

Sistema Automático para el Cálculo del Tiempo de Esterilizado del Fruto de Palma *Elaeis*  
*Guineensis* Mediante Inteligencia Artificial

Luis Alberto López Yepes

Trabajo de Grado para Optar al Título de Magister en Ingeniería Mecánica

Director

William Pinto Hernández.

Doctor en Ciencias de Ingeniería Mecánica

Universidad Industrial de Santander

Facultad de Ingenierías fisicomecánicas

Escuela de Ingeniería Mecánica

Maestría en Ingeniería Mecánica

Bucaramanga

2026

### **Dedicatoria**

Dedico este trabajo a Dios, por darme la fortaleza, la sabiduría y la perseverancia necesarias para culminar esta etapa; y a mi familia, por su apoyo incondicional, paciencia y confianza durante todo el proceso. Este logro es el resultado del esfuerzo, la fe y el amor que me acompañaron en cada paso del camino.

### **Agradecimientos**

A Dios, por ser mi guía y fortaleza en cada etapa de este proceso, por brindarme la sabiduría y la constancia necesarias para superar los desafíos académicos y personales que implicó esta maestría.

A mis padres, Francisco José López Wilches y Rosa Alexandra Yépez Ortega, por su amor incondicional, sus consejos y su apoyo permanente. Su ejemplo de trabajo y responsabilidad ha sido la base sobre la cual he construido mis metas profesionales y personales. Este logro también les pertenece.

A mi director de investigación, William Pinto Hernández, por su orientación rigurosa, acompañamiento constante y compromiso con la excelencia académica. Sus observaciones y confianza en mis capacidades fueron fundamentales para el desarrollo de esta investigación.

A mis hermanos, Javier López, Gabriela López y Francisco López, por su apoyo y palabras de ánimo en los momentos de mayor exigencia.

A mi consejero, Augusto López, por sus valiosos aportes humanos y disposición para contribuir al fortalecimiento de este trabajo.

A Babupalm S.A.S., por facilitar la información requerida y por su colaboración institucional, clave para la consolidación de los resultados obtenidos.

Finalmente, agradezco a todas las personas que, directa o indirectamente, aportaron al cumplimiento de esta meta académica y profesional.

**TABLA DE CONTENIDO**

	<b>Pág.</b>
Introducción .....	15
1. Proceso de Beneficio de la Palma de Aceite .....	16
1.1 Cultivo de Palma de Aceite .....	16
1.1.1 Madurez en Racimos de Palma de Aceite .....	18
1.2 Descripción del Proceso de Extracción de Aceite de Palma .....	21
1.2.1 Recepción y Selección de la Materia Prima.....	21
1.2.2 Esterilización.....	21
1.2.3 Digestión y Prensado .....	22
1.2.4 Clarificación.....	22
1.2.5 Almacenamiento .....	22
2. Objetivos .....	24
2.1 Objetivo General .....	24
2.2 Objetivos Específicos .....	24
3. Marco Teórico .....	25
3.1 Tipos de Imágenes en Procesamiento Digital.....	25
3.1.1 Espectro Electromagnético.....	25
3.1.2 Arquitectura de una Imagen.....	25
3.1.3 Imágenes en Espacio de Color RGB.....	26

TIEMPO DE ESTERILIZADO DEL FRUTO DE PALMA	5
3.1.4 Imágenes Infrarrojas.....	27
3.1.5 Mapas de Profundidad.....	27
3.2 Técnicas de Procesamiento Digital de Imágenes .....	27
3.2.1 Redimensionamiento.....	28
3.2.2 Binarización de una Imagen.....	30
3.2.3 Segmentación de una Imagen.....	31
3.2.4 Filtrado de una Imagen.....	31
3.2.5 Detección de Bordes .....	35
3.2.6 Análisis Morfológico de una Imagen.....	39
3.3 Algoritmos de Aprendizaje Automático .....	40
3.3.1 Regresión lineal de Múltiples Variables.....	40
3.3.2 Redes Neuronales Artificiales.....	40
3.3.3 Redes Neuronales Convolucionales.....	47
3.3.4 Modelos de Aprendizaje Profundo Preentrenados .....	51
4. Diseño Metodológico .....	52
4.1 Bloque 1: Fases Necesarias para la Construcción del Algoritmo de Caracterización de Madurez. 53	
4.1.1 Fase 1: Adquisición de Fotografías.....	54
4.1.2 Fase 2: Elaboración del Algoritmo de Preprocesamiento .....	57
4.1.3 Fase 3: Elaboración de red Neuronal Convolutacional de Preprocesamiento .....	66

4.1.4 Fase 4: Elaboración RNC de Clasificación de Madurez .....	69
4.2 Bloque 2: Fases Necesarias para la Construcción del Algoritmo de Determinación de Tiempo de Esterilizado. ....	72
4.2.1 Fase 1: Adquisición de Información del Ciclo de Esterilizado .....	72
4.2.2 Fase 2: Elaboración del Algoritmo de Caracterización de Tiempos de Esterilizado .....	74
5. Implementación .....	78
5.1 Validación del Modelo Computacional Mediante Implementación en Planta .....	78
5.2 Predicción económica de la implementación del modelo .....	81
6. Conclusiones .....	84
7. Trabajo futuro.....	85
Referencias Bibliográficas .....	87

**Lista de Figuras**

<b>Figura 1</b> Cultivo de palma de aceite. ....	16
<b>Figura 2</b> Racimos de palma de aceite tipo tenera. ....	17
<b>Figura 3</b> Fruto de palma de aceite tipo tenera.....	18
<b>Figura 4</b> Racimos de palma de aceite en estado de maduración "inmaduro". ....	19
<b>Figura 5</b> Racimo de palma de aceite en estado de maduración "maduro". ....	20
<b>Figura 6</b> Racimo de palma de aceite en estado de maduración "sobremaduro". ....	20
<b>Figura 7</b> Redimensionamiento de imágenes por interpolación bilineal.....	29
<b>Figura 8</b> Proceso de binarización de imágenes.....	30
<b>Figura 9</b> Segmentación de imágenes de racimos de palma de aceite. ....	31
<b>Figura 10</b> Dilatación y erosión de frutos de palma de aceite.....	33
<b>Figura 11</b> Aplicación de filtros de suavizado en racimos de palma de aceite.....	35
<b>Figura 12</b> Proceso de filtrado de tipo sobel en imágenes de racimos de palma de aceite. ....	37
<b>Figura 13</b> Aplicación de detección de bordes mediante filtrado canny en racimos de palma de aceite. ....	38
<b>Figura 14</b> Esquema de neurona artificial. ....	41
<b>Figura 15</b> Esquema de red neuronal artificial.....	44
<b>Figura 16</b> Esquema de una matriz de confusión.....	46
<b>Figura 17</b> Esquema de una red neuronal convolucional.....	47
<b>Figura 18</b> Uso de filtro de convolución. ....	49
<b>Figura 19</b> Matriz de agrupación.....	50
<b>Figura 20</b> Esquema metodológico del bloque 1 “Fases necesarias para la construcción del algoritmo de caracterización de madurez” .....	54

<b>Figura 21</b> Imágenes capturadas en transportador de cadena de tipo redler. ....	55
<b>Figura 22</b> Diagrama de flujo para algoritmo de adquisición de fotografías. ....	56
<b>Figura 23</b> Umbralización de imágenes infrarrojas.....	58
<b>Figura 24</b> Determinación del valor de umbralización .....	59
<b>Figura 25</b> Filtrado de imagen de profundidad. ....	59
<b>Figura 26</b> Filtrado de imagen de profundidad y eliminación de pixeles lejanos. ....	60
<b>Figura 27</b> Primer filtrado de contornos pequeños.....	60
<b>Figura 28</b> Determinación de bordes mediante filtro Sobel.....	61
<b>Figura 29</b> Filtrado morfológico mediante dilatación, erosión y filtro gaussiano.....	61
<b>Figura 30</b> Segundo filtrado de contornos pequeños.....	62
<b>Figura 31</b> Suavizado con kernel experimental.....	63
<b>Figura 32</b> Determinación de contornos de potenciales racimos. ....	64
<b>Figura 33</b> Esquema de RNC de tipo 1 .....	67
<b>Figura 34</b> Esquema de RNC de tipo 2. ....	68
<b>Figura 35</b> Esquema metodológico del bloque 2 "fases necesarias para la construcción del algoritmo de caracterización de tiempo de esterilizado" .....	72
<b>Figura 36</b> Matriz de correlación normalizada.....	76

**Lista de Tablas**

<b>Tabla 1</b> Funciones de activación. ....	42
<b>Tabla 2</b> Evaluación de modelos preentrenados para algoritmo de preprocesamiento .....	65
<b>Tabla 3</b> Comparación de modelos de RNC propuestos evaluados en grupos de 50 imágenes. ...	68
<b>Tabla 4</b> Matriz de confusión de RNC de preprocesamiento. ....	69
<b>Tabla 5</b> Comparativa de modelos propuestos para red de detección de madurez. ....	70
<b>Tabla 6</b> Matriz de confusión normalizada en RNC de detección de madurez .....	71
<b>Tabla 7</b> Caracterización del ciclo de esterilizado de acuerdo a la metodología de racimos en tolva .....	73
<b>Tabla 8</b> Evaluación de modelos para determinación de tiempo de esterilizado.....	78
<b>Tabla 9</b> Información recopilada post implementación del modelo. ....	79
<b>Tabla 10.</b> Caracterización del análisis económico .....	81

### **Lista de Apéndices**

Apéndice A. Caracterización de ciclos de esterilizado evaluados.

Apéndice B. Algoritmo de adquisición de fotografías.

Apéndice C. RNC de preprocesamiento.

Apéndice D. RNC de clasificación de madurez.

Apéndice E. RNA de determinación de tiempos de esterilizado.

Apéndice F. Base de datos de imágenes para entrenamiento de RNC de preprocesamiento.

Apéndice G. Base de datos de racimos para entrenamiento de RNC de clasificación de madurez.

Apéndice H. Algoritmo de implementación para la determinación de tiempos de esterilizado.

Apéndice I. Especificaciones técnicas del Hardware utilizado para la implementación de los algoritmos.

## GLOSARIO

**Aceite / RFF:** corresponde al porcentaje en peso de aceite medido con respecto al peso de racimos de fruto de palma de aceite.

**Actividad lipasica:** proceso en el cual se rompen las moléculas de grasa formando ácidos grasos y glicerol.

**AGL:** los ácidos grasos libres (AGL) son formados por la hidrólisis de los triglicéridos en el aceite de palma, puede definirse como un tipo de aceite de difícil procesamiento, por lo que se prefiere un nivel bajo de este; generalmente se presenta en el aceite crudo de palma con valores del 2.5 al 5%, pero pueden presentarse valores superiores si no se tiene un buen control del proceso (Cottrell, 1992).

**Autoclave:** también llamado esterilizador, es un cilindro metálico con entradas de vapor en el cual ingresan los frutos para ser esterilizados a presiones diferentes a la presión atmosférica.

**Endocarpio:** es la capa protectora del endospermo, su color es marrón oscuro y su espesor oscila entre los 2 y 4 mm.

**Endospermo:** también es conocido como almendra, su color es blanco amarillento. Junto con el endocarpio, conforma la nuez o semilla de palma de aceite. Posee un alto contenido de aceite y su función principal es la de servir como alimento en la formación de la planta.

**Exocarpio:** parte externa del fruto de palma de aceite (epidermis), es generalmente conocido como cascara, y, su función principal es la de proteger al fruto de agentes ambientales.

**Fase líquida de prensado:** fluido obtenido al comprimir el fruto de palma de aceite después del proceso de esterilizado, consta de una mezcla de aceite crudo, agua y sólidos en suspensión correspondientes a una mezcla de materia orgánica y otros.

**Fase sólida de prensado:** residuo compactado que queda tras la extracción de la fase líquida de prensado en el fruto. Corresponde principalmente a una mezcla de raquis, fibras y nueces de palma de aceite.

**Fps:** representan la cantidad de imágenes que se capturan o se procesan en un segundo de video (*frames per second*).

**Mesocarpio:** es la parte intermedia del fruto, de apariencia carnosa y color naranja en el estado de madurez plena. En el mesocarpio se encuentra almacenada la fibra y la mayor parte del aceite del fruto.

**Redler:** es un transportador de arrastre utilizado principalmente en la industria para mover racimos, frutas enteras o materiales a granel, que generalmente emplea dos cadenas paralelas unidas por paletas transversales que tienen el objetivo de arrastrar el material a lo largo de un canal desde un punto A hasta un punto B.

**RFF:** son las siglas de racimo de fruta fresca, consta de la agrupación de frutos y el raquis o tusa, el cual es el encargado de dar soporte a los frutos y ser el medio de unión con el resto de la palma.

**RNA:** son las siglas correspondientes a “Redes Neuronales Artificiales”.

**RNC:** son las siglas de “Redes Neuronales Convolucionales”.

**Separador:** también llamados elementos de arrastre o traviesas, son las placas transversales que unen las cadenas de transporte del equipo redler.

## RESUMEN

### Título:

**SISTEMA AUTOMÁTICO PARA EL CÁLCULO DEL TIEMPO DE ESTERILIZADO DEL FRUTO DE PALMA *ELAEIS GUINEENSIS* MEDIANTE INTELIGENCIA ARTIFICIAL.**

### AUTOR

Luis Alberto López Yepes.

### Palabras clave.

Palma de aceite, procesamiento digital de imágenes, tiempo de esterilización, clasificación de madurez en frutos, racimos de fruta fresca, redes neuronales convolucionales, inteligencia artificial, visión por computadora.

### Descripción

En la industria de beneficio de aceite, una de las principales problemáticas se centra en la eliminación de la subjetividad al momento de determinar el tiempo de esterilizado del fruto de palma de aceite. Es conocido que el método de caracterización actual depende principalmente de la experiencia del experto en la zona de esterilización. Por lo cual, pueden surgir errores derivados de una incorrecta caracterización inicial. En este contexto, el presente proyecto de investigación propone un sistema automático para el cálculo del tiempo de esterilizado del fruto de *palma Elaeis guineensis* mediante técnicas de procesamiento de imágenes e inteligencia artificial.

El modelo desarrollado consta de una etapa inicial donde se capturan las imágenes del grupo de RFF a esterilizar en un transportador de cadena de tipo redler. posteriormente, se extraen los racimos predominantes en la escena con el fin de analizar el grado de madurez mediante una red neuronal convolucional de tres salidas que representan los posibles estados de maduración de los racimos (inmaduro, maduro, sobremaduro). Y, se normalizan los resultados del grupo evaluado en un vector de tres posiciones donde cada una de ellas representa el porcentaje de racimos evaluados en cada estado con respecto al total.

Finalmente, se analizan los resultados en el vector de salida normalizado mediante una red neuronal artificial cuya salida indica el tiempo de esterilizado recomendado para el grupo de racimos evaluado.

Como resultado, se obtiene un algoritmo capaz de predecir el grado de madurez de RFF y recomendar un tiempo de esterilizado para el grupo de racimos evaluado en plantas de beneficio. El modelo desarrollado demostró que puede ser aplicable en plantas extractoras, manteniendo pérdidas por impregnación de aceite en fase solida inferiores a 0,8% de (Aceite / RFF). Junto con una reducción del tiempo de esterilización del 2,78% en promedio.

---

\* Proyecto de grado

\*\* Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Director D. Sc. William Pinto Hernández.

## ABSTRACT

### Title:

**AUTOMATIC SYSTEM FOR CALCULATING THE STERILIZATION TIME OF *ELAEIS GUINEENSIS* PALM FRUIT APPLYING ARTIFICIAL INTELLIGENCE.**

### AUTHOR

Luis Alberto López Yepes.

### Keywords.

Oil palm, digital image processing, sterilization time, fruit maturity classification, fresh fruit bunches, convolutional neural networks, artificial intelligence, computer vision.

### Description

In the palm oil processing industry, one of the main challenges lies in eliminating subjectivity when determining the sterilization time of oil palm fruit. It is well known that the current characterization method relies mainly on the experience of the expert in the sterilization area. As a result, errors can arise due to an incorrect initial characterization.

In this context, the present research project proposes an automatic system for calculating the sterilization time of *Elaeis guineensis* palm fruit using image processing techniques and artificial intelligence.

The developed model consists of an initial stage where images of the batch of fresh fruit bunches (FFB) to be sterilized are captured on a redler-type chain conveyor. Subsequently, the predominant bunches in the scene are extracted in order to analyze their degree of ripeness using a convolutional neural network with three outputs, representing the possible ripeness states of the bunches (unripe, ripe, overripe). The results for the evaluated group are then normalized into a three-position vector, where each position represents the percentage of bunches in each state relative to the total.

Finally, the results in the normalized output vector are analyzed using an artificial neural network whose output indicates the recommended sterilization time for the evaluated group of bunches.

As a result, an algorithm capable of predicting the ripeness level of FFB and recommending a sterilization time for the evaluated bunches in processing plants was obtained. The developed model demonstrated applicability in palm oil mills, maintaining oil losses in the solid phase below 0.8% (Oil/FFB), along with an average reduction in sterilization time of 2.78%.

---

\* Project of grade

\*\* Faculty of Physicomechanical Engineering. Mechanical Engineering School. Director D. Sc. William Pinto Hernández.

## Introducción

La agroindustria de la palma de aceite es uno de los sectores que ha sufrido un continuo crecimiento a lo largo de los últimos años. A diferencia de otros cultivos, la palma de aceite se caracteriza por su alta tasa de extracción, facilidad de mantenimiento del cultivo, su capacidad de producción de fruto por hectárea sembrada, entre otras.

