



**UNIVERSIDAD AGRARIA DEL ECUADOR
FACULTAD DE CIENCIAS AGRARIAS
“DR. JACOBO BUCARAM ORTIZ”
CARRERA DE AGROINDUSTRIA**

**TRABAJO DE TITULACIÓN COMO REQUISITO PREVIO PARA
LA OBTENCIÓN DEL TÍTULO DE
INGENIERA AGROINDUSTRIAL**

**DESARROLLO DE UN MODELO PREDICTIVO MEDIANTE
APRENDIZAJE AUTOMÁTICO PARA ESTIMAR EL ÍNDICE DE
MADUREZ DE BANANO (*Musa x paradisiaca* L.) DE
EXPORTACIÓN EN ECUADOR**

AUTOR

RAMOS FRANCO KATHERINE SCARLET

TUTOR

Ing. GARCÍA ORTEGA YOANSY, M. Sc.

GUAYAQUIL, ECUADOR

2025



**UNIVERSIDAD AGRARIA DEL ECUADOR
FACULTAD DE CIENCIAS AGRARIAS
“DR. JACOBO BUCARAM ORTIZ”
CARRERA DE AGROINDUSTRIA**

APROBACIÓN DEL TUTOR

El suscrito, docente de la Universidad Agraria del Ecuador, en mi calidad de Tutor, certifico que el presente trabajo de titulación: DESARROLLO DE UN MODELO PREDICTIVO MEDIANTE APRENDIZAJE AUTOMÁTICO PARA ESTIMAR EL ÍNDICE DE MADUREZ DE BANANO (*Musa x paradisiaca* L.) DE EXPORTACIÓN EN ECUADOR, realizado por la estudiante RAMOS FRANCO KATHERINE SCARLET; con cédula de identidad N° 0952559391 de la carrera AGROINDUSTRIA, Unidad Académica Sede Matriz Dr. Jacobo Bucaram Ortiz - Guayaquil, ha sido orientado y revisado durante su ejecución; y cumple con los requisitos técnicos y legales exigidos por la Universidad Agraria del Ecuador; por lo tanto, se aprueba la presentación del mismo.

Atentamente,

Ing. Yoansy Garcia Ortega, M.Sc.

Guayaquil, 31 de marzo del 2025



UNIVERSIDAD AGRARIA DEL ECUADOR
FACULTAD DE CIENCIAS AGRARIAS
“DR. JACOBO BUCARAM ORTIZ”
CARRERA DE AGROINDUSTRIA

APROBACIÓN DEL TRIBUNAL DE SUSTENTACIÓN

Los abajo firmantes, docentes designados por el H. Consejo Directivo como miembros del Tribunal de Sustentación, aprobamos la defensa del trabajo de titulación: “DESARROLLO DE UN MODELO PREDICTIVO MEDIANTE APRENDIZAJE AUTOMÁTICO PARA ESTIMAR EL ÍNDICE DE MADUREZ DE BANANO (*Musa x paradisiaca* L.) DE EXPORTACIÓN EN ECUADOR”, realizado por la estudiante RAMOS FRANCO KATHERINE SCARLET, el mismo que cumple con los requisitos exigidos por la Universidad Agraria del Ecuador.

Atentamente,

Ing. Calle Mendoza Luis, M. Sc
PRESIDENTE

Ing. García Ortega Yoansy, M.Sc.
EXAMINADOR PRINCIPAL

Ing. Palmay Paredes Julio, M.Sc.
EXAMINADOR PRINCIPAL

Guayaquil, 31 de marzo del 2025

DEDICATORIA

A Dios, que guía mis pasos cada día, gracias por darme la fe que ilumina mi camino para seguir este viaje académico. A mi madre, cuya fuerza, dedicación y amor incondicional han sido el pilar de mi vida. Por tu apoyo constante, por cada sacrificio silencioso y cada palabra de aliento que me permitió llegar hasta aquí. A mi padre, por sus palabras de aliento, siempre únicas, y por enseñarme a ser competitiva. También por mostrarme que reconocer lo que no sé, es el primer paso hacia el verdadero aprendizaje. A mi hermana, por ser mi luz en los momentos más oscuros y por enseñarme que la inteligencia es una herramienta poderosa en la vida. Por mostrarme que, con sabiduría, siempre puedo encontrar mi voz y hacerme escuchar. A mi hermano, por regalarme sonrisas justo cuando más las necesito y por enseñarme que, a veces, la mejor decisión es detenerse y descansar. A mi familia, y especialmente a mis abuelas, por enseñarme que una mujer puede ser poderosa de muchas maneras. Por mostrarme que siempre tengo la libertad de cambiar lo que no me gusta, cuantas veces sea necesario, hasta encontrar la versión de mí que realmente me haga sentir plena. A mis amigos, por ser esa mano que siempre está dispuesta a sostenerme, por escucharme sin juzgar y por recordarme que no estoy sola. Por hacerme valorar cada instante compartido y por llenar mi vida de momentos únicos que atesoraré siempre.

AGRADECIMIENTO

En primer lugar, quiero expresar mi profundo agradecimiento a mi familia, por su enseñanza constante, su amor incondicional y su apoyo inquebrantable a lo largo de mi vida. A Camila Morejón Chávez, por estar a mi lado desde el comienzo de la carrera. Gracias por tu apoyo constante, por ayudarme a crecer y mejorar cada día. A mi tutor, Yoansy García Ortega, por su dedicación, paciencia y por compartir su valioso conocimiento a lo largo de este proceso, por guiarme en cada etapa de este trabajo y por siempre estar dispuesto a resolver mis dudas. Agradezco también a los docentes, Ana Campuzano, Carolina Paz, Luis Calle, Julio Palmay y Alexander Álvarez, por brindarme no solo sus conocimientos y recursos, sino también por crear un ambiente inspirador que me permitió crecer en mi carrera. Su pasión por la enseñanza y su dedicación han hecho que, a lo largo de este proceso, descubra un mayor aprecio por mi disciplina y me motive a seguir adelante.

Autorización de Autoría Intelectual

Yo RAMOS FRANCO KATHERINE SCARLET, en calidad de autora del proyecto realizado, sobre “DESARROLLO DE UN MODELO PREDICTIVO MEDIANTE APRENDIZAJE AUTOMÁTICO PARA ESTIMAR EL ÍNDICE DE MADUREZ DE BANANO (*Musa x paradisiaca* L.) DE EXPORTACIÓN EN ECUADOR.” para optar el título de Ingeniera Agroindustrial, por la presente autorizo a la UNIVERSIDAD AGRARIA DEL ECUADOR, hacer uso de todos los contenidos que me pertenecen o parte de los que contienen esta obra, con fines estrictamente académicos o de investigación.

Los derechos que como autora me correspondan, con excepción de la presente autorización, seguirán vigentes a mi favor, de conformidad con lo establecido en los artículos 5, 6, 8; 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento.

Guayaquil, mayo 5, 2025

RAMOS FRANCO KATHERINE SCARLET

C.I. 0952559391

RESUMEN

El banano es una fruta subtropical importante en el comercio ecuatoriano que sufre transformaciones significativas durante el proceso de maduración, lo cual influye en su calidad. En el presente estudio, se desarrolló un modelo predictivo utilizando aprendizaje automático para estimar el índice de madurez del banano (*Musa x paradisiaca* L.), a partir de parámetros de color (cáscara y pulpa), firmeza, sólidos solubles y acidez mediante cinco repeticiones. durante el período de maduración de 21 días, bajo condiciones controladas de temperatura (13-13,5 °C) y humedad relativa (85-90 %), con cinco repeticiones por cada conjunto de datos recolectados. Se evaluó cuatro algoritmos predictivos, destacándose los modelos de Bosques Aleatorios (RF) y Máquinas de Soporte Vectorial (SVM) por su desempeño en la predicción de firmeza y acidez, obteniendo coeficientes de determinación (R^2) de 0.989. Asimismo, presentaron errores cuadráticos medios (MSE) de 4.483 y 1.219, junto con errores cuadráticos medios raíz (RMSE) de 2.112 y 1.104, respectivamente, lo que evidencia su alta precisión en las predicciones realizadas.

Palabras clave: Algoritmos, banano, maduración, métricas de evaluación, predicción.

ABSTRACT

The banana is a crucial subtropical fruit in Ecuadorian trade that undergoes significant transformations during the ripening process, affecting its quality. In this study, a predictive model was developed using machine learning to estimate the maturity index of the banana (*Musa x paradisiaca L.*), based on color parameters (peel and pulp), firmness, soluble solids, and acidity through five repetitions. The study was conducted over a 21-day ripening period under controlled temperature conditions (13-13.5 °C) and relative humidity (85-90 %), with five repetitions for each collected dataset. Four predictive algorithms were evaluated, with Random Forest (RF) and Support Vector Machines (SVM) standing out for their performance in predicting firmness and acidity, achieving determination coefficients (R^2) of 0.989. Additionally, they presented mean squared errors (MSE) of 4.483 and 1.219, along with root mean squared errors (RMSE) of 2.112 and 1.104, respectively, demonstrating high accuracy in the predictions made.

Keywords: *Algorithms, banana, ripening, evaluation metrics, prediction.*

ÍNDICE GENERAL

1. INTRODUCCIÓN.....	1
1.1 Antecedentes del problema	1
1.2 Planteamiento y formulación del problema	2
1.3 Justificación de la investigación.....	2
1.4 Delimitación de la investigación.....	3
1.5 Objetivo general	4
1.6 Objetivos específicos	4
1.7 Hipótesis	4
2. MARCO TEÓRICO	5
2.1 Estado del arte	5
2.2 Bases científicas y teóricas de la temática.....	7
2.3 Marco legal	14
3. MATERIALES Y MÉTODOS	16
3.1 Enfoque de la investigación	16
3.2 Metodología	17
4. RESULTADOS.....	23
4.1 Caracterización del índice madurez del banano (<i>Musa x paradisiaca L.</i>) (color, acidez titulable, sólidos solubles y firmeza del fruto) en una simulación de parámetros de exportación (temperatura, humedad y un tiempo máximo de exportación).	23
4.2 Entrenamiento del modelo predictivo utilizando valores de color, acidez titulable, sólidos solubles y firmeza del fruto que influyen el índice de madurez del banano, mediante técnicas de aprendizaje automático (bosques aleatorios, máquinas de vectores de soporte, regresión lineal y Perceptrón Multicapa).	25
4.3 Validación del modelo mediante los valores obtenidos de los parámetros de índice madurez (color, acidez titulable, sólidos solubles y firmeza del fruto) en la simulación de parámetros de exportación (temperatura, humedad y un tiempo máximo de exportación).	30
5. DISCUSIÓN.....	32
6. CONCLUSIONES Y RECOMENDACIONES.....	35
6.1. Conclusiones	35
6.2. Recomendaciones.....	36
BIBLIOGRAFÍA.....	37

ANEXOS.....	42
--------------------	-----------

ÍNDICE DE ANEXOS

Anexo N° 1: Banano verde.....	42
Anexo N° 2: Escala de colores de la cáscara de banana de acuerdo con su estado de maduración	42
Anexo N° 3: Ejemplos de máquinas de soporte vectorial con diferentes valores de los hiperparámetros (γ inverso de la ventana de la función kernel y coste C)	43
Anexo N° 4: Representación de una red neuronal perceptrón multicapa	44
Anexo N° 5: Norma para el banano (plátano) CXS 205-1997	45
Anexo N° 6: Muestras de banano usadas en el laboratorio	46
Anexo N° 7: Temperatura de conservación de las muestras	46
Anexo N° 8: Análisis de acidez	47
Anexo N° 9: Análisis de color.....	47
Anexo N° 10: Análisis de sólidos solubles.....	48
Anexo N° 11: Datos de análisis fisicoquímicos	49
Anexo N° 12: Métricas de error de RF.....	51
Anexo N° 13: Métricas de error de SVM	51
Anexo N° 14: Métricas de error de RL.....	51
Anexo N° 15: Métricas de error de MLP.....	52

1. INTRODUCCIÓN

1.1 Antecedentes del problema

La industria alimentaria, ha comprendido la importancia de aplicar modelos predictivos, entre los cuales, se encuentra la Inteligencia Artificial (IA) y las Redes Neuronales Artificiales (RNA) con un enfoque particular en estimar las condiciones funcionales y vida útil de los alimentos lo cual permite la elaboración de mecanismos logísticos que facilitan el transporte y el almacenamiento.

