservación de la fruta, lo cual mejora la cadena de suministro y favorece a la inversión, contribuyendo así al crecimiento de la producción de aguacate (Chicaiza, 2020).

Además, por la insuficiente investigación postcosecha de frutas, se dificulta reducir las pérdidas en esta etapa crucial del desarrollo del aguacate. Esta deficiencia se debe a la complejidad de representar la interacción de variables como temperatura, tiempo, pH y estado de madurez, que afectan el proceso de degradación de los alimentos, debido a la falta de información sobre herramientas tecnológicas que impiden optimizar estos procesos (Márquez et al., 2014). Si se logra relacionar estas variables, se podrá predecir el comportamiento postcosecha y reducir pérdidas mediante un modelado matemático (P. Rodríguez & Henao, 2017).

Por ello, esta investigación se centra en la experimentación numérica del cambio de firmeza del aguacate considerando las variables de temperatura y tiempo de almacenamiento, utilizando técnicas de inteligencia artificial utilizando el programa Matlab. El objetivo es desarrollar un algoritmo predictivo que mejore las prácticas de almacenamiento a base de aprendizaje de máquina, creando un algoritmo que ayude a predecir la firmeza del aguacate.

1.3. Objetivos

1.3.1. Objetivo General

- Modelar la degradación de firmeza del aguacate *Persea americana* hass durante su almacenamiento bajo refrigeración, a través de inteligencia artificial.

1.3.2. Objetivos específicos

- Evaluar la firmeza del aguacate, considerando 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.

1.4. Hipótesis

Alternativa

El cambio de firmeza del aguacate se puede representar en un modelo matemático en función de la temperatura y el tiempo de almacenamiento

Nula

El cambio de firmeza del aguacate no se puede representar en un modelo matemático en función de la temperatura y el tiempo de almacenamiento

CAPÍTULO II

MARCO TEÓRICO

2.1. El Aguacate

El aguacate, "*Persea americana* Mill.", forma parte de la familia Lauraceae (Arias et al., 2018), este árbol es originario de las zonas tropicales de México y América central, y ha sido conocido y empleado por el hombre a través de los siglos (Osuna García et al., 2017). Se trata de un fruto climatérico, lo que significa que debe ser recolectado en su etapa de madurez fisiológica para desarrollar las propiedades óptimas de sabor y textura (Carvalho et al., 2009).

En Ecuador, se envían al extranjero las variedades Hass y Fuerte (también conocida como guatemalteco). A pesar de esto, el país cuenta con más de 20 tipos distintos de aguacates. La variedad "fuerte" es altamente solicitada a nivel nacional porque alcanza su madurez 10 días después de la cosecha. En contraste, la variedad "*Hass*" madura en 15 días y tiene un contenido de aceite superior, convirtiéndola en la más solicitada en el mercado internacional, Tiene una forma ovoide, con una piel rugosa y de textura similar al corcho. Su color distintivo varía desde un tono mate hasta negro. La semilla es de tamaño pequeño y presenta una forma esférica. La pulpa, por su parte, es de un tono verde amarillento, con una textura suave y libre de fibras. (Quiguango, 2023).

2.1.1. Taxonomía

Con una textura cremosa y un sabor excepcional, el aguacate *Hass* se distingue por su tamaño reducido, tiene una forma ovalada y una piel áspera con textura granulada. Su distintivo color verde oscuro evoluciona a un tono morado-negruzco cuando alcanza su punto de madurez, lo que lo hace ideal para ser consumido. (Sanchez, 2018).

Tabla 1
Taxonomía del aguacate

Taxonomía del Aguacate	
Reino	Vegetal
División	Spermatophyta
Subdivisión	Angiospermae
Clase	Dicotyledoneae
Subclase	Dipetala
Orden	Ranales
Familia	Lauraceae
Género	Persea
Especie	<i>Persea americana</i> Miller, <i>Persea gratissima</i> Gaerth, <i>Persea drymifolia</i> Blake.

Tomado de Sánchez (2018)

2.1.2. Maduración

Las características de la fruta comienzan a definirse desde el momento de la cosecha, donde se evalúa su madurez fisiológica. Se reconoce que esta madurez influye tanto en la calidad durante el almacenamiento como en la comestibilidad del fruto. Se destaca que un aguacate fisiológicamente maduro es aquel que ha alcanzado un estado específico de desarrollo, permitiendo que, si se cosecha, madure hasta alcanzar su desarrollo ontogénico con un sabor aceptable y una textura reconocible (Díaz, 2023). Por el contrario, una fruta fisiológicamente inmadura es aquella que no ha alcanzado ese estado particular de desarrollo. Aunque pueda ablandarse, no alcanzará la


calidad comestible aceptable. Si un fruto inmaduro se almacena en condiciones propicias para su maduración normal, suele encogerse, volverse gomoso y perder su coloración original (Huamani, 2017).

- Madurez fisiológica

La madurez fisiológica es la etapa que definido por la norma NTE INEN (1 755:2009, 2009), es el momento en que un fruto, tras ser recolectado, tiene la capacidad de continuar su proceso de desarrollo y lograr las mejores cualidades de sabor.

Figura 1

Maduración de aguacate *Hass*



Tomado de NTE INEN (1 755:2009, 2009)

- Madurez de consumo

Por otro lado, definiendo a la madurez de consumo es la etapa donde se obtiene un tejido fisiológicamente maduro, donde se desarrollan las propiedades organolépticas necesarias para que sea apto para el consumo (NTE INEN 1 755:2009, 2009).

2.2. Características fisicoquímicas del aguacate

El aguacate Hass (*Persea americana*), es altamente valorado en todo el mundo debido a las destacadas cualidades funcionales y sensoriales que presenta en su pulpa. Este fruto, que es rico en vitaminas, grasas poliinsaturadas, minerales y componentes activos, se ha establecido como un alimento funcional de gran importancia (P. Rodríguez & Henao, 2017). Es crucial destacar que el aguacate no completa su proceso de maduración en el árbol. Por lo tanto, se utilizan varios criterios como indicadores de su madurez en la cosecha, como el brillo en la cáscara, la longitud y el diámetro del fruto, la tasa de respiración y la materia seca, entre otros. Esta etapa es fundamental ya que tiene un impacto directo en la adecuada maduración del aguacate (Astudillo & Rodríguez, 2018).

2.2.1. Índice de Madurez

Con el objetivo de lograr atributos de calidad apropiados y reducir los defectos en la etapa postcosecha, se utiliza el índice de madurez de cosecha como un marcador de calidad y, a su vez, como un criterio decisivo en la recolección de los frutos (Cerdas et al., 2014).

“El índice de madurez se obtiene calculando la relación entre el menor valor de los sólidos solubles totales (°Brix) y el mayor valor de la acidez titulable, y se representa como: °Brix/% ácido cítrico” (NTE INEN 2427, 2016).

$$\text{Índice de madurez} = \frac{SST(^{\circ}Brix)}{Acidez\ titulable} \quad (1)$$

2.2.2. Acidez titulable

La acidez titulable es un parámetro importante que implica obtener la concentración de un ácido o una base a través de la adición de un volumen establecido de una solución de concentración conocida. Este método se emplea para identificar y cuantificar ácidos orgánicos como el ácido

cítrico, el ácido málico y el ácido tartárico, entre otros. En el caso del aguacate, el ácido cítrico y el ácido tartárico son los más predominantes. Además, se ha observado que 1 ml de una solución de NaOH 0.1 N equivale a 64 g de ácido cítrico y 75 g de ácido tartárico (Quiguango, 2023).

Para medir la acidez titulable en frutas, se sigue la norma INEN 381, utilizando un potenciómetro y NaOH. Se emplea el método de titulación, que consiste en neutralizar los iones H^+ con NaOH en presencia de un indicador (fenolftaleína). En la Tabla 2 se especifica el factor apropiado para el ácido predominante (Quiguango, 2023).

Tabla 2
Ácidos que predominan en el aguacate

Ácido	Factor
Ácido cítrico	0.64
Ácido tartárico	0.75

Tomado de Quiguango (2023)

2.2.3. Sólidos solubles

El término "sólidos solubles" se utiliza para referirse al porcentaje de sacarosa contenido en una muestra de fruta, y se cuantifica en valores °Brix. La presencia de sólidos solubles guarda una relación proporcional con la maduración de la fruta; de manera que ésta madura, la cantidad de °Brix aumenta (Sandoval et al., 2017). La medición de este contenido se lleva a cabo mediante muestras de pulpa, utilizando un refractómetro (óptico o digital). Este dispositivo permite precisar la cantidad de sólidos solubles, generalmente expresados en °Brix, aunque también pueden ser expresados en términos de índice de refracción (Marcillo & Macías Jhonny, 2022). Según la Norma NTE INEN 1755:2009 la cantidad de sólidos solubles presentes en el aguacate es alrededor de 6 – 7 °Brix.

2.2.4. Firmeza

La firmeza de los frutos es una característica que disminuye gradualmente mientras que el fruto madura. A medida que la fruta se acerca al punto ideal para su consumo, la velocidad de esta disminución aumenta, llegando a ser casi nula durante la plena maduración. Es importante señalar que esta característica puede variar según la región donde se cultive el aguacate y el día en que se coseche (Sandoval et al., 2017).

Otros factores que afectan el deterioro en la postcosecha son la temperatura y el tiempo de almacenamiento, ya que están directamente relacionados con las condiciones que definen la vida útil de la fruta. Estos factores afectan a características clave como el color, la apariencia, la textura y especialmente, la firmeza de la fruta (Huamani, 2017).

La firmeza está relacionada directamente con la resistencia necesaria para romper los tejidos carnosos del fruto, y con los cambios en las propiedades físicas que ocurren debido a la presión mecánica (Herrera et al., 2017). Esta variable se mide mediante diversos métodos, entre los cuales se incluyen la punción, la compresión y, predominantemente, la penetración (Gavicho Uarrota & Pedreschi, 2022). El último método se lleva a cabo utilizando un texturómetro, que emplea una aguja para penetrar el tejido del fruto y determinar su firmeza. Las unidades de medida proporcionadas dependen del modelo de texturómetro, siendo los Newtons (N) la unidad utilizada en estas evaluaciones (Zapata. L et al., 2007).

2.2.5 Estandarización

Para comprender que es la estandarización se deben definir los siguientes términos que la "Norma Técnica Ecuatoriana NTE INEN 1750 Hortalizas y Frutas Frescas", esta norma define el procedimiento para la recolección de muestras en hortalizas y frutas frescas.

- Lote: Una cantidad determinada de la partida, que se asume posee características homogéneas, como la variedad, el grado de madurez, la frescura, el tipo, el tamaño, el calibre, el empaque o el embalaje, que facilitan la evaluación de la calidad y se inspeccionan como una unidad única (NTE INEN 1750:1994, 2012).
- Muestra: Conjunto de unidades seleccionadas de un lote, cuyo propósito es tener la información complementaria para evaluar características del lote, y así tomar decisiones sobre el lote o el proceso que lo originó (NTE INEN 1750:1994, 2012).

2.3. Conservación

Los alimentos requieren procesos de tratamiento para prolongar su durabilidad, y necesitan condiciones específicas para su conservación. (Par Gramajo, 2017) sugiere que la principal causa de su deterioro radica en la acción de bacterias, así como diversos tipos de microorganismos como mohos y levaduras. Entre los principales métodos de conservación se destaca el uso de bajas temperaturas, conocido como conservación por frío, el cual inhibe, total o parcialmente, los agentes que provocan alteraciones, permitiendo así la preservación a largo plazo de los alimentos, en la siguiente tabla 3 se presentan algunas alternativas de post cosecha de alimentos

Tabla 3

Métodos de conservación de frutas

Método	Ejemplos
Conservación a corto plazo	Uso de refrigeración o almacenamiento en atmósferas controladas. También se emplean sistemas de embalaje con gases inertes como nitrógeno o dióxido de carbono.
Tratamientos químicos	Aplicación de sustancias que reducen la actividad del agua, como sal o azúcar, además de ácidos

Fuente: Ulloa (2007)

Para garantizar la preservación y almacenamiento adecuados es fundamental realizar una clasificación según su tamaño, color y asegurar que estén libres de impurezas, ya que estas pueden influir negativamente en su vida útil. Dado que la mayoría de los productos frescos son perecederos, es crucial emplear un plan de conservación más adecuado para alargar el tiempo de duración. En términos generales, se pueden utilizar varios métodos de conservación para frutas y hortalizas. (Chicaiza, 2020).