Colombia, es uno de los países con mayor cantidad de palma de aceite sembrada en el mundo, siendo el mayor productor en Latinoamérica, por lo cual se hace evidente su importancia económica a nivel nacional, facilitando la sostenibilidad de miles de trabajadores en el sector rural, los cuales se encargan del mantenimiento, siembra y cosecha del fruto de palma en campo, y, en el sector industrial, encargado del procesamiento del fruto en plantas de beneficio ubicadas a lo largo del territorio nacional, donde se obtienen sus derivados dentro de los que se destacan el aceite de cocina, aceite de palmiste, biodiesel, abono orgánico, alimento para animales y otros subproductos.

Uno de los aspectos fundamentales en los procesos agrícolas consiste en garantizar la calidad final de los productos. Por lo cual, la eliminación de decisiones que recaen en la subjetividad en los procesos puede afectar de manera significativa la condición final del producto terminado, reducir tiempos muertos de operatividad y, por ende, mejorar la eficiencia de procesos industriales.

Centrándose en el procesamiento en plantas de beneficio una de las principales condiciones basadas en la subjetividad se centra en la determinación del tiempo de esterilizado del fruto de palma de aceite. Como respuesta a lo anterior, el presente trabajo expone un modelo computacional basado en técnicas de procesamiento de imágenes y algoritmos de aprendizaje automático que

permite determinar el grado de madurez y el tiempo de esterilizado de racimos de palma de aceite en tres estados de maduración diferentes (inmaduro, maduro y sobremaduro). Esto, permite disminuir las incertidumbres producidas por las decisiones basadas en la subjetividad del operador al momento de determinar el tiempo de esterilizado. Y, por ende, favorece un proceso de extracción de aceite más eficiente y controlado.

## 1. Proceso de Beneficio de la Palma de Aceite

### 1.1 Cultivo de Palma de Aceite

La palma de aceite *Elaeis Guineensis Jacq* es una planta monocotiledónea desarrollada en áreas tropicales la cual posee una tasa de crecimiento ininterrumpido que varía su velocidad dependiendo principalmente de las condiciones ambientales (Bastidas Pérez et al., 2013), es considerada la oleaginosa de mayor producción por hectárea, por lo cual es ampliamente cultivada en Colombia, y, su apariencia clásica se presenta en la Figura 1.

#### ***Figura 1***

*Cultivo de palma de aceite.*



Los cultivos de palma de aceite generalmente comienzan su etapa productiva al iniciar el tercer año de siembra. y, su principal característica radica en la formación de un tallo único que

crece a razón de la producción de nuevas hojas, que, a su vez, permiten el desarrollo de inflorescencias y racimos en la base de sus hojas (Mauricio et al., 2012).

Hablando exclusivamente de los racimos, estos consisten en aglomeraciones de frutos conectados a través de un raquis, tal como se observa en la Figura 2a donde se presenta la apariencia común de racimos de palma de aceite y la Figura 2b, en la cual se muestra una vista en corte de estos, con el objetivo de observar sus componentes internos.

## Figura 2

*Racimos de palma de aceite tipo tenera.*



(a) Racimos en centro de acopio.



(b) Elementos principales de un racimo.

Entre los frutos, existen tres categorías cultivables que dependen principalmente de la estructura interna de sus semillas, del espesor del endocarpio y de la cantidad de fibras presentes, siendo a nivel nacional, las de tipo tenera las más representativas.

La palma de tipo tenera representa la mayor cantidad de cultivo a nivel mundial (Barcelos et al., 2015) a razón de su alta producción por hectárea sembrada, alto contenido de aceite y labores de mantenimiento de cultivo menos rigurosas que en otras variedades (Mosquera-Montoya et al., 2020). En la Figura 3a se presentan algunos frutos de palma de aceite tipo tenera, caracterizados por oscilar en pesos de 8g a 25g por fruto, poseer almendra, un endocarpio de espesor inferior a

2mm y un exocarpo rico en contenido de aceite. Dichas partes del fruto se pueden observar en la Figura 3b.

### Figura 3

*Fruto de palma de aceite tipo tenera.*



(a) Fruto de palma de aceite



(b) Partes principales de la semilla de palma

#### 1.1.1 Madurez en Racimos de Palma de Aceite

Se define como madurez plena a la etapa en la cual el fruto ha alcanzado las condiciones adecuadas para su cosecha, es decir, el racimo posee el mayor contenido de aceite en el fruto y menor cantidad de ácidos grasos libres (Perez M, 2017).

Generalmente, se definen tres estados de maduración en el racimo de palma de aceite, los cuales han sido utilizados en la caracterización de *Elaeis guineensis* dentro de los procesos de cosecha y beneficio. No obstante, para los híbridos interespecíficos OxG se han propuesto esquemas de clasificación alternativos, que consideran cuatro estados de maduración y criterios asociados a la formación del racimo, tal como se reporta en estudios especializados (Ingrid et al., 2023).

Teniendo en cuenta lo que el objeto de estudio de esta investigación se centra en la caracterización del tiempo de esterilizado del Fruto de Palma *Elaeis Guineensis* se considerarán

únicamente los tres grados de maduración convencionales para los RFF, los cuales se describirán a continuación.

- **Racimo inmaduro.** presentan un color verde o negro e inician su formación después de la fertilización de la flor. Durante este periodo, el fruto adquiere su mayor crecimiento en peso y volumen, y, sus tejidos se encuentran constituidos en mayor medida por agua. En esta etapa, se inicia la formación de aceite en la semilla y la pulpa del fruto.

Los racimos inmaduros se caracterizan por poseer poco contenido de aceite, y, su apariencia puede observarse en la Figura 4a. A su vez, presentan una zona de transición de estado en la cual cambian a un tono rojizo tal como lo observado en la Figura 4b. Sin embargo, los cambios en la coloración del racimo se presentan desde los frutos externos hacia los internos. Por lo cual, un racimo rojo no necesariamente indica una madurez plena del fruto (Ochoa et al., 2013).

#### Figura 4

*Racimos de palma de aceite en estado de maduración "inmaduro".*



(a) Apariencia de racimos  
inmaduros



(b) Zona de transición de  
inmaduro a maduro

- **Racimo maduro.** son los racimos en los cuales el contenido de aceite en el mesocarpio llega a su punto máximo. En esta etapa, todos los frutos pasan a ser de color rojizo y empieza a ser

evidente el desprendimiento de los frutos tal como se observa en la Figura 5. Generalmente, se considera que un racimo se encuentra en madurez plena cuando su porcentaje de frutos sueltos oscila entre el 5% y el 25% (Tailliez et al., 1996; Vera M; et al., 1998; Corley & Tinker, 2015)

### Figura 5


*Racimo de palma de aceite en estado de maduración "maduro".*



- **Racimos sobremaduros.** son caracterizados por poseer más de la mitad de frutos sueltos en el racimo, posee un menor contenido de aceite que los racimos maduros y un mayor contenido de ácidos grasos libres, por ende, mayor acidez, debido a que entra en una etapa de acidificación por actividad lipásica (*Oil Palm Fruit Grading Manual*, 2003). A continuación, se puede apreciar la apariencia de los racimos sobremaduros en la *Figura 6*.

### Figura 6

*Racimo de palma de aceite en estado de maduración "sobremaduro".*



## 1.2 Descripción del Proceso de Extracción de Aceite de Palma

El proceso de extracción de aceite de palma consta de etapas críticas orientadas al aumento de la eficiencia de extracción de aceite, calidad final del producto, reducción de costos operativos y otros elementos a considerar. dichas etapas críticas son las siguientes:

### 1.2.1 *Recepción y Selección de la Materia Prima*

Los racimos son ingresados a las plantas de beneficio, donde son inicialmente pesados, y enviados a una tolva de carga, consecuente a esto, los racimos son transportados a la zona de esterilización.

### 1.2.2 *Esterilización*

La esterilización es un procedimiento en el cual los racimos son sometidos a cocción por medio de equipos denominados “autoclaves o esterilizadores” donde son calentados haciendo uso de vapor en presiones que oscilan entre 5 y 70 psig, en intervalos de tiempo que varían dependiendo de las presiones de vapor manejadas en el esterilizador, el grado de madurez de los racimos y el tipo de esterilizador utilizado.

El proceso de esterilizado permite la separación del mesocarpio y el endospermo, lo que facilita la extracción del aceite (Federación Nacional de Cultivadores de Palma de Aceite, 2016). Las funciones principales del proceso de esterilización son los siguientes:

- Inactivar la lipasa: con esto se busca destruir las enzimas encargadas de aumentar el contenido de ácidos grasos libres (AGL) en el racimo (RUEDA, 2011). Para lograrlo se necesitan temperaturas cercanas a los 60°C por alrededor de 5 minutos (Rodrigo Erales, 2016).
- Promover el desprendimiento de las frutas del racimo.

- Secar parcialmente las nueces y las almendras a fin de facilitar su separación, para lo cual se hace uso de los picos de esterilización previamente definidos (Rozo Ibáñez & Velasco Escalante, 2007; Abdul Azis Ariffin, 2013).
- Evaporar parte del agua de las frutas, con lo cual se facilita la posterior extracción de aceite.
- Ablandar la pulpa de las frutas, con lo cual se mejora su digestión, y, por ende, la liberación de su aceite.

### ***1.2.3 Digestión y Prensado***

Se maceran los frutos mediante digestores para homogenizar la mezcla obtenida, haciendo uso de la aplicación de vapor, con el fin de facilitar la separación del aceite, las fibras, y las nueces (endocarpio). Finalmente, la mezcla es prensada en busca de extraer la mayor cantidad de fase líquida prensada, también denominada licor de prensado.

### ***1.2.4 Clarificación***

El licor extraído en el proceso de digestión y prensado, es llevado a tanques donde inicialmente se realiza una separación estática de sus fases. El licor decantado en la base del tanque es transportado para su separación dinámica por medio de separadores centrífugos. Posteriormente, se transporta el aceite resultante hacia el sistema de secado para reducir su humedad.

### ***1.2.5 Almacenamiento***

El aceite es transportado a diferentes tanques para su despacho, el destino final del aceite dependerá principalmente de la calidad resultante, la cual depende de parámetros tales como: perfil lipídico, índice de yodo, punto de fusión, índice de refracción, ácidos grasos libres, índice de peróxidos, índice de deterioro de blanqueabilidad, humedad e impurezas (Rincón Sandra & Martínez Daniel, 2009).

Encaminándose al mejoramiento del proceso de extracción se hace evidente que el proceso de esterilización es uno de los más importantes, debido a que de este dependen factores como la calidad final del aceite y pérdidas por impregnación en los subproductos. por lo cual, un mejor control de los factores que inciden en el mismo, puede ayudar al aumento de la separación del endocarpio y mesocarpio, disminución de las pérdidas de aceite, control de acidez y con ello una mejora en la eficiencia de la planta.

## 2. Objetivos

### 2.1 Objetivo General

Determinar el tiempo de esterilizado del fruto de palma de aceite *elaeis guineensis* por medio de un sistema de clasificación del grado de madurez empleando técnicas de procesamiento de imágenes y técnicas de *machine learning*.

### 2.2 Objetivos Específicos

Realizar un algoritmo de preprocesamiento capaz de identificar regiones de interés correspondientes a racimos de palma de aceite “*elaeis guineensis*” por medio de operaciones morfológicas realizadas a imágenes RGB, imágenes infrarrojas y mapas de profundidad, generando un dataset que permita su implementación en la determinación del grado de madurez de RFF.

Implementar un algoritmo basado en redes neuronales convolucionales con el propósito de clasificar los frutos en tres estados de maduración (inmaduro, maduro y sobremaduro) tomando como información características físicas extraídas a partir del preprocesamiento de imágenes.

Elaborar un algoritmo de aprendizaje automático que correlacione los estados de maduración de un grupo de racimos de fruta fresca (inmaduro, maduro, sobremaduro) para la caracterización del tiempo de esterilizado en plantas de beneficio.

### **3. Marco Teórico**

#### **3.1 Tipos de Imágenes en Procesamiento Digital**

##### **3.1.1 *Espectro Electromagnético***

El espectro electromagnético, es definido como el conjunto de todas las frecuencias posibles que puede tomar la radiación electromagnética. Enfatizando en el procesamiento digital de imágenes. Se destacan la zona de la luz visible y los rayos infrarrojos, debido a su potencial aplicación en la detección de características de imágenes.

##### **Luz visible**

Representa la zona del espectro electromagnético que puede ser observada por los ojos humanos. Se encuentra entre la zona de la radiación infrarroja y radiación ultravioleta y oscila entre las longitudes de onda de 380 nm a 780 nm aproximadamente.

##### **Rayos infrarrojos**

Los rayos infrarrojos son un tipo de radiación de mayor longitud de onda que la luz visible y menor longitud de onda que la radiación de microondas, generalmente se define entre los 800 nanómetros y 1000 micrómetros. Dentro de los rayos infrarrojos existe a su vez una zona de especial interés para el análisis de fotografías denominada infrarrojo cercano, el cual se encuentra entre los valores de 800 a 2500 nanómetros (Ramírez-García et al., 2012)

##### **3.1.2 *Arquitectura de una Imagen***

Una imagen puede ser definida como una representación matricial de una función de intensidad discreta de la luminosidad (Gonzalez & Woods, 2009), se encuentra conformada por

pixeles donde cada pixel representa un valor en una posición determinada y generalmente puede tomar valores de [0 a 255].

Una configuración tradicional de una imagen es descrita en la ecuación 1 donde se muestra una matriz indexada de tamaño (M x N) en la cual cada pixel es representado por un sistema de coordenadas (“i”, “j”) con origen en la parte superior izquierda, donde “i” representa las filas y “j” las columnas.

$$\begin{matrix} (0,0) & (0,1) & \dots & (0,N-1) \\ \vdots & \vdots & \dots & \vdots \\ \vdots & (i,j) & \dots & (i,N-1) \\ \vdots & \vdots & \dots & \vdots \\ (M-1,0) & (M-1,j) & \dots & (M-1,N-1) \end{matrix} \quad (1)$$

Centrándose en el estudio de propiedades cromáticas, se hace necesario un modelo que permita la representación de los componentes del color. Dicho modelo es conocido como espacio de color. El cual, permite describir de forma asertiva la manera en la se encuentran distribuidos los colores dentro de una imagen.

Los espacios de color generalmente utilizados son el RGB, HSI, HSV, YIQ, CIE L A\*B, CMY, CMYK. (Tkalcic, 2003). Como objeto de la investigación es resaltable el papel jugado por el espacio de color RGB en el análisis de características en imágenes, debido a su amplia implementación en modelos de adquisición y visualización digital.

### 3.1.3 *Imágenes en Espacio de Color RGB*

Son imágenes adquiridas en el espacio de color RGB, el cual Establece que cualquier color puede ser construido por tres colores primarios (rojo, verde, azul), (Camilo Carrillo González, 2015). Se basa en un modelo tridimensional donde cada eje representa uno de los colores

primarios, en la cual la representación del color negro es el origen (cero en cada uno de los ejes) y para el color blanco un valor máximo (255) para cada eje, enfatizando en que solo se pueden tomar valores enteros, por lo que es posible obtener  $16'777.216$  colores diferentes (Antonio et al., 2009).

### ***3.1.4 Imágenes Infrarrojas***

Son imágenes que representan la absorción de la radiación electromagnética en la zona de radiación infrarroja. Permite enfatizar características de imágenes que generalmente son difíciles de reconocer mediante el espectro de la luz visible por lo cual son ampliamente utilizadas en la clasificación de frutos (Francisca Parra, 2012).

### ***3.1.5 Mapas de Profundidad***

Los mapas de profundidad son esquemas matriciales que representan la distancia desde un objeto hasta un punto de adquisición de imágenes (Calderón Saavedra, 2012). Son generalmente adquiridas mediante sensores LiDAR (light Detection and Ranging) y sensores de tiempo de vuelo (ToF). Siendo estos últimos ampliamente aplicados debido a su alta velocidad de captura, facilidad de integración en sistemas compactos, alta precisión a distancias inferiores a diez metros y bajo consumo energético (Hussmann, 2008).

## **3.2 Técnicas de Procesamiento Digital de Imágenes**

El objetivo principal del preprocesamiento de imágenes radica en la eliminación de ruido en las fotografías o el reconocimiento de algunos patrones de interés presentes en ellas. Para esto, se emplean técnicas como el cambio de espacio de color, eliminación de fondo, ajuste a un tamaño predeterminado u otras, que faciliten su posterior procesamiento en futuros algoritmos. A continuación, se presentan algunas técnicas de procesamiento de alta relevancia para la presente investigación.

### 3.2.1 Redimensionamiento

El redimensionamiento es una técnica que consiste en alterar las dimensiones de una imagen. Es ampliamente utilizada en algoritmos de visión por computadora debido a que permite estandarizar un grupo proporcionado de fotografías con dimensiones diferentes manteniendo información similar a la de la imagen original.

Aunque existen múltiples funciones de redimensionamiento, dentro de ellas se destaca el redimensionamiento por interpolación bilineal, donde el valor de cada pixel de la nueva imagen se calcula mediante el promedio de los cuatro pixeles más cercanos a un punto escalado al de la imagen original (Gonzalez & Woods, 2009).

A continuación, se muestra la ecuación implementada para el redimensionamiento bilineal de una imagen.

$$I'(i', j') = (1 - c) * (1 - r) * I(i_0, j_0) + c(1 - r)I(i_0, j_1) + (1 - c)r * I(i_1, j_0) + cr * I(i_1, j_1) \quad (2)$$

Donde  $(i'$  y  $j')$  son las coordenadas del pixel en la imagen redimensionada,  $(c$  y  $r)$  son las fracciones de desplazamiento vertical y horizontal calculadas con respecto a la imagen original y  $(i_0$  y  $j_0)$  son las coordenadas del pixel en la imagen original.