Torres et al. (2013) mencionan que, durante la maduración del banano, la corteza pierde su color verde por degradación de la clorofila adquiriendo un color amarillo. Donde la aparición de puntos oscuros en las cortezas amarillas indica el inicio de la sobre maduración. Las variaciones en el pH, acidez, sólidos solubles e índice de madurez también están relacionadas con parámetros de color.

Mundialmente, durante el año 2023 Ecuador se posicionó como el mayor exportador de banano a nivel mundial donde registró un crecimiento del 7 %, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2023). Esta fruta es ampliamente demandada por sus propiedades nutricionales y características sensoriales una vez que logra su madurez, estado en el cual se evidencian transformaciones bioquímicas detectables a través de la formación de fructosa.

Por otro lado, se han realizado trabajos de investigación que tienen resultados destacables, dentro de los que se encuentran, la aplicación de un modelo predictivo para la medición del estado o índice de madurez de *Musáceas sp*, cultivadas al suroeste del Ecuador, usando algoritmos de aprendizaje de máquina (Martínez-Mora et al., 2022), para sintetizar datos para entrenamiento y prueba del modelo, con 91 % de precisión en la predicción del estado de madurez.

Así mismo, estas nuevas tecnologías ayudan a la selección de materia prima como en estudios previos, de la clasificación de manzanas utilizando visión artificial y redes neuronales artificiales (Delfin et al., 2018), en el cual exploran la aplicación industrial de la clasificación por características visuales como tamaño, color y forma del fruto, también implementaron 2,800 imágenes de 128x128 píxeles dando como resultado una precisión del 98.3 % en entrenamiento, 95.36 % en prueba y una precisión del 92.25 % en la clasificación de video en tiempo real.

1.2 Planteamiento y formulación del problema

1.2.1 Planteamiento del problema

El sector bananero desempeña un papel crucial en la economía ecuatoriana, por lo tanto, la industria enfrenta desafíos relacionados con la estimación precisa del índice de madurez del banano (*Musa x paradisiaca L.*) destinado a la exportación, es fundamental para optimizar la cadena de suministro, minimizar las pérdidas y garantizar la entrega de un producto fresco y de alta calidad a los mercados internacionales.

Actualmente, uno de los retos más significativos en el manejo del estado de madurez del banano de exportación se basa en factores como la variación de temperatura, humedad, tiempo de almacenamiento y transporte que pueden afectar considerablemente la calidad del producto, resultando en pérdidas económicas debido a la disminución de la calidad de este.

En este contexto, los métodos convencionales no utilizan al máximo la información que proporcionan indicadores que están relacionados con la madurez y la calidad del banano, parámetros clave como el color, los sólidos solubles (°Brix), la acidez y la firmeza del fruto.

1.2.2 Formulación del problema

¿Es posible desarrollar un modelo predictivo basado en aprendizaje automático que utilice los datos de parámetros de índice de madurez (color, sólido soluble, acidez titulable y firmeza del fruto) para estimar con precisión la madurez del banano (*Musa x paradisiaca L.*) destinado a la exportación en Ecuador?

1.3 Justificación de la investigación

Ecuador se distingue como uno de los principales exportadores de banano a nivel mundial, en el 2023 alcanzó 176.369 superficie de hectáreas cultivadas, donde las provincias que encabezan en la producción de esta fruta tropical son Los Ríos con 60.593 hectáreas sembradas, seguidas de Guayas con 60.263 hectáreas y El Oro con 44.251 hectáreas, Ministerio de Agricultura y Ganadería (MAG, 2022), este cultivo es fundamental para la economía del país y generador de empleos. Donde uno de los retos más significativos en la industria

bananera es el manejo de la cadena de suministro y la logística de distribución debido a que es un producto perecedero.

En las etapas posteriores a la cosecha del banano los desperdicios constituyen con índices que oscilan entre 10 a 80 % (Vásquez et al., 2019). Esta situación pone a disposición la necesidad de implementar protocolos mejorados para los productores, a fin de garantizar el adecuado tratamiento del producto desde el cultivo hasta su distribución, disminuyendo así los factores que contribuyen el deterioro acelerado y dando como resultado la pérdida de valor de un bien de tanta relevancia económica para el país. En este aspecto, se desarrolló un modelo predictivo para estimar el índice de madurez de banano (*Musa x paradisiaca* L.) de exportación en Ecuador, que busco el mejoramiento de la cadena de abastecimiento para mantener el impacto en los mercados internacionales.

Por lo tanto, se utilizó aprendizaje automático el cual es una técnica que permite detectar secuencias repetitivas en miles de datos individuales, donde los modelos predictivos son destacables ya que permiten la automatización de procesos, toma de decisiones y el aprendizaje continuo basado en datos, estos sistemas están diseñados para mejorar automáticamente con el tiempo e integrarse en diversas mejoras para la industria bananera.

En este contexto, contribuye en la reducción significativa de los desperdicios y permite una mejor planificación de la logística para aumentar la seguridad de que el banano llegue en óptimas condiciones e incremente su valor comercial, dando como resultado el refuerzo de la imagen de Ecuador como un proveedor confiable de productos de alta calidad.

1.4 Delimitación de la investigación

El desarrollo de esta investigación cuenta con la siguiente información:

- **Espacio:** La presente investigación se llevó a cabo en la provincia del Guayas, en la ciudad de Guayaquil, en el laboratorio de la Facultad de Ciencias Agrarias "Dr. Jacobo Bucaram Ortiz" de la Universidad Agraria del Ecuador, Campus Guayaquil.
- **Tiempo:** La investigación se desarrolló durante un período de 8 meses.
- **Población:** La investigación fue dirigido a un público general interesado en obtener información sobre el desarrollo de un modelo predictivo mediante

aprendizaje automático para estimar el índice de maduración del banano de exportación en el Ecuador.

1.5 Objetivo general

Desarrollar un modelo predictivo utilizando aprendizaje automático para estimar el índice de madurez del banano (*Musa x paradisiaca L.*) de exportación en Ecuador, a partir de parámetros de madurez (color, acidez titulable, sólidos solubles y firmeza del fruto).

1.6 Objetivos específicos

- Caracterizar la índice madurez del banano (*Musa x paradisiaca L.*) (color, acidez titulable, sólidos solubles y firmeza del fruto) en una simulación de parámetros de exportación (temperatura, humedad y un tiempo máximo de exportación).
- Entrenar el modelo predictivo utilizando valores de color, acidez titulable, sólidos solubles y firmeza del fruto que influyen el índice de madurez del banano, mediante técnicas de aprendizaje automático (bosques aleatorios, máquinas de vectores de soporte, regresión lineal y Perceptrón Multicapa).
- Validar el modelo mediante los valores obtenidos de los parámetros de índice madurez (color, acidez titulable, sólidos solubles y firmeza del fruto) en la simulación de parámetros de exportación (temperatura, humedad y un tiempo máximo de exportación).

1.7 Hipótesis

Podrá obtenerse predicciones acertadas al desarrollar un modelo predictivo mediante aprendizaje automatizado para estimar el índice de madurez del banano (*Musa x paradisiaca L.*) en condiciones de exportación.

2. MARCO TEÓRICO

2.1 Estado del arte

En el estudio de Sanaeifar et al. (2016) sobre la vida útil del banano, se observó que, a medida que el fruto madura, la firmeza disminuye significativamente, pasando de 102.52 a 17.40 N. Paralelamente, los sólidos solubles totales aumentan de 7.8 a 20 °Brix. El color de la piel del banano cambia de verde a amarillo a medida que madura, con un incremento gradual en el valor b^* hasta el quinto día de vida útil, estabilizándose posteriormente. En cuanto a la acidez titulable, se observa un aumento durante la maduración, seguido de una disminución en la senescencia.

De la misma forma el estudio de Jaiswal et al. (2014) analizó simultáneamente el color (valores L^* , a^* , b^*) y la textura (firmeza del banano) en un ambiente controlado, utilizando el Hunter Color Lab y el Texture Analyser. Donde hubo un efecto significativo del período de maduración en la característica de textura considerada y las propiedades de color de los bananos.

En el estudio que asoció las etapas de maduración con los cambios fisicoquímicos y de calidad del banano, se emplearon análisis de regresión lineal para determinar el rendimiento del modelo mejor ajustado en términos de coeficiente de regresión (R^2). Entre los parámetros físicos y ópticos, los sólidos solubles totales (°Brix), acidez, firmeza y color (L^* , a^* , b^*) mostraron una correlación positiva ($R^2 \geq 0,93$) con la maduración (Owoeye et al., 2023).

Los productos utilizados para este estudio fueron bananas, naranjas, plátano verde y manzanas. Los resultados obtenidos permitieron determinar datos mínimos requeridos para el entrenamiento de los modelos de identificación y las tasas de error durante la etapa de validación. Antes del proceso de control y supervisión de calidad, se considera necesario que el prototipo pase por una etapa de entrenamiento supervisado para que el sistema reconozca y diferencie intuitivamente entre datos útiles para este modelo (González y Hernandez, 2020).

El estudio realizado por Martinez-Mora et al. (2022), implicó el desarrollo de un modelo predictivo para evaluar el estado de madurez de *Musaceas sp.*, cultivadas en el suroeste del Ecuador, empleando algoritmos de Machine Learning (ML) como Support Vector Machines (SVMs) y Random Forests (RF). La investigación en la primera etapa consistió en la recopilación de datos sobre las características fisicoquímicas (°Brix y la acidez titulable), en la segunda etapa

utilizaron algoritmos de ML para procesar dos conjuntos de datos, uno para entrenamiento y otro para prueba. Los resultados indicaron que es posible predecir el estado inmaduro, maduro o sobre maduro del banano con un resultado de 91 % de exactitud.

De igual forma Ma et al. (2022), emplearon métodos no destructivos para predecir la madurez de los bananos, analizando cambios en dulzura y color de diferentes segmentos durante la maduración. Los resultados mostraron que estos segmentos maduran de manera no simultánea. Usando análisis de componentes principales y parcelas de racimo, se identificaron seis etapas de madurez. Se desarrollaron dos algoritmos de predicción de madurez mediante bosque aleatorio (RF), red neuronal artificial (NNET) y máquinas de vectores de soporte (SVM), confirmando la adecuación de las seis etapas.

