



**UNIVERSIDAD POLITÉCNICA SALESIANA**  
**SEDE GUAYAQUIL**  
**CARRERA DE MECATRÓNICA**

**IMPLEMENTACIÓN DE UN SISTEMA DE CLASIFICACIÓN DE  
BANANO BASADO EN EL ESTADO DE MADURACIÓN**

Trabajo de titulación previo a la obtención del  
Título de Ingeniero en Mecatrónica

**AUTORES:** Cantos Chávez Amy Verushka  
Loor Maridueña Jorge Andrés  
**TUTOR:** Ing. Alberto Santiago Ramírez Farfán

Guayaquil - Ecuador  
2024-2025

## CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, **Amy Verushka Cantos Chávez** con documento de identificación N° **0953816451** y **Jorge Andrés Loor Maridueña** con documento de identificación N° **0953390093**; manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo.

Guayaquil, 07 de Febrero del año 2025

Atentamente,



---

Amy Verushka Cantos Chávez  
0953816451



---

Jorge Andrés Loor Maridueña  
0953390093

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA  
UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, **Amy Verushka Cantos Chávez** con documento de identificación N° **0953816451** y **Jorge Andrés Loor Maridueña** con documento de identificación N° **0953390093**, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del **Dispositivo Tecnológico: IMPLEMENTACIÓN DE UN SISTEMA DE CLASIFICACIÓN DE BANANO BASADO EN EL ESTADO DE MADURACIÓN**, el cual ha sido desarrollado para optar por el título de: Ingeniero en Mecatrónica, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Guayaquil, 07 de Febrero del año 2025

Atentamente,



---

Amy Verushka Cantos Chávez  
0953816451



---

Jorge Andrés Loor Maridueña  
0953390093

## CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, **Alberto Santiago Ramírez Farfán**, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: **IMPLEMENTACIÓN DE UN SISTEMA DE CLASIFICACIÓN DE BANANO BASADO EN EL ESTADO DE MADURACIÓN**, realizado por **Amy Verushka Cantos Chávez** con documento de identificación N° **0953816451** y por **Jorge Andrés Loor Maridueña** con documento de identificación N° **0953390093**, obteniendo como resultado final el trabajo de titulación bajo la opción **Dispositivo Tecnológico** que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 07 de Febrero del año 2025

Atentamente,



---

Ing. Alberto Santiago Ramírez Farfán, Mg.  
0923348890

## DEDICATORIA

A mi mamá, Verónica Álava, por su amor incondicional, su apoyo constante y su sabiduría. Gracias por ser mi guía y mi fuerza, por enseñarme a seguir adelante, sin importar los obstáculos.

A mi papá, Cristóbal Loor, por su firmeza, su dedicación y por siempre creer en mí. Tu apoyo y tus consejos han sido esenciales en cada paso de este camino.

A mi hermano, Jordy Loor, por ser mi compañero inquebrantable, y por estar siempre a mi lado, en los buenos y en los malos momentos.

A mis mascotas, Pibeerry, Oso y Chocolate, por su amor sincero y por recordarme cada día lo importante que es disfrutar del presente. Su compañía y alegría han sido mi refugio en los momentos de estrés.

A todos ustedes, con todo mi amor y gratitud, dedico este logro. Son la razón por la cual este sueño se hizo realidad.

**Jorge Andrés Loor Maridueña**

Este proyecto representa el fruto de años de esfuerzo, aprendizaje y dedicación. Lo dedico, en primer lugar, a mis padres, cuyo apoyo incondicional ha sido fundamental en este camino. A mi madre, por su fortaleza, amor y sacrificio, siempre preocupada por mi bienestar y brindándome el soporte emocional y económico necesario para seguir adelante. A mi padre, cuya presencia y respaldo constante han sido un pilar en mi vida académica, siempre dispuesto a ayudar en cada situación, asegurándose de que nada interfiriera en mi formación.

A mi hermana, quien ha sido testigo de mis noches de esfuerzo, de mis momentos de frustración y también de mis logros. Su paciencia y consejos han sido una guía valiosa a lo largo de esta travesía. A mi mascota, Príncipe, por ser una compañía incondicional, brindándome alegría y consuelo en los momentos más difíciles.

Finalmente, dedico este logro a mis compañeros de carrera, quienes con su amistad y apoyo han hecho que este proceso sea más llevadero, compartiendo desafíos, sacrificios y también alegrías. Su compañía ha sido clave para superar cada obstáculo y alcanzar esta meta.

**Amy Verushka Cantos Chávez**

## AGRADECIMIENTO

Quiero extender mi más profundo agradecimiento a todas las personas que han sido parte de este proceso y me han acompañado a lo largo de este camino tan especial.

A mis profesores, por su dedicación, paciencia y orientación. Cada uno de ustedes ha contribuido de manera significativa a mi crecimiento académico y personal, siempre dispuestos a brindarme su conocimiento y apoyo.

A mis amigos y compañeros de estudio, por sus momentos de risas, por la colaboración y la motivación que me han ofrecido. Su compañía hizo de este proceso algo mucho más llevadero.

A todas las personas que me han brindado palabras de aliento, que me han escuchado, y que han sido mi fuente de motivación en aquellos días difíciles. Su apoyo, en todos los aspectos de la vida, ha sido invaluable.