Para el cálculo de las coordenadas  $(i_0$  y  $j_0)$  se pueden implementar las ecuaciones 3 y 4.

$$i_0 = \lfloor i' \rfloor = \left\lfloor i * \frac{M - 1}{M' - 1} \right\rfloor \quad (3)$$

$$j_0 = \lfloor j' \rfloor = \left\lfloor j * \frac{N - 1}{N' - 1} \right\rfloor \quad (4)$$

Donde,  $(M$  y  $N)$  representan la dimensión de la imagen original, y  $(M'$  y  $N')$  indican el tamaño de la imagen resultante.

Los valores de  $(c$  y  $r)$  pueden ser calculados con la ecuación 5 y ecuación 6.

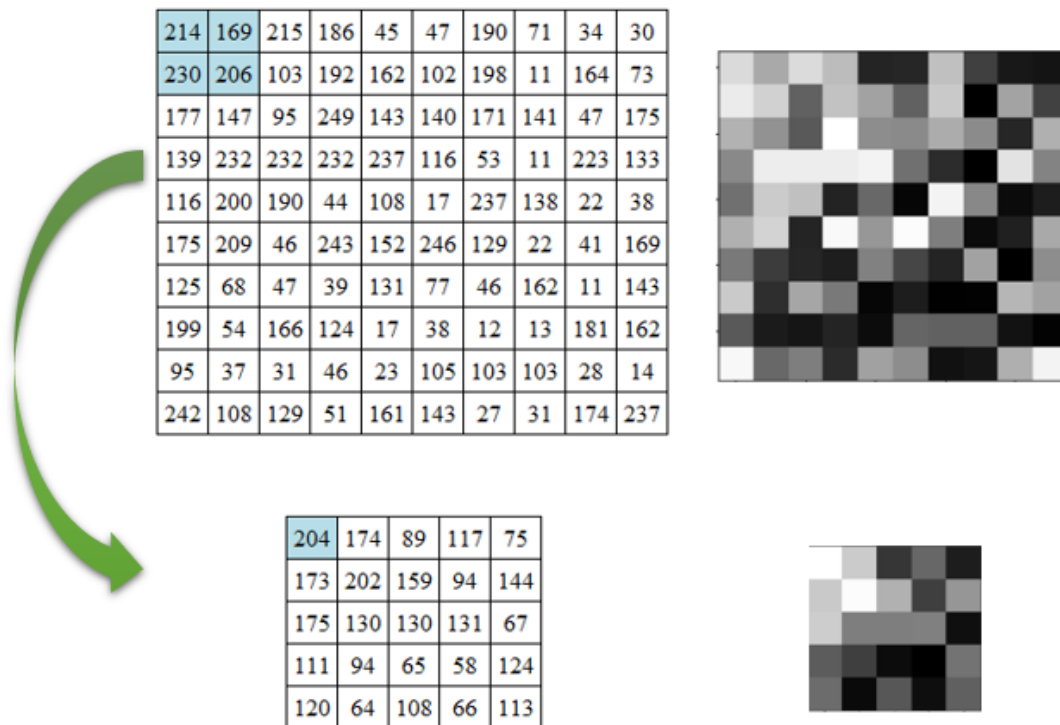
$$c = i' - i_0 \tag{5}$$

$$r = j' - j_0 \tag{6}$$

Un ejemplo de lo anterior, se expone en la *Figura 7*, donde se muestra el redimensionamiento de una imagen descrita por la matriz de dimensión 10 x 10, hasta un tamaño de 5 x 5 con el método de interpolación bilineal.

**Figura 7**

*Redimensionamiento de imágenes por interpolación bilineal.*



### 3.2.2 Binarización de una Imagen

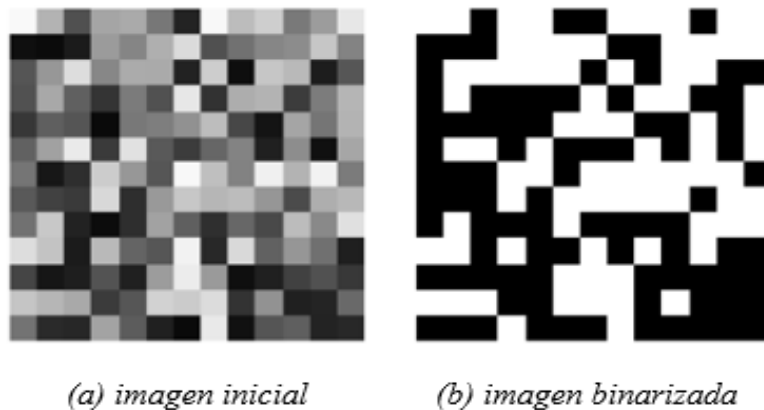
La binarización de una imagen consiste en la transformación de una imagen en escala de grises a una imagen con solo dos posibles estados de un pixel, generalmente cero para negro y uno para blanco.

Este proceso, basa la decisión del valor tomado por un pixel por medio de la selección con respecto a un umbral previamente definido, donde si los valores del pixel de la imagen original resultan superiores al umbral elegido, el pixel toma el valor de uno en la nueva imagen generada. En caso contrario es cero.

A continuación, se presenta en la Figura 8 un ejemplo del binarizado en una imagen de 13 x 13 pixeles, en el cual se define que los pixeles de una imagen (a) cuyo valor se encuentre por debajo de un umbral previamente definido en 125 obtendrán un valor de cero en la imagen binarizada (b).

#### Figura 8

*Proceso de binarización de imágenes.*




### 3.2.3 Segmentación de una Imagen

La segmentación de una imagen consiste en subdividirla en sus partes constituyentes con el fin de aislar las regiones de interés del resto de la imagen para futuros análisis de información (Palomino & Concha, 2009). Es considerable que el método de segmentación a utilizar no sigue un patrón específico, y dependerá principalmente del problema a resolver (Rodríguez Pulido, 2013). En la Figura 9 se puede observar un ejemplo de la segmentación aplicada a imágenes orientadas a determinar regiones de interés, en el cual, se separan los frutos de palma de aceite del fondo de la imagen. Así mismo, se describirá con posterioridad las operaciones necesarias para la segmentación implementada en esta investigación.

#### Figura 9

*Segmentación de imágenes de racimos de palma de aceite.*



### 3.2.4 Filtrado de una Imagen

El filtrado tiene como objetivo principal la eliminación de ruido de una imagen y la mejora de algunas características que faciliten su posterior procesamiento. Generalmente, se distinguen dos tipos principales de filtros en imágenes. Filtros en el dominio de frecuencia y filtros de tipo

espacial los cuales se basan en el cambio de los valores de los pixeles de una fotografía por medio de la aplicación de matrices denominadas kernels.

A continuación, se exponen algunas operaciones de filtrado de especial interés para el desarrollo de este proyecto.

- **Dilatación:** la dilatación es una operación de procesamiento morfológico generalmente utilizada en una imagen binarizada con el objetivo de aumentar las regiones claras de una imagen y la concatenación de bordes cercanos por medio de la expansión de los pixeles claros haciendo uso de un elemento estructurante denominado kernel o núcleo.

La dilatación es definida por la siguiente ecuación:

$$A \oplus B = \{x | (\hat{B})_x \cap A \neq \emptyset\} \quad (7)$$

Donde “A” representa a la imagen evaluada y “B” representa el elemento estructurante, que generalmente es una matriz unitaria de dimensión “n x n”.

- **Erosión:** la erosión es una operación aplicada al procesamiento digital de imágenes generalmente utilizada para la reducción de ruido blanco en imágenes binarizadas. Se entiende como aquellos pixeles de una imagen donde al situar un kernel “B” sobre una imagen “A” muestren el mismo valor de los pixeles en el kernel y la imagen. Lo anterior es descrito por la ecuación 8.


$$A \ominus B = \{x | B_x \subseteq A\} \quad (7)$$

En la erosión, si el valor de los pixeles aledaños a un pixel en la imagen original el valor es 1 entonces el pixel en la imagen erosionada es uno, en caso contrario es cero, tal como lo mencionado por (Alegre et al., 2003)

De acuerdo a lo anterior, en la Figura 10, se muestra el proceso de dilatación y erosión en los frutos de palma de aceite.

**Figura 10**

*Dilatación y erosión de frutos de palma de aceite.*



- **Filtro de media:** el filtro de media es generalmente utilizado para la suavización de elementos en una imagen. en el cual, se reemplaza el valor del pixel en una imagen por el promedio de sus vecinos.

La elección del número de vecinos se encuentra previamente definido por una ventana representada por una matriz de dimensión  $(k \times k)$  y su tamaño dependerá principalmente del tamaño de la imagen de entrada.

A continuación, se describe en la ecuación 9 el nuevo valor de un pixel de una imagen después de aplicar la operación de suavizado.

$$I'(i, j) = \frac{1}{k^2} \sum_{m=-r}^r \sum_{n=-r}^r I(i + m, j + n) \quad (9)$$

Donde:

" $I'(i, j)$ " es el nuevo valor del pixel en la posición " $(i, j)$ " después del filtrado de la imagen.

“ $k$ ” es la dimensión de la ventana aplicada.

" $I(i + m, j + n)$ " representan los pixeles vecinos al pixel evaluado en la imagen

“ $r$ ” es el radio del filtro (ver ecuación 10).

$$r = \frac{k - 1}{2} \quad (10)$$

- **Filtro gaussiano:** El filtro gaussiano, es otro filtro comúnmente utilizado para el suavizado de una imagen. Tiene la particularidad de que utiliza un kernel basado en una distribución normal, con el fin de dar un peso mayor a los pixeles centrales que a los pixeles aledaños de los bordes del núcleo elegido.

Los valores que pueden tomar los diferentes elementos de un kernel aplicable para el filtro gaussiano se encuentran definidos en la siguiente ecuación.

$$G(m, n) = \frac{1}{2\pi\sigma^2} * \exp\left(-\frac{m^2 + n^2}{2\sigma^2}\right) \quad (11)$$

Donde:

“ $(m, n)$ ” representan los desplazamientos relativos con respecto al centro del filtro.

" $G(m, n)$ " corresponde al valor dentro del kernel en la posición “ $(m, n)$ ”.

" $\sigma$ " corresponde a la desviación estándar de la distribución gaussiana.


En la ecuación 12 se describen los valores que pueden tomar los pixeles de una imagen después de la aplicación del filtro gaussiano.

$$I_{filtrada}(i, j) = \sum_{m=-k}^k \sum_{n=-k}^k G(m, n) * I(i + m, j + n) \quad (12)$$

Teniendo en cuenta los métodos de suavización por filtro de media y filtro gaussiano previamente descritos, se expone en Figura 11 su aplicación en un racimo de fruto de palma con el objetivo de facilitar su comprensión.

### **Figura 11**

*Aplicación de filtros de suavizado en racimos de palma de aceite.*



En la Figura 11 se pueden observar las diferencias tras la aplicación de los filtros en la misma imagen. Se destaca que el filtro gaussiano permite una mejor preservación de bordes que el filtro de media. Sin embargo, sus tiempos de cálculo son mayores que los del filtro de media. Junto con lo anterior, es relevante mencionar que el filtro de media genera mejores resultados en la eliminación del ruido producido por pixeles dispersos de forma aleatoria, también conocido como ruido “sal y pimienta” (Kaur & Singh, 2017).

#### **3.2.5 Detección de Bordes**

La detección de bordes, es una técnica en la cual se determinan los cambios abruptos entre los valores de pixel de una imagen con el objetivo de determinar entidades continuas dentro del espacio evaluado. Generalmente, los cambios abruptos determinados corresponden a los límites de los elementos de un contorno, por lo cual resulta esencial para la delimitación de los objetos dentro de una escena.

Aunque existe una alta variedad de metodologías implementadas para la detección de bordes, se destacan los métodos de detección por filtrado *sobel*, el cual se resalta por su alta velocidad de cálculo y el filtrado de tipo *canny*, que permite la detección de bordes más suaves con un ruido en la imagen resultante menor al del filtrado *sobel*, con la diferencia de que sus tiempos de cálculo son considerablemente mayores.

- **Filtro Sobel:** Es un método implementado para la detección de bordes que calcula la intensidad de una imagen en cada pixel mediante de la aplicación de dos mascarar conocidas como operadores sobel (Gonzalez & Woods, 2009) las cuales generan dos mapas de gradientes que se combinan en una imagen resultante tal como se muestra en la ecuación 13, donde se describe el valor de cada pixel de la imagen resultante.

$$|G| = \sqrt{G_x^2 + G_y^2} \quad (13)$$

A continuación, se presenta el operador Sobel en la dirección “x” en la ecuación 14 y en la dirección “y” en la ecuación 15.

$$G_x = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad (14)$$


$$G_y = \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix} \quad (15)$$

En la Figura 12 se puede observar el proceso de aplicación del filtrado de tipo sobel en una imagen. Donde, en la Figura 12a, se observa la imagen original. En la Figura 12b y Figura 12c, se

muestran las imágenes resultantes después de la implementación del operador sobel en cada uno de los pixeles descritos en la ecuación 14 y ecuación 15. Finalmente, en la Figura 12d se presenta la magnitud del gradiente resultante después de las operaciones descritas en la ecuación 13.

### Figura 12

*Proceso de filtrado de tipo sobel en imágenes de racimos de palma de aceite.*

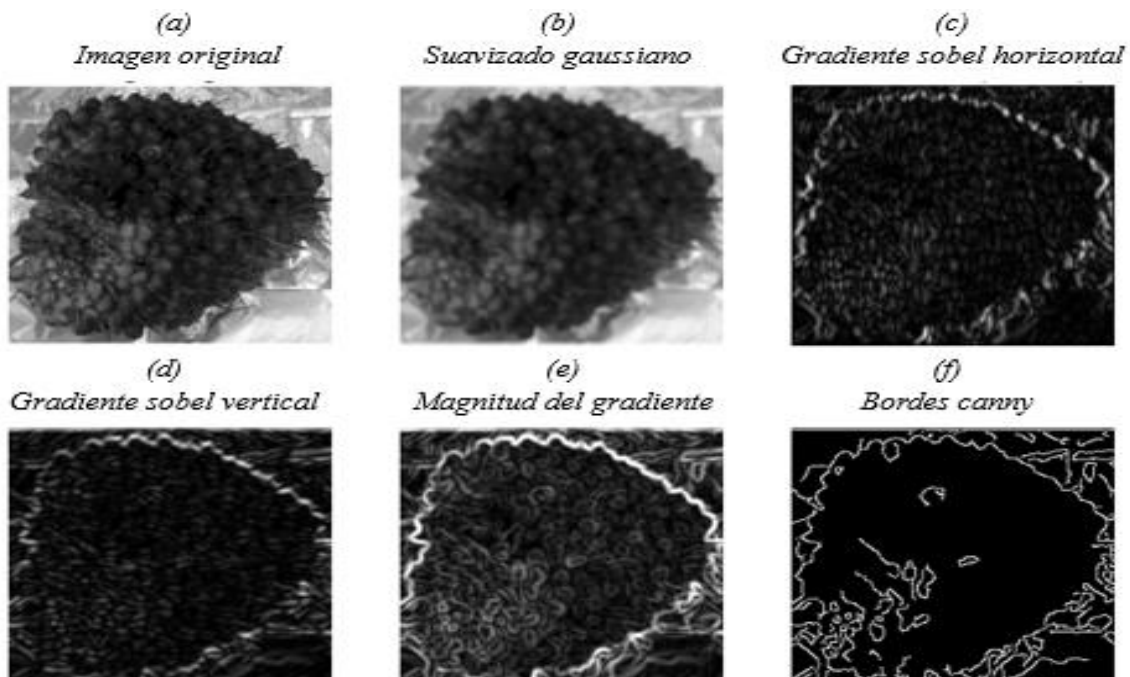


- **Filtro canny:** Es un algoritmo de procesamiento el cual es ampliamente utilizado para la detección de bordes en imágenes y se destaca principalmente por su capacidad para producir bordes suaves y contornos con bajo contenido de ruido debido a la aplicación inicial de un filtrado gaussiano. Al igual que el filtro sobel, éste calcula la intensidad de una imagen en cada pixel mediante los mismos operadores de gradiente implementados en la ecuación 14 y ecuación 15 para el filtro *sobel*, con la diferencia de que también calcula la dirección del borde, en la cual se elige el pixel con el valor más alto según sus vecinos, permitiendo así, eliminar el ruido presentado en la imagen resultante.

A continuación, en la Figura 13 se presenta la aplicación del filtrado de tipo canny. Donde en la Figura 13a. se presenta la imagen original, en la Figura 13b. se observa la imagen resultante después de la aplicación de un filtro gaussiano implementado para suavizar las regiones de la imagen, posteriormente, se presentan en la Figura 13c y Figura 13d las imágenes resultantes consecuentes a la implementación de los operadores sobel en la dirección “x” y “y” respectivamente, en la Figura 13e se calcula la magnitud del gradiente para cada pixel, y, finalmente, se determina la dirección del gradiente por medio de la ecuación 16, se compara la magnitud de los pixeles con sus vecinos en esa dirección y se eliminan los valores menores. Los resultados del proceso anterior pueden ser observados en la Figura 13f.

**Figura 13**

*Aplicación de detección de bordes mediante filtrado canny en racimos de palma de aceite.*



$$\theta = \arctan \left( \frac{G_x}{G_y} \right) \quad (16)$$

### 3.2.6 *Análisis Morfológico de una Imagen*

Basándose en máscara resultante extraída mediante la segmentación de imágenes, se pueden obtener características destacables de un objeto evaluado y que pueden llegar a tener representación física. En función del desarrollo de esta investigación resulta conveniente resaltar las siguientes:

**Área:** Es comúnmente utilizada en imágenes binarizadas. Consiste en contar el número de píxeles que conforman una región de interés en una imagen.