La aplicación propone detectar frutas redondas, como manzanas, naranjas y limones, utilizando un nuevo proceso desarrollado. También ofrece una interfaz gráfica de usuario para controlar y recopilar datos, evaluar modelos y monitorear la operación completa del sistema, mejorando así la eficiencia de la aplicación. Este marco utiliza un modelo de entrenamiento en dos etapas. En la primera etapa, se codifican los valores propios en un codificador automático y se decodifican. La función de pérdida utiliza el error cuadrático medio (MSE) un método de tasa de aprendizaje adaptativa. El MSE se utiliza para calcular la entrada del codificador y la salida del decodificador (Chen et al., 2022).

La calidad y los estados de maduración de las bananas se estudiaron a diferentes temperaturas (20, 25, 27.5 y 30 °C) usando una cámara de smartphone y una red neuronal artificial (RNA). Se analizaron propiedades como firmeza, sólidos solubles totales (TSS), pH y proporción de pulpa a cáscara, y su relación con características de color extraídas de imágenes RGB. Los modelos de RNA predijeron eficientemente la firmeza y los TSS, con valores de R^2 superiores a 0.96, pero no fueron adecuados para predecir el pH y la proporción de pulpa a cáscara. Se demostró que una cámara de smartphone puede ser una herramienta útil para estimar la calidad del producto (Cho y Shigenobu , 2021).

2.2 Bases científicas y teóricas de la temática

2.2.1 Caracterización del banano (*Musa x paradisiaca* L.)

El banano es una de las frutas más antiguas cultivadas y se considera un cultivo altamente evolucionado. Perteneciente a la familia *Musaceae*, tiene como nombre científico *Musa x paradisiaca* L. Originario del Sudeste Asiático, ha evolucionado considerablemente desde sus antecesores silvestres, transformándose en una fruta carnosa, presenta una notable diversificación morfológica en cuanto a tamaño, forma y color del fruto, no contiene semillas debido a su naturaleza partenocarpia, es decir, no requiere polinización ni fertilización para su desarrollo (Heslop-Harrison y Schwarzacher, 2007).

Esta *Musacea* se cosecha en su madurez fisiológica, es decir, cuando aún está verde (Anexo No 1). Con un calibre aproximado de 35 a 44 mm, una longitud mínima de 21 cm y una forma curva. Al madurar, es rico en vitaminas como la vitamina A (ácido retinoico), vitamina C (ácido ascórbico), vitamina E (tocoferol) y vitamina K (filoquinona), además del complejo de vitaminas B. También contiene minerales como el calcio (Ca) y el fósforo (P), pero destaca especialmente por su alto contenido de potasio (K), con 370 mg por cada 100 g de pulpa.

2.2.1.1. Taxonomía.

La clasificación del banano (*Musa x paradisiaca* L.) se describe en la Tabla 1:

Tabla 1.

Taxonomía del banano

Clasificación	Nombre
Reino	Plantae
División	Magnoliophyta
Clase	Liliopsida
Orden	Zingiberales
Familia	<i>Musaceae</i>
Género	<i>Musa</i>
Especie	<i>Musa x paradisiaca</i> L. (Cavendish)

Fuente: Guanuchi Castro (2024). Elaborado por: La Autora, 2025.

2.2.1.2. Parámetros del índice de madurez del banano.

Durante la maduración, los bananos experimentan modificaciones en sus características, lo cual es crucial evaluar para identificar los cambios a lo largo de su vida útil. Estos parámetros del índice de madurez del banano que deben ser evaluados incluyen:

- **Color**

El color de la cáscara se considera el primer parámetro de calidad evaluado por los consumidores y está asociado con sabores específicos o usos que pueden determinar su aceptación. De modo que, el color de la cáscara se correlaciona bien con los cambios físicos y químicos que ocurren durante la maduración de los bananos, incluyendo el color de la cáscara. Durante la maduración, el color de la cáscara del banano cambia de verde a amarillo, con la aparición de manchas marrones en el amarillo al final del proceso como se representa en el Anexo No 2 (Said et al., 2021).

- **Firmeza**

Según Ciro Velásquez y Millán Cardona (2012), la firmeza de los bananos es una característica compleja influenciada por varios factores, como es la estructura de los tejidos y las células de la fruta. A medida que los bananos maduran, su textura cambia de fruta dura a una fruta amarilla con pulpa suave, y eventualmente se vuelve blanda en la fase de senescencia. Esta pérdida de firmeza durante la maduración puede afectar la calidad de la fruta y aumentar el riesgo de daños durante la manipulación y el transporte, variando según el tipo de banano y el cultivo.

- **Acidez titulable**

La acidez titular cuantifica la cantidad de ácido en un producto. Para los bananos, el ácido predominante del plátano es málico, la medición de este se emplea principalmente para evaluar la calidad de la fruta para el consumo y descubrir características que no se ven a simple vista. La acidez titular es un indicador de la madurez de los bananos, ya que el equilibrio entre azúcar y acidez determina el sabor de la fruta, lo que hace que esta medición sea crucial en la

evaluación del sabor durante la poscosecha (Ciro Velásquez y Millán Cardona, 2012).

- **Sólidos solubles**

Ciro Velásquez y Millán Cardona (2012) mencionan que, el banano, está formado por numerosos compuestos solubles en agua como azúcares, ácidos, vitamina C (ácido ascórbico), aminoácidos y algunas pectinas, que constituyen los sólidos solubles totales (SST). En la mayoría de las frutas maduras, los azúcares son el componente predominante de estos sólidos. La cantidad de SST en los bananos aumenta a medida que la fruta madura, lo que hace de este parámetro un buen indicador de su estado de madurez. Sin embargo, el grado de aumento en los SST varía entre diferentes etapas de madurez.

2.2.1.3. Manejo post cosecha.

La recolección del banano para exportación se determina por el grosor y llenado de la fruta, utilizando un calibre de medida, y generalmente se realiza cuando el racimo tiene entre 9 y 11 semanas de edad, con un grosor entre 39 mm y 46mm y una longitud de 28 cm. Un día antes de la cosecha, se realiza una medición para marcar los racimos que deben ser cortados. Luego, se muestrean datos como edad, calibración, longitud del dedo, peso y defectos de la fruta (Navarro Patta, 2020).

Se controla la calidad del racimo eliminando flores secas y materiales ajenos, se lava para eliminar contaminantes. Tras el desmane, los bananos se sumergen en una tina con un producto que elimina el látex, donde se limpian y descartan los frutos dañados. Durante este proceso, también se clasifican, pesan, se aplica un tratamiento fungicida a la corona, y finalmente, se etiquetan y empacan conforme a los estándares del mercado utilizando cartón corrugado y papel absorbente. (Freire Castro, 2022).

2.2.1.4. Transporte.

Zein et al., (2023) indican que, en el transporte se regula los factores que influyen en la maduración de los bananos, prolongando la coloración verde por un tiempo más largo y poder permitir su comercialización. El grado de madurez a elegir depende de la duración del transporte, que varía considerablemente (desde

unos pocos días hasta 21 días). El productor debe programar el corte de los bananos de manera que el grado de madurez (estimado a partir de su madurez fisiológica) sea compatible con el transporte previsto. Los parámetros que se controlan principalmente durante el transporte son la temperatura (entre 13 – 13,5°C) y la humedad (entre 85 – 90 %).

2.2.2 Algoritmos predictivos

Según Estabrooks et al. (2004), la capacidad de las máquinas para aprender automáticamente de datos, mejorar su rendimiento con la experiencia y realizar predicciones sin necesidad de programación explícita. Utilizando datos históricos de entrenamiento, estos algoritmos crean modelos matemáticos que permiten realizar predicciones o tomar decisiones. Esta disciplina combina la informática y la estadística para construir modelos predictivos que mejoran su desempeño a medida que se alimentan con más información. Entre los algoritmos que se utilizan para predicciones están: Bosques Aleatorios (RF), Máquinas de Vectores de Soporte (SVM), Regresión Lineal (RL) y Perceptrón Multicapa (MLP).

2.2.2.1. Bosques Aleatorios (Random Forest - RF).

El bosque aleatorio, utiliza la estrategia de aleatorización para generar múltiples árboles de decisión. Cada árbol se construye mediante un proceso de muestreo aleatorio con reemplazo del conjunto de datos, conocido como "embolsado". Esto implica que algunas observaciones pueden ser seleccionadas más de una vez, mientras que otras pueden quedar excluidas, formando así un conjunto "fuera de bolsa" útil para evaluar el rendimiento del modelo. Además, en cada nodo de decisión de los árboles individuales, se selecciona aleatoriamente un subconjunto de predictores, sobre los cuales se evalúan múltiples umbrales para determinar la mejor división. Este proceso de selección aleatoria y partición continúa hasta que se alcanzan nodos "puros" o se cumple algún criterio predefinido de terminación (Breiman, 2004).

2.2.2.2. Máquinas de Vectores de Soporte (Support Vector Machines - SVM).

James et al. (2021) mencionan que las SVM, o Máquinas de Soporte Vectorial, es un modelo de aprendizaje supervisado empleados en clasificación y

regresión. Su objetivo principal es encontrar un hiperplano óptimo que maximice la distancia (margen) entre las muestras más cercanas de cada clase, conocidas como vectores de soporte. En casos de problemas no lineales, se utilizan funciones kernel, para proyectar los datos a un espacio de mayor dimensión donde un hiperplano pueda efectivamente separar las clases.

Algunas de las funciones kernel más utilizadas son:

- Kernel lineal

$$K(x, y) = x^t y$$

- Kernel polinómico

$$K(x, y) = (1 + \gamma x^t y)^d$$

- Kernel radial

$$K(x, y) = \exp(-\gamma \|x - y\|^2)$$

- Tangente hiperbólica

$$K(x, y) = \tanh(1 + \gamma x^t - y)$$

La flexibilidad de esta metodología se amplía significativamente con la opción de emplear diversos kernels, aunque es crucial realizar una selección cuidadosa de los parámetros de la función kernel (como γ y d) y del parámetro C , con el fin de evitar el sobreajuste, tal como se ilustra en el Anexo No 3.

2.2.2.3. Regresión Lineal (Linear Regression - RL).

Faraway (2016) indica que, en los modelos lineales, se asume que la función de regresión es lineal, lo que significa que el efecto de las variables explicativas sobre la respuesta es proporcional a su valor, facilitando su interpretación, donde la función de regresión es lineal:

$$E(Y|X) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p$$

El coeficiente β_j representa el incremento medio de Y al aumentar en una unidad X_j , manteniendo fijas las demás covariables. Sin embargo, en la práctica, las variables predictoras suelen estar correlacionadas, lo que puede complicar esta interpretación.

El ajuste de estos modelos se realiza comúnmente usando el método de mínimos cuadrados, asumiendo una distribución normal de la respuesta, conocido como modelo de regresión lineal múltiple. Para casos donde la distribución de la variable respuesta no es normal, se utilizan modelos lineales generalizados con una

función enlace, ajustados mediante máxima verosimilitud. Ambos modelos son fundamentales en estadística y sirven como base para métodos más avanzados en análisis de datos.

2.2.2.4. Perceptrón Multicapa (Multilayer Perceptron - MLP).

Según Efron y Hastie (2021), esta estructura avanzada se denomina perceptrón multicapa (MLP), incluye varias capas ocultas en las que cada neurona está conectada a todas las neuronas de las capas adyacentes. Aunque no sea necesario, es común que todas las neuronas de una capa compartan la misma función de activación. Al combinar múltiples capas ocultas con funciones de activación no lineales, estos modelos de red pueden aprender prácticamente cualquier patrón. Puede actuar como un aproximador universal de cualquier función, así como se visualiza en el Anexo No 4.