Finalmente, a aquellos que, aunque no mencionados explícitamente, han sido parte de mi vida y de este logro, su influencia y cariño han sido un aliciente constante para seguir adelante.

**Jorge Andrés Loor Maridueña**

Expreso mi profundo agradecimiento a Dios, por darme la fortaleza y la sabiduría necesarias para enfrentar cada reto y permitirme llegar hasta este punto de mi vida académica.

A mis padres, por su esfuerzo incansable para brindarme una educación de calidad y por ser mi mayor fuente de inspiración. Su paciencia, enseñanzas y apoyo incondicional han sido fundamentales en mi desarrollo personal y profesional.

A mi hermana, por su confianza en mí, sus consejos y su apoyo inquebrantable, incluso en los momentos en los que yo misma dudaba de mis capacidades. A mi familia extendida, incluidos mis tíos y primos, por sus palabras de aliento y por contribuir a fortalecer mi confianza en este proceso.

A mi compañero de tesis, con quien he compartido este desafío académico desde los primeros semestres. Su compromiso y esfuerzo han sido clave para llevar a cabo este proyecto con éxito.

Por último, agradezco a mis profesoras y profesores, quienes han sido guías en mi formación, compartiendo sus conocimientos y acompañándome en este proceso de crecimiento académico y profesional. Gracias a todos los que, de una u otra manera, han contribuido a la culminación de esta etapa tan importante en mi vida.

**Amy Verushka Cantos Chávez**

## I. RESUMEN

La industria bananera ecuatoriana, como pilar de la economía nacional, enfrenta el desafío de modernizar sus procesos para satisfacer las crecientes exigencias del mercado internacional. Este proyecto de sustentación se enfoca en la implementación de un sistema automatizado de clasificación de bananos basado en visión artificial, capaz de identificar el estado de maduración de la fruta mencionada mientras circulan sobre una banda transportadora. La solución propuesta combina técnicas avanzadas de procesamiento de imágenes y aprendizaje profundo, con el fin de optimizar la precisión y velocidad en la clasificación.

Inicialmente, es necesario destacar que se llevó a cabo un análisis del estado del arte en sistemas de visión artificial aplicados a la clasificación de bananos, identificando metodologías, arquitecturas de redes neuronales y estrategias de preprocesamiento relevantes para la problemática planteada. Posteriormente, se desarrolló un conjunto de datos representativo, compuesto por imágenes de alta resolución de bananos en un entorno controlado, manteniendo condiciones uniformes de iluminación, orientación fija y un fondo único. Este conjunto de datos fue empleado para entrenar una red neuronal convolucional mediante técnicas de aprendizaje por transferencia, utilizando modelos preentrenados en MobileNet, ajustados para optimizar el rendimiento en la tarea específica.

Finalmente, el desempeño del sistema fue evaluado en un entorno controlado, utilizando métricas como precisión, sensibilidad, especificidad y tiempo de procesamiento, con el objetivo de medir la efectividad del modelo al clasificar bananos en diferentes estados de madurez. Los resultados obtenidos buscan demostrar que la implementación de sistemas de visión artificial en la industria bananera no solo mejora la eficiencia operativa, sino que también posiciona al sector como un actor competitivo y sostenible en el ámbito global. Este trabajo sienta las bases para futuras aplicaciones de tecnologías de inteligencia artificial en la modernización de procesos agrícolas y agroindustriales.

**Palabras claves:** Industria bananera, visión artificial, clasificación de bananos, estado de maduración, aprendizaje profundo, Redes neuronales convolucionales (CNN), procesamiento de imágenes, aprendizaje por transferencia, banda transportadora, optimización de procesos, inteligencia artificial

## II. ABSTRACT

The Ecuadorian banana industry, as a pillar of the national economy, faces the challenge of modernizing its processes to meet the growing demands of the international market. This support project focuses on the implementation of an automated banana grading system based on artificial vision, capable of identifying the ripening stage of the fruit as they circulate on a conveyor belt. The proposed solution combines advanced image processing and deep learning techniques to optimize sorting accuracy and speed.

Initially, it is necessary to highlight that an analysis of the state of the art in computer vision systems applied to banana classification was carried out, identifying methodologies, neural network architectures and preprocessing strategies relevant to the proposed problem. Subsequently, a representative dataset was developed, composed of high-resolution images of bananas in a controlled environment, maintaining uniform illumination conditions, fixed orientation and a single background. This dataset was used to train a convolutional neural network by means of transfer learning techniques, using pre-trained models in MobileNet, adjusted to optimize performance for the specific task.

Finally, the performance of the system was evaluated in a controlled environment, using metrics such as accuracy, sensitivity, specificity and processing time, in order to measure the effectiveness of the model in classifying bananas at different stages of maturity. The results obtained seek to demonstrate that the implementation of artificial vision systems in the banana industry not only improves operational efficiency, but also positions the sector as a competitive and sustainable player in the global arena. This work lays the foundation for future applications of artificial intelligence technologies in the modernization of agricultural and agro-industrial processes.

**Key words:** Banana industry, computer vision, banana classification, ripening state, deep learning, convolutional neural networks (CNN), image processing, transfer learning, conveyor belt, process optimization, artificial intelligence.