**Perímetro:** Consiste en determinar la longitud de un contorno cerrado, para su cálculo cabe resaltar que si dos píxeles se encuentran concatenados de forma horizontal o vertical su contribución para el cálculo del perímetro será de uno. Si, por el contrario, los píxeles del borde se encuentran concatenados en su diagonal, su contribución para el cálculo del perímetro será  $\sqrt{2}$ .

**Diámetro equivalente:** Es una medida utilizada para representar el diámetro que tendría un círculo con la misma área del contorno.

**Elipse equivalente:** es una elipse con la misma área de la imagen original. Este método, es comúnmente utilizado como criterio de comparación de imágenes con bordes irregulares. Conserva ciertas características de la imagen original, tales como su proporción y dirección. Por lo cual, surge como una aproximación para caracterizar la forma de objetos complejos de una forma compacta.

**Elipse ajustada por mínimos cuadrados:** consiste en encontrar los parámetros de una elipse que minimicen el error cuadrático entre los píxeles que conforman un contorno cerrado (Andrew Fitzgibbon et al., 1999).

**Similitud con una elipse:** surge de la división del área de una imagen segmentada entre el área de una elipse ajustada. Se destaca que valores cercanos a 1 se traducen en una mayor semejanza de la imagen original y una elipse.

### 3.3 Algoritmos de Aprendizaje Automático

#### 3.3.1 *Regresión lineal de Múltiples Variables*

Permite ajustar modelos lineales entre una variable dependiente y un grupo de variables independientes (Gareth James et al., 2023).

El modelo general de la regresión lineal múltiple puede expresarse de la siguiente manera:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon \quad (17)$$

Donde:

“y” es la variable dependiente,  $x_1, x_2, \dots, x_p$  son las variables independientes,  $\beta_0$  es el valor estimado de una variable “y” cuando todas las variables independientes son cero, finalmente,  $\beta_1, \beta_2, \dots, \beta_p$  son los coeficientes que acompañan a las variables independientes y  $\epsilon$  representa el residuo individual.

#### 3.3.2 *Redes Neuronales Artificiales*

Las Redes Neuronales Artificiales (RNA) surgen como un intento de modelar el comportamiento del cerebro humano, por lo cual se encuentran inspiradas en el funcionamiento de las redes neuronales biológicas (Olabe, 1998).

Las características bioinspiradas de una red neuronal son:

**Aprender:** las RNA pueden cambiar su comportamiento dependiendo del entorno, para lograr esto, se utiliza una serie de entradas que se ajustan para producir salidas consistentes.

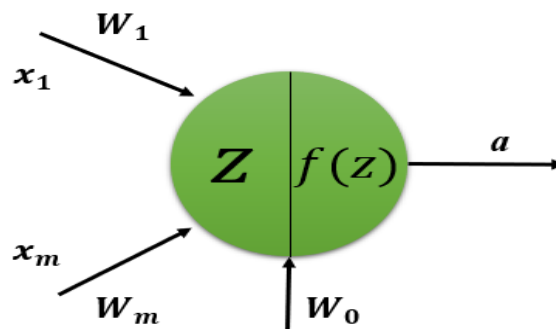
**Generalizar:** tienen la capacidad de extender sus decisiones a elementos que no formen parte de la base de datos inicial, ofreciendo respuestas acertadas dentro de un margen con variaciones que se pueden deber al ruido o insuficiencia de los datos adquiridos.

**Abstraer:** algunas redes neuronales son capaces de abstraer o considerar la esencia de elementos de un conjunto de entrada que en apariencia no poseen aspectos en común.

**3.3.2.1 Neurona Artificial.** la neurona es la unidad fundamental en el sistema nervioso, el cerebro humano cuenta con millones de ellas. Realizando una analogía con las neuronas naturales se construyen las neuronas artificiales, las cuales también son llamadas elemento procesador PE (Olabe, 1998) por sus siglas en inglés (“*process element*”). Un esquema común de una neurona artificial puede ser observado en la Figura 14.

**Figura 14**

*Esquema de neurona artificial.*



Las neuronas artificiales pueden tener varias entradas ( $x_1, x_m$ ), que son evaluadas en función del peso específico de cada uno de las entradas en el sistema (“ $W_1, W_m$ ”) con la finalidad de determinar la entrada neta (“ $z$ ”) para el cálculo de la salida esperada, que depende de la función

de activación evaluada por la neurona. Dicha salida puede ser concatenada a otras neuronas formando diferentes capas. El cálculo de la entrada neta resultante puede ser realizado mediante la ecuación 18.


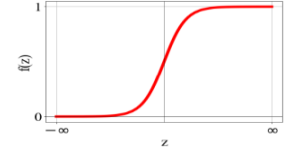
$$z = \sum_{i=1}^m W_i * x_i + W_0 \quad (18)$$


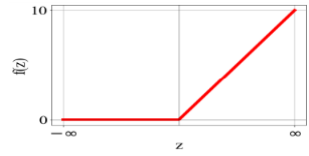
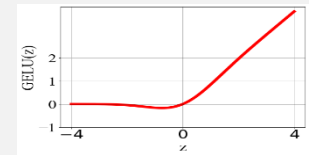
**Funciones de activación:** son componentes en la red neuronal cuya función principal es introducir no linealidades que permitan modelar relaciones complejas entre un conjunto de datos definido (Dubey et al., 2022). Por lo cual, un modelo de red que no contemple este tipo de funciones, puede ser generalizado como un modelo lineal común.

La función de activación permite delimitar el rango de salida de una neurona y se selecciona de acuerdo al objeto del problema a solucionar (Llano et al., 2007). De acuerdo al objeto de la investigación desarrollada, en la Tabla 1 se presentan algunas funciones de activación comúnmente utilizadas para el desarrollo de modelos de aprendizaje automático.

**Tabla 1**

*Funciones de activación.*

Nombre	Función	Rango	Gráfica
Escalón	$f(z) = \begin{cases} 0 & \text{si } z < 0 \\ 1 & \text{si } z \geq 0 \end{cases}$	$[0, 1]$	
Sigmoide	$f(z) = \frac{1}{1 + e^{-z}}$	$(0, 1)$	

<p><b>Gaussiana</b></p>	$f(z) = Ae^{\frac{-x^2}{2*\sigma^2}}$	<p>[0, 1]</p>	
<p><b>Relu</b></p>	$f(z) = \max(0, z)$	<p>[0, infinity)</p>	
<p><b>Gelu</b></p>	$f(z) \approx 0.5z(1 + \tanh(h))$ $h = \sqrt{\frac{2}{\pi}} * (z + 0.044715 * z^3)$	<p>(-infinity, infinity)</p>	

Junto con las funciones anteriormente descritas, es destacable mencionar también a la función de activación “*Softmax*”. Debido a su importancia en la clasificación multiclase en la capa de salida de la red implementada. Esta función, convierte un vector de valores de salida no normalizados en la última capa de la red neuronal (capa de salida de la red, con un numero de neuronas igual al número de salidas esperadas) en un vector de probabilidades donde todas las salidas se encuentran en un rango entre cero y uno. Y, la suma de todas las salidas es igual a 1.

Cabe resaltar, que, el valor de salida de la red corresponde al valor máximo del vector de probabilidad de salida resultante. A continuación, se presenta la forma de cálculo de las salidas de la función de activación *Softmax* en la ecuación 19.

$$f(z_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \tag{19}$$

Donde:

“  $z = [z_1, z_2, z_3, \dots, z_K]$  ” representa el vector de valores de salida no normalizados.

“ $K$ ” representa el número total de clases.


“ $i$ ” indica el índice de la clase para la cual se está calculando la probabilidad.

“ $j$ ” es el índice que recorre las clases posibles (funciona como una variable de iteración).

**Esquema de una red neuronal:** Una red neuronal es un sistema compuesto por unidades elementales (neuronas artificiales) generalmente organizadas en capas interconectadas que funciona como un sistema de procesamiento paralelo, lo que le permite ejecutar múltiples operaciones simultáneamente, y, por tanto, procesar información de manera más eficiente que los sistemas secuenciales tradicionales. Un esquema convencional de una red neuronal puede observarse en la Figura 15.

**Figura 15**

*Esquema de red neuronal artificial.*



En una red neuronal, las entradas son ingresadas a los elementos de procesamiento que se encuentran conectados a las entradas por medio de “pesos” ( $W$ ) que para múltiples entradas se convierte en una matriz. Suponiendo que cada neurona se encuentra conectada a todas las entradas,

se deduce que la salida de la neurona es entregada por la función evaluada en la suma ponderada de los pesos multiplicado por cada elemento de entrada; dicho de otra forma:

$$a^{(l+1)} = f(W^l * x^l * b^l) \quad (20)$$

Donde: “ $W$ ” es la matriz de pesos, “ $l$ ” representa la capa evaluada, “ $x^l$ ” son los valores de entrada y finalmente “ $b^l$ ” es denominada la matriz “*bias*”, cuyos valores son los pesos iniciales de cada neurona en la capa evaluada.

**Evaluación de la salida de una red:** La evaluación de las salidas de una red permiten medir la eficacia del modelo mediante métricas cuantitativas que reflejen la calidad de las predicciones durante las etapas de entrenamiento, validación y evaluación (Terven et al., 2025). Dentro de las métricas más utilizadas, se destacan la exactitud debido a que permite evaluar que tan exactas son las inferencias del modelo con la salida esperada (Marcela Quintana, 2024), y, la función de pérdida, debido a que permite cuantificar las discrepancias entre el vector de salida de un modelo “ $f(z_i)$ ” (Ver Ecuación 19) y el valor esperado por el modelo.

- **Exactitud:** es definida como el número de predicciones correctas con respecto al total de predicciones evaluadas. Matemáticamente, para modelos de clasificación de dos clases puede expresarse de la siguiente manera.

$$Exactitud = \frac{Clasificaciones\ correctas}{Clasificaciones\ totales} = \frac{V_p + V_n}{V_p + V_n + F_p + F_n} \quad (21)$$

Donde “ $V_p$ ” y “ $V_n$ ” indican los valores de la clase 1 y 2 identificados por la red que coinciden con los valores reales. Y, “ $F_p$ ” y “ $F_n$ ” muestran los valores de salida de la red que no coinciden con los valores esperados de la clase 1 y clase 2.

Lo anteriormente mencionado, puede expresarse de manera similar mediante una matriz de confusión, la cual consiste en una tabla donde cada fila indica la clase esperada para cada entrada y las columnas corresponden a la salida predicha por la red (Isaac Pérez & Manuel Gegúndez, 2021). En la Figura 16 se muestra el esquema de una matriz de confusión para una red de dos salidas.

**Figura 16**

*Esquema de una matriz de confusión.*

	Valores reales	
Valores predichos	Verdaderos positivos	Falsos positivos
	Falsos negativos	Verdaderos negativos

- **Función de pérdida:** También conocida como función de error, función de coste o pérdida, es una función matemática que permite estimar la diferencia entre los valores en el vector de salida de una red con respecto a los valores reales de entrenamiento del modelo (Isaac Pérez & Manuel Gegúndez, 2021)..

Dentro de las funciones de pérdida más utilizadas se destaca la función de entropía cruzada, la cual, se encuentra definida por la siguiente ecuación.

$$Perdida = - \frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K y_{n,k} * \ln (\hat{y}_{n,k}) \quad (22)$$

Donde:

“N” es el número total de muestras.

" $K$ " es el número de clases a evaluar.

" $y_{n,k}$ " representa un vector con el valor real de la muestra, siendo uno en la posición de la clase correcta y cero en cualquier otra posición.


" $\hat{y}_{n,k}$ " indica el vector de probabilidades de salida de la red después de su normalización.

### 3.3.3 Redes Neuronales Convolucionales

Una red neuronal convolucional (RNC), por sus siglas en inglés (CNN) puede ser definida como una red neuronal profunda donde se mantiene una representación jerárquica a través del aprendizaje de las características internas de los datos. La idea principal de su aplicación radica en la disminución de parámetros a tener en cuenta para formular una solución, lo que permite la utilización de capas que profundicen la red (Manaswi, 2018). Un esquema de dicho tipo de red neuronal es mostrado en la *Figura 17*.

**Figura 17**

*Esquema de una red neuronal convolucional.*



Son potencialmente aplicables al análisis de imágenes, debido a que posee una fuerte dependencia espacial, puesto a que fue inicialmente diseñada para trabajar con entradas estructurales en cuadrícula (Aggarwal, 2023).

Para su uso en el análisis de imágenes es necesario la normalización de las mismas (dividir el valor del pixel entre el máximo valor de pixel posible) a fin de facilitar su aplicación. a su vez, es necesario que las imágenes utilizadas en el dataset de alimentación de la red sean de un tamaño similar.

La característica principal de una RNC son las convoluciones, las cuales consisten en operar los pixeles de entrada mediante una matriz denominada kernel la cual también es conocida como filtro y su dimensión es ( $n \times n \times p$ ) donde  $n$  representa el tamaño del filtro, y,  $p$  representa el número de canales del kernel, el cual, debe coincidir con los de la imagen original.

Las capas convolucionales tienen como función principal la extracción de características relevantes en una imagen tales como bordes, diferencias de cambios en tonalidad, texturas u otros patrones de aprendizaje para la red. Para lo cual, se mapea la imagen de entrada ( $I$ ) por medio del kernel ( $K$ ) con el objetivo de obtener un mapa de características ( $S$ ) tal como se define en la ecuación 23.


$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n) * K(i - m, j - n) \quad (23)$$

Donde Los índices ( $i$ ,  $j$ ) representan las coordenadas del nuevo valor en el mapa de características  $S$  generado, ( $m$ ,  $n$ ) indican las dimensiones de la matriz  $K$  que recorre la imagen que se está operando y  $I(m, n)$  son las coordenadas de la imagen que se alinean con el kernel en la posición ( $i$ ,  $j$ ).

Los valores obtenidos por el kernel se almacenarán en una nueva matriz que será una nueva capa de neuronas ocultas (Artola Moreno, 2019). Un ejemplo del uso del kernel es mostrado en la Figura 18 donde los valores de una matriz (posible imagen) son modificados y posteriormente almacenados en una nueva matriz (capa convolucionada). El tamaño de la nueva matriz será de  $(m-n+1) * (m-n+1)$ , siendo " $(m * m)$ " el tamaño de la matriz original.

### Figura 18

*Uso de filtro de convolución.*



Nota: Adaptado de Clasificación de imágenes usando redes neuronales convolucionales en Python (Artola Moreno, 2019). Pag 29.

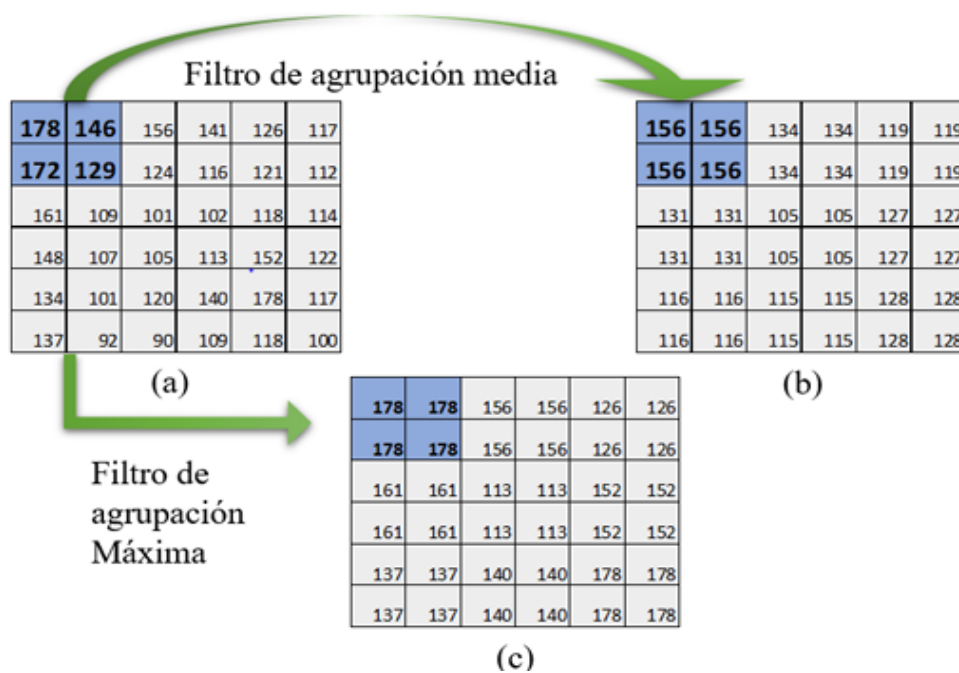
Posterior a una capa de convolución se aplica a la matriz resultante una capa de agrupación, su función es la de determinar las características predominantes disminuyendo así la carga computacional de trabajar con grandes volúmenes de información. Los tipos de agrupación que se pueden encontrar son la agrupación promedio, en la cual se extrae el valor promedio de los píxeles evaluados y la agrupación máxima, por medio de esta se obtiene el valor máximo de los píxeles y es guardada en una nueva capa.

A continuación, en la Figura 19 se presenta el uso de una matriz de agrupación (2 x 2) para construir los dos tipos de capas de agrupación resultantes.

finalmente, la nueva capa conformada puede ser utilizada como base para una nueva matriz de convolución repitiendo el proceso.

**Figura 19**

*Matriz de agrupación.*



La decisión de la salida de la RNC es tomada por una capa completamente conectada (*full connected*), que se encuentra después de la última capa de agrupación, y el número de neuronas de salida depende del número de clases elegido o determinado por la red. Para nuestro caso particular, los grados de maduración del racimo.