2.3.1. Almacenamiento en frío

Para conservar productos agrícolas en almacenamiento en frío, es esencial que la temperatura de los productos al ser transportados desde el campo no difiera significativamente de la temperatura en el almacenamiento en frío, ya que grandes diferencias pueden causar daños (Osuna García et al., 2017). Para prevenir esto, se lleva a cabo un proceso conocido como "pre-enfriamiento", el cual se encarga de bajar la temperatura de los frutos. Este procedimiento es particularmente importante para frutas y verduras (Chicaiza, 2020).

Actualmente, se emplean técnicas avanzadas que relacionan parámetros como pH, acidez, sólidos totales, textura, color y firmeza para modelar el comportamiento de la fruta durante el almacenamiento (Lara, 2022). Estas técnicas, que utilizan la inteligencia artificial (IA), son fundamentales para prevenir el deterioro del producto. Así, el aprendizaje de máquina juega un papel destacado al crear modelos predictivos basados en datos, lo que permite prever el comportamiento de la fruta con mayor precisión.

2.4. Inteligencia Artificial

Según la autora (Lara, 2022) la inteligencia artificial (IA) se describe como una de las principales ramas de la informática, ya que consiste en una tecnología que busca emular la capacidad intelectual humana en computadoras. En este sentido, la IA puede replicar los procedimientos de pensamiento humano utilizando máquinas. La adquisición de conocimiento en esta área se logra mediante la recopilación de datos, su procesamiento y la capacidad de autocorrección. Algunas de las áreas específicas donde se aplica la inteligencia artificial son los sistemas expertos, el reconocimiento de voz y la visión artificial.

2.4.1. Matlab

MATLAB es una plataforma de desarrollo y computación diseñada para proyectos que implican cálculos matemáticos avanzados y la visualización gráfica de datos. Combina herramientas para análisis numérico, cálculo matricial, procesamiento de señales y gráficos en un entorno único e integrado. Su mayor ventaja radica en que permite expresar problemas y soluciones de forma directa, sin necesidad de programación tradicional.

Además, MATLAB cuenta con una amplia gama de Toolboxes especializados que amplían las capacidades del programa principal. Estos Toolboxes cubren campos tal cual son, procesamiento de imágenes, análisis de señales, control robusto, estadísticas, análisis financiero, matemáticas simbólicas, redes neuronales que simulan el comportamiento de las neuronas del cerebro, entre otros. MATLAB es un estándar de la industria para el cálculo técnico y la visualización numérica, ofreciendo capacidades avanzadas y sin igual en su campo (Plata, 2015).


2.4.2. Redes neuronales artificiales (RNA)

La Red Neuronal Artificial (RNA) cuya estructura se acerca a la de las neuronas en el cerebro es un programa, diseñada como un modelo de computación distribuida que conecta varios procesadores básicos (Lara, 2022). Este diseño busca imitar el funcionamiento del sistema nervioso humano, el cual se destaca por su capacidad de aprender a partir de la experiencia generalizado a partir de una base de datos. La RNA logra aprender de los datos mediante un entrenamiento secuencial en el que, a través de repeticiones, la red neuronal desarrolla habilidades para reconocer ejemplos, clasificar datos y predecir situaciones futuras (Moreno, 2023).

Hay diferentes tipos de redes neuronales, véase en la figura 2, pero siempre constan de los mismos componentes:

Figura 2

Componentes de las Redes Neuronales



Fuente: (González, 2021)

2.4.3. Neuronal Net Fitting

La red neuronal artificial implementada en MATLAB emplea un algoritmo de retroalimentación de errores para evaluar los pesos de la red, mostrando atributos de sistema dinámico que facilita la construcción y programación de redes. Tras adquirir conocimientos a partir de


patrones de entrada para la predicción, el modelo de red neuronal de tres neuronas somete a un examen de la capacidad de ajuste y precisión comparativamente con un modelo de regresión. La red neuronal muestra una ventaja clara sobre el modelo de regresión en términos de rapidez de ajuste y precisión del modelo.

2.4.4. Regression learner

La herramienta Regression Learner permite entrenar modelos de regresión para predecir información, como se indica en la figura 3. Mediante esta herramienta, es posible analizar datos, elegir los parámetros a estudiar, definir estructuras de validación, entrenar modelos y evaluar de manera consecutiva los resultados obtenidos. También es posible realizar un entrenamiento automatizado con el objetivo de encontrar el tipo de modelo de regresión más adecuado, incluyendo opciones como modelos lineales de regresión, árboles de regresión, modelos de procesos gaussianos, máquinas de soporte vectorial, modelos de aproximación de kernel, conjuntos de árboles de regresión y modelos de redes neuronales para regresión (Entrenar Modelos de Regresión - MATLAB - MathWorks América Latina, n.d.b., 2020).

Figura 3

Proceso común para entrenar en la aplicación Regression Learner..



Nota. Adaptado de (Entrenar Modelos de Regresión - MATLAB - MathWorks América Latina, n.d.c., 2020).

- **Métricas de evaluación del modelo de regresión**

Utilizando un modelo de regresión, podemos prever o calcular el valor numérico de una cantidad desconocida basándonos en ciertas características conocidas. La discrepancia entre nuestra predicción y el valor real se conoce como error, siendo este último una variable aleatoria que puede variar dependiendo de las características específicas consideradas. En la actualidad, existen diversas técnicas para estimar el desempeño y evaluar la precisión del modelo utilizado (Lara, 2022).

- **Error cuadrático medio (MSE)**

El error cuadrático medio (MSE) se utiliza para medir la exactitud de los modelos de regresión al determinar el cuadrado de la diferencia entre los valores previstos por el modelo y los valores observados reales. Este cálculo se basa en la discrepancia entre las estimaciones del modelo y los valores observados (también conocidos como valores reales) para cada punto de datos. Posteriormente, se eleva al cuadrado esta discrepancia con el fin de evitar que los valores negativos anulen los valores positivos, y se obtiene el promedio de todas estas diferencias al cuadrado. Un MSE menor sugiere un mejor rendimiento del modelo, ya que indica que las predicciones están más cerca de los valores reales (Restrepo & Sánchez, 2023).

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

El coeficiente de determinación R^2 se utiliza para evaluar qué proporción de la variabilidad de una variable dependiente puede ser explicada por una o más variables independientes en un modelo. Este coeficiente varía entre 0 y 1: un valor de 0 indica que el modelo no explica ninguna variación en la variable dependiente, mientras que un valor

de 1 señala que explica toda la variabilidad. Cuando R^2 se aproxima a 1, sugiere que el modelo se ajusta adecuadamente a los datos; por el contrario, un valor cercano a 0 indica que el modelo no es adecuado para describir la variabilidad observada. (Restrepo & Sánchez, 2023).

2.5. Validación

La validación del modelo se refiere al proceso de evaluar la capacidad de un modelo predictivo entrenado para generalizar consiste en determinar si puede realizar predicciones precisas sobre datos nuevos que no fueron utilizados durante el entrenamiento. Esta validación es esencial para prevenir el sobreajuste y asegurar que el modelo sea capaz de extrapolar patrones y relaciones a datos no observados previamente. Por otro lado, la verificación del modelo implica compararlo con estándares, identificar y corregir errores de diseño, evaluar propiedades clave y realizar simulaciones para demostrar que los resultados del modelo coinciden con lo esperado. (Rodríguez & Rodríguez, 2021).

2.6. App Designer

App Designer es una herramienta que posibilita la creación de aplicaciones y la definición de su funcionamiento de manera visual y sencilla. Integra el editor de MATLAB y ofrece una variedad de componentes interactivos para la interfaz de usuario. Además, incluye un sistema de diseño de cuadrículas para organizar la interfaz y opciones de ajuste automático que permiten que la aplicación se adapte al tamaño de la pantalla. También facilita la distribución de las aplicaciones, permitiendo empaquetarlas en archivos de instalación directamente desde la barra de herramientas de App Designer o generar aplicaciones web o de escritorio independientes. (The MathWorks, 2024).

App Designer ofrece una amplia gama de elementos para la creación de aplicaciones profesionales, incluso para aquellos que no son desarrolladores de software profesionales. Su interfaz simplifica significativamente el proceso de programación, destacando las siguientes ventajas:

- **Empaquetado Sencillo de Aplicaciones MATLAB:** Facilita la creación de un único archivo que contiene aplicaciones MATLAB, el cual puede compartirse de manera conveniente con otros usuarios mediante MATLAB Desktop y MATLAB Online. Al empaquetar una aplicación, MATLAB genera un archivo de instalación único (.mlappinstall), permitiendo una instalación rápida y acceso directo desde la galería de aplicaciones con un solo clic (Rodríguez & Rodríguez, 2021).
- **Creación Integral de Aplicaciones:** App Designer unifica las dos tareas esenciales en la creación de una aplicación: la organización de los componentes visuales en la interfaz gráfica de usuario (APP) y la programación del comportamiento de la aplicación. Este enfoque integrado facilita el desarrollo eficiente de aplicaciones (Rodríguez & Rodríguez, 2021).

CAPÍTULO III

METODOLOGÍA

3.1. Tipo de investigación

Esta investigación fue de carácter cuantitativo el cual adoptó un enfoque científico y experimental, ya que involucró la realización de experimentos con el propósito de evaluar cómo la temperatura y el tiempo de almacenamiento influyen en la firmeza del aguacate Hass.

3.2. Ubicación del experimento o del área experimental

La ejecución de la etapa experimental tuvo lugar en la ciudad de Ibarra, en los laboratorios de análisis experimental e innovación en la Facultad de Ingeniería en Ciencias Agropecuarias y Ambientales (FICAYA) así como también en el laboratorio del campus San Vicente de Paúl de la Universidad Técnica del Norte. En la Tabla 4 se detalla la ubicación de la fase experimental.

Tabla 4

Ubicación del experimento

Provincia	Imbabura
Cantón	Ibarra
Parroquia	El Sagrario
Altitud	2.256 m.s.n.m.
Humedad relativa promedio	97%
Precipitación	Promedio 550 m/Año
Temperatura promedio	15.4°C

Fuente: INAMHI, (2022)

3.3. Métodos, técnicas e instrumentos.

Los materiales de campo, de laboratorio, equipos y software que se emplearon en el desarrollo de la investigación se describen en la tabla 5.

Tabla 5

Materiales, equipos, software

Equipos	Materiales	Insumos	Reactivos	Software
Refractómetro digital	Soporte universal	Aguacate	Hidróxido sodio (NaOH) solución 0,1N	de Microsoft Word.
Balanza digital Scale	Bureta de vidrio (25- 50ml)		Fenolftaleína 1%	al Microsoft Excel
Refrigeradora	Probeta de 100ml		Agua destilada	Plataforma de programación MATLAB
Controladores	Frasco de Erlenmeyer 250ml			
Agitador magnético	Vaso de precipitación			
Colorimétrico	Mortero			
Medidor de pH (potenciómetro)				

3.4 Evaluar la firmeza del aguacate, considerando temperatura y tiempo de almacenamiento para la obtención de datos experimentales.

Se implementó técnicas y métodos para la obtención, estudio y evaluación de datos experimentales, que permitieron modelar los mismos a través de un entrenamiento y validación usando IA.