## ÍNDICE

<b>I.</b>	<b>RESUMEN</b>	3
<b>II.</b>	<b>ABSTRACT</b>	4
<b>III.</b>	<b>INTRODUCCIÓN</b>	1
<b>IV.</b>	<b>PROBLEMA</b>	2
<b>V.</b>	<b>JUSTIFICACIÓN</b>	3
<b>VI.</b>	<b>OBJETIVOS</b>	5
	VI-A. Objetivo general . . . . .	5
	VI-B. Objetivos específicos . . . . .	5
<b>VII.</b>	<b>FUNDAMENTOS TEÓRICOS</b>	6
	VII-A. La industria bananera en Ecuador . . . . .	6
	VII-B. Desafíos de la automatización . . . . .	7
	VII-C. Proceso de clasificación manual . . . . .	8
	VII-D. Manufactura adictiva . . . . .	9
	VII-E. Ventajas de la visión artificial . . . . .	9
	VII-F. Aprendizaje automático . . . . .	11
	VII-G. Redes neuronales convolucionales . . . . .	12
	VII-H. Comparación entre modelos de redes convolucionales . . . . .	12
	VII-H1. Red MOBILNETV1 . . . . .	12
	VII-H2. Red MOBILNETV2 . . . . .	13
	VII-H3. Comparación entre MobileNetV1 y MobileNetV2 . . . . .	13
	VII-I. Selección de hardware . . . . .	13
	VII-I1. Banda transportadora . . . . .	14
	VII-I2. Camara OV5647-62 FOV . . . . .	15
	VII-I3. Grove - Vision AI Module V2 . . . . .	16
	VII-I4. Xiao ESP32S3 . . . . .	17
	VII-I5. Servomotor Tower Pro MG996R Standard . . . . .	18
	VII-I6. Módulos Led Luz Blanca 5050 . . . . .	19
	VII-I7. Sistema de alimentación . . . . .	19
	VII-J. Selección de software . . . . .	20
	VII-J1. Edge impulse . . . . .	21
	VII-J2. SenseCraft AI . . . . .	22
	VII-J3. Arduino IDE . . . . .	23
	VII-K. Selección de Materiales Eléctricos . . . . .	24
	VII-L. Selección de Materiales Mecánicos . . . . .	27
<b>VIII.</b>	<b>MARCO METODOLÓGICO</b>	29
	VIII-A. Fase de Análisis . . . . .	29
	VIII-B. Diseño . . . . .	29
	VIII-B1. Diseño Mecánico . . . . .	29
	VIII-B2. Diseño Electrónico . . . . .	31
	VIII-B3. Control . . . . .	32
	VIII-B4. Software . . . . .	33
	VIII-C. Simulación . . . . .	36

VIII-D.	Proceso post-entrenamiento . . . . .	36
VIII-D1.	Optimización y Compresión del Modelo . . . . .	36
VIII-D2.	Conversión a Formato TensorFlow Lite . . . . .	37
VIII-D3.	Implementación en el Hardware . . . . .	37
VIII-D4.	Ejecución de Inferencia en Tiempo Real . . . . .	38
VIII-E.	Prototipo . . . . .	38
VIII-F.	Validación . . . . .	39
<b>IX.</b>	<b>RESULTADOS</b>	<b>41</b>
<b>X.</b>	<b>CRONOGRAMA</b>	<b>45</b>
<b>XI.</b>	<b>PRESUPUESTO</b>	<b>46</b>
<b>XII.</b>	<b>CONCLUSIONES</b>	<b>47</b>
<b>XIII.</b>	<b>RECOMENDACIONES</b>	<b>48</b>
<b>Anexo A:</b>	<b>Programación</b>	<b>53</b>
<b>Anexo B:</b>	<b>Prototipo</b>	<b>54</b>
<b>Anexo C:</b>	<b>Armado</b>	<b>56</b>

## ÍNDICE DE FIGURAS

1.	Industria Bananera.[15]	6
2.	Proceso de clasificación manual [21].	7
3.	Proceso de clasificación manual [21].	8
4.	Impresión 3D [25].	9
5.	Aprendizaje automático [32].	11
6.	CNN [34].	12
7.	Banda transportadora [41].	14
8.	Cámara FOV [45].	15
9.	Grove - Vision AI Module V2 [48].	16
10.	Xiao ESP32S3 [50].	17
11.	Servomotor Tower Pro MG996R Standard[52].	18
12.	Módulos Led [54].	19
13.	Fuente AC-DC [56].	20
14.	Fuente de alimentación 12v [58].	20
15.	Edge impulse [60].	21
16.	SenseCraft [63].	22
17.	Arduino IDE [66].	23
18.	Cajas de conexiones [69].	24
19.	Riel DIN [71].	25
20.	Toma corriente [73].	25
21.	Conductor eléctrico [75].	26
22.	Perfil de aluminio [77].	27
23.	Soporte de esquina [77].	28
24.	Tuerca T [77].	28
25.	Diseño del case para el modulo de visión artificial [80].	29
26.	Esquema de conexiones entre los equipos [80].	31
27.	Esquema de conexiones entre los equipos [80].	33
28.	Elaboración del Dataset [80].	33
29.	Elaboración del Dataset [80].	34
30.	Elaboración del Dataset [80].	35
31.	Elaboración del Dataset [80].	36
32.	Elaboración del Dataset [80].	39
33.	Métricas del entrenamiento [80].	41
34.	Tiempo por inferencia [80].	42
35.	Ajuste de hiperparametros [80].	43
36.	Comparación entre procesos de clasificación [80].	44
37.	Programación en ARDUINO [80].	53
38.	Programación en ARDUINO [80].	53
39.	Programación en ARDUINO [80].	54
40.	Prototipo en solidworks [80].	55
41.	Prototipo en playwood [80].	55
42.	prototipo de base [80].	56
43.	Programación en ARDUINO [80].	57
44.	Armado de estructura para soportes [80].	58
45.	Nivelación de estructura [80].	59
46.	Nivelación de estructura [80].	60
47.	Creación de dataset [80].	61