Es conveniente señalar que en algunos casos es necesario aplicar técnicas de regulación antes de la capa de salida con el fin de mitigar el sobreajuste que puede producirse al trabajar con redes muy profundas.

Una de las técnicas más comunes de regularización es el “*dropout*”, el cual consiste en desactivar aleatoriamente algunas neuronas durante la etapa de entrenamiento para evitar el sobreajuste permitiendo así, mejorar la generalización del modelo. A su vez, es destacable mencionar que el dropout no tiene parámetros entrenables, por lo cual solo opera como un interruptor durante la fase de entrenamiento, siendo común en valores de (0.5) como base inicial para redes entrenadas con un alto número de parámetros.

#### ***3.3.4 Modelos de Aprendizaje Profundo Preentrenados***

Una de las alternativas más comunes para el entrenamiento de modelos de aprendizaje es la implementación de modelos convolucionales preentrenados con grandes conjuntos de datos. Debido a que permiten la extracción de características generales en las imágenes de entrada mediante aprendizaje transferido. Por esta razón, son ampliamente utilizados en modelos predictivos de alta complejidad que cuenten con un conjunto de entrenamiento limitado. En modelos de aprendizaje profundo preentrenados se destacan como ventajas la alta eficiencia computacional y una alta precisión alcanzada en el modelo con conjuntos de datos pequeños. A su vez, permiten la implementación de estrategias de ajuste fino en las capas más profundas de la red, que mejoren la exactitud en el algoritmo final. Permitiendo así, realizar predicciones más asertivas ante nuevos conjuntos de datos evaluados (Krizhevsky et al., 2017; Penatti & Dos Santos, 2015).

Para el desarrollo de esta investigación, se destaca la importancia de los modelos preentrenados de las familias ConvNext a razón de su alta exactitud en problemas de clasificación

global de imágenes (Lv et al., 2025). Y, las arquitecturas de la familia *Ultralytics-Yolo (You Only Look Once)* debido a que han demostrado una alta precisión junto con bajos tiempos de inferencia en tareas de segmentación de instancias(Alsuwaylimi, 2024)

#### 4. Diseño Metodológico

El enfoque principal de este trabajo de investigación recae en la determinación del tiempo de esterilizado de racimos de fruto fresco (RFF) mediante técnicas de procesamiento de imágenes y la aplicación de modelos de inteligencia artificial. Debido a que, con esto, se puede eliminar la subjetividad en la evaluación y clasificación del grado de madurez del RFF y, por ende, en la determinación del tiempo de esterilizado el cual depende principalmente de la condición de maduración de los frutos que ingresan a ser esterilizados.

Lo anterior, puede derivar en mejoras en el proceso de extracción de aceite, disminución de pérdidas por impregnación, reducción de tiempos muertos de proceso, e incluso la mejora de la eficiencia de equipos térmicos en el proceso de esterilizado.

El proyecto fue probado en condiciones reales en una planta de beneficio de aceite con esterilización de tipo dinámica. Donde se realizó la adquisición de imágenes de los RFF durante el proceso de transporte de la tolva de recepción de fruto a la zona de esterilización a partir del equipo “transportador de cadena tipo redler” y se catalogaron en alguno de los tres estados de maduración previamente establecidos (inmaduro, maduro y sobremaduro).

Es relevante indicar que, si el porcentaje de racimos sobremaduros a esterilizar es mayor, el tiempo de esterilización implementado tiende a ser más bajo en comparación al de lotes con una mayor predominancia de racimos inmaduros y maduros (Guimaraes Rojas, 2019).

Conviene señalar paralelamente que la esterilización implementada maneja una rampa de presión controlada al inicio del ciclo mediante un aumento gradual de presión (aproximadamente 5 psig /min) hasta alcanzar los parámetros de operación (40 psi en aproximadamente ocho minutos).

Con el objeto de facilitar la comprensión de la metodología implementada para el desarrollo de la investigación, se expondrá en un primer bloque las fases correspondientes a la adquisición de información referente a imágenes y la construcción de los algoritmos necesarios para la determinación del grado de madurez en los RFF. Adicionalmente, se expondrá en un segundo bloque las fases necesarias para la construcción del algoritmo para la determinación del tiempo de esterilizado.

#### **4.1 Bloque 1: Fases Necesarias para la Construcción del Algoritmo de Caracterización de Madurez.**

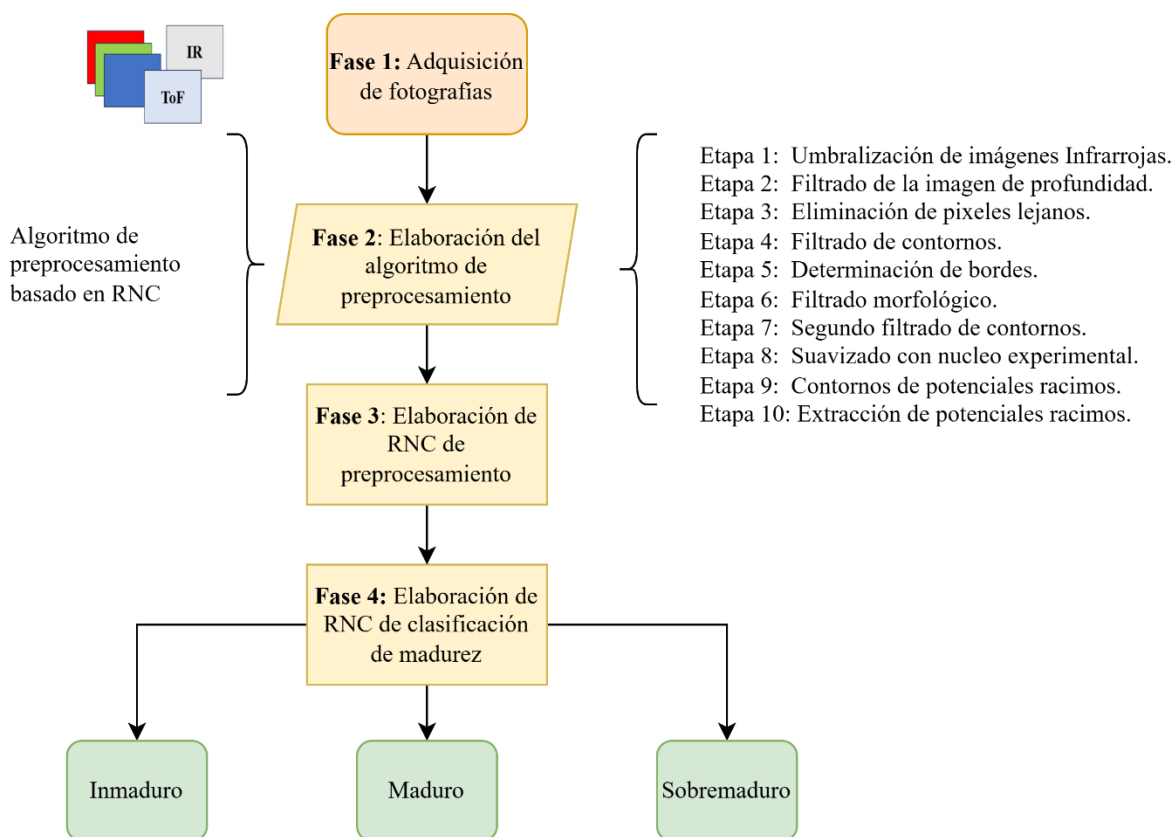
Con el objetivo de caracterizar el grado de madurez de los RFF, el cual es requerido para la determinación del tiempo de esterilizado, se exponen en este bloque las cuatro fases para la construcción de los algoritmos relevantes para para el análisis de las imágenes y su procesamiento orientado a la obtención de un vector de tres salidas que indiquen los porcentajes de maduración de los RFF que ingresan en la autoclave para ser esterilizados. Este vector será necesario para su posterior procesamiento mediante los algoritmos construidos en el bloque 2 en la etapa de implementación del modelo en la planta de beneficio.

A continuación, se expone el esquema metodológico de este bloque de forma general en la Figura 20, donde se describe de forma visual las fases para la construcción de los algoritmos

necesarios para la implementación final. Así mismo, se describirá con posterioridad cada una de las fases y etapas descritas.

### Figura 20

*Esquema metodológico del bloque 1 “Fases necesarias para la construcción del algoritmo de caracterización de madurez”*



#### 4.1.1 Fase 1: Adquisición de Fotografías


En cumplimiento del desarrollo de la investigación se realiza el registro fotográfico en el transportador de doble cadena tipo redler que traslada los RFF desde la zona de recepción de fruto hacia los esterilizadores.

Los tres tipos de fotografías se capturaron en tres formatos diferentes. Imágenes infrarrojas (IR), mapas de profundidad adquiridos mediante una cámara ToF y fotografías en formato Red-Green-Blue (RGB) que son redimensionadas a 512 x 424 píxeles por medio de interpolación de vecinos cercanos (ver Ecuación 2). La adquisición se automatiza mediante un sensor de proximidad infrarrojo programado en Arduino el cual envía la señal a un algoritmo en Python (“Algoritmo de adquisición de fotografías” Ver Apéndice B), programado para guardar las imágenes en carpetas diferentes al detectar un valor de cero en el sensor de proximidad, tal como se muestra en la Figura 21.

Junto con lo anterior, se realiza el etiquetado de los racimos encontrados en las imágenes en acompañamiento de tres expertos en calificación del fruto, permitiendo catalogar los racimos en uno de los tres estados de madurez categorizados para la investigación (inmaduro, maduro, sobremaduro).

### Figura 21

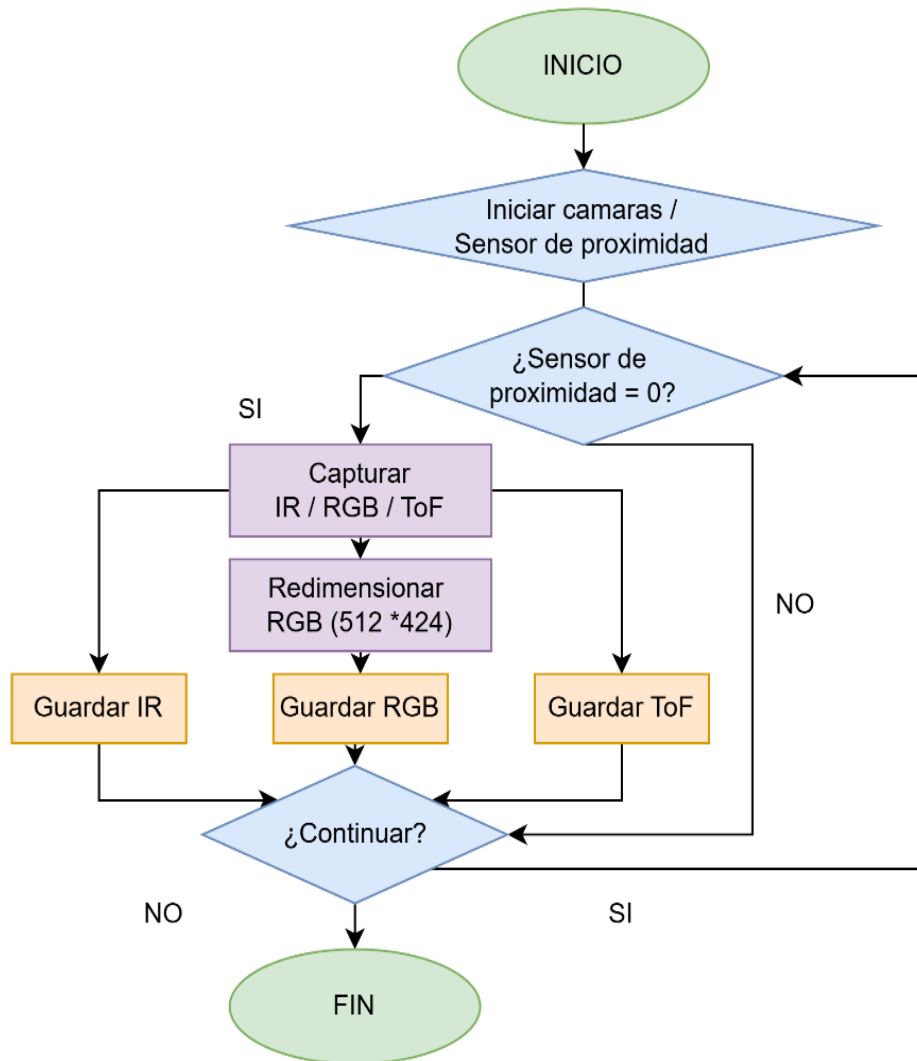
*Imágenes capturadas en transportador de cadena de tipo redler.*



A continuación, en la Figura 22 se presenta el diagrama de flujo del algoritmo elaborado para adquisición de las fotografías.

**Figura 22**

*Diagrama de flujo para algoritmo de adquisición de fotografías.*



Las imágenes adquiridas mediante el algoritmo de procesamiento se adquirieron con una cámara multimodal con las siguientes características:

**Espacio de color RGB:** Imágenes capturadas a 30 fps con una resolución de 1920 x 1980 píxeles.

**Imágenes infrarrojas:** Imágenes capturadas a 30 fps con resolución de 512 x 424 píxeles con capacidad de operación en oscuridad total.

**Mapas de profundidad:** Imágenes adquiridas a 30 fps con resolución de 512 x 424 píxeles.

Es destacable que el dispositivo de captura permite la sincronización de imágenes a partir de correlaciones automáticas de distorsión óptica para garantizar la coherencia de los datos en entornos dinámicos.

#### ***4.1.2 Fase 2: Elaboración del Algoritmo de Preprocesamiento***

Las imágenes recolectadas son canalizadas a través de un algoritmo de preprocesamiento encargado de segmentar automáticamente los racimos en la escena.

Con el fin de elegir el modelo de segmentación de regiones de interés adecuado para la implementación en el algoritmo final se proponen inicialmente dos algoritmos diferentes, el primer algoritmo, basado en técnicas de procesamiento de imágenes de los tres tipos fotografías almacenadas en la etapa anterior. Y, el segundo de ellos, consiste en la implementación de una red neuronal convolucional dentro de los modelos de segmentación desarrollados por *Ultralytics* debido a que han demostrado tener una alta precisión en labores de segmentación de imágenes con tiempos de procesamiento relativamente cortos.

**4.1.2.1 Construcción del Algoritmo Basado en Técnicas de Procesamiento de Imágenes** A continuación, se describen las etapas necesarias para la construcción de este algoritmo.


**Etapas 1 Umbralización de imágenes infrarrojas:** se realiza una umbralización de las imágenes infrarrojas, en la cual se binariza la imagen con un umbral de 141 con el objetivo de

eliminar la mayor parte de los elementos metálicos reflexivos en la fotografía infrarroja, tal como se muestra en la Figura 23.

Para la elección del valor de umbralización seleccionado se realizó el histograma de 100 imágenes infrarrojas sin regiones de interés (racimos) y se eliminaron las regiones de alta iluminación en la imagen con el fin de dejar solamente los elementos en la escena que representaran materiales metálicos. Como resultado se observó que en todas las imágenes evaluadas el 99% de los píxeles se encontraban por debajo de este umbral, caso contrario al evidenciado en imágenes infrarrojas compuestas mayoritariamente por racimos en la escena, donde los valores de los píxeles son predominantemente altos.

### Figura 23

*Umbralización de imágenes infrarrojas.*




En la Figura 24a puede observarse el histograma de una de las imágenes infrarrojas evaluadas, junto con la imagen original que se muestra en la Figura 24b, y, la imagen resultante posterior al proceso de eliminación manual de zonas de alta iluminación en la escena que se presenta en la Figura 24c.

**Figura 24**


*Determinación del valor de umbralización*



(a)



(b)




(c)

**Etapas 2 Filtrado de la imagen de profundidad:** se realizó una superposición de los valores de la imagen infrarroja sobre la imagen de profundidad por medio de una multiplicación pixel x pixel con el objetivo de eliminar los elementos metálicos en la imagen de profundidad que se filtraron en la etapa anterior para la imagen infrarroja. Los resultados de esta etapa se pueden observar en la Figura 25.

**Figura 25**


*Filtrado de imagen de profundidad.*



**Etapa 3 Eliminación de píxeles lejanos:** se realiza una eliminación de los píxeles más lejanos en la imagen de profundidad resultante de la etapa 2 debido a que son potencialmente frutos sueltos en la fotografía. Como resultado, se obtiene una matriz binaria cuyos valores altos representan las regiones de interés (Aquellas que pertenecen potencialmente a un racimo). El proceso anteriormente descrito se observa en la *Figura 26*.

### Figura 26

*Filtrado de imagen de profundidad y eliminación de píxeles lejanos.*



**Etapa 4 Filtrado de contornos:** se realiza una eliminación de ruido inicial de la imagen mediante un rellenado de los contornos internos cerrados inferiores a 200 píxeles continuos debido a que representan ruido blanco en la imagen y se binariza tal como se observa en la *Figura 27*.

### Figura 27

*Primer filtrado de contornos pequeños.*



**Etapas 5 determinación de bordes:** se realiza un filtrado de tipo “*sobel*” con un núcleo (3 x 3), con el cual se determinan las transiciones de intensidad ocurridas al detectar un contorno en los racimos de palma y se resaltan por medio de binarización los bordes de mayor interés según lo apreciado en la imagen resultante (Ver *Figura 28*).

### Figura 28

*Determinación de bordes mediante filtro Sobel.*



**Etapas 6 Filtrado morfológico:** se realizan operaciones morfológicas concatenadas de dilatación, con núcleo (3 x 2) y erosión, con núcleo (2 x 3). Seguido a esto, se aplica un filtro gaussiano con núcleo (7 x 7) con el fin de desenfocar los elementos en la imagen en busca de fusionar los bordes continuos más cercanos y se binariza nuevamente la imagen tal como se observa en la *Figura 29*.