3.4.1. Estandarización

La recopilación de datos se realizó mediante la utilización de aguacate *Hass*. La materia prima se adquirió de productores locales, en un estado de madurez fisiológica, de acuerdo con la norma NTE INEN (1 755:2009, 2009) es aquella etapa en la cual la fruta, al ser cosechada, tiene la capacidad de continuar su desarrollo ontogénico y adquiere las características gustativas óptimas. En la figura 4 se muestra una escala de maduración del aguacate, donde se tomó como referencia para este estudio la etapa 1 y 2. Asimismo, en la tabla 6 se muestra los parámetros de calidad para la variedad *Hass*.

Figura 4

Escala de maduración del aguacate



Fuente: Tomado de (Herrera et al., 2017)

Tabla 6

Requisitos fisicoquímicos de aguacate Hass

Parámetro	Madurez Fisiológica	Método de ensayo
Contenido de aceite, % m/m	11,0-12,0	Método de extracción Soxhlet, y el resultado se expresa en porcentaje de masa.
Acidez titulable (ácido tartárico), % m/m	8-9	NTE INEN 381
Sólidos solubles, %	6-7	NTE INEN 380
Penetrabilidad, kg/cm^2	50-54	Se determina con un penetrómetro (embolo 5 mm) su resultado se expresa en kg/cm^2
pH	6,93-6,95	NTE INEN 389

Fuente: NTE INEN (1 755:2009, 2009)

Definidos los parámetros de recepción de aguacate se estandarizó la muestra con la ecuación (1), donde interviene la medición de sólidos totales (Brix) y acidez titulable, esto permitirá partir de un mismo índice de madurez en todas las unidades experimentales.

$$\text{Índice de madurez} = \frac{\text{Sólidos solubles (\%Brix)}}{\text{Acidez total (\%)}} \quad (1)$$

Fuente: (NTE INEN 2427, 2016)

Se midió la misma magnitud con el objetivo de obtener resultados estadísticamente válidos. La decisión de incrementar o no el número de mediciones dependió de la dispersión observada. Para tomar esta decisión, se realizó la toma de tres medidas de la misma magnitud (X_1, X_2, X_3), se calculó el valor de la dispersión D y, a partir de este valor, se determina el porcentaje de dispersión, T, que viene dado por:

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

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

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

donde;

T= Porcentaje de dispersión

D= Dispersión total

\bar{X}_n = Es el valor medio de n medidas.

n= Total de medidas

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

$$\bar{X}_n \pm S$$

Si el valor de D es mayor que S, se procederá a aumentar el número de medidas de la magnitud. Este aumento se condiciona por el valor del porcentaje dispersión T, detallado en la tabla 7.

Tabla 7

Criterio por seguir con relación al valor del porcentaje de dispersión T.

Porcentaje de dispersión (T)	Medidas necesarias
$T_3 \leq 2\%$	Bastan las 3 medidas realizadas
$2\% < T_3 \leq 8\%$	Hay que hacer 3 medidas más, hasta un total de 6
$8\% < T_6 \leq 15\%$	Hay que hacer un total de 15 medidas
$15\% < T_{15}$	Hay que hacer un mínimo de 50 medidas

Fuente: Miguel & Chinchilla, n.d., (2010)

- **Determinación de la acidez titulable**

La obtención de la acidez titulable acorde a la normativa (NTE INEN-ISO 750, n.d.), se realizó mediante titulación y por triplicado de solución de agua destilada (45 ml) con 5 g de pulpa en un vaso de precipitado. Previamente la muestra se extrajo con ayuda del mortero, pelando, cortando y machacando la fruta estudiada, se añadirán tres gotas de fenolftaleína a la muestra. Luego, se incorpora lentamente NaOH 0.1 N hasta que la pulpa cambie de color de manera ligera pero permanente. Al finalizar, se registran los mililitros de hidróxido de sodio utilizados hasta el cambio de color. Con esta información, se aplica la ecuación (5) y los resultados de acidez se expresan como un porcentaje del ácido cítrico presente en la muestra.

$$\text{Acidez total} = (V) \cdot (2) \cdot (F) \quad (5)$$

Donde:

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

V= volumen de solución de NaOH 0.1N empleado en la titulación.

F= Factor de acidez del ácido cítrico (0.064), (NTE INEN-ISO 750, n.d.).

- **Determinación de sólidos solubles totales**

Este procedimiento se realizó de acuerdo con la norma NTE INEN 8380, se trabajó con la ayuda del refractómetro digital, equipo con el cual se determina el Grados °Brix. En este instrumento se tomó tres medidas independientes de una misma muestra, empleando para cada una de ellas unas gotas de pulpa, tomando como valor definitivo la media de los tres valores obtenidos de acuerdo con la ecuación (6) (Chiang María & Taipei Juan, 2017)

$$\text{Sólidos solubles totales} = \frac{\sum 3 \text{ mediciones } (^{\circ}\text{Brix})}{3} \quad (6)$$

3.4.2. Almacenamiento y toma de datos

Al estandarizar la materia prima, el aguacate se almacenó en refrigeración, las condiciones óptimas de temperatura según (Benítez et al., 2021) están entre 5-9°C y con un tiempo de almacenamiento de 20 días. En esta investigación para obtener un modelo robusto y eficiente, se medirán datos entre 2 a 18°C empezando en 2°C con intervalos de 4°C y alcanzando los 100 datos experimentales (por triplicado), para ello se utilizó el texturómetro SHIMADZU EZ-SX que se encuentra en el laboratorio de Análisis Físico Químico y Microbiológico ubicado en el campus San Vicente de Paul.

3.4.3. Determinación de firmeza

Para la obtención de la variable firmeza, se utilizó el reporte generado por el texturómetro Shimadzu EZ-SX. Se realizaron tres mediciones por muestra, y el promedio de estas fue considerado como el dato experimental. Cabe destacar que las lecturas obtenidas del equipo están expresadas en unidades de fuerza (Newtons, N). Sin embargo, para satisfacer los requisitos de la norma NTE INEN 1755:2009 y facilitar un análisis comparativo, se decidió comparar la firmeza en unidades de presión, específicamente en kilogramos fuerza por centímetro cuadrado (kgf/cm^2).

Desde una perspectiva física, la presión se define como:

$$P = \frac{F}{A} \approx P = \frac{F_{medición}}{A_{aguja}}, \quad (7)$$

Donde:

- $F_{medición}$ representa la fuerza medida por el texturómetro en Newtons (N).
- A_{aguja} corresponde al área de la aguja utilizada, expresada en centímetros cuadrados (cm^2).

Este procedimiento permitió convertir las unidades a kgf/cm^2 , garantizando consistencia con las especificaciones normativas y mejorando la interpretación de los resultados.

3.5. Generar un modelo representativo del cambio de firmeza mediante inteligencia artificial.

A continuación, se describe el procedimiento para realizar el análisis de datos utilizando inteligencia artificial.

3.5.1. Análisis de datos

Los datos de la fruta fueron recolectados durante el período de almacenamiento, registrados y contabilizados para su análisis posterior. Se empleó aprendizaje automático (machine learning), el cual, de manera autónoma (es decir, sin necesidad de programación específica), logra extraer información significativa de los datos procesados (González-García, 2018). Antes de ello, se debe obviar los datos atípicos para un estudio más confiable, una vez apartados estos datos se seleccionaron el 70% de ellos para aleatorizar y proceder a su entrenamiento y el 30% restante se emplearon en la validación respectiva.

Para el entrenamiento del 70% de los datos, se trabajó la estrategia de muestreo (Bootstrap). Ledesma (2008), menciona que esta técnica considera un enfoque versátil que puede abordar diversos objetivos de análisis de datos. Esta estrategia estadística fue clave para tratar con la cantidad limitada de datos experimentales (De la Rosa, n.d.), proporcionando estimaciones fiables de la variabilidad y la precisión de las predicciones. A través de la generación de múltiples subconjuntos de datos, logrando validar la estabilidad de los modelos, lo que reforzó la confianza en los resultados obtenidos. Una vez aleatorizados todos los datos se dividieron en cuatro conjuntos fijos, los cuáles se entrenaron posteriormente con la ayuda de las aplicaciones de Matlab regresión learning y neural net fitting.

Para evaluar la efectividad del entrenamiento, se analizaron los indicadores de regresión, como el Error Cuadrático Medio (MSE), para los modelos. Los valores de MSE se encuentran en el intervalo de 0 a 1, donde 1 refleja una diferencia absoluta de las predicciones del modelo y los datos reales. En consecuencia, se buscó un modelo con un MSE más bajo, acercándose a 0. Además, se consideró el coeficiente de determinación (R^2), que también varía de 0 a 1, siendo así,

los valores que se acercaron a 1 indican una correlación positiva entre variables, por lo que se aspiró a seleccionar un modelo con un R^2 más alto.

- Error cuadrático medio (MSE)

Evalúa la discrepancia entre los valores reales y los predichos, calculando el promedio de las diferencias al cuadrado a lo largo de todo el conjunto de datos (González, 2018).

$$\text{MSE} = \frac{1}{n} \sum (Y_n - \bar{Y})^2 \quad (7)$$

- Coeficiente de determinación (R^2)

Representa el coeficiente que mide qué tan bien los valores predichos se ajustan a los valores reales, con un rango que va de 0 a 1, que puede interpretarse como un porcentaje. A mayor valor, mejor será el rendimiento del modelo (González, 2018).

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (8)$$

Donde SSE representa la suma de los cuadrados de los errores, SSR es la suma de los cuadrados de la regresión, y SST es la suma total de los cuadrados (González, 2018).

3.5.2. Uso de la aplicación Regression Learner

La aplicación Regression Learner entrena diversos modelos de regresión con el fin de predecir datos (tabla 8). Esta aplicación permitió realizar diversas acciones, como la exploración de datos, la selección de funciones, la especificación de esquemas de validación, la capacitación de modelos y la evaluación de resultados. En el entrenamiento de datos el cual corresponde al 70%, se dividió en 3 subconjuntos los cuales fueron entrenados con los diferentes modelos de la aplicación. Además, la efectividad del modelo desarrollado se evaluó utilizando indicadores

estadísticos como el coeficiente de determinación (R^2), el error cuadrático medio (MSE), la raíz del error cuadrático medio normalizado (NRMSE) y el criterio de información de Akaike (AIC), esto para poder observar de manera más clara y elegir el mejor modelo que representará al sistema (De La Cruz Rojas et al., 2024).

Tabla 8

Modelos integrados en la app Regression Learner

Tipo de modelo de regresión	Modelo
1. Modelos de regresión lineal	Lineal Interacciones lineales Paso a paso lineal Robusto lineal
2. Árboles de regresión.	Buen árbol o árbol fino Árbol mediano Árbol grueso
3. Modelos de regresión de procesos gaussianos.	Racional cuadrático Exponencial al cuadrado Materno 5/2 Exponencial
4. Máquina de vectores de soporte	Lineal Cuadrática Cúbico Gaussiana fina Gaussiana media Gaussiana gruesa
5. Conjunto de árboles de regresión	Árboles potenciados Árboles empaquetados

6. Redes Neuronales

Red neuronal estrecha
 Red neuronal media
 Amplia red neuronal
 Red neuronal bicapa
 Red neuronal de tres capas

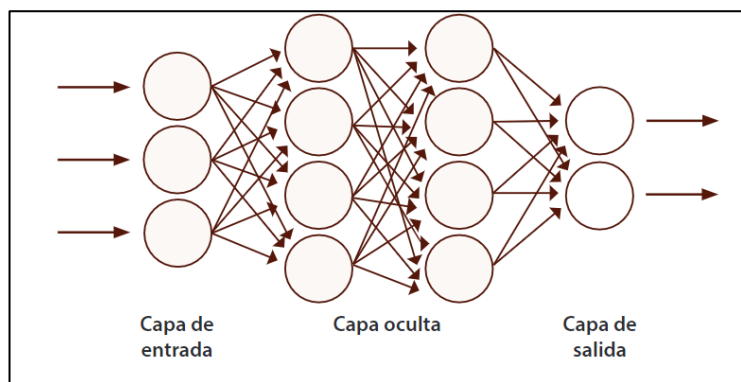
Fuente: (*Choose Regression Model Options - MATLAB & Simulink - MathWorks América Latina*, n.d.)