## ÍNDICE DE TABLAS

I.	Cronograma	45
----	------------	----

### III. INTRODUCCIÓN

La modernización de los procesos industriales ha llevado a la automatización de tareas que anteriormente dependían de la intervención humana. En sectores productivos donde la clasificación de productos es un factor clave para la calidad y eficiencia, la implementación de nuevas tecnologías ha permitido mejorar la precisión y reducir los tiempos de procesamiento. Sin embargo, la adopción de estas soluciones sigue enfrentando desafíos técnicos y económicos que requieren estudios detallados para su validación y optimización.

En este contexto, la combinación de sistemas inteligentes con dispositivos mecánicos ha demostrado ser una estrategia efectiva para optimizar tareas repetitivas y minimizar errores asociados a la evaluación visual tradicional. Mediante la incorporación de herramientas avanzadas de análisis, es posible estandarizar procesos y garantizar que los productos cumplan con los requisitos de calidad exigidos en el mercado.

La presente investigación se enfoca en el desarrollo e implementación de un sistema automatizado capaz de evaluar y clasificar elementos de forma clara y precisa. Se han utilizado técnicas avanzadas de procesamiento para identificar características específicas y facilitar la toma de decisiones en tiempo real. La integración de estos métodos permite mejorar la eficiencia operativa y asegurar una mayor uniformidad en la selección de productos.

El impacto de este estudio se extiende más allá de su aplicación específica, ya que la optimización de procesos mediante el uso de nuevas tecnologías contribuye a la competitividad del sector productivo. La reducción de pérdidas, el incremento en la velocidad de procesamiento y la estandarización de criterios son algunos de los beneficios asociados a la implementación de este tipo de soluciones.

Para evaluar el rendimiento del sistema, se han diseñado pruebas experimentales que permiten analizar su precisión y eficacia en condiciones operativas reales. Los resultados obtenidos servirán como base para futuras mejoras y adaptaciones, posibilitando su implementación en diferentes contextos productivos donde la automatización pueda representar una ventaja competitiva.

En conclusión, la integración de herramientas tecnológicas en los procesos de clasificación representa una oportunidad para transformar la manera en que se realizan ciertas tareas. Con este trabajo, se busca demostrar la viabilidad y el impacto positivo de la automatización en la optimización de procesos, estableciendo un marco de referencia para su aplicación en diferentes entornos industriales.

#### IV. PROBLEMA

La producción de banano en Ecuador es una de las bases fundamentales de la economía nacional. Sin embargo, enfrenta el desafío crucial de mejorar sus procesos de clasificación para satisfacer las demandas de un mercado globalizado y cada vez más competitivo [1]. Los métodos tradicionales, basados en la inspección visual humana, son propensos a errores y limitan la capacidad de respuesta eficiente del sector. En este contexto, la implementación de un sistema de visión artificial se presenta como una oportunidad única para transformar la clasificación en esta industria. No obstante, su desarrollo y puesta en marcha exitosa representan varios desafíos técnicos y económicos.

Uno de los principales obstáculos es el alto costo de implementación. La adopción de sistemas de visión artificial requiere una inversión considerable en tecnología y en recursos humanos, ya que implica la adquisición de hardware y software especializados [2]. Además, integrar estos sistemas en los procesos productivos existentes puede requerir modificaciones en la infraestructura y ajustes en los flujos de trabajo, lo que genera costos adicionales que pueden ser significativos.

Otro reto importante radica en la disponibilidad y calidad de los datos de entrenamiento necesarios. La creación de bases de datos con imágenes de bananos anotadas de manera precisa y representativa es un proceso complejo, costoso y laborioso [3]. La falta de datos de alta calidad limita la capacidad de entrenar modelos de visión artificial que generalicen correctamente en diferentes condiciones y para diversas variedades de banano. Además, factores como la variabilidad en las condiciones de captura, incluyendo la iluminación, el fondo y la orientación del fruto, introducen ruido en los datos, dificultando la extracción de características relevantes para lograr una clasificación precisa.

La cantidad y calidad de los datos de entrenamiento son factores esenciales para el éxito de los modelos basados en aprendizaje profundo [4]. En el caso de la clasificación de bananos, es fundamental recolectar imágenes de alta resolución que reflejen la diversidad de representaciones visuales, estados de madurez, defectos y condiciones de iluminación. Estas imágenes deben ser anotadas manualmente, un proceso que requiere mucho tiempo, pero que es determinante para alcanzar la precisión del modelo en la clasificación de frutas.

En conclusión, la adopción de sistemas de visión artificial en la producción de banano en Ecuador ofrece un gran potencial para mejorar la eficiencia y precisión de los procesos de clasificación. Sin embargo, lograr una implementación exitosa depende de la superación de importantes retos, como el alto costo de inversión y la necesidad de datos de calidad [5]. Superar estos desafíos permitirá al sector no solo adaptarse a las exigencias del mercado internacional, sino también asegurar una posición competitiva a largo plazo en el ámbito global.