2.2.3 Métricas de Evaluación

Todos los algoritmos mencionados anteriormente se verifican utilizando métricas para validar la precisión de cada modelo en la realización de predicciones correctas. Estas métricas se enfocan en las propiedades específicas de cada modelo y demuestran la aproximación de replicar la variable de respuesta solicitada. Los criterios que más se utilizados para evaluar el nivel de exactitud son:

2.2.3.1. Error Cuadrático Medio (MSE).

El error cuadrático medio (MSE) es una métrica que evalúa modelos de regresión. MSE se calcula como media de los errores de predicción al cuadrado en la totalidad de los casos de prueba. El error de predicción se define como la diferencia entre el valor real y el valor predicho para una instancia (Sammut y Webb, 2011).

La fórmula del ECM es:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

n : Número total de observaciones

y_i : Valores observados

$\hat{y}_1$: Valores predichos por el modelo

2.2.3.2. Raíz Del Error Cuadrático Medio (RMSE).

Hodson (2022) menciona que, el error cuadrático medio (RMSE) es una métrica estándar utilizada en la evaluación de modelos. El RMSE se calcula por medio de la raíz cuadrada del error cuadrático medio, lo que proporciona una medida que tiene las mismas unidades que los datos originales y representa el error típico para errores distribuidos normalmente.

Formula de RMSE se expresa matemáticamente:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

n : Número de puntos de datos

y_1 : Valores observados

$\hat{y}_i$: Valores predichos.

2.2.3.3. Error Absoluto Medio (MAE).

El Error Absoluto Medio o MAE es una métrica de evaluación de modelos que se calcula como el promedio del valor absoluto de los errores entre las predicciones y las observaciones. Se utiliza para errores con distribución de Laplace y se considera más eficiente que el RMSE frente a valores fuera del rango, ya que no eleva los errores al cuadrado. El MAE mantiene la escala de los datos originales, permite una mejor interpretación, y es apropiado para distribuciones de error "contaminadas" (Hodson, 2022).

Está representada en la siguiente formula:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

y_i : Valor actual

$\hat{y}_i$: Valor de las predicciones

n : Numero de observaciones

2.2.3.4. Coeficiente de determinación (R^2).

El coeficiente de determinación R^2 es una medida que describe la dimensión de la varianza en la variable dependiente que es predecible a partir de las variables independientes en un modelo de regresión. Indica como los datos observados se

ajustan al modelo de regresión propuesto. Así mismo, R^2 mide la proporción de la varianza en la variable dependiente que puede ser explicada por la variable independientes en el modelo.

Matemáticamente, R^2 se calcula como:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_1)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

y_1 : Valores observados

$\hat{y}_1$: Valores predichos por el modelo

$\bar{y}$: Media de los valores observados

n : Número de observaciones

2.3 Marco legal

El Codex Alimentarius estandariza la normativa CXS 205-1997 norma para el banano (plátano) que indica disposiciones relativas a la calidad y disposiciones relativas a la clasificación por calibres

Requisitos mínimos

- Estar enteros: Tomando el dedo como referencia
- Estar sanos: Sin podredumbre o deterioro que los haga no aptos para el consumo.
- Estar limpios: Libres de cualquier materia extraña visible.
- Estar prácticamente exentos de plagas: Que afecten el aspecto general del producto.
- Estar prácticamente exentos de daños causados por plagas.
- Estar exentos de humedad externa anormal: Excepto la condensación normal después de ser retirados de una cámara frigorífica o si están envasados en atmósfera modificada.
- Estar exentos de cualquier olor o sabor extraños.
- Ser de consistencia firme.
- Estar exentos de daños por bajas temperaturas.
- Estar prácticamente exentos de magulladuras.
- Estar exentos de malformaciones o curvaturas anormales de los dedos.
- Estar sin pistilos.

- Tener el pedúnculo intacto: Sin doblarse, dañarse por hongos o desecarse.
- Adicionalmente, las manos y racimos deben incluir:
- Una porción suficiente de cuello: De color normal, sano y sin contaminación por hongos.
- Un cuello de corte limpio: No achaflanado ni rasgado, y sin fragmentos de pedúnculo.
- El desarrollo y la condición de los bananos deben permitir:
- Alcanzar el grado apropiado de madurez fisiológica, según las características de la variedad.
- Soportar el transporte y la manipulación.
- Llegar en estado satisfactorio al destino, permitiendo una maduración adecuada.
- En las manos: el dedo medio en la hilera exterior de la mano.
- En los racimos: el dedo junto a la sección de corte de la mano, en la hilera exterior del racimo.
- La longitud mínima debe ser de al menos 14,0 cm y el grosor mínimo de 2,7 cm.

3. MATERIALES Y MÉTODOS

3.1 Enfoque de la investigación

3.1.1 Tipo y alcance de la investigación

En la presente investigación, se aplicó un enfoque cuantitativo para la recolección de datos y muestras de banano de exportación durante la etapa de transporte. Las muestras se analizaron en una simulación de parámetros de exportación considerando la temperatura (13 - 13,5 °C), la humedad (85 – 90 %) y el tiempo máximo de exportación (21 días) de exportación. Donde se estudió el estado de madurez del producto evaluando parámetros como el color, la acidez titulable, los sólidos solubles y la firmeza del fruto, utilizando técnicas de aprendizaje automático.

Esta investigación es también del tipo descriptiva ya que se recolectó datos y muestras durante la etapa de transporte, ya que describe las condiciones y características del producto en esa fase. Además, es explicativa por que se estudió la relación entre variables como temperatura, humedad, tiempo de exportación, explicando cómo estos factores influyen en la madurez del banano. Así mismo, tiene un componente correlacional, ya que mediante el análisis de los parámetros del fruto (color, acidez, sólidos solubles y firmeza) y su relación con el índice de madurez, se pudo establecer correlaciones entre estas variables.

3.1.2 Diseño de investigación

El diseño de esta investigación fue del tipo de modelación de análisis predictivo ya que se estableció un enfoque que permite controlar la temperatura, humedad y tiempo máximo de exportación, en un ambiente controlado de laboratorio. A través de este diseño, se pudo observar directamente los efectos de estas variables sobre la madurez del banano, evaluando parámetros como el color, la acidez titulable, los sólidos solubles y la firmeza del fruto; se utilizó estos datos para entrenar y validar el modelo predictivo. Implementando técnicas de aprendizaje automático que reforzó la precisión y fiabilidad de los resultados, permitiendo así una evaluación detallada de las condiciones de transporte en la madurez del producto. Validando el modelo mediante la simulación de condiciones reales de exportación. Esta etapa permitió comprobar la efectividad del modelo

predictivo en escenarios prácticos, ajustando y perfeccionando el modelo según fue necesario.

3.2 Metodología

3.2.1 Variables

3.2.1.1. Variable independiente.

- Temperatura
- Humedad
- Tiempo máximo de exportación

3.2.1.2. Variable dependiente.

- Color
- Acidez titulable
- Sólidos solubles
- Firmeza del fruto

3.2.2 Matriz de operacionalización de variables

La matriz de operacionalización de variables se presentó a detalle en la Tabla 3 y la Tabla 4.

Tabla 2.

Matriz de operacionalización de las variables independientes

Variables independientes			
Variables	Tipo	Nivel de medida	Descripción
Temperatura	Cuantitativo	Continua	La temperatura es una medida de percepción del calor y que se determina usando un termómetro.
Humedad	Cuantitativo	Continua	Cantidad de agua (vapor) presente en el aire.
Tiempo máximo de exportación	Cuantitativo	Discretas	Magnitud física que permite cuantificar la duración del transporte.

Fuente: La Autora, 2025

Tabla 3.***Matriz de operacionalización de las variables dependientes***

Variable dependiente			
Variables	Tipo	Nivel de medida	Descripción
Color	Cuantitativo	Continua	Se mide objetivamente mediante un colorímetro, el cual proporciona valores en el espacio de color Lab (luminosidad, tono rojo-verde y tono amarillo-azul).
Acidez titulable	Cuantitativo	Continua	Representa la cantidad de ácidos orgánicos (ácido málico) presentes en la muestra
Sólidos solubles	Cuantitativo	Continua	Medida la concentración de azúcares disueltos en la muestra (banano).
Firmeza del fruto	Cuantitativo	Continua	Evalúa la resistencia de la muestra (banano) ante una fuerza aplicada.

Fuente: La Autora, 2025

3.2.3 Diseño experimental

En el presente trabajo de investigación se empleó estadística descriptiva para sintetizar datos de las caracterizas del índice madurez el banano (*Musa x paradisiaca L.*) como el color, la acidez titulable, los sólidos solubles (°Brix) y la firmeza del fruto. Se aplicó medidas de tendencia central como la media y la mediana, así como medidas de dispersión como la desviación estándar, para resumir y describir estas variables. Esto proporcionó una comprensión detallada de estas características y de cómo se relacionan con la madurez durante la exportación.

Posteriormente, se entrenó un modelo predictivo utilizando los valores obtenidos de color, acidez titulable, sólidos solubles y firmeza del fruto. Se

implemento técnicas de aprendizaje automático como bosques aleatorios (RF), máquinas de vectores de soporte (SVM), regresión lineal (RL) y Perceptrón Multicapa (MLP). La estadística descriptiva fue crucial en la preparación de datos, asegurando que los datos de entrenamiento sean precisos, para el rendimiento efectivo del modelo predictivo. Se validó el modelo por Error Cuadrático Medio (MSE), Raíz del Error Cuadrático Medio (RMSE), Error Absoluto Medio (MAE) y Coeficiente de determinación (R^2).

3.2.4 Recolección de datos

3.2.4.1. Recursos.

3.2.4.1.1. Materia prima.

- Banano

3.2.4.1.2. Equipos.

- Refractómetro
- Penetrómetro
- Colorímetro

3.2.4.1.3. Instrumentos.

- Matraz Erlenmeyer
- Soporte universal
- Bureta de 1000 mL
- Gotero

3.2.4.1.4. Reactivos.

- Hidróxido de sodio 0.1 N
- Fenolftaleína

3.2.4.2. Métodos y técnicas.

3.2.4.2.1. Simulación de parámetros de exportación.

Las muestras de banano (*Musa x paradisiaca L.*) se sometieron a un proceso de simulación que replicó condiciones típicas de exportación. Esta simulación consideró una serie de parámetros en la etapa de transporte. Entre estos parámetros, se incluyó la temperatura, la cual se mantuvo en un rango controlado de entre 13 y 13,5 °C; la humedad relativa, que se reguló para permanecer entre el 85 y el 90 %; y un periodo máximo de exportación que no se excedió de los 21 días.

3.2.4.2.2. Determinación de color.

La medición de color se realizó con un colorímetro profesional VK10. Por medio de la escala CIE L*a*b* (CIELAB), se adquirió las variables de luminosidad (L*, 0 %= blanco, 100 %= negro), a* (verde en valores negativos y rojo en valores positivos), y b* (amarillo en valores positivos y azul en valores negativos). A partir de a* y b* se calculó el ángulo de tono o hue (h°) y el índice de saturación o croma (C*) Jha (2010). Los valores de las variables de color están influenciados por el ángulo que se coloca el equipo en la muestra para la lectura. También la uniformidad del color en la superficie de productos sólidos, translúcidos u opacos es crucial, si esto es irregular, la ubicación de la lectura afectará los datos de color.