3.5.3. Desarrollo de la técnica Neural Net Fitting

Una red neuronal artificial es un modelo matemático desarrollado para simular el funcionamiento de las neuronas en el cerebro humano, permitiendo el aprendizaje a partir de experiencias previas. Está formada por unidades de procesamiento conectadas entre sí, con la capacidad de identificar patrones, clasificar información y prever eventos futuros con gran precisión. La configuración de una red neuronal, representada en la Figura 5, incluye una capa de entrada, dos capas intermedias y una capa de salida (Incio-Flores et al., 2023).

Figura 5

Estructura de una red neuronal



Fuente: Incio-Flores et al. (2023)

La red neuronal fue configurada mediante el software Matlab, el cual dispone del paquete Statistics and Machine Learning Toolbox. Dentro de esta herramienta, se utilizó la aplicación Neural net Fitting para la selección de datos, así como la creación y entrenamiento de la red

neuronal. Este entrenamiento empezó en 10 neuronas y fue variando con un aumento de 5 hasta llegar a 100, iterando sobre cada configuración para seleccionar el modelo más representativo, basándose en los indicadores de representación MSE y el R^2 descritos anteriormente. Durante el proceso de entrenamiento, se proporcionó a la red un conjunto de datos junto con sus salidas correspondientes, las cuales actuaron como variables objetivo (Parra, 2020).

3.6. Validación de los modelos para elegir el que mejor se ajuste a los datos.

En validación, se ejecutó el algoritmo con el 30% de los datos experimentales que se habían dividido con anterioridad, es impórtate mencionar que no se calculó los indicadores de representación para la técnica de neural net fitting ya que permite determinar los indicadores de regresión de entrenamiento y validación al momento de ingresar los datos. Sin embargo, los modelos entrenados a través de la aplicación de regression learner, no incluyen esta capacidad; en tal virtud, con ésta aplicación, sólo se determina los indicadores de entrenamiento, por lo que, se hizo necesario exportar todos los modelos utilizados para predecir los datos experimentales reservados para la validación y luego con estos valores de predicción y los valores de respuesta experimentales de validación se determinó manualmente los indicadores de regresión respectivos.

Al momento de validar los modelos, no necesariamente significa que el mejor resultado de entrenamiento es el mejor resultado de validación, se compararán todos los modelos y aquel que presente los mejores valores con respecto a los indicadores de representación se seleccionará como aquel que representa al sistema de estudio, si por el contrario, no se consigue un modelo que represente de mejor manera el sistema en entrenamiento y en validación se procederá a seleccionar el que más se acerque a esta condición.

3.7. Crear un sistema de supervisión, control y adquisición de datos aplicando el modelo de IA.

A continuación, se describe App designer, programa que sirvió para desarrollar una aplicación destinada a emplear el modelo analizado. Esta aplicación, se construyó utilizando el programa Matlab y permitió a los exportadores identificar las características con las que el aguacate alcanzará su destino bajo condiciones específicas de almacenamiento.

3.7.1. App Designer

En esta fase, se utilizó MATLAB App Designer para desarrollar una aplicación interactiva que permite predecir la firmeza de las frutas mediante un modelo de regresión. La interfaz gráfica de usuario fue diseñada para ser intuitiva y accesible, facilitando la entrada de datos relevantes como características de la fruta y condiciones de almacenamiento (González-García, 2018). Se integró el modelo de regresión desarrollado previamente, asegurando que la aplicación procese los datos ingresados y realice predicciones precisas. Además, se añadieron componentes gráficos para visualizar los resultados de manera clara y comprensible, así como opciones para guardar y exportar los datos y resultados; finalmente, se creó una guía de usuario detallada con un plan de mantenimiento para asegurar que la aplicación se mantenga actualizada y funcional en diferentes entornos de producción (G. Rodríguez & Rodríguez, 2021).

CAPÍTULO IV

RESULTADOS

En este capítulo se exponen los resultados obtenidos al evaluar la firmeza del aguacate, considerando temperatura y tiempo de almacenamiento, así como el procesamiento de los datos y la creación del aplicativo.

4.1. Caracterización de la materia prima

Se llevó a cabo la caracterización de la materia prima una estandarización de cada lote mediante análisis comparativos, tomando como referencia la norma INEN 1755:2009. En este contexto, se seleccionó una escala de madurez correspondiente a los niveles 1 y 2 (Figura 4). Los valores de penetrabilidad obtenidos para los distintos lotes estuvieron por debajo de lo establecido en la norma, lo que indica una menor resistencia de la fruta, asociada a su estado de madurez inicial.

Para evaluar la consistencia entre los lotes, se utilizó el cálculo del error muestral y la dispersión total, obteniéndose un valor menor al 2%. Esto refleja una alta uniformidad en las muestras almacenadas durante los 15 días propuestos a diferentes temperaturas. Además, la desviación estándar y el coeficiente de variación de las mediciones estuvieron dentro del límite aceptable del 10%, lo que asegura la uniformidad y fiabilidad de los resultados obtenidos. Los datos de estandarización se encuentran en la Tabla 9.

Tabla 9

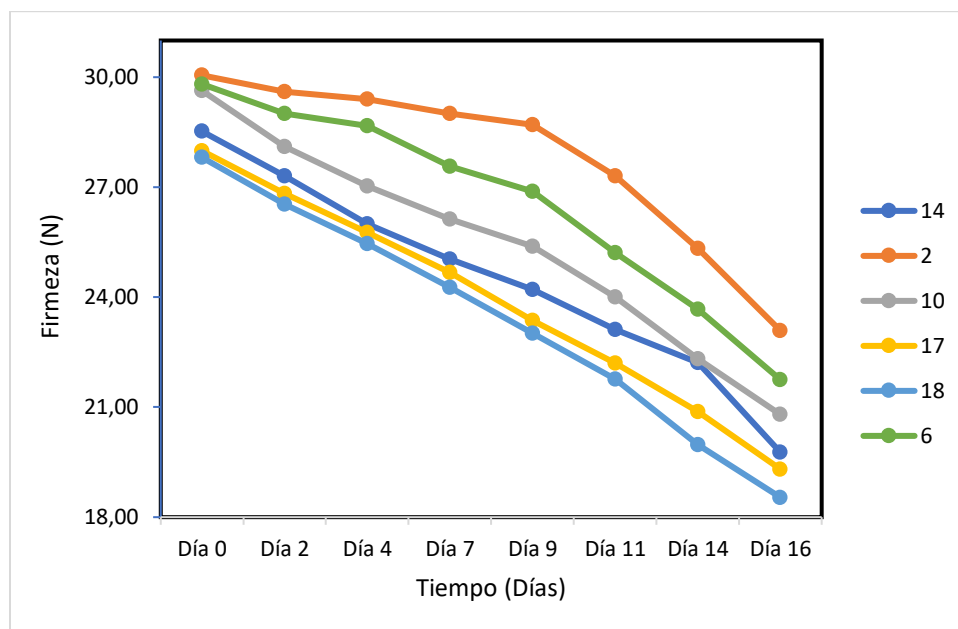
Datos de estandarización por lotes

Lote	Parámetros					
	° Brix	Firmeza (N)	Firmeza ($\frac{kg}{cm^2}$)	Acidez titulable (g/100ml)	Índice de madurez	Porcentaje de dispersión T (%)
1	7	28.52	41.56	1.2	40.11	0.09
2	6.6	30.00	43.71	1.2	37.19	0.03
3	6.7	29.60	43.13	1.2	36.41	0.06
4	6.7	28.00	40.80	1.2	38.00	0.14
5	6.9	29.80	43.42	1.3	39.09	0.09
6	6.8	29.40	42.84	1.2	36.61	0.02
7	6.9	26.66	38.85	1.3	37.18	0.17
Total	6.8	28.85	42.04	1.23	37.80	0.09

Se obtuvieron los datos de estandarización, que funcionaron como base para la medición de los datos experimentales, utilizando las temperaturas establecidas de 2°C, 6°C, 10°C, 14°C y 18°C. Se observó que la firmeza del aguacate *Hass* disminuye significativamente a medida que aumenta el tiempo de almacenamiento, particularmente a temperaturas superiores a 10°C. Véase en la figura 6.

Figura 6

Lectura de firmeza a través de la temperatura y tiempo de almacenamiento.



Los resultados obtenidos coinciden con los reportados por Gavicho Uarrota y Pedreschi (2022), quienes también documentaron una disminución en la firmeza del aguacate bajo condiciones controladas de almacenamiento y temperatura. Durante el proceso de maduración, la firmeza del fruto disminuye progresivamente; sin embargo, esta pérdida de firmeza se acelera considerablemente cuando el aguacate alcanza la temperatura de maduración. Esta actúa como un factor crítico, afectando directamente la cinética de los procesos enzimáticos involucrados en la descomposición de las paredes celulares, lo que explica la aceleración de la disminución de la firmeza hasta estabilizarse en la madurez completa. Este cambio en la firmeza está relacionado con la descomposición de la pectina, un componente clave de las paredes celulares, que es degradado por enzimas como las pectinasas, lo que provoca el ablandamiento del fruto. Además, la producción de etileno, una hormona que regula la maduración en frutos climatéricos como el

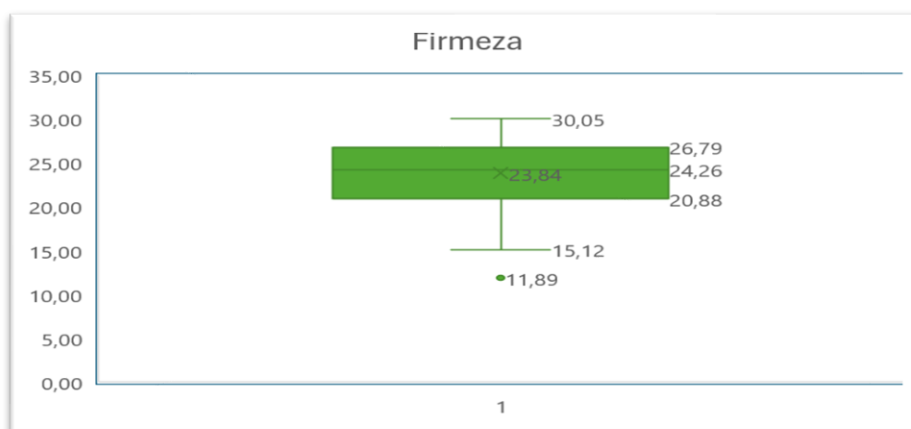
aguacate, acelera este proceso y contribuye a la pérdida de firmeza, alterando su color y mejorando sus características (Márquez et al., 2014).

4.2 Generar un modelo representativo del cambio de firmeza mediante inteligencia artificial

Se recopilaron 101 datos experimentales de firmeza y se analizaron mediante un diagrama de cajas para identificar y eliminar outliers o datos atípicos, como se muestra en la Figura 7. Un outlier es una observación que se desvía considerablemente de las demás, lo que sugiere que podría haber sido generada por un mecanismo diferente, distorsionando las medias y las desviaciones estándar de las variables, y afectando negativamente las relaciones entre ellas (Muñoz & Uribe, 2013). La eliminación de estos outliers permitió recalcular las estadísticas descriptivas de manera más precisa. Este procedimiento destacó la relevancia de la identificación y el tratamiento de datos atípicos en la investigación experimental, asegurando que los análisis reflejen fielmente la naturaleza de los datos y mejorando la validez y confiabilidad de las conclusiones del estudio.

Figura 7

Diagrama de caja de la variable firmeza para determinar outliers.