## V. JUSTIFICACIÓN

La producción de banano en Ecuador requiere mejorar sus procesos de clasificación para responder a las crecientes exigencias de un mercado internacional altamente competitivo. En este sentido, desarrollar e implementar un sistema automatizado de clasificación basado en visión artificial, adaptado a las características específicas de esta producción, representa una oportunidad significativa para elevar la precisión, rapidez y objetividad en la evaluación de los frutos [6]. Esta mejora en la gestión de la calidad no solo reducirá el tiempo de clasificación, sino que también incrementará la satisfacción del cliente.

Uno de los principales desafíos en la implementación de este sistema es la creación de un conjunto de datos de alta calidad, con anotaciones detalladas y representativas de diversas condiciones [7]. Este proceso es complejo y costoso, lo que puede limitar la capacidad de los modelos para generalizar en distintas situaciones. Herramientas como Anaconda y EdgeImpulse, sin embargo, pueden facilitar la construcción de bases de datos robustas, ayudando a reducir la variabilidad en factores como la iluminación, el fondo y la orientación del fruto, y mejorando así la detección de características esenciales para una clasificación precisa[8].

Para abordar la escasez de datos, el aprendizaje por transferencia es una estrategia prometedora. Esta técnica consiste en preentrenar una red neuronal en una base de datos amplia y general, como ImageNet, y luego ajustar sus últimas capas para la tarea específica de clasificación de bananos [9]. Este enfoque permite aprovechar el conocimiento adquirido en tareas previas, acelerando el entrenamiento del modelo y reduciendo considerablemente la necesidad de datos anotados.

Las aplicaciones de la visión artificial en la industria del banano van más allá de la clasificación. Por ejemplo, esta tecnología también puede emplearse para detectar enfermedades y plagas en las plantaciones, facilitando intervenciones tempranas y minimizando pérdidas económicas[10]. Además, mediante el análisis de imágenes aéreas de alta resolución, es posible estimar el rendimiento de las plantaciones y mejorar la gestión agrícola. La visión artificial contribuye igualmente al control de calidad durante la postcosecha, permitiendo la detección de signos de deterioro en los frutos para asegurar el cumplimiento de los estándares de mercado.

Otro aspecto crítico en el desarrollo del sistema de clasificación es la selección de la arquitectura de red neuronal. Modelos como VGG, ResNet y MobileNet han mostrado eficacia en tareas de clasificación de imágenes, pero la elección óptima dependerá del tamaño de la base de datos, la complejidad de las características a extraer y los recursos computacionales disponibles. Modelos profundos como ResNet ofrecen mayor precisión, aunque demandan una mayor capacidad de cómputo, mientras que arquitecturas ligeras como MobileNet son más adecuadas para dispositivos con recursos limitados [11]. La decisión final debe equilibrar precisión y eficiencia computacional.

A pesar de los desafíos, la visión artificial tiene el potencial de transformar la clasificación de bananos, proporcionando rapidez y una calidad elevada en este proceso. Un sistema ideal debería contar con cámaras de alta resolución para capturar los detalles sutiles del fruto, iluminación controlada para minimizar sombras y asegurar imágenes de calidad, así como una calibración precisa para garantizar la exactitud en las mediciones [12]. Adicionalmente, el sistema debería ser capaz de procesar imágenes en tiempo real, ser robusto frente a variaciones ambientales y adaptable a distintas variedades de banano.

La investigación en visión artificial avanza rápidamente, y nuevas tecnologías surgen continuamente. Áreas como el aprendizaje por refuerzo profundo, la visión por computadora en 3D y la inteligencia artificial explicable representan tendencias prometedoras que podrían impactar de forma positiva al sector. La integración de visión artificial con otras tecnologías, como la robótica y el Internet de las Cosas (IoT), también contribuirá a la automatización y mejora de los procesos productivos[13].

En conclusión, la implementación de sistemas de visión artificial en la producción de banano representa una oportunidad estratégica para mejorar la competitividad y sostenibilidad del sector [14]. No obstante, es fundamental

enfrentar los desafíos técnicos y económicos que esta tecnología conlleva, así como asegurar su integración eficiente con los sistemas productivos existentes.

## VI. OBJETIVOS

### VI-A. *Objetivo general*

Desarrollar un sistema automatizado mediante visión artificial y un mecanismo de clasificación para la identificación de bananos maduros en una banda transportadora.

### VI-B. *Objetivos específicos*

1. Analizar el estado del arte sobre los sistemas de visión por computadora para la detección de bananos maduros, mediante la revisión sistemática de documentos científicos, con el fin de establecer las bases conceptuales y metodológicas para el desarrollo de la investigación.
2. Entrenar una red neuronal convolucional con un conjunto de datos de prueba para la detección y clasificación de bananos maduros circulando por una banda transportadora.
3. Evaluar el desempeño del sistema, empleando bananos en diferentes estados de maduración, con la finalidad de medir la eficiencia del proceso.