### Figura 29


*Filtrado morfológico mediante dilatación, erosión y filtro gaussiano.*



**Etapa 7 Segundo filtrado de contornos:** se aplica un filtro de tipo *canny* con la finalidad de obtener los contornos pequeños que podrían haberse generado a partir de las operaciones previamente realizadas, posteriormente, se rellenan nuevamente los elementos que conformen un área cerrada inferior a 200 píxeles. El resultado de las operaciones realizadas se puede observar en la *Figura 30*, donde se presenta la imagen original en el espacio de color RGB y la imagen resultante del proceso anteriormente descrito.

### Figura 30

*Segundo filtrado de contornos pequeños.*



**Etapa 8 Suavizado con núcleo experimental:** se aplica un filtro convolucional con un kernel personalizado de dimensión (5 x 5) para realzar los bordes y unir contornos cercanos. Consecuente a esto, se aplican operaciones de erosión con núcleo (4 x 4) a razón de reducir el espesor de las regiones blancas en la imagen resultante, en la *Figura 31* se puede observar la imagen resultante después de culminar esta etapa.

A continuación, se presenta la ecuación de cálculo del valor de los píxeles después de aplicar el filtro convolucional y el kernel asociado.


$$K = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & -5 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (24)$$

$$I'(i, j) = \sum_{m=-k}^k \sum_{n=-k}^k K(m, n) * I(i + m, j + n) \quad (25)$$

Donde  $I'(i, j)$  representa el valor de salida del pixel de el nuevo mapa de características generado y  $K(m, n)$  indica el valor de la mascara evaluada en la posicion “ $(m, n)$ ”.

### Figura 31

*Suavizado con kernel experimental.*



**Etapas 9 Contornos de potenciales racimos:** se realiza una detección de los contornos que conformen un área cerrada mayor a 1000 pixeles cuadrados. De estos, se seleccionan los contornos cuya similaridad con una elipse ajustada por mínimos cuadrados como la descrita por (Andrew Fitzgibbon et al., 1999) sea superior al 75% y cuenten con un área inferior a 35000 pixeles cuadrados.

Cabe resaltar, que, para la elección del número de pixeles elegidos como límite superior y límite inferior en esta etapa, se calculó el área de 600 imágenes consideradas como posibles

racimos válidos y se determinó que los elementos detectados con áreas superiores a 35000 píxeles cuadrados no corresponden a elementos de interés en la escena. Así mismo, se observó que contornos con un área inferior a 1000 píxeles cuadrados representaban en todos los casos evaluados a elementos de alta iluminación en la escena.


Junto a lo anterior, se destaca que el valor elegido para la similaridad con una elipse se debe a que los racimos de fruta fresca pueden ser aproximados a elipses con una precisión superior al 75% tal como lo mostrado por (Yunus et al., 2015).

**Etaapa 10 Extracción de potenciales racimos:** se rellenan internamente los contornos seleccionados con anterioridad, se superponen individualmente sobre la imagen RGB original y se redimensiona la región de interés en una imagen de 200 x 200 píxeles y posteriormente se almacena.

En la *Figura 32* se muestran algunas imágenes resultantes después de la implementación del algoritmo de preprocesamiento. El algoritmo resultante permite caracterizar el 84% de la totalidad de los racimos en la escena con una precisión en la detección de los racimos del 76% y un tiempo de procesamiento de 1,56 segundos por cada lote de 50 imágenes.

### Figura 32

*Determinación de contornos de potenciales racimos.*



**4.1.2.2 Implementación de Algoritmo de Preprocesamiento basado en RNC.** El algoritmo elegido consiste en la implementación de un modelo preentrenado de la familia YOLOv8-seg. Para determinar el modelo a implementar se evaluaron la precisión en la determinación de los contornos de los RFF.

Los modelos se entrenaron con un dataset de 500 imágenes en el espacio de color RGB de las cuales se destinaron 400 fotografías para entrenamiento, 100 para validación y 100 para una última etapa de evaluación. A continuación, se presenta en la Tabla 2 los resultados en los modelos evaluados junto con los datos obtenidos en el algoritmo basado en técnicas de procesamiento de imágenes propuesto para el mismo lote de imágenes.

**Tabla 2**

*Evaluación de modelos preentrenados para algoritmo de preprocesamiento*

<b>Modelo</b>	<b>Racimos detectados (%)</b>	<b>Precisión en la detección de racimos (%)</b>	<b>Tiempo de procesamiento (s) / lote</b>
<b>YOLOv8n-seg</b>	75,3	82,5	12,8
<b>YOLOv8s-seg</b>	77,8	80	40,9
<b>YOLOv8m-seg</b>	83,8	83	71,6
<b>YOLOv8l-seg</b>	85,2	80,4	126,7
<b>Técnicas de preprocesamiento de imágenes</b>	84,0	76,0	1,56

Realizando una comparación de los resultados de los dos tipos de algoritmos de segmentación propuestos, se observa que el modelo basado en técnicas de preprocesamiento de imágenes permite determinar el 84% de los racimos en el lote de imágenes evaluadas, este valor

es similar al obtenido en los modelos de mayor exactitud en los algoritmos de segmentación basados en las CNN preentrenadas evaluadas, pero con tiempos de procesamiento significativamente menores. Por lo cual, se decide utilizar este algoritmo para la implementación en el modelo final.

Se destaca que, el algoritmo propuesto segmenta de forma asertiva los RFF en la escena, no obstante, también detecta dentro de las regiones de interés los elementos de alta iluminación. Por lo cual, se hace necesario una posterior clasificación de las imágenes segmentadas a fin de clasificar los racimos verdaderos de los elementos de alta iluminación

#### ***4.1.3 Fase 3: Elaboración de red Neuronal Convolutacional de Preprocesamiento***

Como algoritmo propuesto para detección de imágenes de interés se implementó un modelo basado en redes neuronales convolucionales, entrenado para la clasificación de imágenes en dos categorías (Racimos y Descartes). La elección de este tipo de algoritmo de aprendizaje recae en que las RNC han demostrado ser altamente efectivas en tareas de clasificación de imágenes, superando las RNA convencionales tal como lo mencionado por (Rawat & Wang, 2017). El modelo propuesto, se entrenó con una base de datos de 2554 imágenes divididas en dos categorías. Las cuales se separaron aleatoriamente 1776 imágenes para entrenamiento, 302 para validación y las 476 imágenes restantes se destinaron para la etapa de evaluación.

**4.1.3.1 Selección de la Arquitectura de la red Neuronal Convolutacional de preprocesamiento.** Debido a que no existe una metodología específica para la calibración de parámetros en la red, se realizan pruebas a dos redes con las siguientes arquitecturas.

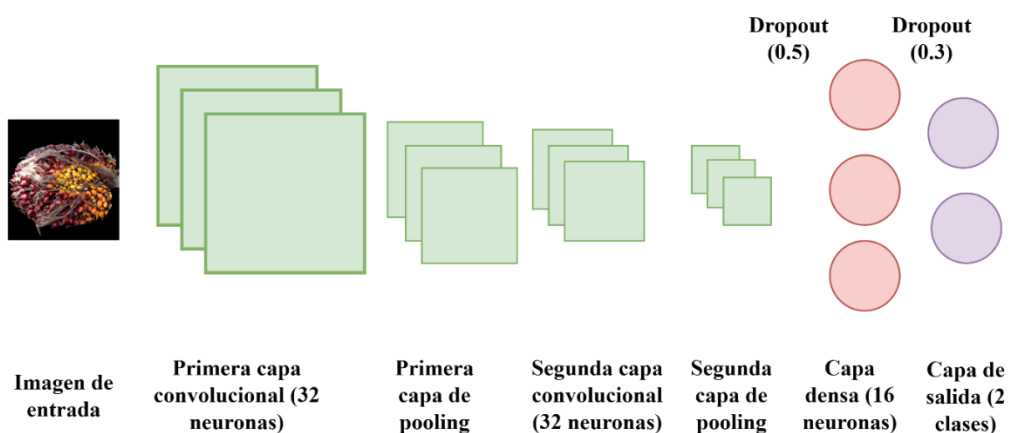
**Red de tipo 1:** Se evalúa un modelo de red basado en dos capas convolucionales de 32 neuronas cada una, con funciones de activación switch y relu respectivamente, seguidas de una

capa de agrupación posterior a cada capa convolucional. Adicionado a lo anterior, se aplicó una capa de regularización por *Dropout* posterior a la última capa convolucional. Finalmente, se implementó una capa densa de 16 neuronas con una regularización por *Dropout* durante el entrenamiento y una capa de salida con una función de activación *softmax*.

El esquema de la red anteriormente descrita, se muestra en la Figura 33.

### Figura 33

*Esquema de RNC de tipo 1*

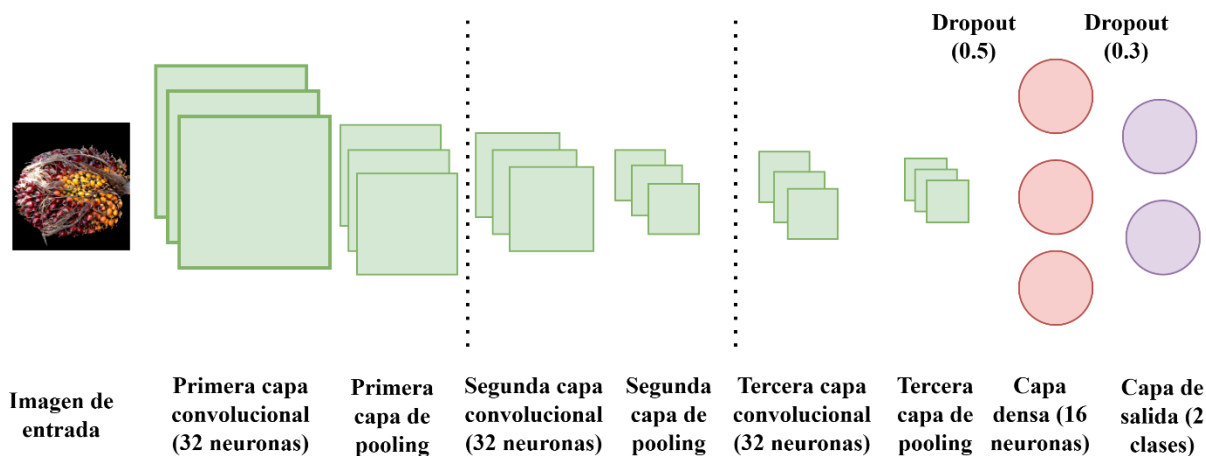


**Red de tipo 2:** Se implementa un modelo jerárquico de tres capas convolucionales de 32 neuronas cada una con funciones de activación *switch* en la primera capa y *relu* en la segunda y tercera capa, seguidas de una capa de agrupación después de cada capa convolucional.

Después de lo anterior, se implementó una capa de regularización por *Dropout* posterior a la última capa convolucional. Finalmente, se implementó una capa densa de 16 neuronas con una regularización por *Dropout* durante el entrenamiento y una capa de salida con una función de activación *softmax*. En la Figura 34 se presenta un esquema del modelo propuesto para la red de tipo dos.

**Figura 34**

*Esquema de RNC de tipo 2.*



Los modelos anteriormente descritos se entrenaron en lotes de 50 imágenes. A continuación, se presenta una comparativa de la época número cinco de ambos modelos propuestos en la Tabla 3.

**Tabla 3**

*Comparación de modelos de RNC propuestos evaluados en grupos de 50 imágenes.*

Parámetros	Red de tipo 1	Red de tipo 2
Épocas de entrenamiento	5	5
Precisión en evaluación	0,92	0,97
Pérdida	0,25	0,09
Tiempo de procesamiento (s) / lote	0,51	0,57

Como se puede observar en la Tabla 3, la red de tipo 2 presenta una precisión superior y una pérdida inferior en su quinta época. Así mismo, el tiempo promedio de procesamiento por imagen es

similar en ambos casos. Razón por la cual, se decide implementar a la red de tipo 2 para el modelo de clasificación de RFF de palma de aceite.

**4.1.3.2 Implementación de la Arquitectura de Red Neuronal Convolutiva Seleccionada.** Posterior al entrenamiento final del algoritmo, se obtiene un modelo que alcanza una exactitud en el conjunto de datos de validación de 98,89% una vez entrenado el modelo final, y, se procede a generar una matriz de confusión con los datos de prueba tal como la mostrada por (Reiner Armas et al., 2020). A continuación, en la Tabla 4 se muestra la matriz de confusión generada.

**Tabla 4**

*Matriz de confusión de RNC de preprocesamiento.*

	Valor predicho	
	Descartes	Racimos
Descartes	239	4
Racimos	1	232
Precisión final	98,95%	

Observando los resultados, se destaca que la precisión final de la red, asciende al 98,95% en el conjunto de prueba con una pérdida de 0,0326. De acuerdo con lo anterior, la exactitud en la clasificación de los racimos con respecto a elementos de bajo interés en las fotografías es considerablemente alta. Por lo cual, resulta favorable para su implementación en el modelo final.

#### **4.1.4 Fase 4: Elaboración RNC de Clasificación de Madurez**

Entendiendo que uno de los procesos fundamentales para la determinación del tiempo de esterilizado es la caracterización del grupo de racimos evaluado, se propuso la implementación de

un modelo basado en redes neuronales convolucionales cuyas entradas son imágenes de RFF y como salida se obtiene el estado de madurez del racimo evaluado (inmaduro, maduro o sobremaduro).

Se destaca que el modelo para clasificación se basa en un modelo con pesos preentrenados de la familia (ConvNext) debido a que son altamente aplicables a tareas de clasificación de imágenes con patrones complejos gracias a su enfoque detallado para la extracción de características (Aldaz Noble, 2025). Para la elección del modelo a implementar, se evaluó la precisión alcanzada en algunas de las diferentes arquitecturas ofrecidas.

Los modelos propuestos se entrenaron con un dataset de 2839 imágenes de tamaño (200 x 200 x 3) en el cual se destinó el 70% para entrenamiento, 10% para validación y 20% para evaluación. A continuación, en la Tabla 5 se muestra un cuadro comparativo entre los diferentes modelos evaluados.

**Tabla 5**

*Comparativa de modelos propuestos para red de detección de madurez.*

<b>Modelo</b>	<b>Capas totales</b>	<b>número de parámetros</b>	<b>Validación</b>	<b>Evaluación</b>
<b>ConvNeXt-Tiny</b>	59	28,60 millones	77,1%	74,6%
<b>ConvNeXt-Small</b>	75	50,20 millones	76,5%	78,6%
<b>ConvNeXt-Base</b>	88	88,60 millones	80,9%	79,9%
<b>ConvNeXt-Large</b>	152	197,8 millones	82,9%	83,4%
<b>ConvNeXt-XLarge</b>	196	350,1 millones	87,8%	91,2%

Debido al alto contenido de ruido en las imágenes recopiladas producido por la velocidad de movimiento del transportador en planta de beneficio, se observa que es necesario un modelo de mayor robustez para obtener una precisión aceptable, por lo cual se implementó en el algoritmo final el modelo de ConvNeXt-XLarge debido a que tiene la exactitud más alta entre los evaluados modelos.

Posterior a la implementación del modelo, se realiza la matriz de confusión con sus valores normalizados para las imágenes de evaluación tal como se observa en la Tabla 6, finalmente, se obtiene un modelo capaz de predecir el estado de madurez de RFF con un 91,23 % de exactitud y una pérdida de 0,288.

**Tabla 6**

*Matriz de confusión normalizada en RNC de detección de madurez.*

	Clases predichas		
	Inmaduro	Maduro	Sobremaduro
<b>Inmaduro</b>	0,870	0,086	0,043
<b>maduro</b>	0,091	0,904	0,005
<b>Sobremaduro</b>	0,015	0,030	0,954

En la matriz de confusión anterior, se observa que la categoría con menor exactitud en la clasificación del grupo de evaluación son las fotografías correspondientes a racimos inmaduros con un 87%. Sin embargo, se destaca que el mayor grado de confusión se da con los racimos maduros. Lo anterior puede deberse a que los frutos con un tono rojizo no necesariamente indican

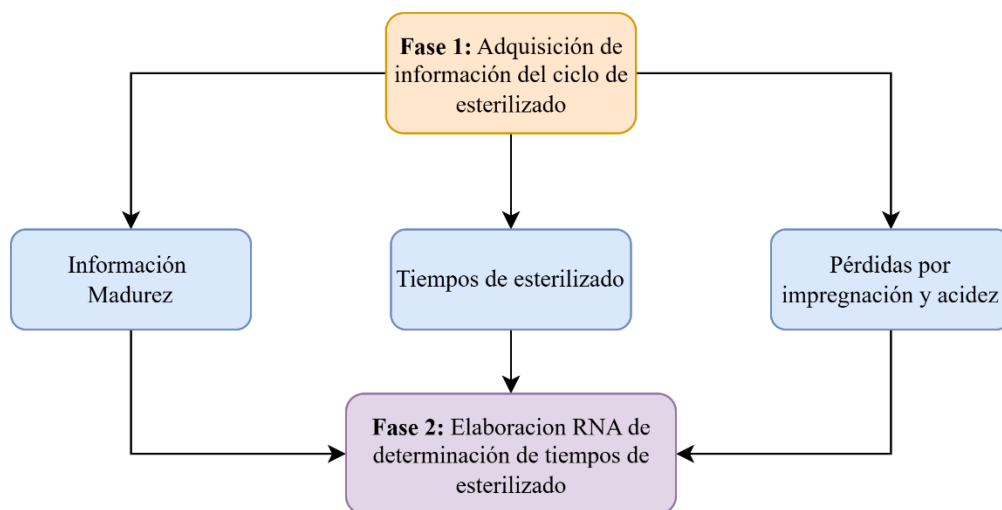
madurez plena en los racimos (Ochoa et al., 2013), por lo cual pueden ser racimos inmaduros que se encontraban en la zona de transición de estado.