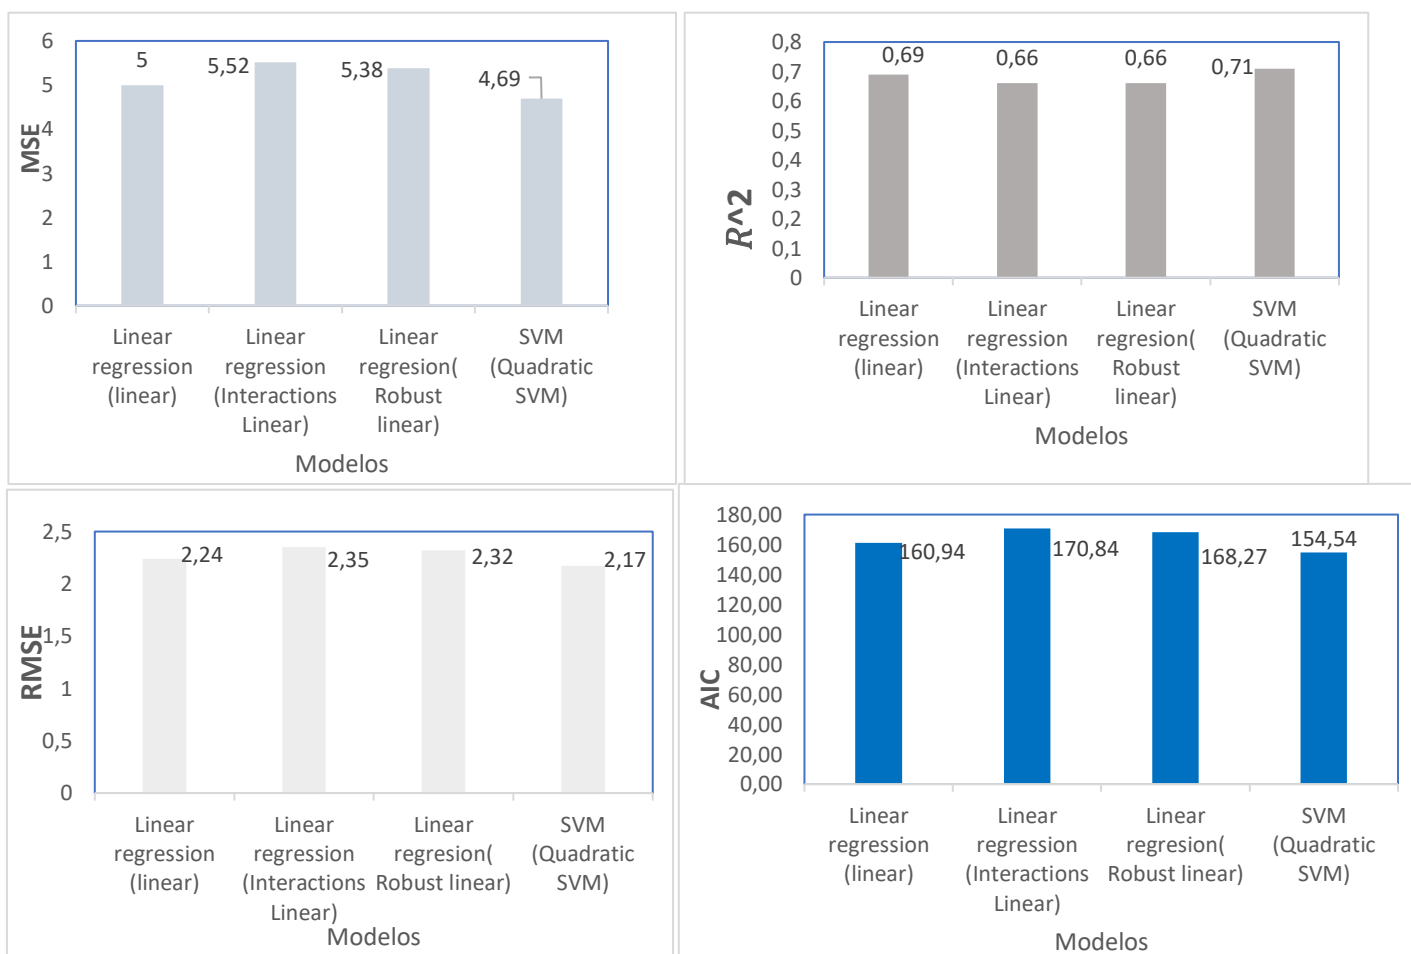
Nota: Se observa un solo outlier (11.89 N) que se eliminó de los datos de firmeza.

Al eliminar outliers resultaron 100 datos, a los cuales se aleatorizó utilizando Excel, posteriormente la aplicación del método bootstrap en este estudio permitió una validación robusta de los modelos predictivos desarrollados.

Los datos de entrenamiento (70% del total) se subdividieron en tres conjuntos para su posterior estudio. A continuación, se almacenó los valores de cada bloque y se promedió los indicadores, para observar cual fue el modelo que mejor se ajusta a los datos de acuerdo con los indicadores de representación. El desempeño de los modelos con mejor rendimiento (Figura 8) presentaron un R^2 que se encuentra dentro del rango de representatividad alta (Moreno, 2023) para estimar la predicción de firmeza del aguacate bajo refrigeración.

Figura 8

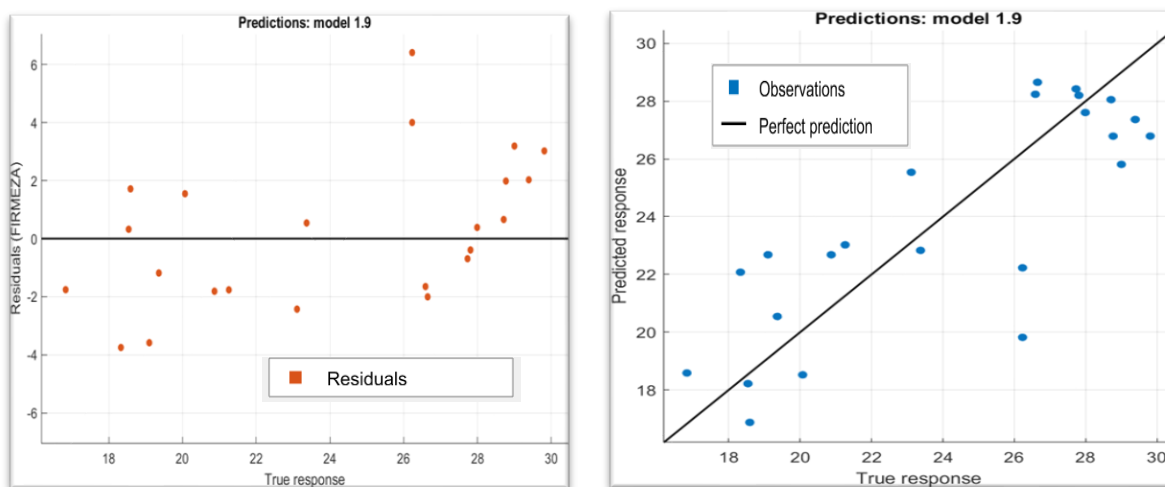
Coefficientes de entrenamiento con Regression Learner



En su mayoría los modelos de regresión presentan indicadores aceptables sin embargo el mejor modelo de regresión en el entrenamiento fue Máquina de Vectores de Soporte Cuadrático (SVM Quadratic), este modelo fue eficaz en la captura de las relaciones no lineales entre la firmeza del aguacate, la temperatura y el tiempo de almacenamiento, debido a su uso de un kernel cuadrático. Este kernel proyecta las relaciones complejas de segundo grado en un espacio de mayor dimensión, esta capacidad de transformación permitió que el modelo se ajustara con mayor precisión a los datos experimentales, algo que los modelos lineales o más simples no lograron, ya que no podían capturar la complejidad inherente en estas interacciones (Bautista et al., 2014). Con ello se obtuvo métricas de representación con mejor rendimiento que los otros modelos con un R^2 de 0.71, un MSE de 4,69, un RMSE de 2.17 y un AIC de 154.54, que fue el de mejores valores y sirvió para determinarlo como el mejor para entrenamiento, en la figura 9 se observa el ajuste de los datos del modelo SVM quadratic mediante gráfica de datos residuales y datos predichos.

Figura 9

Gráfica de datos residuales vs gráfica de datos predichos.



Matlab- Regression learner

➤ Neural Net Fitting

Al igual que en regression learner se obtuvo los coeficientes de cada conjunto de bloques y se promedió para su respectivo análisis visto en la tabla 11.

Tabla 11

Rendimiento de los algoritmos de aprendizaje de NNF en entrenamiento.

Número de neuronas	Levenberg-Marquardt				Scaled Conjugated Gradient			
	R^2	MSE	RMSE	AIC	R^2	MSE	RMSE	AIC
5	0,78	7,73	2,78	204,56	0,92	2,53	1,59	92,82
10	0,86	4,09	2,02	140,77	0,91	2,26	1,50	81,54
15	0,94	1,25	1,12	22,58	0,81	6,47	2,54	186,72
20	0,75	11,17	3,34	241,32	0,93	2,24	1,50	80,65
25	0,94	7,84	2,80	205,92	0,89	3,37	1,84	121,49
30	0,98	0,42	0,65	-86,75	0,88	3,29	1,81	119,09
35	0,98	0,49	0,70	-71,33	0,65	24,76	4,98	320,92
40	0,97	0,83	0,91	-18,63	0,66	26,46	5,14	327,56
45	0,97	0,79	0,89	-23,57	0,88	15,49	3,94	274,02
50	0,96	1,08	1,04	7,70	0,8	9,12	3,02	221,05
55	0,99	0,42	0,65	-86,75	0,72	28,43	5,33	334,74
60	0,98	0,24	0,49	-142,71	0,92	2,54	1,59	93,22
65	0,68	165,67	12,87	511,00	0,79	8,37	2,89	212,47
70	0,97	0,54	0,73	-61,62	0,82	5,96	2,44	178,51
75	0,98	0,56	0,75	-57,98	0,74	26,51	5,15	327,75
80	0,96	1,17	1,08	15,70	0,83	6,34	2,52	184,69
85	0,98	0,42	0,65	-86,75	0,95	1,96	1,40	67,29
90	0,97	0,66	0,81	-41,55	0,86	7,58	2,75	202,55
95	0,99	0,25	0,50	-138,63	0,79	10,92	3,30	239,06
100	0,98	0,16	0,40	-183,26	0,66	6,33	2,52	184,53

El entrenamiento de la red se realizó mediante los dos algoritmos Levenberg-Marquardt y Scaled Conjugated Gradient, resultando con mejores indicadores de representación el primero mencionado, debido a su capacidad para resolver eficientemente problemas no lineales, combinando las técnicas de Gauss-Newton y descenso por gradiente. Esto permitió una convergencia más eficiente y exacta, particularmente en conjuntos de datos pequeños o medianos. A diferencia del SCG, que requiere más iteraciones y es menos eficiente en la captura de relaciones

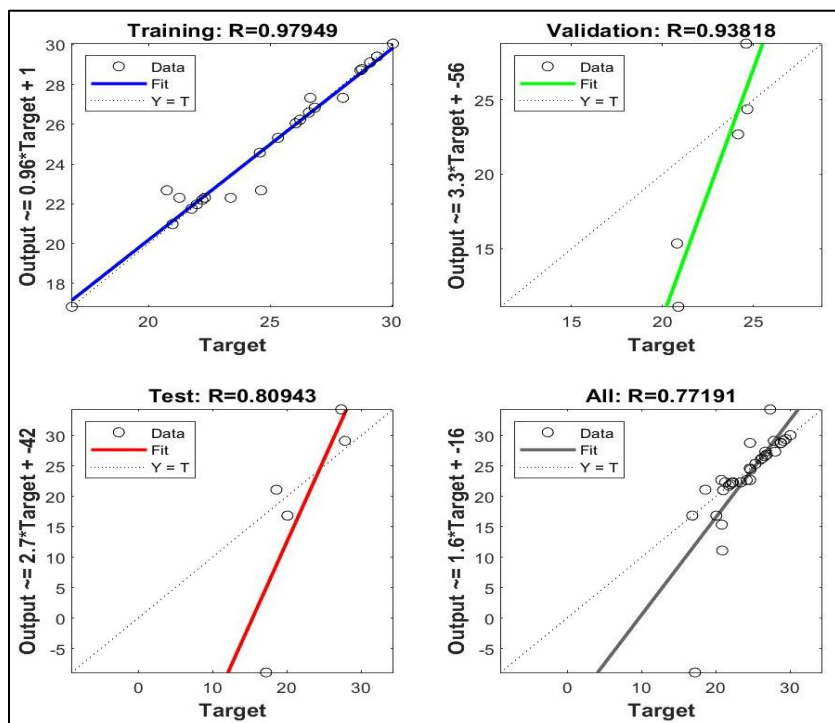
complejas, el Levenberg-Marquardt ajusta de manera adaptativa según el error, logrando un equilibrio óptimo entre precisión y velocidad (Incio-Flores et al., 2023).