## VII. FUNDAMENTOS TEÓRICOS

### VII-A. La industria bananera en Ecuador



Figura 1. Industria Bananera.[15]

La adopción de tecnologías emergentes está transformando la industria bananera en Ecuador, un país que se destaca como uno de los principales exportadores de banano a nivel mundial. En 2022, las exportaciones de banano generaron aproximadamente USD 2.662 millones para el país [16]. Este liderazgo en el mercado global ha impulsado la implementación de soluciones innovadoras que mejoran la gestión de los cultivos, optimizan los procesos de postcosecha y elevan la calidad del producto destinado a la exportación.

Entre las tecnologías emergentes que están revolucionando el sector se encuentran los sistemas de visión artificial y las herramientas de agricultura de precisión. Estas innovaciones permiten una monitorización detallada de los cultivos, facilitando la detección temprana de plagas y enfermedades, y optimizando el uso de insumos agrícolas. Por ejemplo, el uso de drones para la fumigación y monitoreo de plantaciones ha reducido costos y mejorado la rentabilidad de la producción bananera en Ecuador [17].

Además, la biotecnología ha desempeñado un papel crucial en el desarrollo de prácticas agrícolas más sostenibles. Investigaciones recientes han demostrado que la aplicación de técnicas biotecnológicas, como el uso de microorganismos beneficiosos, estimula el crecimiento de raíces y mejora la productividad de las plantas de banano [18]. Estas prácticas contribuyen a la sostenibilidad del cultivo y a la reducción del impacto ambiental.

La producción de banano orgánico también ha ganado relevancia en Ecuador. En 2023, las exportaciones de banano orgánico a la Unión Europea alcanzaron los USD 227,8 millones, representando el 51,3% del total de exportaciones de este rubro [19]. Este crecimiento refleja una tendencia hacia prácticas agrícolas más limpias y una mayor demanda de productos orgánicos en los mercados internacionales.

Sin embargo, a pesar de estos avances, persisten desafíos en la adopción de tecnologías en el sector bananero ecuatoriano. Un análisis descriptivo reveló que más del 50% de las bananeras nunca actualizan su infraestructura tecnológica, y el promedio de empleados por unidad es bajo, lo que limita la capacidad de innovación y adaptación a nuevas tecnologías [20].

En este contexto, es esencial explorar alternativas tecnológicas avanzadas, como sistemas basados en visión artificial y aprendizaje automático, que puedan superar las barreras económicas y técnicas actuales. Estas herramientas deben ofrecer soluciones más precisas, adaptables y accesibles para promover la sostenibilidad y competitividad de la industria bananera, consolidando a Ecuador como líder en el comercio global de esta fruta.

## VII-B. Desafíos de la automatización



Figura 2. Proceso de clasificación manual [21].

La visión artificial se presenta como una solución revolucionaria para la industria bananera en Ecuador, un sector fundamental para la economía nacional [22]. No obstante, su implementación enfrenta desafíos considerables, como el elevado costo de las tecnologías avanzadas y la necesidad de contar con grandes volúmenes de datos de alta calidad para entrenar modelos de inteligencia artificial. Este proceso implica capturar miles de imágenes de bananos en diferentes estados de maduración, bajo diversas condiciones de iluminación y desde múltiples ángulos, lo cual resulta laborioso y costoso. Además, se requiere una meticulosa anotación de las imágenes para que el sistema pueda aprender a clasificar con precisión.

A pesar de estas dificultades, los beneficios que la visión artificial puede ofrecer son significativos y transformadores. Permite una clasificación más precisa y eficiente de las frutas, reduciendo errores humanos inherentes a los métodos tradicionales de inspección visual. Asimismo, la automatización minimiza el desperdicio al evitar que frutas en buen estado sean descartadas por error, garantizando que los productos cumplan con los más altos estándares de calidad. Esto mejora la competitividad del sector y contribuye a la sostenibilidad, un aspecto crucial en un mercado global cada vez más exigente.

En la actualidad, la mayoría de los procesos de clasificación aún se realizan manualmente, como se ilustra en la figura 47, lo que pone de relieve la necesidad de automatizar tareas repetitivas y propensas a errores. La implementación de tecnologías avanzadas no solo incrementará la eficiencia, sino que también permitirá a las empresas bananeras adaptarse al modelo de la Industria 4.0. Este modelo se caracteriza por la integración de sistemas inteligentes, la digitalización de procesos y el uso de datos para la toma de decisiones en tiempo real, posicionando al sector para enfrentar los desafíos del mercado global.

### VII-C. Proceso de clasificación manual



Figura 3. Proceso de clasificación manual [21].

La clasificación manual de banano ha sido el método predominante en la industria durante décadas debido a la experiencia y pericia de los trabajadores, quienes evalúan visualmente factores como tamaño, color, estado de madurez y defectos [23]. Aunque este enfoque permite identificar detalles complejos gracias a la capacidad humana, presenta importantes limitaciones. Entre ellas destacan la subjetividad inherente al juicio humano, que puede variar entre individuos, y la disminución de precisión causada por la fatiga o desgaste físico durante la jornada laboral como se puede visualizar en la figura . Esto genera inconsistencias en los resultados y afecta la calidad general del proceso. Además, la clasificación manual es un método lento y laborioso, lo que dificulta el procesamiento eficiente de grandes volúmenes de fruta para satisfacer la creciente demanda global.