#### 4.2 Bloque 2: Fases Necesarias para la Construcción del Algoritmo de Determinación de Tiempo de Esterilizado.

En este bloque se expone la metodología implementada para la elaboración del algoritmo de caracterización del tiempo de esterilizado que será desarrollado para su posterior implementación en planta de beneficio. Adicionalmente, en la Figura 35 se muestra el esquema metodológico correspondiente.

##### Figura 35

*Esquema metodológico del bloque 2 "fases necesarias para la construcción del algoritmo de caracterización de tiempo de esterilizado"*



##### 4.2.1 Fase 1: Adquisición de Información del Ciclo de Esterilizado

Con la finalidad de caracterizar las condiciones de esterilización de la planta de beneficio adecuadas para un buen proceso de extracción se recopila la información del estado de madurez

del grupo de racimos que ingresa a ser esterilizado. Para esto, se utiliza una metodología aplicada en planta inspirada en la metodología de racimos en tolva (Fausto Prada & Hernán Romero, 2012). En la cual se eligen al azar 28 racimos y se evalúa su estado de madurez. Esto, resulta fundamental para realizar el cálculo del tiempo de esterilizado.

Junto con lo anterior, se recopila el tiempo de esterilizado de cada grupo de racimos que ingresa a ser procesado. Así mismo, se recolecta en una base de datos la pérdida de aceite por impregnación en fase sólida post prensado.

En la Tabla 7 se presentan las características principales de cinco grupos de racimos que ingresan a las autoclaves para su esterilización. Adicionalmente, en el Apéndice B se presenta la información correspondiente a 80 grupos de racimos esterilizados.

La información recopilada en esta etapa, permitirá entrenar el algoritmo de determinación de tiempos de esterilizado en etapas posteriores.

**Tabla 7**

*Caracterización del ciclo de esterilizado de acuerdo a la metodología de racimos en tolva.*

<b>Grupo</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>
<b>Inmaduro</b>	10,7	10,7	28,6	28,6	0,0
<b>Maduro</b>	39,3	78,6	71,4	60,7	28,6
<b>Sobremaduro</b>	50,0	10,7	0,0	10,7	71,4
<b>Tiempo (min)</b>	35	40	40	40	35
<b>Pérdida (%Ac /RFF)</b>	1,00	0,79	1,36	1,42	0,89

En la anterior tabla, los valores de inmaduro, maduro y sobremaduro corresponden al porcentaje de racimos en ese grado de madurez con respecto al grupo que ingresa a ser esterilizado. El tiempo de esterilizado (minutos) se encuentra definido por inferencia experimental por parte del líder de producción de la planta de beneficio.

Adicionalmente, el valor de pérdida, corresponde al porcentaje de impregnación de aceite en la fase solida post prensado. Para garantizar una adquisición adecuada de esta variable, se mantuvo un flujo de prensado constante y un rango de amperaje entre 85 y 90 amperios en el motor de la prensa con el objetivo de regular la presión aplicada al fruto macerado, tal como lo implementado por (Hernández et al., 2004).

#### 4.2.2 Fase 2: Elaboración del Algoritmo de Caracterización de Tiempos de Esterilizado

Para la construcción del algoritmo de caracterización de tiempos de esterilizado se realizó inicialmente una matriz de correlación tal como la implementada por (Luis Guillermo Díaz & Mario Alfonso Morales, 2012). Con el objetivo de determinar las variables de mayor incidencia en la determinación del tiempo de esterilizado.

La matriz de correlación corresponde a la normalización de la matriz de covarianza, la cual se encuentra definida en la ecuación 26.

$$\sigma = \begin{pmatrix} 1 & \rho_{12} & \rho_{13} & \rho_{14} & \dots & \rho_{1p} \\ \rho_{21} & 1 & \rho_{23} & \rho_{24} & \dots & \rho_{2p} \\ \rho_{31} & \rho_{32} & 1 & \rho_{34} & \dots & \rho_{4p} \\ \rho_{41} & \rho_{42} & \rho_{43} & 1 & \dots & \rho_{5p} \\ \rho_{51} & \rho_{52} & \rho_{53} & \rho_{54} & \ddots & \vdots \\ \rho_{p1} & \rho_{p2} & \rho_{p3} & \rho_{p4} & \dots & 1 \end{pmatrix} \quad (26)$$

donde  $\rho_{xy}$  representa el coeficiente de correlación de Pearson, el cual se encuentra definido en la siguiente ecuación.

$$\rho_{XY} = \frac{Cov(X, Y)}{\sigma_x * \sigma_y} \quad (27)$$

Donde  $Cov(X, Y)$  representa la covarianza entre dos variables.

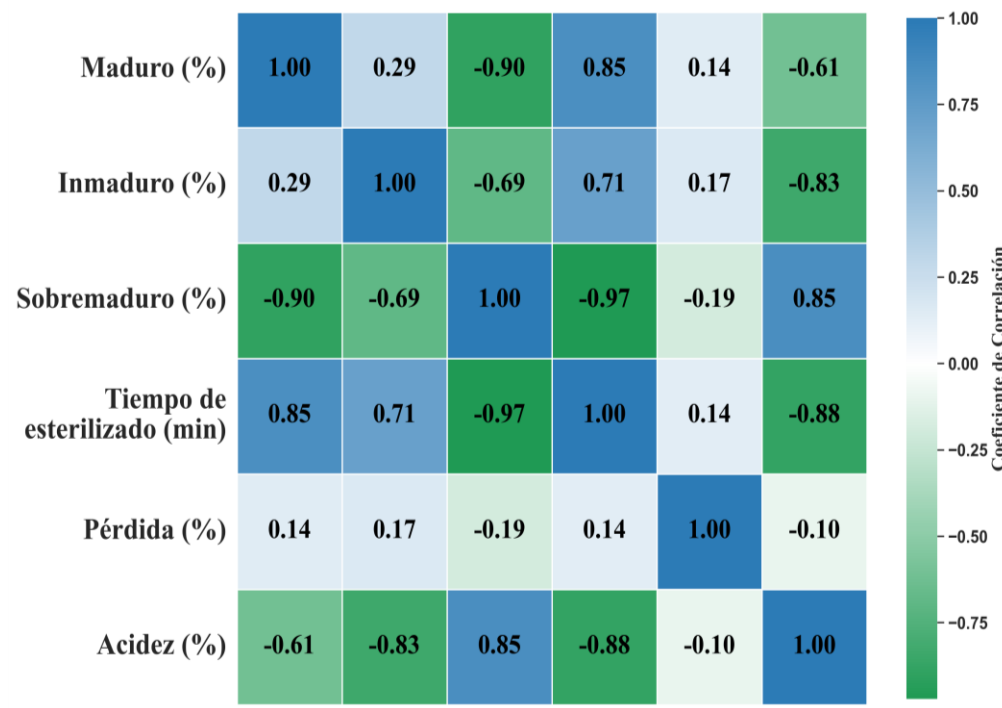
$$Cov(X, Y) = \frac{1}{n-1} * \sum_{i=1}^n (X_i - \bar{X}) * (Y_i - \bar{Y}) \quad (28)$$

A su vez,  $\sigma_x$   $\sigma_y$  representan la desviación estándar y se encuentran definidas por las siguientes ecuaciones:

$$\sigma_x = \sqrt{Var(x)} = \sqrt{\frac{1}{n-1} * \sum_{i=1}^n (X_i - \bar{X})^2} \quad (29)$$

$$\sigma_y = \sqrt{Var(y)} = \sqrt{\frac{1}{n-1} * \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (30)$$

Como resultado de la implementación anterior, en la Figura 36 se presenta la matriz de correlación para las variables obtenidas en la etapa de caracterización de información para el ciclo de racimos esterilizados. Se destaca que para refinar la información de entrenamiento del algoritmo final se eligieron únicamente los grupos de datos en los cuales la pérdida por impregnación en fibra y raquis sea inferior a 0,8% AC/RFF a fin de desarrollar un modelo predictivo que se encuentre condicionado a predecir valores que generen pérdidas por impregnación de aceite bajas al momento de su extracción.

**Figura 36***Matriz de correlación normalizada.*

Se informa que las variables analizadas se pueden resumir de la siguiente manera:

- Estado de madurez del grupo de racimos evaluado (Maduro, Inmaduro, sobremaduro).
- Tiempo de esterilización (tiempo\_est).
- Pérdida de aceite por impregnación en fibra y raquis (Pérdida).
- % Acidez

Encaminándose en la caracterización de las variables de mayor incidencia en el cálculo del tiempo de esterilizado, se observa una alta correlación con los estados de madurez y la acidez. Por lo cual se concluye que un modelo desarrollado con las variables de los estados de madurez como valores de entrada, puede realizar inferencias asertivas en la determinación del tiempo de esterilizado.

Adicionado a lo anterior, se indica una correlación positiva entre los estados de maduración inmaduro y maduro con el tiempo de esterilizado. Sin embargo, existe una correlación más fuerte con el estado de maduración inmaduro debido a que su valor es más cercano a uno. De igual manera, se presenta una fuerte correlación inversa entre el tiempo de esterilización y el estado Sobremaduro.

Así mismo, se observa que las variables de los estados de maduración y tiempo de esterilizado, pueden ser implementadas en futuros modelos predictivos del porcentaje de acidez en la fase líquida prensada.

**4.2.2.1 Selección del modelo para predicción de tiempos de esterilizado.** Teniendo en cuenta los resultados anteriores, se propone como primer algoritmo una red neuronal artificial (RNA), la cual fue construida con una capa de entrada de tres neuronas, que corresponden al porcentaje de racimos en cada uno de los tres estados con respecto al número total de frutos a esterilizar, una capa única intermedia constituida por dos neuronas y una capa de salida con una única neurona, la cual representa el tiempo de esterilizado.

La elección del número de neuronas en la capa intermedia se debe principalmente a las limitaciones en la cantidad de datos de entrenamiento. Por lo cual, se propone un sistema con un bajo número de neuronas. El cual, aunque necesite un mayor número de épocas para llegar a la convergencia permite un entrenamiento con un conjunto de datos menor, tal como lo mencionado por (Nielsen, 2015).

Como segundo modelo se propone un algoritmo basado en regresión lineal múltiple tal como el implementado por (Colchado & Joselina, 2019). debido a presunciones experimentales de la linealidad entre el tiempo de esterilizado y el porcentaje de madurez de los racimos esterilizados.

Los modelos evaluados se entrenaron con 30 datos de entrenamiento y 7 datos de validación. A continuación, se muestran los resultados posteriores a la implementación de ambos algoritmos en la Tabla 8.

**Tabla 8**

*Evaluación de modelos para determinación de tiempo de esterilizado.*

	<b>coeficiente de determinación (validación)</b>	<b>Tiempo de procesamiento (s)</b>
<b>Red Neuronal Artificial (RNA)</b>	0,97	0,078
<b>Regresión lineal múltiple</b>	0,95	0,015

De acuerdo a la información adquirida en la tabla anterior, se observa que el coeficiente de determinación en la etapa de validación es mayor en el algoritmo de red neuronal artificial. Así mismo, los tiempos de procesamiento de ambos modelos son inferiores a 0,1 segundos. Por lo cual, se decide utilizar el algoritmo basado en redes neuronales en la implementación final.

## 5. Implementación

### 5.1 Validación del Modelo Computacional Mediante Implementación en Planta

Con el objetivo de validar el modelo desarrollado se realizó la implementación en planta de beneficio para lo cual, se capturan las imágenes del grupo de racimos a esterilizar mediante el algoritmo de adquisición de información descrito con anterioridad. Posteriormente, se extraen las fotografías segmentadas de los racimos por medio del algoritmo de preprocesamiento (Ver

apéndice B. Algoritmo de preprocesamiento) y la implementación de la red de detección de falsos positivos (Ver apéndice C. RNC de preprocesamiento). Consecuente a lo anterior, se determina el estado de madurez de cada uno de los racimos detectados (Ver apéndice D.) y se guarda en un vector de tres salidas el cual es evaluado por medio de la red neuronal de determinación de tiempos de esterilizado (Ver apéndice E.).

Los datos de evaluación corresponden a 10 ciclos de esterilizado donde se garantizaron condiciones similares a las de la etapa de adquisición de información. y sus resultados pueden observarse en la Tabla 9.

**Tabla 9**

*Información recopilada post implementación del modelo.*

<b>Grupo</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>	<b>9</b>	<b>10</b>
<b>tiempo procesamiento (s)</b>	13,3	18,5	19,5	22,5	23,5	21,1	15,7	11,4	19,1	18,1
<b>% Inmaduro</b>	28,3	20,0	30,0	34,8	58,8	37,9	23,2	28,3	29,6	22,5
<b>% Maduro</b>	33,8	33,8	32,7	22,8	11,1	24,8	9,7	28,3	37,4	41,4
<b>% Sobremaduro</b>	37,9	46,3	37,3	42,4	30,1	37,4	67,1	43,4	33,0	36,1
<b>Pérdida (%Ac /RFF)</b>	0,78	0,76	0,78	0,72	0,78	0,78	0,73	0,68	0,71	0,73
<b>Tiempo modelo (min)</b>	35	33	36	35	39	35	30	34	37	36
<b>tiempo convencional (min)</b>	35	35	35	35	40	35	35	35	40	35

---

<b>Diferencia</b>	10 minutos
-------------------	------------

---

Los elementos caracterizados en la tabla anterior se pueden resumir de la siguiente manera:

**tiempo procesamiento (s):** indica el tiempo de ejecución del algoritmo desarrollado

**% Inmaduro, % Maduro, % Sobremaduro:** señalan el porcentaje de racimos en cada uno de los estados con respecto al total de los racimos que ingresan a ser esterilizados.

**Pérdida (%Ac /RFF):** representa el porcentaje en peso de aceite medido con respecto al peso de racimos de fruto de palma.

**Tiempo modelo:** expone el tiempo de esterilización sugerido por el modelo para el grupo de racimos que ingresan a la autoclave.

**tiempo convencional:** presenta el tiempo de esterilización generalmente sugerido por el experto en la planta de beneficio para grupos de racimos con características similares, es resaltable mencionar que la decisión del tiempo a implementar es de carácter experimental.

**Diferencia:** Indica el valor resultante de la variación entre los tiempos sugeridos por el modelo y los tiempos convencionales.

Adicionalmente, se observa que con la implementación del modelo desarrollado (Ver Apéndice H. Algoritmo de implementación para determinación de tiempos de esterilizado) se puede reducir en promedio un minuto por cada ciclo de esterilizado manteniendo pérdidas por impregnación en fase solida bajas.

Teniendo en cuenta que el ciclo de esterilizado generalmente se estandariza en 40 minutos, el uso de inteligencia artificial orientado a la determinación de tiempos de esterilizado y

caracterización de la madurez de los RFF representa una disminución del 2.78% con respecto al tiempo comúnmente implementado en las plantas de beneficio.

Esta disminución de tiempo, podría permitir el incremento de la capacidad de procesamiento por hora, mejorar la eficiencia térmica del proceso de esterilización, minimizar el costo del personal operativo por tonelada de RFF procesado y por ende, mejorar la eficiencia de la planta de beneficio.

## 5.2 Predicción económica de la implementación del modelo

Con la finalidad de realizar una aproximación económica al comportamiento esperado en las plantas de beneficio de aceite, se presenta una evaluación preliminar del impacto financiero asociado a la implementación del algoritmo desarrollado.

En este contexto, la evaluación se orienta a estimar el efecto económico de la aplicación del modelo sobre el desempeño del proceso de esterilización, teniendo en cuenta que el sistema logró mantener pérdidas por impregnación en la fase sólida inferiores al 0,8% de Aceite / RFF y generó una reducción promedio del tiempo de esterilización del 2,78% en comparación con los métodos de caracterización convencionales. A partir de estas consideraciones, en la tabla 10. se presentan los parámetros utilizados para la estimación del impacto financiero esperado.

### **Tabla 11.**

*Caracterización del análisis económico*

Descripción	Unidades	Abreviatura	Valor
Reducción del tiempo de esterilizado	%	RTE	2,78

Reducción tentativa de pérdidas	t Aceite/t RFF	RPI	0,001
Capacidad de procesamiento de fruto	t RFF / h	CPF	15
Horas de proceso diarias	h	HP	20
Días de proceso efectivos mensuales	días	DPEM	25
Tasa de extracción de aceite	%	TEA	24
Tasa de aceite atribuible a pago de fruto	%	TAPF	19
Precio de venta del aceite crudo de palma	(\$ / t Aceite)	\$CPO	\$ 4'325,674

Con base en los parámetros mencionados en la tabla 12, la predicción económica considera dos fuentes principales de incremento potencial de ingresos para la planta de beneficio. La primera de ellas, se fundamenta en el potencial de procesamiento de fruta adicional, producto de la reducción del tiempo de esterilizado, y la segunda se basa en el potencial de aceite adicional recuperado, asumiendo una reducción tentativa de las pérdidas por impregnación de aceite en fase sólida del 0,1% (equivalente a 0,001 t Aceite / t RFF).