Las capas entrenadas tienen similitud en sus coeficientes por ello fue de suma importancia optar por el cálculo de RMSE y AIC que ayudó a elegir el mejor modelo correspondiente al algoritmo de Levenberg-Marquardt, con valores de R^2 de 0.98, un MSE de 0.16, un RMSE de 0.40 y un AIC de -183.26, siendo valores similares al estudio de De La Cruz Rojas et al., (2024).

En la figura 10 se observa el rendimiento de regresión del mejor modelo (LM con 100 capas), donde se representa los valores predichos por la red neuronal con respecto a la firmeza.

Figura 10

Datos predichos por el modelo de NNF



Tomado de Neural Net Fitting

4.2.1 Validación de modelos matemáticos con diferentes datos a los de entrenamiento

La validación no solo evalúa la precisión del modelo, sino que también nos permite identificar y corregir errores de sobreajuste, evaluando propiedades clave y realizando simulaciones para asegurar que los resultados del modelo sean consistentes con las expectativas, por tal motivo, se realizó la validación con datos diferentes a los de entrenamiento, equivalentes al 30% del total de la muestra obtenida de la fase experimental mencionada anteriormente. De igual manera se seleccionaron los modelos con mejores coeficientes de MSE, AIC, RMSE y R^2 (Hernández et al., 2018). En la tabla 12 están los resultados de rendimiento de los modelos de entrenamiento y validación.

Tabla 12

Coeficientes entrenamiento y validación, SVM Quadratic = Máquina de soporte vectorial cuadrática; LM-NNF100 = Red neuronal 100 neuronas con algoritmo Levenberg-Marquardt.

Fase	Modelo	R^2	MSE	RMSE	AIC
Entrenamiento	(SVM Quadratic)	0,71	4,69	2,17	154,54
	LM-NNF100	0,98	0,16	0,40	-183,26
Validación	(SVM Quadratic)	0,81	2,59	1,61	94,97
	LM-NNF100	0,35	10,12	3,18	231,4

Se observó un mejor ajuste con el modelo de regression learner en comparativa que el modelo de red neuronal, teniendo un cambio significativo sus indicadores de representación, como posibles causas a un sobre ajuste de datos. Sin embargo, la validación arrojó otros mejores modelos tanto para regression learner como para neural net fitting, que se exponen en la tabla 13.

Tabla 13

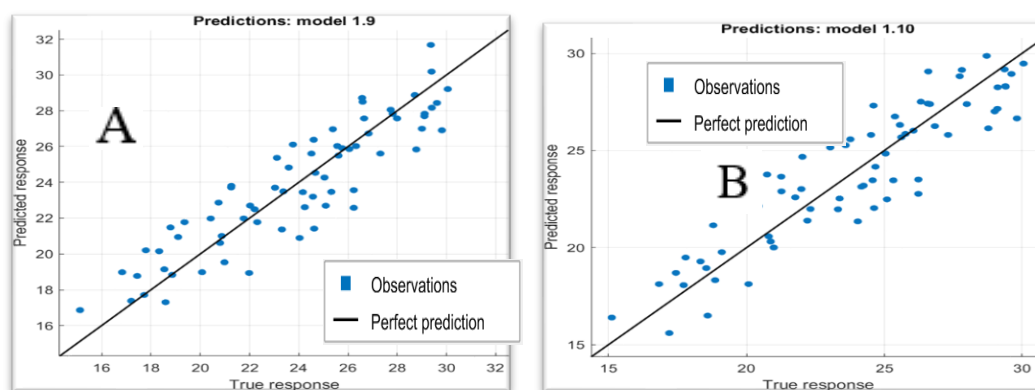
Modelos más eficientes en validación.

	Validación			
	R^2	MSE	RMSE	AIC
(SVM Cubic)	0,84	2,17	1,47	29,19
SCG-NNF5	0,91	2,74	1,66	100,8

En contraste con los modelos de entrenamiento, el sobreajuste de datos puede explicar los mejores coeficientes de determinación observados durante el entrenamiento. Por esta razón, es crucial validar los modelos estudiados, ya que la validación ayuda a comprobar su robustez y consistencia frente a diferentes conjuntos de datos (Ibarra et al., 2020). En la tabla 13, se pueden observar los dos mejores modelos de validación. En la figura 11 se encuentra el ajuste del 30% de datos con el mejor modelo de entrenamiento en comparación con el mejor modelo obtenido en validación de regression learner y en la figura 12 se observan lo mismo, pero con los modelos de neural net fitting.

Figura 11

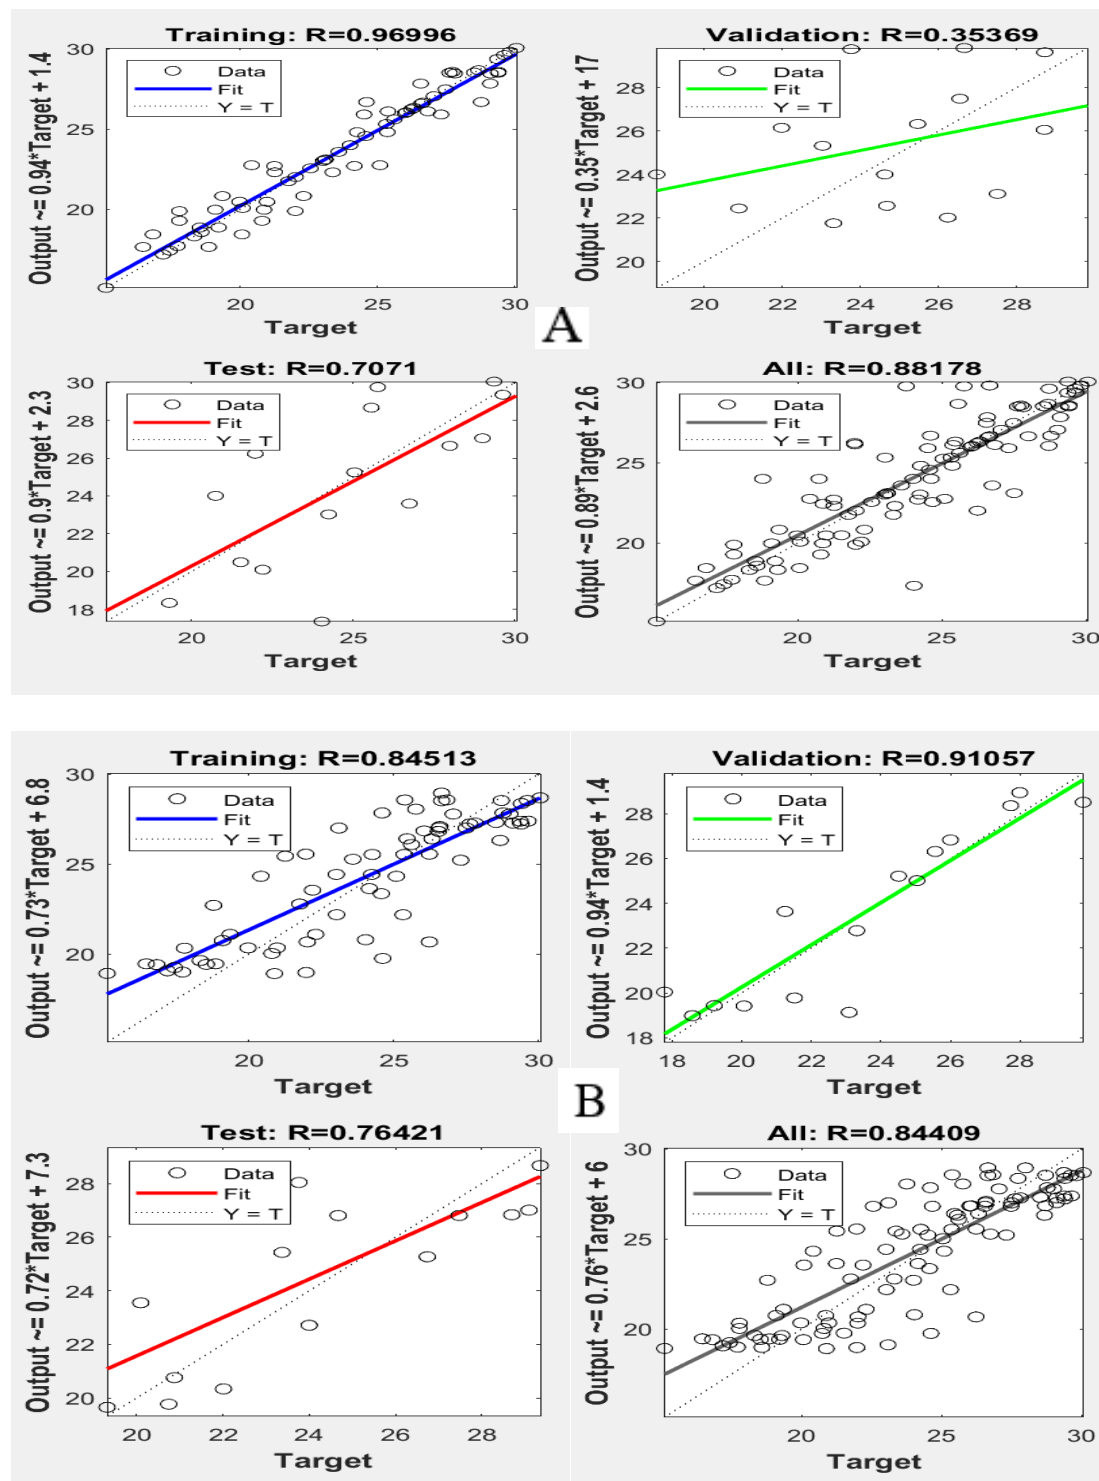
Mejor modelo de entrenamiento A= (SVM Quadratic), vs mejor modelo de validación B= (Cubic SVM);



Un modelo de regresión es confiable cuando los datos se acercan más a la línea diagonal y están menos dispersos. Comparando las dos gráficas, la gráfica B muestra un mejor ajuste en comparación con la gráfica A.

Figura 12

Indicadores de modelamiento A) Mejor modelo de entrenamiento (Levenberg-Marquardt NNF 100), B) mejor modelo de validación (Scaled Conjugate Gradient NNF 5).



En los modelos neuronales, el eje X (Target) muestra los valores reales de la variable dependiente, mientras que el eje Y (Output) refleja los valores predichos por la red neuronal durante la validación. Las líneas de colores diferentes (verde, azul, rojo y negro) ilustran la relación lineal entre los valores predichos y los reales, mientras que la línea punteada ($Y=T$) indica la línea ideal en la que los valores predichos coincidirían perfectamente con los valores reales (Plata, 2015). Esto evidencia que el modelo D tiene un mejor ajuste en comparativa con el modelo C de redes neuronales.