3.2.4.2.3. Determinación de sólidos solubles.

Los sólidos solubles fueron medidos utilizando un refractómetro (°Brix (0-90 %)). El proceso consistió en tomar una muestra homogenizada del producto y colocarla en el lente del refractómetro, en condiciones específicas de preparación y temperatura. Esta concentración se expresó en porcentaje en masa y el valor obtenido se anotó en la tabla de resultados, metodología basada en norma NTE INEN-ISO 2173 (2020). La medición de esta variable se realizó desde el día 1 hasta el día 21.

3.2.4.2.4. Determinación de firmeza.

La firmeza de la pulpa de los bananos se determinó en secciones de la fruta tomadas transversalmente, según el siguiente procedimiento:

- Se realizó un corte transversalmente, en el punto medio, 1 cm de tejido de la fruta (es decir, la cáscara y la pulpa).
- Para luego colocar la muestra sobre una superficie firme para luego medir la fuerza necesaria para penetrar 1 cm del tejido de la pulpa con una sonda cilíndrica de 6 mm de diámetro
- El valor registrado es la fuerza máxima necesaria para que la pulpa ceda a la punta de la sonda. La firmeza de la pulpa generalmente se registra en kilogramo-fuerza (kgf) o Newtons (N) ($1 \text{ kgf} = 9.80665 \text{ N}$) (Brenes-Gamboa, 2017).

Tomando en cuenta que la temperatura de las muestras puede afectar las mediciones y también es necesario documentar el diámetro de la sonda del penetrómetro.

3.2.4.2.5.Determinación de acidez titulable.

Dadzie y Orchard (1997) describen el procedimiento utilizado para la determinación de acidez titulable.

- Primero se pesó 30 g del tejido de la fruta y se colocó en un procesador, añadiendo 90 mL de agua destilada. Luego se procedió a mezcla por 2 minutos y se filtró.
- Del mismo modo se transfirió 25 mL de filtrado en un frasco cónico de 125 mL, añadiendo 25 mL de agua destilada y 4-5 gotas de indicador de fenolftaleína.
- Posteriormente se llenó la probeta de 25 mL de capacidad con 0.1 N de hidróxido de sodio (NaOH) y se ajustó la marca en cero después de eliminar las burbujas.
- Se tituló con 0.1 N de hidróxido de sodio hasta que el indicador cambie su color a rosado/rojo.
- Fue registrado el volumen titulado del NaOH añadido. Posteriormente, los resultados se expresaron (miliequivalentes por 100 g de muestra) en términos del ácido predominante presente, en el caso del banano es ácido málico.

3.2.5 Análisis estadístico

Se implementó cuatro algoritmos para seleccionar el adecuado y desarrollando un modelo que prediga el estado de madurez del banano de exportación utilizando métodos aleatorios: bosques aleatorios (RF), máquinas de vectores de soporte (SVM), regresión lineal (RL) y Perceptrón Multicapa (MLP). Estos algoritmos de predicción utilizaron valores promedio de color, acidez titulable, sólidos solubles y firmeza fruto. Todos los modelos se desarrollaron en R Studio. Los datos se expresaron como la media $\pm$ desviación estándar de 5 réplicas. Se aplicó un análisis de varianza (ANOVA) junto con la prueba de Tukey al 5 % de probabilidad. El modelo fue validado por Error Cuadrático Medio (MSE), Raíz del Error Cuadrático Medio (RMSE), Error Absoluto Medio (MAE) y Coeficiente de determinación (R^2).

4. RESULTADOS

4.1 Caracterización del índice madurez del banano (*Musa x paradisiaca* L.) (color, acidez titulable, sólidos solubles y firmeza del fruto) en una simulación de parámetros de exportación (temperatura, humedad y un tiempo máximo de exportación).

En el presente estudio, se llevó a cabo la caracterización del índice de madurez del banano (*Musa x paradisiaca* L.) a través del análisis del color de la cáscara y pulpa, acidez titulable, sólidos solubles y firmeza del fruto. Estos indicadores fueron evaluados bajo condiciones controladas de temperatura (13 - 13,5 °C), humedad (85 – 90 %) y tiempo máximo (21 días) de exportación de transporte. En la Tabla 4, se muestran los resultados de estadística descriptiva del parámetro color, durante los 21 días de maduración.

Tabla 4.

Color de la cáscara y pulpa del banano en diferentes estados de maduración.

Etapas de maduración (Días)	Cáscara			Pulpa		
	L*	a*	b*	L*	a*	b*
1	51.05±0.25 ^a	-9.10±0.20 ^a	26.37±0.61 ^a	76.34±0.80 ^d	0.03±0.047 ^a	13.11±0.45 ^a
5	51.26±0.31 ^a	-8.76±0.29 ^{ab}	27.47±0.61 ^a	75.67±0.40 ^{cd}	0.15±0.04 ^{ab}	15.76±0.59 ^b
8	51.87±0.28 ^{ab}	-9.04±0.20 ^{ab}	28.11±0.70 ^a	75.14±0.48 ^{cd}	0.44±0.08 ^{bc}	14.92±0.32 ^{ab}
12	51.98±0.25 ^{ab}	-8.68±0.27 ^{ab}	26.86±0.82 ^a	74.56±0.48 ^{bc}	0.56±0.04 ^c	15.86±0.38 ^b
15	52.74±0.27 ^{bc}	-8.93±0.21 ^{ab}	26.88±0.45 ^a	74.29±0.54 ^{bc}	0.72±0.10 ^{cd}	16.35±0.11 ^{bc}
19	53.13±0.51 ^{bc}	-8.49±0.10 ^{ab}	27.46±0.46 ^a	73.26±0.67 ^b	0.63±0.04 ^c	16.60±0.51 ^{bc}
21	53.77±0.11 ^c	-8.16±0.02 ^b	27.91±0.46 ^a	71.40±0.38 ^a	1.02±0.12 ^d	18.40±0.15 ^c

Los valores corresponden a la media±error estándar (n=5). L* valores alto brillo y valores bajos reflejan oscuridad, a* verde negativos y rojos positivos, y b* amarillos positivos y azules negativos. Diferencias significativas (p <0,05) se identifican mediante letras minúsculas.

Elaborado por: La Autora, 2025

El banano presentó cambios en la apariencia de la cáscara, donde el valor L* aumentó de 51.05 en la etapa 1 a 53.77 en la etapa 21, lo que indica un incremento en la claridad a medida que avanza la maduración. En cuanto al valor a*, se observó un cambio de -9.10 en la etapa 1 hasta -8.16 en la etapa 21, lo que indica una reducción en la intensidad del color verde, aunque mantuvo valores

negativos, lo que evidencia una persistencia del tono verde en la cáscara. El valor b^* aumentó de 26.37 en la etapa 1 a 29.71 en la etapa 21, lo que señala el cambio de la cáscara a tonos más amarillos, debido a la degradación de la clorofila y la acumulación de carotenoides durante el proceso de maduración.

En cuanto a la pulpa, el valor L^* mostró una disminución leve, pasando de 76.34 en la etapa 1 a 71.40 en la etapa 21, lo que indica una ligera pérdida de luminosidad y brillo conforme avanza la maduración, debido a un aumento en los sólidos solubles y el cambio en la estructura celular de la pulpa. El valor a^* se incrementó de 0.03 a 1.02, lo que refleja una tendencia hacia colores más cálidos, aunque de manera moderada. El valor b^* mostró un aumento significativo de 13.11 en la etapa 1 a 18.40 en la etapa 21, lo que indica el incremento en la intensidad de los tonos amarillos en la pulpa. A pesar de los cambios observados en los valores de color, no se alcanzó un amarillo intenso ni en la cáscara ni en la pulpa. Esto se puede atribuir a las condiciones de temperatura controlada (13-13.5°C) y humedad (85-90 %), que, aunque favorecieron el proceso de maduración, no permitieron el desarrollo de un color amarillo intenso.

Tabla 5.

Parámetros fisicoquímicos del banano en diferentes estados de maduración.

Etapas de maduración	Acidez Titulable (%m/m de ácido málico)	SST (°Brix)	Firmeza (kg f/cm²)	Índice de madurez
1	0.20±0.005 ^a	3.4±0.24 ^a	8.8±0.071 ^f	17
5	0.23±0.002 ^b	5.6±0.25 ^b	8.5±0.032 ^e	24.34
8	0.24±0.002 ^b	7.6±0.24 ^c	7.66±0.060 ^d	31.67
12	0.25±0.006 ^c	7.8±0.20 ^c	6.9±0.10 ^c	31.2
15	0.27±0.004 ^c	7.8±0.37 ^c	6.24±0.04 ^b	28.89
19	0.30±0.005 ^d	8±0.44 ^c	5.88±0.058 ^a	26.67
21	0.32±0.004 ^d	8.4±0.24 ^c	5.64±0.051 ^a	26.25

Los valores corresponden a la media±error estándar (n=5). SST: Sólidos Solubles Totales. Diferencias significativas (p <0,05) se identifican mediante letras minúsculas.

Elaborado por: La Autora, 2025

La Tabla 5 presenta los valores medios de los parámetros de acidez titulable, sólidos solubles totales y firmeza del banano en diferentes estados de maduración. En cuanto a la acidez, el banano mostró un aumento, pasando de 0.20 en la etapa 1 a 0.32 en la etapa 21, lo que se debe a la degradación de los almidones. Por otro lado, los sólidos solubles presentaron un aumento de 3.4 en la etapa 1 a 8.4 en la etapa 21, debido a que el almidón presente en el banano se descompone en azúcares más simples. Este proceso es el principal responsable del incremento de los sólidos solubles. Finalmente, la firmeza cambió, pasando de 8.80 en la etapa 1 a 5.64 en la etapa 21, lo que se debe a modificaciones en la composición de las paredes celulares.

4.2 Entrenamiento del modelo predictivo utilizando valores de color, acidez titulable, sólidos solubles y firmeza del fruto que influyen el índice de madurez del banano, mediante técnicas de aprendizaje automático (bosques aleatorios, máquinas de vectores de soporte, regresión lineal y Perceptrón Multicapa).


Se utilizó 70 % de los datos para entrenamiento y el 30 % de datos para prueba, cada uno de los modelos (bosques aleatorios, máquinas de vectores de soporte, regresión lineal y Perceptrón Multicapa) diseñados para predecir las variables (firmeza, acidez, sólidos y el día de maduración). Se seleccionaron como variables predictoras el color de la cáscara (L_Peel, a_Peel, b_Peel) y de la pulpa (L_Pulp, a_Pulp, b_Pulp).

4.2.1 Entrenamiento de bosques aleatorios

Durante el proceso de entrenamiento, RF utilizó un conjunto de 500 árboles de decisión (ntree = 500), cada uno utilizó una muestra aleatoria del conjunto de datos de entrenamiento.

Figura 1.

Comparación de valores reales vs predichos en el modelo de árboles aleatorios de Firmeza, Sólidos, Acidez y Día.



La línea roja representa la referencia de igualdad entre valores reales y valores predichos.

Elaborado por: La Autora, 2025

La Figura 1. muestra que los datos de firmeza y acidez se distribuyeron cerca de la línea de referencia, lo que evidencia un buen ajuste del modelo para esta variable, pero también revela pequeñas desviaciones. Por otro lado, los sólidos solubles presentaron una dispersión más pronunciada en valores más bajos alrededor de la línea de referencia, por lo cual el modelo obtuvo un desempeño moderado al predecir esta variable, lo que manifiesta algunas inconsistencias en sus predicciones. En los días, los datos se mantuvieron cercanos a la línea de referencia, especialmente en los valores superiores, lo que indica un buen ajuste del modelo para esta variable.