En contraste, los sistemas de clasificación automática, basados en visión artificial e inteligencia artificial, ofrecen una solución moderna y eficiente [24]. Equipados con cámaras de alta resolución y algoritmos avanzados, estos sistemas analizan múltiples características de las frutas en tiempo real, eliminando las variaciones propias de la evaluación humana y proporcionando resultados objetivos y consistentes. Además, los sistemas automáticos pueden identificar defectos externos, como manchas o golpes, e internos, como indicios de enfermedades, con mayor precisión que la inspección visual tradicional. Esto los convierte en una herramienta estratégica para mejorar la calidad del proceso y garantizar productos de alta calidad.

La implementación de sistemas automáticos no solo incrementa la productividad al procesar grandes volúmenes de fruta a alta velocidad, sino que también reduce significativamente los costos operativos. Al ser programables, estos sistemas pueden adaptarse a diferentes estándares de calidad, clasificando los bananos en múltiples categorías según las necesidades del mercado o de los clientes. Esto optimiza la gestión del inventario y facilita la logística, mejorando la eficiencia en la distribución y garantizando que los productos cumplan con los requisitos de los consumidores finales.

La automatización del proceso no solo mejora la calidad y consistencia de los productos, sino que también reduce el desperdicio y facilita la gestión eficiente del inventario y la logística. Esto permite cumplir con los requisitos de los consumidores finales mientras se optimizan los recursos disponibles. Así, la clasificación automática se posiciona como un avance estratégico hacia la modernización del sector bananero, promoviendo su competitividad global en un mercado cada vez más exigente y tecnológico.

#### VII-D. *Manufactura adictiva*

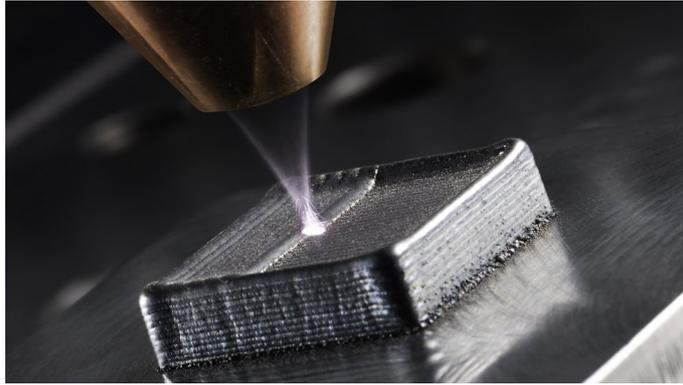


Figura 4. Impresión 3D [25].

La manufactura aditiva, conocida como impresión 3D, es una tecnología innovadora que permite fabricar objetos capa por capa a partir de un modelo digital tridimensional.[26]. A diferencia de la manufactura sustractiva, este proceso optimiza el uso de materiales y reduce el desperdicio, lo que lo hace eficiente y versátil en diversas industrias.

El proceso de impresión 3D inicia con el diseño digital de la pieza, que es segmentado en capas mediante software especializado. Luego, se utilizan distintas tecnologías de fabricación, como la fusión de filamento fundido (FFF), la estereolitografía (SLA) y la sinterización selectiva por láser (SLS), permitiendo la producción de piezas con plásticos, metales, resinas y otros compuestos avanzados.[27]

Entre sus principales ventajas destaca la capacidad de fabricar geometrías complejas y personalizadas, lo que ha impulsado su aplicación en sectores como la medicina, la automoción y la aeroespacial. En el ámbito médico, por ejemplo, facilita la producción de prótesis y dispositivos adaptados a cada paciente, mientras que en la industria automotriz y aeroespacial permite fabricar componentes más ligeros y resistentes.

Desde una perspectiva ambiental, la manufactura aditiva reduce el desperdicio de materiales y fomenta el uso de recursos reciclados, promoviendo prácticas más sostenibles. No obstante, persisten desafíos relacionados con la velocidad de fabricación [28], la resistencia mecánica de las piezas y la estandarización de procesos, aspectos que continúan en constante investigación.

En términos de avances tecnológicos, se han desarrollado materiales con propiedades mejoradas y técnicas que aumentan la eficiencia y calidad de impresión. A medida que esta tecnología evoluciona, se amplían sus aplicaciones en la producción en serie, representando una alternativa viable a los métodos de manufactura tradicionales.

En conclusión, la manufactura aditiva enfocada en la impresión 3D se posiciona como una herramienta clave en la transformación industrial. Su flexibilidad, eficiencia y menor impacto ambiental la convierten en una tecnología prometedora que seguirá revolucionando la forma en que se diseñan y fabrican productos en el futuro.

#### VII-E. *Ventajas de la visión artificial*

La visión artificial ha revolucionado la industria agrícola, transformando procesos que tradicionalmente dependían de la experiencia humana en sistemas altamente automatizados y precisos [29]. En el caso de la clasificación de bananos, esta tecnología ha demostrado ser un aliado indispensable. Al equipar las líneas de producción con sistemas de visión computarizada, es posible analizar de manera rápida y precisa grandes volúmenes de frutas, identificando

características clave como el grado de madurez, el tamaño, la forma, la presencia de defectos y el color. Estos sistemas no solo superan las limitaciones de la inspección visual humana, sino que también son capaces de detectar variaciones sutiles que a menudo pasan desapercibidas para el ojo humano. Esto se traduce en una clasificación más precisa, objetiva y consistente, que cumple con los estándares de calidad más exigentes en mercados nacionales e internacionales.