Sin embargo, a pesar de que la red neuronal Scaled Conjugate Gradient NNF 5 presenta el R^2 más alto de todos los modelos de validación, no es el mejor, ya que los otros indicadores de rendimiento son inferiores al segundo mejor modelo, que es la máquina de soporte vectorial cúbica (SVM Cubic). Esto puede deberse a que el modelo de regresión maneja datos lineales con relaciones simples y pocas variables interrelacionadas (De La Cruz Rojas et al., 2024). Los resultados obtenidos para el SVM Cubic fueron: un $R^2=0.84$, $MSE=2.17$, $RMSE=1.66$ y un $AIC=29.19$. Por tanto, este modelo es el mejor para el sistema estudiado y se optó por él para representar el cambio de firmeza a través de la temperatura y el tiempo de almacenamiento.


4.3 Crear un sistema de supervisión, control y adquisición de datos aplicando el modelo de IA.

Tras seleccionar el algoritmo SVM Cubic como el modelo de regresión más adecuado para representar el sistema de estudio, se procedió a desarrollar una aplicación personalizada en Matlab utilizando la herramienta App Designer. Esta integración permitió la automatización y visualización eficiente de los resultados, facilitando el análisis de los datos experimentales y las predicciones del modelo.

Se trabajó con la interfaz propia de la aplicación, la cual ofrece la adición de gráficos representativos, tanto ilustrativos como diagramas y representación de datos o figuras, además de la inclusión de tablas y logo representativo de la institución. En la figura 13 se puede observar el diseño final de la aplicación creada.

Figura 13

Aplicación que predice el comportamiento de la firmeza de aguacate en función de la temperatura y tiempo de almacenamiento.



Como se observa en la figura 13, en la aplicación debe proporcionarse la temperatura y días de almacenamiento del aguacate a los que se quiere saber la firmeza. La aplicación refleja una tabla con el cambio de firmeza en el paso del tiempo hasta alcanzar los días establecidos cómo parámetro inicial. Acompaña también una gráfica que muestra el comportamiento de la variable de estudio (Firmeza). En la interfaz presentada, se ha incorporado una etiqueta titulado "Desviación", que permite ajustar un intervalo de confianza para los resultados de firmeza del

aguacate. Esta etiqueta ajusta el rango de variabilidad de la firmeza predicha, reflejándose en la tabla como F+ (límite superior de la desviación) y F- (límite inferior de la desviación), los límites superior e inferior del intervalo de confianza calculado representan los valores extremos dentro de los cuales se espera que se encuentre el valor real de la variable, con un nivel de confianza determinado. Estos límites definen el rango de incertidumbre alrededor de la estimación obtenida. De esta manera se proporciona una medida del grado de variación posible en las predicciones de firmeza. Esta funcionalidad ofrece flexibilidad al usuario, permitiéndole ajustar el nivel de incertidumbre de acuerdo con sus necesidades específicas. De este modo, se puede visualizar no solo el valor estimado de firmeza, sino también un margen de variación que facilita un análisis más preciso y adaptable a diversos escenarios experimentales, así mismo en la parte derecha de la tabla se muestra a la penetrabilidad configurada con las unidades propuestas por la norma para un mejor análisis y comparación de datos. La Figura 14 muestra un ejemplo práctico del uso de esta herramienta dentro de la aplicación desarrollada en Matlab.

Figura 14

Cálculo de variabilidad de la firmeza.



UNIVERSIDAD TÉCNICA DEL NORTE
FICAYA
AGROINDUSTRIA



1 2 3 4 5

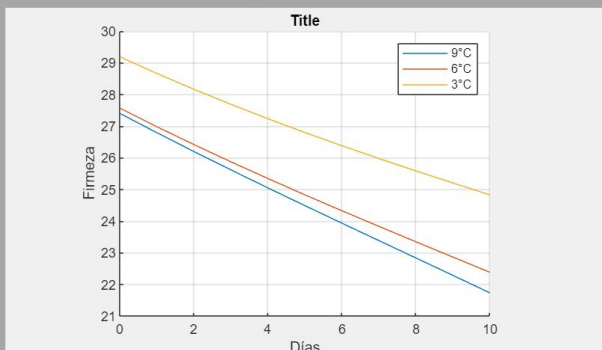
Desviación(0-5)

Temperatura

Días



Días	F+	Firmez...	F-	Penetrabilidad (kgf/(cm) ²)
0	27.3961	27.5603	29.1844	39.7587
1.0000	26.7870	26.9760	28.6585	38.9158
2.0000	26.1938	26.4128	28.1689	38.1034
3.0000	25.6139	25.8683	27.6833	37.3178
4.0000	25.0450	25.3401	27.2294	36.5568
5.0000	24.4847	24.8258	26.7946	35.8139
6.0000	23.9307	24.3230	26.3767	35.0886
7.0000	23.3805	23.8294	25.9732	34.3766
8.0000	22.8319	23.3426	25.5818	33.6743
9.0000	22.2823	22.8602	25.2001	32.9784
10.0000	21.7295	22.3798	24.8257	32.2853



Extraer

Nota

El valor de firmeza tiene unidades de Newtons (N).
El valor de penetrabilidad en unidades de kgf/(cm)², con respecto a la norma.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

- Los resultados de la investigación revelaron que tanto la temperatura como el tiempo influyen en la variación de la firmeza del aguacate. Se comprobó que a medida que disminuye la temperatura, se ralentiza la pérdida de firmeza, lo que indica una regresión lineal entre el cambio de temperatura y la variación en la firmeza.
- El modelo SVM Cubic fue el más adecuado para predecir el cambio de firmeza del aguacate (R^2 de 0.84, MSE de 2.17, RMSE de 1.66 y AIC de 29.19), logrando captar eficazmente las relaciones no lineales entre la firmeza, la temperatura y el tiempo de almacenamiento, demostrando precisión y confiabilidad en las predicciones bajo diferentes condiciones de almacenamiento.
- Se complementó la investigación mediante la creación de una aplicación, la cual permite el ingreso de valores de temperatura ($^{\circ}\text{C}$) y el intervalo de tiempo en días para la predicción de la firmeza, perfeccionando su visualización mediante una tabla y una gráfica de representación de datos.

5.2 Recomendaciones

- Para futuras investigaciones, se recomienda estudiar el impacto de otros factores, como la humedad relativa o el uso de atmósferas controladas, para complementar los resultados obtenidos y optimizar la vida útil del aguacate durante el almacenamiento.
- Ampliar el alcance del modelo predictivo aplicándolo a otras variedades de aguacate, con el fin de evaluar su eficacia y determinar si se pueden obtener resultados similares en distintas condiciones.
- La investigación cuenta con una aplicación en la que se implementó el modelo SVM Cubic en procesos industriales de almacenamiento y distribución de aguacates, facilitando la toma de decisiones para garantizar la calidad del producto durante el transporte.

La investigación cuenta con una aplicación en la que se implementó el modelo.

BIBLIOGRAFÍA

- Arias, F., Montoya, C., & Velásquez, O. (2018). Dinámica del mercado mundial de aguacate. *Revista Virtual Universidad Católica Del Norte*, 55, 22–35. <https://doi.org/10.35575/rvucn.n55a2>
- Bautista, E., Guzmán, E., & Figeroa, J. (2004). *Predicción de Múltiples Puntos de Series de Tiempo Utilizando Support Vector Machines Forecasting of Multiple Points in Time Series with Support Vector Machines*.
- Benítez, J., Sánchez, A., Bolaños, C., Bernal, Lk., Ochoa- Martínez, C., Vélez, C., & Sandoval, A. (2021). Cambios Físicoquímicos del aguacate Hass durante el almacenamiento frío y la maduración acelerada. *Biotecnología En El Sector Agropecuario y Agroindustrial*, 19(2), 18–26.
- Carvalho, C., Velásquez, M., & Van Rooyen, Z. (2009). *Porcentaje mínimo de materia seca para una cosecha adecuada del aguacate cv. "Hass" en Colombia*.
- Cerdas, M., Calderón, M., & Somarribas, O. (2014). *VERIFICACIÓN DEL CONTENIDO DE MATERIA SECA COMO INDICADOR DE COSECHA PARA AGUACATE (persea americana) CULTIVAR HASS EN ZONA INTERMEDIA DE PRODUCCIÓN DE LOS SANTOS, COSTA RICA*. www.mag.go.cr/revagr/index.htmlwww.cia.ucr.ac.cr
- Chiang María, & Taipei Juan. (2017). *Proyecto Integrador*.
- Chicaiza, B. (2020). *EFFECTO DE LA APLICACIÓN DE ATMÓSFERAS MODIFICADAS ACTIVAS Y TEMPERATURA DE ALMACENAMIENTO SOBRE LAS PROPIEDADES FÍSICOQUÍMICAS Y EL CONTENIDO DE ÁCIDO ASCÓRBICO DEL PEPINO DULCE Solanum muricatum*. Universidad Técnica del Norte.
- De La Cruz Rojas, E. M., Nuñez-Pérez, J., Lara-Fiallos, M., Pais-Chanfrau, J. M., Espín-Valladares, R., & DelaVega-Quintero, J. C. (2024). An Artificial Intelligence Approach for Estimating the Turbidity of Artisanal Wine and Dosage of Clarifying Agents. *Applied Sciences (Switzerland)*, 14(11). <https://doi.org/10.3390/app14114416>

De la Rosa, J. (n.d.). *MÉTODOS BOOTSTRAP: Principios, Teoría y su aplicación al Procesamiento Digital de Señales*.

Díaz, Y. (2023). *PROPIEDADES FÍSICOQUÍMICAS Y FISIOLÓGICAS DE LA PALTA (Persea americana) DE LAS VARIETADES HASS Y FUERTE CON RECUBRIMIENTO BIODEGRADABLE A BASE DE ALMIDÓN DE PAPA NATIVA (Solanum tuberosum ssp. Andigena) Y MUCÍLAGO DE NOPAL (Opuntia ficus-indica)*. UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO.

Gavicho Uarrota, V., & Pedreschi, R. (2022). *Mathematical modelling of Hass avocado firmness by using destructive and non-destructive devices at different maturity stages and under two storage conditions*. https://doi.org/10.2478_fhort-2022-0011

Gonzalez, L. (2018, November 23). *Evaluando el error en los modelos de regresión*. <https://Aprendeia.Com/Evaluando-El-Error-En-Los-Modelos-de-Regresion/>.

González, L. (2021, November 8). *¿Qué son las Redes Neuronales Artificiales?*

González-García, C. (2018). *En qué consiste el aprendizaje automático (machine learning) y qué está aportando a la Neurociencia Cognitiva*. www.cienciacognitiva.org

Herrera, J., Salazar, S., Martínez, H., & Ruiz, J. (2017). *INDICADORES PRELIMINARES DE MADUREZ FISIOLÓGICA Y COMPORTAMIENTO POSTCOSECHA DEL FRUTO DE AGUACATE MÉNDEZ*. 40(1).

Huamani, L. (2017). *TEMPERATURA DE ALMACENAMIENTO EN EL COMPORTAMIENTO DE LA MADUREZ POSCOSECHA DE LA PALTA cv HASS (Persea americana)*. UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE HUAMANGA.