Las variables Firmeza, Acidez y Día muestran una relación más lineal o predecible con las variables independientes, lo cual permitió que el modelo identificara estas relaciones y generara predicciones más exactas. Por el contrario,


los sólidos solubles indicaron que su relación con las variables independientes resultó más compleja para la adaptación de este algoritmo.

4.2.2 Entrenamiento de máquinas de vectores de soporte (SVM)

En los modelos SVM se utilizó kernel = "radial" para capturar relaciones no lineales entre las variables de entrada y las variables de salida.

Figura 2.

Comparación de Valores Reales vs Predichos en el modelo de máquinas de vectores de soporte de Firmeza, Sólidos, Acidez y Día.



La línea roja representa la referencia de igualdad entre valores reales y valores predichos.

Elaborado por: La Autora, 2025

En la Figura 2. se observan las predicciones realizadas por un modelo de SVM. Las predicciones de firmeza y día mostraron un mejor ajuste respecto a la línea de referencia, lo cual indica que el modelo tuvo una buena adaptación entre las variables independientes y las variables a predecir. Sin embargo, en el caso de la variable sólidos solubles y acidez titulable, se observó una mayor dispersión de


los puntos alrededor de la línea, lo que sugiere dificultades para predecir y revela un sesgo mínimo en el modelo.

4.2.3 Entrenamiento de regresión lineal (RL)

Durante el entrenamiento, los modelos ajustaron sus coeficientes para minimizar la diferencia entre las predicciones y los valores reales.

Figura 3.

Comparación de valores reales vs predichos en regresión lineal de firmeza, sólidos, acidez y día.



La línea roja representa la referencia de igualdad entre valores reales y valores predichos.

Elaborado por: La Autora, 2025

En la Figura 3. se observa que, en el caso de firmeza, acidez y Día, los valores predichos mostraron un patrón consistente con los valores reales, con una alineación aceptable respecto a la línea de regresión. Sin embargo, se identificaron algunas desviaciones puntuales, lo que sugiere un sesgo mínimo en la predicción. Por otro lado, la variable sólidos presentó una mayor dispersión en los valores


predichos, lo que muestra una capacidad limitada del modelo para capturar con precisión su comportamiento.

4.2.4 Entrenamiento de perceptrón multicapa (MLP)

Para el algoritmo MLP se utilizó una arquitectura con 5 nodos en la capa oculta (size = 5), lo que permitió a la red aprender representaciones complejas, también se empleó la opción linout = TRUE para garantizar que la salida del modelo fuera continua, el número de iteraciones fue limitado a 500 (maxit = 500) para evitar el sobreajuste y garantizar la convergencia del modelo.

Figura 4.

Comparación de valores reales vs predichos en perceptrón multicapa de firmeza, sólidos, acidez y día.



La línea roja representa la referencia de igualdad entre valores reales y valores predichos.

Elaborado por: La Autora, 2025

En la Figura 4., la firmeza mostró un ajuste adecuado, ya que los valores presentaron una tendencia cercana a los valores reales. En cuanto a la variable

sólidos solubles, se observaron predicciones constantes a lo largo de los valores reales de forma horizontal, sin seguir la tendencia esperada; debido a esto, el modelo no logró aprender adecuadamente las relaciones de esta variable. Por otro lado, para la variable acidez, los valores predichos tuvieron cercanía a la línea de regresión, aunque con mayor dispersión en los valores más altos, lo que refleja una buena adaptación de este modelo para capturar la relación entre las variables de entrada y salida.

En la variable día, el modelo mostró una dispersión horizontal que sugiere un aprendizaje deficiente de los patrones. Este comportamiento podría explicarse por la complejidad de la relación no lineal entre las características de entrada y la variable a predecir, así como por limitaciones en la arquitectura seleccionada o en el número de iteraciones establecido.

4.3 Validación del modelo mediante los valores obtenidos de los parámetros de índice madurez (color, acidez titulable, sólidos solubles y firmeza del fruto) en la simulación de parámetros de exportación (temperatura, humedad y un tiempo máximo de exportación).

En la Tabla 6, la evaluación de los modelos predictivos mostró que el algoritmo de bosques aleatorios presentó un MSE de 4.460, un RMSE de 2.112 y un MAE de 2.619, con un R^2 de 0.989. Las máquinas de vectores de soporte lograron un MSE de 1.219, un RMSE de 1.104, un MAE de 2.823 y un R^2 de 0.989, lo que permitió capturar con mayor precisión las iteraciones complejas presentes en los datos, al tener bajos valores de error y altos valores de ajuste (R^2).

A diferencia de estos, la regresión lineal presentó menos precisión debido a su relación estrictamente lineal entre variables, lo que limitó su capacidad para modelar patrones más complejos. Por otro lado, el Perceptrón Multicapa (MLP), a pesar de su potencial para captar relaciones no lineales, mostró un rendimiento inferior debido a un número limitado de iteraciones o a una relación insuficiente durante el entrenamiento de las variables de entrada y salida, lo que resultó en una adaptación deficiente del modelo.

Tabla 6.

Validación de los modelos predictivos con métricas de error

Métricas de error	Bosques aleatorios	Máquinas de vectores de soporte	Regresión lineal	Perceptrón multicapa
MSE	4.483	1.219	6.860	18.801
RMSE	2.112	1.104	2.619	4.336
MAE	2.634	2.822	3.411	4.802
R^2	0.989	0.989	0.984	0.976

MSE: Error cuadrático medio, **RMSE:** Raíz del error cuadrático medio, **MAE:** error absoluto medio y **R^2 :** Coeficiente de determinación.

Elaborado por: La Autora, 2025

5. DISCUSIÓN

En la evaluación de la firmeza del fruto y los sólidos solubles, los resultados obtenidos hasta el día 21 (5.4 kg f/cm^2 y 8.4°Brix) presentan diferencias con los reportados por Sanaeifar et al. (2016), bananos evaluados hasta el día 10 con una firmeza de 3.04 kg f/cm^2 y sólidos solubles 20°Brix , lo cual se atribuye principalmente a la aplicación de etileno en las muestras durante el segundo día de experimentación, factor que acelera significativamente el proceso de maduración. Los resultados de color con el estudio de Huang et al. (2024), se identifican diferencias notables en el color de la pulpa ($L^* 87.29$, $a^* 0.81$, $b^* 16.38$), evidenciando un valor inicial de iluminación considerablemente más elevado del presente trabajo ($L^* 76.34$). Los valores iniciales del color de la cáscara ($L^* 51.76$, $a^* -11.32$, $b^* 34.39$) exhiben una mayor concordancia en términos de luminosidad, aunque manifiestan una tendencia más acentuada hacia los espectros verde y amarillo. Esta variabilidad en los resultados enfatiza la importancia de considerar las características específicas del fruto y las condiciones experimentales al evaluar los parámetros de madurez.

El porcentaje de acidez evidencia un incremento sistemático y progresivo a lo largo del período de observación. Esta tendencia muestra concordancia con las observaciones documentadas por Taiti et al. (2015), aunque en dicha investigación los valores alcanzaron un 7.25% , diferencia atribuible a que el primer muestreo se realizó dentro de las 24 h posteriores a la compra; el segundo muestreo en grado de madurez completa se realizó después de 10 días de almacenamiento en una cámara climática condiciones controladas de temperatura (14°C) y humedad relativa ($85\text{--}90 \%$). De acuerdo con Quiceno et al. (2014), este fenómeno se fundamenta en la aceleración del metabolismo inicial y favoreció una rápida acumulación de ácidos orgánicos y otros compuestos de maduración, resultando en un aumento rápido y elevado del porcentaje de acidez.

La metodología de entrenamiento implementada por Martínez-Mora et al. (2022) presentan una notable similitud en la distribución y separación de los conjuntos de datos para las fases de entrenamiento y prueba. Esta concordancia se fundamenta en el diseño metodológico de partición de datos en dos segmentos principales (30% para prueba y 70% para entrenamiento), estructura que optimiza el equilibrio en la capacidad predictiva del modelo. Cervellini y Carbone (2020)

sostienen que esta estrategia metodológica permite optimizar los parámetros del modelo mientras minimiza el error entre el aprendizaje de los datos y su capacidad de generalización, garantizando así la robustez del sistema predictivo.

En la investigación desarrollada por Ma et al. (2022), donde se implementaron los algoritmos RF y SVM, las predicciones relacionadas con los sólidos solubles muestran patrones de comportamiento análogos, aunque se observan inconsistencias en las variaciones de estas variables durante la maduración en el segmento intermedio del fruto. En este contexto, Adebayo et al. (2017) reportan resultados coincidentes en las predicciones de firmeza mediante SVM, alcanzando un coeficiente de determinación (R^2) de 0.946. No obstante, estos resultados evidencian una capacidad predictiva inferior en comparación con los obtenidos en la presente investigación. Martínez-Mora et al. (2022) argumentan que estas variaciones se fundamentan en las condiciones específicas de temperatura y humedad relativa, variables que ejercen una influencia determinante en la cinética de maduración de las Musáceas.

El modelo de regresión lineal implementado en esta investigación demuestra una capacidad predictiva satisfactoria para la variable de acidez, superando la precisión de los resultados reportados por Owoeye et al. (2023). Sin embargo, en concordancia con dicho estudio, el modelo exhibe limitaciones significativas en su capacidad para capturar y modelar variaciones no lineales en los sólidos solubles. Respecto a el parámetro de color, se observa una evaluación general satisfactoria con las demás variables fisicoquímicas, aunque las predicciones específicas del componente b^* presentan imprecisiones atribuibles a la presencia de patrones no lineales en su comportamiento durante la maduración.

Los modelos de aprendizaje automático basados en Perceptrón Multicapa (MLP) evidencian limitaciones significativas en la predicción de sólidos solubles del banano. En contraste con los hallazgos reportados por Sanaeifar et al. (2016), quienes establecieron correlaciones significativas entre el análisis de sólidos solubles y los parámetros cromáticos (L^* , a^* , b^*), la implementación independiente de estos últimos se constituye como una herramienta metodológica más robusta y confiable para la evaluación integral de la madurez en el banano, permitiendo una caracterización más precisa del estado fisiológico del fruto.

Los valores de MSE reducidos (4.483 y 1.219) obtenidos mediante la implementación de bosques aleatorios y máquinas de vectores de soporte,

respectivamente, evidencian una elevada precisión en la predicción de firmeza y sólidos solubles totales (SST) del banano bajo condiciones experimentales controladas. En comparación con la investigación de Cho y Shigenobu (2021), el modelo desarrollado alcanza valores de MSE significativamente inferiores a 72.32 para firmeza y 1.40 para SST, demostrando una eficiencia superior en estas métricas de evaluación. La efectividad de los métodos avanzados de aprendizaje automático en la predicción de parámetros críticos para la madurez del banano, aunque la precisión específica depende esencialmente de la naturaleza y comportamiento de las variables analizadas.

Los coeficientes de determinación (R^2) de 0.989 obtenidos mediante la implementación de Bosques Aleatorios y SVM destacan por su precisión y reducidos márgenes de error (MSE de 1.219 y 4.460, MAE de 2.823 y 2.619), superando significativamente el desempeño de modelos alternativos como el Perceptrón Multicapa y la regresión lineal convencional. Por el contrario, Aouant et al. (2023) reportan valores inferiores de R^2 (0.717 y 0.822) y errores específicos (MSE de 2.330 y 0.150, MAE de 1.180 y 0.270), evidenciando un menor ajuste y capacidad predictiva. Por otra parte, Sinanoglou et al. (2023) reportan un R^2 superior a 0.98, resultado comparable con el presente estudio, atribuible a la implementación de modelos avanzados capaces de capturar eficientemente las relaciones no lineales en conjuntos de datos complejos.