Teniendo en cuenta lo anterior, en la ecuación 31 y 32, se presentan las ecuaciones para la estimación del cálculo del potencial adicional de ingresos por procesamiento adicional de fruto y reducción de pérdidas por impregnación, post implementación del modelo.

$$PAA 1(\$) = RTE(\%) * \frac{Fruta\ procesada}{dia} * \frac{\#\ dias\ de\ proceso}{mes} * (TEA - TAPF) * \frac{\$}{t\ aceite} \quad (31)$$

$$PAA 2(\$) = RPI(\%) * \frac{Fruta\ procesada}{dia} * \frac{\#\ dias\ de\ proceso}{mes} * \frac{\$}{t\ aceite} \quad (32)$$

Al resolver las ecuaciones (31) y (32) a partir de los parámetros definidos en la Tabla 10, se obtiene un potencial estimado de ingresos adicionales por venta de aceite asociado al procesamiento de fruta adicional ( *PAA 1* ) de \$ 45'095.151 / mes, mientras que el potencial de ingresos adicionales derivado de la reducción de pérdidas por impregnación en fase sólida ( *PAA 2* ) alcanza un valor de \$ 38'931.066 / mes. En conjunto, estos resultados representan un incremento económico total estimado de \$ 84 026 217 / mes, atribuible a la implementación del modelo propuesto bajo las condiciones operativas consideradas.

Los valores estimados permiten evidenciar el impacto económico potencial de la aplicación del modelo en las plantas de beneficio de aceite, constituyendo una referencia cuantitativa para la toma de decisiones en escenarios de implementación industrial y sirviendo como base para análisis económicos más detallados en futuras investigaciones.

## 6. Conclusiones

- La implementación del algoritmo de preprocesamiento desarrollado permite identificar las regiones de interés correspondientes a los racimos de palma de aceite con exactitudes similares a las adquiridas mediante modelos de segmentación de la familia Ultralytics-Yolo preentrenados, pero con un tiempo de procesamiento más de ochenta veces inferior al requerido por el algoritmo de segmentación basado en redes neuronales convolucionales de mayor precisión en la determinación de regiones de interés.
- Aunque el algoritmo de segmentación inicial alcanza una exactitud del 84 % en la detección de los racimos, se observó que también tiende a umbralizar las regiones con alta iluminación, introduciendo falsos positivos en el proceso. Para mitigar este inconveniente, se desarrolló una red neuronal convolucional (CNN) de preprocesamiento, que permite discriminar correctamente los racimos reales de las regiones erróneamente segmentadas. Esta etapa de clasificación alcanzó precisiones superiores al 98,8 %, mejorando significativamente la fiabilidad de los datos de entrada en procesos posteriores.
- La implementación del modelo ConvNeXt-XLarge de la familia ConvNext permitió caracterizar el grado de maduración de los RFF con una exactitud superior al 91,2%. Sin embargo, la integración de cámaras con velocidades de captura superiores a 30 fps podría reducir el ruido producido en la adquisición de las imágenes, y, por ende, la posibilidad de mejorar la exactitud final del algoritmo y abriría la posibilidad de utilizar arquitecturas más simples que disminuyan el tiempo de ejecución y los recursos computacionales requeridos.
- Se identificó una fuerte correlación entre los estados de maduración de los RFF y el tiempo de esterilizado. En este contexto, la implementación de modelos de predicción por regresión lineal multivariable ofrece precisiones levemente inferiores a las alcanzadas con

algoritmos basados en redes neuronales. Debido a esto, resultan favorables en contextos donde el conjunto de datos de entrenamiento sea bajo y se requiera un tiempo de ejecución inferior al de las arquitecturas de ANN convencionales.

- Existe una alta correlación entre la maduración y la acidez en el aceite de los RFF. Por lo cual, modelos predictivos entrenados con variables de los estados de madurez como valores de entrada, podrían generar predicciones asertivas del porcentaje de ácidos grasos libres (AGL) en el aceite.
- El modelo de inteligencia artificial desarrollado demostró que puede ser aplicable en plantas de beneficio para la determinación del tiempo de esterilizado del fruto de palma de aceite *elaeis guineensis* manteniendo pérdidas por impregnación en la fase solida del prensado inferiores a 0.8% de aceite / RFF. A su vez, se observó una reducción de tiempo de esterilización promedio de 2.78% con respecto a los métodos convencionales lo que permite incrementar la productividad manteniendo la calidad en la extracción.

## 7. Trabajo futuro

De acuerdo a los resultados obtenidos en el trabajo de grado desarrollado, se recomiendan las siguientes líneas de trabajo futuro para fortalecer y expandir la aplicabilidad del modelo en la agroindustria de la palma de aceite:

**Expansión de la Base de Datos con Híbridos OxG:** Se recomienda Ampliar la base de datos mediante la incorporación de imágenes de frutos híbridos (OxG), con el objetivo de aumentar la robustez y mejorar la capacidad de generalización del modelo frente a variaciones genéticas y morfológicas del RFF.

**Integración de Variables Fisicoquímicas y Predicción de Calidad:** Se recomienda evolucionar el modelo actual hacia una herramienta de caracterización que no solo determine el tiempo de esterilizado, sino que también anticipe la calidad final del aceite mediante la integración de nuevas variables fisicoquímicas, tales como la acidez (AGL) y el índice de deterioro de blanqueabilidad (DOBI).

**Análisis de Atributos Morfométricos mediante Mapas de Profundidad:** Aprovechando la capacidad de los mapas de profundidad utilizados en este proyecto para la segmentación, se recomienda el análisis de atributos morfométricos avanzados de los racimos, tales como volumen estimado, geometría y peso proyectado. La incorporación de estos parámetros permitiría establecer criterios técnicos objetivos para la evaluación de proveedores en las plantas de beneficio, basados en características físicas cuantificables y reproducibles, en lugar de depender exclusivamente de la inspección visual tradicional.

**Soluciones de Integración y Monitoreo en Línea:** Como línea futura de desarrollo, se plantea la integración del modelo propuesto con sistemas de monitoreo en línea que permitan su operación continua en entornos industriales reales. Esta integración deberá considerar variables operativas como la velocidad del transportador y las condiciones de iluminación industrial, con el objetivo de habilitar esquemas de automatización capaces de ajustar parámetros del proceso en tiempo real, mejorando la eficiencia operativa y reduciendo las pérdidas de aceite.

### Referencias Bibliográficas

- Abdul Azis Ariffin. (2013). Esterilización a alta presión de racimos de fruta fresca de palma de aceite, cero frutos adheridos en tusas y máximo 5% de aceite en fibra de prensa. *Palmas*, 34, 36–46.
- Aggarwal, C. C. (2023). *A Textbook Second Edition Neural Networks and Deep Learning* (2nd ed.). Springer Cham. <https://doi.org/DOIhttps://doi-org.bibliotecavirtual.uis.edu.co/10.1007/978-3-031-29642-0>
- Aldaz Noble, A. E. ; S. M. D. A. (2025). *Análisis comparativo de redes neuronales para la predicción de cáncer de mama en imágenes médicas mediante la evaluación estadística de rendimiento* [Bachelor's thesis]. Universidad politécnica salesiana.
- Alegre, E., Sánchez, L., & Ángel Fernandez-Díaz, R. (2003). *Procesamiento Digital de Imágenes. Fundamentos y Practicas con Matlab (Digital image processing. Fundamentals and practices with Matlab)*. <https://www.researchgate.net/publication/229828279>
- Alsuwaylimi, A. A. (2024). Enhanced YOLOv8-Seg instance segmentation for real-time submerged debris detection. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2024.0429000>
- Andrew Fitzgibbon, Maurizio Pílu, & Robert B. (1999). Direct Least Square Fitting of Ellipses. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 21(5), 476–480.
- Antonio, M., Pérez, A., Javier, J., & Rojas, B. (2009). *Espacios de Color RGB, HSI y sus Generalizaciones a n-Dimensiones*.
- Artola Moreno, Á. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*. Universidad de Sevilla.

- Barcelos, E., De Almeida Rios, S., Cunha, R. N. V., Lopes, R., Motoike, S. Y., Babiychuk, E., Skiryecz, A., & Kushnir, S. (2015). Oil palm natural diversity and the potential for yield improvement. *Frontiers in Plant Science*, 6(MAR), 1–16. <https://doi.org/10.3389/fpls.2015.00190>
- Bastidas Pérez, S., Peña Rojas, E., & Reyes Cuesta, R. (2013). *Preguntas sobre Palma de aceite Elaeis guineensis Jacq., palma Noli Elaeis oleifera (Kunth) Cortés y los híbridos interespecíficos Noli × Palma de aceite (E. oleifera × E. guineensis)*. Cenipalma. [www.corpoica.org.co](http://www.corpoica.org.co)
- Calderón Saavedra, D. S. (2012). *Generación de mapas de profundidad a partir de imágenes estéreo utilizando registro no rígido memoria para optar al título de ingeniero civil electricista* [Proyecto de grado]. Universidad de Chile.
- Camilo Carrillo González. (2015). *Análisis del color RGB*. 140–169.
- Colchado, R., & Joselina, A. (2019). *Predicción de calidad y etapa de madurez en mango Kent (mangifera indica) usando imágenes hiperespectrales* [B.S. thesis]. Universidad Nacional de Trujillo.
- Corley, R. H. V., & Tinker, P. B. (2015). La palma de aceite. In John Wiley & Sons (Ed.), *The Oil Palm* (Español). <https://doi.org/10.1002/9781118953297.fmatter>
- Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation functions in deep learning: A comprehensive survey and benchmark. *Neurocomputing*, 503, 92–108. <https://doi.org/10.1016/j.neucom.2022.06.111>

Fausto Prada, & Hernán Romero. (2012). *Tecnologías para la agroindustria de la palma de aceite*  
*Guía para facilitadores*. Cenipalma. [www.cenipalma.org](http://www.cenipalma.org)

Federación Nacional de Cultivadores de Palma de Aceite. (2016). *Guía ambiental para el*  
*subsector de la agroindustria de la palma de aceite*.

Francisca Parra. (2012). *Modelo hiperspectral para imágenes termográficas en la banda del*  
*infrarrojo cercano* [Tesis de maestría]. Universidad de Concepción.

Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani, & Jonathan Taylor. (2023). *An*  
*Introduction to Statistical Learning with Applications in Python*. Springer Cham.  
<https://doi.org/https://doi-org.bibliotecavirtual.uis.edu.co/10.1007/978-3-031-38747-0>

Gonzalez, R. C. ., & Woods, R. E. . (2009). *Digital image processing* (4th ed.). Pearson Prentice  
Hall.

Guimaraes Rojas, O. E. (2019). *Influencia del estado de la madurez y condiciones de esterilización*  
*de los frutos, en el rendimiento y calidad de aceite crudo de palma africana (Elaeis*  
*guineensis) de la Planta Extractora Oleaginosas Amazónicas SA–Ucayali 2018* [Proyecto de  
grado]. Universidad Nacional Intercultural de la Amazonia.

Hernández, C., Yáñez, É., & Granados, F. (2004). Manejo integrado de pérdidas de aceite y  
almendra. *Palmas*, 25(special no. II), 418–424.

HUGO ALFONSO RUEDA RUEDA. (2011). *Evaluación del tiempo postcosecha sobre la*  
*actividad lipásica del mesocarpio del fruto de la palma de aceite y la calidad del aceite* [Tesis  
de grado en Química]. Universidad Industrial de Santander.

- Hussmann, S. ; R. T. ; H. B. (2008). *A performance review of 3D TOF vision systems in comparison to stereo vision systems*. Stereo Vision.
- Ingrid, C., Silvia, C., Nidia, R., & Jesus, G. (2023). Characterization of the Quality Criteria of Fresh Fruit Bunches from Hybrid Cultivars OxG Resumen. *Revista Palma*, 44.
- Isaac Pérez, & Manuel Gegúndez. (2021). *Deep learning*.
- Kaur, R., & Singh, E. R. (2017). Image Filtering Techniques-A Review. *International Journal of Advance Research in Science and Engineering*, 6(08).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(60), 84–90.  
<http://code.google.com/p/cuda-convnet/>
- Llano, L., Hoyos, A. ; A. F., & Velásquez, J. (2007). Comparación del desempeño de funciones de activación en redes Feedforward para aproximar funciones de datos con y sin ruido. *Revista Avances En Sistemas e Informática*, 4, 79–87.
- Luis Guillermo Díaz, & Mario Alfonso Morales. (2012). *Análisis estadístico de datos multivariados* (1st ed.). Universidad Nacional de Colombia.
- Lv, P., Xu, H., Zhang, Q., Shi, L., Li, H., Chen, Y., Zhang, Y., Cao, D., Liu, Z., Liu, Y., Han, J., Zhang, Z., & Qi, Y. (2025). An improved lightweight ConvNeXt for rice classification. *Alexandria Engineering Journal*, 112, 84–97. <https://doi.org/10.1016/j.aej.2024.10.098>
- Manaswi, N. K. (2018). Deep Learning with Applications Using Python. In *Deep Learning with Applications Using Python*. Apress. <https://doi.org/10.1007/978-1-4842-3516-4>

- Marcela Quintana. (2024). *Modelo de segmentación semántica de imágenes satelitales basado en redes neuronales convolucionales para la clasificación de cobertura de la tierra en páramos*. Universidad Nacional de Colombia.
- Mauricio, H., Angulo, R., Diana, A., Forero, C., Paola, H., Hormaza, A., Leidy, M., Moreno, P., Rodrigo, C., & Romero, R. (2012). *Generalidades sobre la morfología y fenología de la palma de aceite*.
- Mosquera-Montoya, M., Ruiz-Álvarez, E., Munévar, D. A., Estupiñan, M. C., Diaz, L., Guerrero, A. E., Cala, S. L., & Sierra, S. M. (2020). *Costos de producción 2020 para la palmicultura colombiana: estudio de benchmarking a empresas adoptantes de buenas prácticas*.
- Nielsen, M. (2015). *Neural Networks and Deep Learning* (Vol. 25). Determination Press.  
<http://neuralnetworksanddeeplearning.com>
- Ochoa, I. E., Suárez, C. A., & Cayón, D. G. (2013). Desarrollo y maduración de frutos en palma de aceite (*Elaeis guineensis* Jacq.) e híbridos OxG (*E. oleifera* × *E. guineensis*) de Unipalma S.A. *Palmas*, 34, 326–336.
- Oil palm fruit grading manual*. (2003). Malaysian Palm Oil Board.
- Olabe, X. B. (1998). *Redes neuronales artificiales y sus aplicaciones* (Vol. 5). Publicaciones de la Escuela de Ingenieros.
- Palomino, N. L. S., & Concha, U. N. R. (2009). Técnicas de segmentación en procesamiento digital de imágenes. *Revista de Investigación de Sistemas e Informática*, 6(2), 9–16.

- Penatti, O. A. ; N. K., & Dos Santos, J. A. (2015). Do deep features generalize from everyday objects to remote sensing and aerial scenes domains? *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 44–51.
- Perez M. (2017). *Determinación de color en fruto y acidez en aceite de palma africana como parámetros de calidad en Tenosique, Tabasco*. Colegio de postgraduados.
- Ramírez-García, S., Hazel Carranza-Castro, P., Gutiérrez-Salinas, J., García-Ortiz, L., Hernández-Rodríguez, S., Ramírez García, S., Médico, D., & Juárez, B. (2012). Aplicación en medicina de la espectroscopia de infrarrojo cercano. *Medicina Interna de México*, 28(4), 365–370.
- Rawat, W., & Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. In *Neural Computation* (Vol. 29, Number 9, pp. 2352–2449). MIT Press Journals. [https://doi.org/10.1162/NECO\\_a\\_00990](https://doi.org/10.1162/NECO_a_00990)
- Reiner Armas, Miguel Túpac, Guillermo Kemper, & Christian del Carpio. (2020). Un algoritmo de clasificación de semillas forestales basado en procesamiento digital de imágenes y redes neuronales convolucionales. *Décima Novena Conferencia Iberoamericana En Sistemas, Cibernética e Informática (CISCI 2020)*.
- Rincón Sandra, & Martínez Daniel. (2009). Análisis de las propiedades del aceite de palma en el desarrollo de su industria. *Palmas*, 30(2), 11–24.
- Rodrigo Erales. (2016). *Calidad de Cosecha*.
- Rodríguez Pulido, F. J. (2013). *Aplicación de técnicas de imagen para la evaluación de la madurez fenólica de semillas de uva* [Tesis doctoral]. Universidad de Sevilla.

- Rozo Ibáñez, & Velasco Escalante. (2007). *Ingeniería de automatización para el proceso de esterilización en la extracción de aceite de palma africana*.
- Tailliez, B., Siaka Coulibaly, M., Bonny, C. P., & Jacquemard, J. C. (1996). La maduración de los racimos de palma y los criterios de cosecha en Palmindustrie (Costa De Marfil)\* Oil palm bunch ripening and heversting criteria at Palmindustrie (Ivory Cosí). In *PALMAS* (Vol. 17, Number 1).
- Terven, J., Cordova-Esparza, D. M., Romero-González, J. A., Ramírez-Pedraza, A., & Chávez-Urbiola, E. A. (2025). A comprehensive survey of loss functions and metrics in deep learning. *Artificial Intelligence Review*, 58(7). <https://doi.org/10.1007/s10462-025-11198-7>
- Tkalcic, M. ; T. J. F. (2003). Colour spaces: perceptual, historical and applicational background. *The IEEE Region 8 EUROCON 2003. Computer as a Tool*, 304–308.
- Vera M;, Peña E., & Espinoza N. (1998). Control previo de la calidad de cosecha en palma de aceite (*Elaeis guineensis* Jacq.) en la región de Tumaco, Colombia. *Palmas*, 19(1), 9–15.
- Yunus, R., Zurina, Z. A., Syafiie, S., & Chang, T. S. (2015). Modeling and simulation of heat and mass transfer in oil palm fruit digestion process. *Journal of Emerging Trends in Engineering and Applied Sciences*, 6(2).