Ibarra, E., Oñate, Á., & Villavicencio, Á. (2020). *Modelado para la determinación del poder calorífico de la gasificación de la balsa en instalaciones downdraft mediante redes neuronales artificiales*. *Científica*, 24(2), 103–110. <https://doi.org/10.46842/ipn.cien.v24n2a10>

- Incio-Flores, F. A., Capuñay-Sanchez, D. L., & Estela-Urbina, R. O. (2023). Artificial Neural Network Model to Predict Academic Results in Mathematics II. *Revista Electronica Educare*, 27(1). <https://doi.org/10.15359/ree.27-1.14516>
- Lara, S. (2022). *APLICACIÓN DE TÉCNICAS DE MACHINE LEARNING COMO MÉTODO DE VALIDACIÓN PARA PREDECIR LA EFECTIVIDAD DE UN MODELO ESTADÍSTICO DE SERIES DE TIEMPO EN LA PRODUCCIÓN DE FRUTA FRESCA EN LAS DIFERENTES PROVINCIAS DEL ECUADOR*. Universidad de Guayaquil.
- Ledesma, R. (2008). Introduccción al Bootstrap. Desarrollo de un ejemplo acompañado de software de aplicación. In *Tutorials in Quantitative Methods for Psychology* (Vol. 4, Issue 2).
- Marcillo, M., & Macías Jhonny. (2022). *PARÁMETROS DE CALIDAD POSCOSECHA DE FRUTAS COMERCIALIZADAS EN LAS FERIAS DE LA AMAZONÍA ECUATORIANA*.
- Márquez, C., Yepes, D., Sanchez, L., Quimica, I., & Osorio, J. (2014). CAMBIOS FÍSICO-QUÍMICOS DEL AGUACATE (*Persea americana* Mill. cv. "Hass") EN POSCOSECHA PARA DOS MUNICIPIOS DE ANTIOQUIA. In *TEMAS AGRARIOS* (Vol. 19, Issue 1).
- Mata, A., Vásquez, L., Alvarado, K., Erazo, C., Tuarez, D., Chang, J., & Intriago, F. (2022). *Valoración bromatológica en dos variedades de aguacate hass*.
- Morales Leonardo, Moisés Alejandro, Cárdenas Mauricio, Jiménez Sandra, & Miranda Rita. (2016). *CARACTERIZACIÓN SENSORIAL E INSTRUMENTAL DE AGUACATE HASS CON MADUREZ FISIOLÓGICA*. http://www.siap.sagarpa.gob.mx/ar_comdeagr.html
- Moreno, A. (2023). *DESARROLLO DE UN MÉTODO COMPUTACIONAL PARA LA CLASIFICACIÓN DE NARANJAS (Citrus x sinensis O.), VARIEDADES VALENCIA Y WASHINGTON*. Universidad Técnica del Norte.
- Muñoz, J., & Uribe, I. (2013). Técnicas para detección de outliers multivariantes. In *Revista en telecomunicaciones e informática* (Vol. 3, Issue 5).
- NTE INEN 1 755:2009. (2009). *FRUTAS FRESCAS. AGUACATE. REQUISITOS*.

NTE INEN 1750:1994. (2012). *INSTITUTO ECUATORIANO DE NORMALIZACIÓN HORTALIZAS Y FRUTAS FRESCAS. MUESTREO.*

NTE INEN-ISO 750. (n.d.). *NORMA TÉCNICA ECUATORIANA NTE INEN-ISO 750:2013.*

Osuna García, J. A., Nolasco González, Y., Antonio Herrera González, J., Horacio Guzmán Maldonado, S., & Álvarez Bravo, A. (2017). *Influencia del clima y rugosidad sobre la tolerancia a refrigeración del aguacate 'Hass'* Influence of climate and roughness on the tolerance to refrigeration of avocado "Hass."*

Par Gramajo, M. (2017). Aplicación de los métodos de conservación de alimentos. *Revista Ingeniería y Ciencia .*

Parra, F. (2020). *DISEÑO DE UNA RED NEURONAL PARA LA PREDICCIÓN DE LA PRODUCCIÓN DE METANOL EN UNAPLANTA DE HIDROGENACIÓN DE CO2.*

Plata, R. (2015). *MatLab & Redes Neuronales.*

Quiguango, M. (2023). *ESTUDIO DE LA APLICACIÓN DE ATMÓSFERAS MODIFICADAS EN LA CONSERVACIÓN DEL AGUACATE FUERTE(Persea americana Mill. cv. "Fuerte") agroindustrial.*

Restrepo, V., & Sánchez, A. (2023). *Predicción de estancias hospitalarias en pacientes geriátricos en un hospital de cuarto nivel de complejidad de la ciudad de Medellín-Antioquia en los años 2021-2022.* Universidad de Antioquia.

Rodríguez, G., & Rodríguez, C. (2021). *Diseño de un software en la aplicación App Designer de Matlab para el cálculo de los niveles de aislamiento asignados y normalizados para tensiones menores a 245 kV y distancias mínimas eléctricas según estándar IEC.*

Rodríguez, P., & Henao, J. (2017). Maduración del aguacate (Persea americana Mill. cv. Hass) y calidad de los frutos. *Agronomía Colombiana Suplemento.*

<https://doi.org/10.15446/agron.colomb.sup.2016n1.58101>


Sanchez, O. (2018). *ESTUDIO DE LA INTERNALIZACIÓN DE AGUACATE HASS Y LAS OPORTUNIDADES DE INGRESAR A ESTADOS UNIDOS, EN EL MERCADO DEL TRATADO DE LIBRE COMERCIO*. UNIVERSIDAD COOPERATIVA DE COLOMBIA.

Sandoval, J., Hernández, M., Rodríguez, P., & Herrera, A. (2017). *EVALUACIÓN DE VARIABLES FÍSICO QUÍMICAS DE IMPORTANCIA EN LA CALIDAD DEL FRUTO DE AGUACATE (Persea americana Mill.) cv. HASS, PRODUCIDO EN CUATRO MUNICIPIOS DE COLOMBIA*.

Zapata. L, Malleret. A, Quinteros. C, Lesa. C, Vuarant. C, Rivadeneira. M, & Gerard. J. (2007). *CIENCIAS EXACTAS Y NATURALES INVESTIGACIÓN Estudio sobre cambios de la firmeza de bayas de arándanos durante su maduración*.

ANEXOS

Anexo 1. Requisitos del aguacate basados en las normas INEN.

 INSTITUTO ECUATORIANO DE NORMALIZACIÓN Quito - Ecuador	<p>e) Estar exentos de daños causados por plagas;</p> <p>f) Estar exentos de daños causados por altas y bajas temperaturas;</p> <p>g) Tener un pedúnculo de longitud no superior a 10 mm, cortado limpiamente.;</p> <p>h) Estar exentos de humedad externa anormal, salvo la condensación consiguiente a su remoción de una cámara frigorífica;</p> <p>i) Estar exentos de cualquier olor y/o sabor extraños.</p>																																																																
NORMA TÉCNICA ECUATORIANA NTE INEN 1755:2009 Primera Edición Primera revisión	<p>6.1.2 Los residuos de plaguicidas no deben exceder los límites máximos establecidos en el Codex Alimentarius o los exigidos por el país de destino.</p> <p>6.1.3 El fruto maduro no debe tener sabor amargo.</p> <p>6.2 Requisitos específicos. Los aguacates deben cumplir con los requisitos establecidos en la siguiente tabla:</p>																																																																
FRUTAS FRESCAS. AGUACATE. REQUISITOS. Primera Edición FRESH FRUIT. AVOCADO. SPECIFICATIONS. First Edition	<p>TABLA 3. Requisitos físico químicos de los aguacates</p>																																																																
<small>DESCRIPCIÓN: Tecnología de los alimentos, frutas, frutas frescas, aguacate, requisitos. AL: 02.03.435 COU: 024.051.93 CMI: 1113 ICS: 67.060.10</small>	<table border="1"> <thead> <tr> <th></th> <th>Madurez fisiológica</th> <th>Madurez de consumo</th> <th>Método de ensayo</th> </tr> </thead> <tbody> <tr> <td>Contenido de aceite, % m/m</td> <td></td> <td></td> <td>Ver 8.2</td> </tr> <tr> <td>Variedad Hass</td> <td>11,0 – 12,0</td> <td>> 17,0</td> <td></td> </tr> <tr> <td>Variedad fuerte</td> <td>7,0 – 8,0</td> <td>> 15,0</td> <td></td> </tr> <tr> <td>Acidez titulable (ácido tartárico), % m/m</td> <td></td> <td></td> <td>NTE INEN 381</td> </tr> <tr> <td>Variedad Hass</td> <td>8 – 9</td> <td>> 16</td> <td></td> </tr> <tr> <td>Variedad fuerte</td> <td>9 – 10</td> <td>> 18</td> <td></td> </tr> <tr> <td>Sólidos solubles, %</td> <td></td> <td></td> <td>NTE INEN 380</td> </tr> <tr> <td>Variedad Hass</td> <td>6 – 7</td> <td>> 8</td> <td></td> </tr> <tr> <td>Variedad fuerte</td> <td>5 – 6</td> <td>> 8</td> <td></td> </tr> <tr> <td>Penetrabilidad, kg/cm²</td> <td></td> <td></td> <td>Ver 8.3</td> </tr> <tr> <td>Variedad Hass</td> <td>50 – 54</td> <td>6 – 7</td> <td></td> </tr> <tr> <td>Variedad fuerte</td> <td>43 – 46</td> <td>2 – 3</td> <td></td> </tr> <tr> <td>Ph</td> <td></td> <td></td> <td>NTE INEN 389</td> </tr> <tr> <td>Variedad Hass</td> <td>6,93 – 6,95</td> <td>6,45 – 6,47</td> <td></td> </tr> <tr> <td>Variedad Fuerte</td> <td>6,69 – 6,73</td> <td>6,55 – 6,57</td> <td></td> </tr> </tbody> </table>		Madurez fisiológica	Madurez de consumo	Método de ensayo	Contenido de aceite, % m/m			Ver 8.2	Variedad Hass	11,0 – 12,0	> 17,0		Variedad fuerte	7,0 – 8,0	> 15,0		Acidez titulable (ácido tartárico), % m/m			NTE INEN 381	Variedad Hass	8 – 9	> 16		Variedad fuerte	9 – 10	> 18		Sólidos solubles, %			NTE INEN 380	Variedad Hass	6 – 7	> 8		Variedad fuerte	5 – 6	> 8		Penetrabilidad, kg/cm²			Ver 8.3	Variedad Hass	50 – 54	6 – 7		Variedad fuerte	43 – 46	2 – 3		Ph			NTE INEN 389	Variedad Hass	6,93 – 6,95	6,45 – 6,47		Variedad Fuerte	6,69 – 6,73	6,55 – 6,57	
	Madurez fisiológica	Madurez de consumo	Método de ensayo																																																														
Contenido de aceite, % m/m			Ver 8.2																																																														
Variedad Hass	11,0 – 12,0	> 17,0																																																															
Variedad fuerte	7,0 – 8,0	> 15,0																																																															
Acidez titulable (ácido tartárico), % m/m			NTE INEN 381																																																														
Variedad Hass	8 – 9	> 16																																																															
Variedad fuerte	9 – 10	> 18																																																															
Sólidos solubles, %			NTE INEN 380																																																														
Variedad Hass	6 – 7	> 8																																																															
Variedad fuerte	5 – 6	> 8																																																															
Penetrabilidad, kg/cm²			Ver 8.3																																																														
Variedad Hass	50 – 54	6 – 7																																																															
Variedad fuerte	43 – 46	2 – 3																																																															
Ph			NTE INEN 389																																																														
Variedad Hass	6,93 – 6,95	6,45 – 6,47																																																															
Variedad Fuerte	6,69 – 6,73	6,55 – 6,57																																																															

Anexo 2. Medición de firmeza de aguacate



Anexo 3. Interfaz de Regression Learner



Anexo 4. Interfaz Neural net fitting

Neural Fitting (nftool)

Select Data

What inputs and targets define your fitting problem?

Get Data from Workspace

Input data to present to the network.

Inputs: (none) ...

Target data defining desired network output.

Targets: (none) ...

Samples are: Matrix columns Matrix rows

Want to try out this tool with an example data set?

Load Example Data Set

Summary

No inputs selected.

No targets selected.

Select inputs and targets, then click [Next].

Neural Network Start Welcome Back Next Cancel