Los modelos predictivos fundamentados en bosques aleatorios y máquinas de soporte vectorial (SVM) exhiben valores de RMSE de 2.112 y 1.104, respectivamente, junto con un R^2 de 0.989, demostrando una elevada precisión en la caracterización del índice de madurez del banano. De manera análoga, Galal et al. (2022) reportan coeficientes de determinación de hasta 0.97 para sólidos solubles totales (TSS) y 0.98 para firmeza, con valores de RMSE de 1.83 y 3.37, diferenciándose principalmente en la implementación de técnicas no destructivas para la obtención de datos experimentales.

6. CONCLUSIONES Y RECOMENDACIONES

6.1. Conclusiones

Los valores de color en la cáscara mostraron un incremento en la luminosidad (L^*) de 51.05 a 53.77, una reducción en la intensidad del verde (a^*) de -9.10 a -8.16, y un aumento en los tonos amarillos (b^*) de 26,37 a 27,91. Además, la acidez titulable presentó un incremento de 0.20 a 0.32 %, los sólidos solubles aumentaron de 3.4 a 8.4 °Brix, y la firmeza disminuyó de 8.8 a 5.64 kg f/cm², evidenciando la evolución del proceso de maduración sin llegar a una madurez comercial bajo las condiciones controladas de temperatura (13-13.5°C) y humedad relativa (85-90 %) por 21 días.

El entrenamiento de los modelos predictivos mediante técnicas de aprendizaje automático mostró que los modelos de RF y SVM expusieron un rendimiento mayor en la predicción de firmeza y acidez, con datos distribuidos consistentemente cerca de la línea de referencia. La RL mostró un desempeño aceptable en la predicción de acidez, mientras que el MLP presentó limitaciones significativas en la predicción de sólidos solubles, manifestando una tendencia a generar predicciones constantes sin seguir el patrón esperado de los valores reales.

La validación de los modelos predictivos evidencia una buena capacidad de predicción de los algoritmos de RF y SVM, alcanzando R^2 de 0.989 y valores reducidos de error MSE (4.483 y 1.219) y RMSE (2.112 y 1.104). El rendimiento inferior de la RL y el MLP, que mostraron limitaciones en la captura de relaciones no lineales y mayor dispersión en sus predicciones, particularmente en la estimación de sólidos solubles y variables cromáticas durante el proceso de maduración del plátano.

6.2. Recomendaciones

La extensión del periodo de evaluación bajo condiciones controladas de temperatura (13 - 13,5°C) y humedad (85 – 90 %) más allá de los 21 días permitirá una caracterización más exhaustiva de los parámetros de maduración del banano para exportación. Proporcionando mayor cantidad de datos sobre las variaciones de madurez para comprender el comportamiento del fruto en condiciones de exportación y determinar el punto óptimo de madurez comercial que garantiza la calidad del producto en el mercado de destino.

La incorporación de modelos de aprendizaje profundo como las Redes Neuronales Convolucionales (CNN) o arquitecturas híbridas que integran elementos de diferentes algoritmos puede mejorar la capacidad predictiva del modelo, especialmente para la variable de sólidos solubles que mostró un comportamiento no lineal complejo. La implementación de técnicas de regularización y validación cruzada dentro de estos modelos puede ayudar a prevenir el sobreajuste y mejorar la generalización de las predicciones en nuevos conjuntos de datos.

La optimización del modelo Perceptrón Multicapa requiere una estrategia integral que incluya la experimentación con diferentes arquitecturas de capas ocultas y el ajuste metódico de hiperparámetros críticos. La estructura del modelo puede mejorarse mediante la incorporación de variables fisiológicas relevantes como la tasa de respiración del fruto, la producción de etileno y el contenido de almidón durante el proceso de maduración permitirá desarrollar modelos más precisos para predecir el comportamiento del banano durante su maduración bajo condiciones controladas de exportación.

La validación de los modelos predictivos puede fortalecerse mediante la implementación de técnicas de remuestreo como el bootstrap y la validación cruzada k-fold. El uso de estas técnicas ayudará a obtener estimaciones más confiables de las métricas de error, para identificar posibles problemas de varianza en los modelos, especialmente en aquellos que mostraron un rendimiento inferior como el Perceptrón Multicapa y la Regresión Lineal.

BIBLIOGRAFÍA

- Adebayo, S., Hashim, N., Abdan, K., Hanafi, M., y Zude-Sasse, M. (2017). Banana Quality Attribute Prediction and Ripeness Classification Using Support Vector Machine. *International Journal of Food Engineering*, 3(1). doi:10.18178/ijfe.3.1.42-47
- Alemán, S. (2019). Estudio de la composición físico-química, propiedades funcionales y nutricionales de almidones nativos y modificados extraídos de clones de diferentes variedades de musaceas. [Tesis Doctoral, Universidad Central de Venezuela]. Saber UCV. Obtenido de Saber UCV: <http://hdl.handle.net/10872/5874>
- Aouant, K., Mouka, E., Ladika, G., Sinanoglou, V. J., y Cavouras, D. (2023). Assessment of banana quality and shelf-life during ripening by generating prediction models. *Applied Sciences*.
- Breiman, L. (2004). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical science*, 16(3), 199-231. <https://doi.org/10.1214/ss/1009213726>
- Brenes-Gamboa, S. (2017). Parámetros de producción y calidad de los cultivares de banano FHIA-17, FHIA-25 y Yangambi. *Agronomía Mesoamericana*, 28(3), 719-733. <https://doi.org/10.15517/ma.v28i3.21902>
- Cervellini, M., y Carbone, M. (2020). Utilización de un modelo predictivo como soporte para la revisión de los recursos ordinarios de apelación. <http://sedici.unlp.edu.ar/handle/10915/116746>
- Chen, M. C., Cheng, Y. T., y Liu, C. Y. (2022). Implementation of a Fruit Quality Classification Application Using an Artificial Intelligence Algorithm. *Sensors and Materials*, 34(1), 151–162. <https://doi.org/10.18494/SAM3553>
- Cho, B. H., y Shigenobu, K. (2021). Determination of banana quality indices during the ripening process at different temperatures using smartphone images and an artificial neural network. *Scientia Horticulturae*, 288. doi:<https://doi.org/10.1016/j.scienta.2021.110382>
- Ciro Velásquez, H. J., y Millán Cardona, L. d. (2012). Caracterización mecánica y físico-química del banano tipo exportación (*Cavendish valery*). Corporación Universitaria Lasallista. <http://hdl.handle.net/10567/136>

- Codex Alimentarius CODEX. (2022). Norma para el banano (plátano) CXS 205-1997.
- Dadzie, B., y Orchard, J. (1997). *Evaluación rutinaria postcosecha de híbridos de bananos y plátanos: criterios y métodos*. Bioversity International.
- Delfin, C. M., González, C. J., y Rojas, J. O. (2018). Clasificación de manzanas utilizando visión artificial y redes neuronales artificiales. *Ingeniería y Región*, 20(1), 52-57. doi:10.25054/22161325.1917
- Efron, B., y Hastie, T. (2021). *Computer age statistical inference, student edition: algorithms, evidence, and data science*. Cambridge University Press.
- Estabrooks, A., Jo, T., y Japkowicz, N. (2004). *A Multiple Resampling Method for Learning from Imbalanced Data Sets*. Computational intelligence.
- FAO. (2023). Banana Market Review – Preliminary results 2023. Rome.
- Faraway, J. J. (2016). *Extending the linear model with R: generalized linear, mixed effects and nonparametric regression models*. Chapman and Hall/CRC.
- Freire Castro, M. D. (2022). *Caracterización del manejo post cosecha del banano y su industrialización por medio de revisión bibliográfica*. [Tesis de pregrado, Universidad Técnica de Machala]. <http://repositorio.utmachala.edu.ec/handle/48000/18470>
- Galal, H., Elsayed, S., Allam, A., y Farouk, M. (2022). Indirect Quantitative Analysis of Biochemical Parameters in Banana Using Spectral Reflectance Indices Combined with Machine Learning Modeling. *Horticulturae*, 8(5), 438. <https://doi.org/10.3390/horticulturae8050438>
- González, C. A., y Hernandez, V. (2020). Clasificador de Productos Agrícolas para Control de Calidad basado en Machine Learning e Industria 4.0. *Revista Perspectivas*, 2(2), 21-28. doi:<https://doi.org/10.47187/perspectivas.vol2iss2.pp21-28.2020>
- Guanuchi Castro, A. O. (2024). Descripción de daños causado por *Erwinia carotovora* en el racimo de Banano (*Musa AAA*). [Tesis de Maestría, Universidad Técnica de Babahoyo]. <http://dspace.utb.edu.ec/handle/49000/16050>
- Heslop-Harrison, J. S., y Schwarzacher, T. (Octubre de 2007). Domestication, Genomics and the Future for Banana. *Annals of Botany*, 100(5), 1073–1084. doi:<https://doi.org/10.1093/aob/mcm191>

- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development Discussions*, 15(14), 1-10. <https://doi.org/10.5194/gmd-15-5481-2022>
- Huang, P.-H., Cheng, Y.-T., Lu, W.-C., Chiang, P.-Y., Yeh, J.-L., Wang, C.-C., . . . Li, P.-H. (2024). Changes in Nutrient Content and Physicochemical Properties of *Cavendish* Bananas var. Pei Chiao during Ripening. *Horticulturae*, 10, 384. <https://doi.org/10.3390/horticulturae10040384>
- Jaiswal, P., Jha, S. N., Kaur, P. P., Bhardwaj, R., Singh, A. K., y Wadhawan, V. (2014). Prediction of textural attributes using color values of banana (*Musa sapientum*) during ripening. *Journal Food Science Technol*, 51(6), 1179-1184. doi:<https://doi.org/10.1007/s13197-012-0614-2>
- James, G., Witten, D., Hastie, T., y Tibshirani, R. (2021). *An Introduction to Statistical Learning: With Applications in R*. Springer.
- Jha, S. N. (2010). *Colour Measurements and Modeling*. Springer eBooks. https://doi.org/10.1007/978-3-642-15796-7_2
- Ma, L., Liang, C., Cui, Y., Du, H., Liu, H., Zhu, L., . . . Brennan, C. (2022). Prediction of banana maturity based on the sweetness and color values of different segments during ripening. *Current Research in Food Science*, 5(1), 1808-1817. doi:<https://doi.org/10.1016/j.crfs.2022.08.024>
- MAG. (2022). Cartografía de estimación de superficie plantada de los cultivos de banano, palma aceituna y caña de azúcar. Escala 1:25.000. *Ministerio de Agricultura y Ganadería*.
- Martinez-Mora, O., Capuñay-Uceda, O., Caucha-Morales, L., y Ruilova-Cueva, M. B. (2022). Modelo predictivo para la medición del estado de madurez de *Musáceas* sp., cultivadas al suroeste del Ecuador, usando algoritmos de Machine Learning. *Magazine de las Ciencias: Revista de Investigación e Innovación*, 7(2), 62-72. doi:<https://doi.org/10.33262/rmc.v7i2.2809>
- Maxwell, M. (2023). *Ecuador sets out banana sustainability progress*. Fruitnet. <https://www.fruitnet.com/eurofruit/ecuador-sets-out-banana-sustainability-progress/248412.article>
- Navarro Patta, F. R. (2020). *Efecto de la nutrición translaminar en las características del racimo de banano (Musa AAA. var. Williams) en el cantón Valencia*. [Tesis de Pregrado, Universidad Técnica Estatal de Quevedo]. <https://repositorio.uteq.edu.ec/handle/43000/5998>

- Owoeye, O. R., Oluwole, A. M., Jolayemi, O. S., y Oluwalana, I. B. (2023). Linear and nonlinear regression modeling of the chemical, physical and quality variations in Cardaba banana (*Musa acuminata* x *balbisiana* – ABB) during ripening. *Journal of Food Measurement and Characterization*, 17(1), 12-23. <https://doi.org/10.1007/s11694-022-01570-4>
- Quiceno, M. C., Giraldo, G. A., y Villamizar, R. H. (2014). Caracterización fisicoquímica del plátano (*Musa paradisiaca* sp. AAB, *Simmonds*) para la industrialización. *UG Ciencia*, 20, 48-54. <https://core.ac.uk/download/pdf/268087837.pdf>
- Said, N. M., Madzin, H., Ali, S. K., y Beng, N. S. (2021). Comparison of color-based feature extraction methods in banana leaf diseases classification using SVM and K-NN. *Indonesian Journal of Electrical Engineering and Computer Science*, 24(3), 1523-1533. <https://doi.org/10.1007/s11694-022-01570-4>
- Sammut, C., y Webb, G. I. (2011). *Encyclopedia of machine learning*. Springer.
- Sanaeifar, A., Bakhshipour, A., y De la Guardia, M. (2016). Prediction of banana quality indices from color features using support vector regression. *Talanta*, 148(1), 54-61. doi:<https://doi.org/10.1016/j.talanta.2015.10.073>
- Sinanoglou, V. J., Tsiaka, T., Aouant, K., Mouka, E., Ládika, G., Kritsi, E., . . . Cavouras, D. (2023). Quality Assessment of Banana Ripening Stages by Combining Analytical Methods and Image Analysis. *Applied Sciences*, 13(6), 3533. <https://doi.org/10.3390/app13063533>
- Taiti , C., Costa, C., Menesatti , P., Caparrotta , S., Bazihizina, N., Azzarello , E., . . . Giordani , E. (2015). Use of volatile organic compounds and physicochemical parameters for monitoring the post-harvest ripening of imported tropical fruits. *Eur Food Res Technol*, 241, 91. doi:10.1007/s00217-015-2438-6
- Torres, R., Montes, E., Pérez, O., y Andrade, R. (2013). Relación del Color y del Estado de Madurez con las Propiedades Fisicoquímicas de Frutas Tropicales. *Información tecnológica*, 24(3), 51-56. doi:<https://doi.org/10.4067/s0718-07642013000300007>
- Vásquez, W., Racines, M., Moncayo, P., Viera, W., y Seraquive, M. (2019). Calidad del fruto y pérdidas poscosecha de banano orgánico (*Musa acuminata*) en el Ecuador. *Enfoque UTE*, 10(4), 57-66. doi:<https://doi.org/10.29019/enfoque.v10n4.545>

Zein, R. N., Sawi'eo, Y., Arum, Z., y Sari, A. (2023). Post-harvest Handling of Cavendish Banana (*Musa acuminata cavendish*). *Atlantis Press*, 584-590.
https://doi.org/10.2991/978-94-6463-122-7_55

ANEXOS

Anexo N° 1:



Banano verde

Fuente: Maxwell, 2023

Anexo N° 2:


Escala de colores de la cáscara de banana de acuerdo con su estado de maduración

COLOR	DESCRIPCIÓN
	1- Totalmente verde
	2- Verde con trazos amarillos
	3- Más verde que amarillo
	4- Más amarillo que verde
	5- Amarillo con puntas verdes
	6- Completamente amarilla
	7- Amarilla con áreas marrones

Fuente: Alemán , 2019

Anexo N° 3:


Ejemplos de máquinas de soporte vectorial con diferentes valores de los hiperparámetros (γ inverso de la ventana de la función kernel y coste C)



Fuente: James et al., 2021

Anexo N° 4:

Representación de una red neuronal perceptrón multicapa



Fuente: Efron y Hastie, 2021

Anexo N° 5:***Norma para el banano (plátano) CXS 205-1997*****NORMA PARA EL BANANO (PLÁTANO)****CXS 205-1997****Adoptada en 1997. Enmendada en 2005, 2022.****Enmienda aprobada en 2022**

Las siguientes enmiendas se introdujeron en el texto de la norma a raíz de las decisiones adoptadas en el 45.º período de sesiones de la Comisión del Codex Alimentarius celebrado en diciembre de 2022:

Página	Ubicación	Texto original	Texto impreso
2	1. DEFINICIÓN DEL PRODUCTO	Esta norma se aplica a las variedades comerciales de bananos (plátanos) obtenidos de <i>Musa</i> spp. (AAA), de la familia Musaceae, en estado verde, que habrán de suministrarse frescos al consumidor, después de su acondicionamiento y envasado. Se excluyen los bananos (plátanos) destinados solamente para su cocción o a la elaboración industrial. Las variedades reguladas por esta norma se indican en el anexo.	Esta norma se aplica a las variedades comerciales de bananos (plátanos) obtenidos de <i>Musa</i> spp., de la familia Musaceae, en estado verde, que habrán de suministrarse frescos al consumidor, después de su acondicionamiento y envasado. Se excluyen los bananos (plátanos) destinados solamente para su cocción o a la elaboración industrial. Las variedades reguladas por esta norma se indican en el anexo.

Fuente: CODEX, 2022

Anexo N° 6:***Muestras de banano usadas en el laboratorio***

Elaborado por: La Autora, 2025

Anexo N° 7:***Temperatura de conservación de las muestras***

Elaborado por: La Autora, 2025

Anexo N° 8:***Análisis de acidez***

Elaborado por: La Autora, 2025

Anexo N° 9:***Análisis de color***

Elaborado por: La Autora, 2025

Anexo N° 10:***Análisis de sólidos solubles***

Elaborado por: La Autora, 2025

Anexo N° 11:

Datos de análisis fisicoquímicos

Día	L_Peel	a_Peel	b_Peel	L_Pulp	a_Pulp	b_Pulp	Acidez (g/100ml)	Sólidos (%)	Firmeza (kg/cm2)
1	51.01	-8.56	27.39	76.93	-0.14	11.71	0.19	4	8.9
1	50.55	-8.69	27.09	75.62	0.04	14.43	0.2	3	8.8
1	51.29	-9.5	27.16	75.6	0.15	13.7	0.2	3	9
1	51.87	-9.24	26.16	77.42	0.05	12.87	0.21	3	8.7
1	50.53	-9.52	24.08	76.15	0.05	12.85	0.22	4	8.6
5	52.2	-8.59	26.73	76.49	0.19	17.17	0.22	5	8.5
5	51.73	-8.77	26.98	76.76	0.01	16.84	0.22	6	8.6
5	50.75	-9.19	27.45	74.37	0.27	15.48	0.23	5	8.5
5	51.12	-9.48	29.83	76.48	0.16	13.81	0.23	6	8.4
5	50.52	-7.78	26.39	74.23	0.14	15.49	0.23	6	8.5
8	51.81	-8.38	26.61	75.29	0.21	15.35	0.23	7	7.8
8	50.86	-9.52	30.57	75.3	0.74	13.83	0.23	7	7.5
8	51.83	-9.36	27.19	75.14	0.48	15.31	0.24	8	7.8
8	52.58	-8.81	27.32	74.35	0.44	14.56	0.24	8	7.6
8	52.25	-9.14	28.85	75.66	0.33	15.55	0.24	8	7.6
12	51.96	-7.84	26.99	74.62	0.48	14.56	0.24	7	7.2
12	52.48	-8.48	26.62	74.55	0.6	15.55	0.25	8	6.8
12	51.96	-9.16	24.47	73.77	0.65	16.12	0.26	8	7
12	52.44	-8.56	26.64	74.84	0.62	16.28	0.27	8	6.9
12	51.07	-9.37	29.6	75.04	0.45	16.79	0.27	8	6.6
15	52.52	-8.82	28.2	74.17	0.62	16.17	0.27	7	6.3
15	53.37	-8.8	27.29	73.43	0.67	16.12	0.27	8	6.2
15	52.08	-8.24	25.94	74.88	0.81	16.28	0.27	8	6.3

Día	L_Peel	a_Peel	b_Peel	L_Pulp	a_Pulp	b_Pulp	Acidez (g/100ml)	Sólidos (%)	Firmeza (kg/cm2)
15	52.31	-9.47	27.19	74.56	1.07	16.39	0.27	7	6.1
15	53.41	-9.33	25.8	74.42	0.42	16.79	0.29	9	6.3
19	52.94	-8.78	26.6	73.36	0.47	18.09	0.29	7	6
19	51.35	-8.37	28.54	73.87	0.68	15.29	0.29	8	5.8
19	53.85	-8.71	28.33	73.68	0.68	16.16	0.31	7	5.9
19	54.41	-8.34	26.19	73.25	0.7	17.67	0.31	9	5.7
19	53.1	-8.23	27.63	72.13	0.62	16.24	0.31	9	6
21	53.47	-8.14	26.21	71.48	0.95	18.78	0.31	9	5.6
21	54.07	-8.12	27.67	71.45	1.31	20.43	0.31	9	5.5
21	53.98	-8.21	28.72	71.99	0.75	16.76	0.32	8	5.7
21	53.54	-8.12	28.62	71.04	0.78	16.58	0.32	8	5.8
21	53.83	-8.23	28.34	71.06	1.33	19.45	0.33	8	5.6

Elaborado por: La Autora, 2025

Anexo N° 12:***Métricas de error de RF***

```

> cat("MAE global:", MAE_global, "\n")
MAE global: 2.634528
> cat("MSE global:", MSE_global, "\n")
MSE global: 4.483296
> cat("RMSE global:", RMSE_global, "\n")
RMSE global: 2.117379
> cat("R² global:", R2_global, "\n")
R² global: 0.9891322

```

Elaborado por: La Autora, 2025

Anexo N° 13:***Métricas de error de SVM***

```

> cat("MAE global:", MAE_global, "\n")
MAE global: 2.822065
> cat("MSE global:", MSE_global, "\n")
MSE global: 1.219919
> cat("RMSE global:", RMSE_global, "\n")
RMSE global: 1.104499
> cat("R² global:", R2_global, "\n")
R² global: 0.9891518

```

Elaborado por: La Autora, 2025

Anexo N° 14:***Métricas de error de RL***

```

> cat("MAE global:", MAE_global, "\n")
MAE global: 3.41185
> cat("MSE global:", MSE_global, "\n")
MSE global: 6.860039
> cat("RMSE global:", RMSE_global, "\n")
RMSE global: 2.619168
> cat("R² global:", R2_global, "\n")
R² global: 0.9842632

```

Elaborado por: La Autora, 2025

Anexo N° 15:***Métricas de error de MLP***

```
> cat("MAE global:", MAE_global, "\n")
MAE global: 4.802108
> cat("MSE global:", MSE_global, "\n")
MSE global: 18.80144
> cat("RMSE global:", RMSE_global, "\n")
RMSE global: 4.336063
> cat("R² global:", R2_global, "\n")
R² global: 0.9767945
```

Elaborado por: La Autora, 2025