Una de las principales ventajas de la visión artificial es la mejora en la velocidad de los procesos de clasificación [30]. Los sistemas de visión computarizada están diseñados para operar a altas velocidades, procesando cientos de bananos por minuto con una precisión que sería imposible de alcanzar mediante métodos manuales. Esta capacidad de procesamiento masivo permite a las empresas reducir drásticamente los tiempos de clasificación y aumentar su capacidad productiva. Al automatizar estos procesos, también se logra una significativa reducción de los costos laborales, dado que se minimiza la necesidad de intervención humana directa en tareas repetitivas. Además, al eliminar el margen de error humano, estos sistemas aseguran una mayor consistencia en los resultados, mejorando la confiabilidad del proceso de clasificación.

La eficiencia lograda con la visión artificial tiene un impacto directo en la competitividad de las empresas productoras y exportadoras de banano. Una mayor velocidad y precisión en la clasificación se traduce en una reducción del tiempo de procesamiento, lo que permite satisfacer la demanda del mercado de manera más ágil [31]. Además, esta tecnología facilita la optimización de recursos y contribuye a una gestión más eficiente de las líneas de producción, lo que, en última instancia, aumenta la rentabilidad del negocio.

Adicionalmente, la visión artificial permite identificar y separar con precisión las frutas que presentan defectos visibles, como manchas, deformidades o daños causados durante la cosecha y el transporte. Esto ayuda a reducir significativamente las pérdidas económicas asociadas con la comercialización de productos de baja calidad o no aptos para el consumo.

Además, esta tecnología también abre la puerta a nuevas posibilidades, como la recopilación de datos en tiempo real sobre la calidad y características de los bananos procesados. Esto puede ser aprovechado para mejorar la toma de decisiones estratégicas, optimizar la logística y desarrollar nuevos productos que se adapten mejor a las preferencias del mercado.



## VII-G. Redes neuronales convolucionales

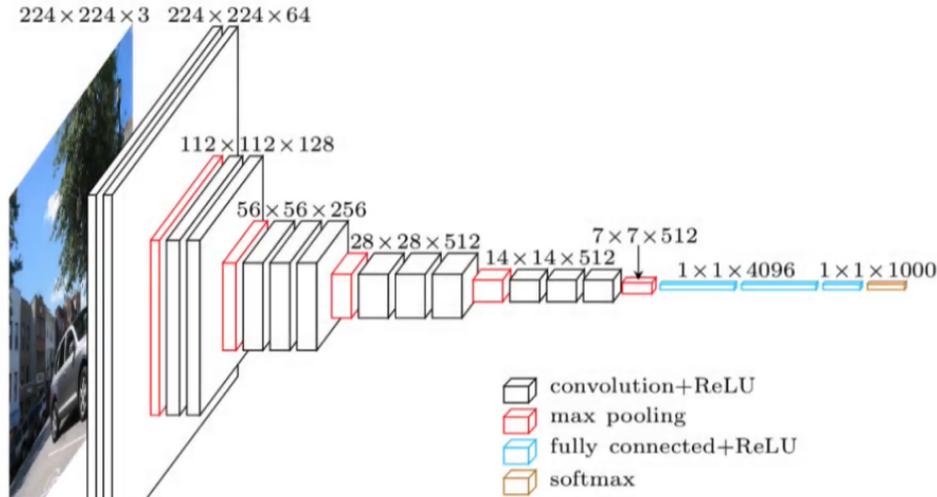


Figura 6. CNN [34].

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son un tipo de arquitectura de aprendizaje profundo diseñada específicamente para el procesamiento de imágenes y datos visuales. Estas redes están inspiradas en el funcionamiento del córtex visual humano, lo que les permite identificar patrones y características en imágenes con alta precisión. Su estructura se compone de múltiples capas, incluyendo capas convolucionales, de pooling y completamente conectadas, que trabajan en conjunto para extraer y analizar atributos visuales como bordes, texturas, formas y colores [35].

En la industria, las CNN han demostrado su eficacia en tareas como reconocimiento de objetos, detección de defectos y clasificación de productos agrícolas, ofreciendo una solución robusta para la automatización de procesos. En la clasificación de bananos, estas redes permiten identificar con precisión el estado de maduración y detectar imperfecciones, mejorando la eficiencia y reduciendo la subjetividad inherente a la inspección visual humana. Su capacidad de adaptación a distintas condiciones de iluminación y orientación hace que sean ideales para entornos industriales dinámicos.

Además, la integración de las CNN en sistemas de visión artificial agiliza el procesamiento en tiempo real, permitiendo la implementación de soluciones escalables y sostenibles. La combinación de estas redes con tecnologías como Internet de las Cosas (IoT) y computación en la nube abre nuevas posibilidades para la trazabilidad y control de calidad en la producción agrícola. Su aplicación en la industria bananera no solo optimiza la clasificación del producto, sino que también contribuye a la reducción de costos operativos y mejora la competitividad en el mercado global [36].

## VII-H. Comparación entre modelos de redes convolucionales

**VII-H1. Red MOBILNETV1:** MobileNetV1 corresponde a una arquitectura de redes neuronales convolucionales optimizada para dispositivos con recursos computacionales limitados, como teléfonos móviles y sistemas embebidos. Desarrollada por Google, se basa en convoluciones separables en profundidad (depthwise separable convolutions), lo que reduce significativamente el número de parámetros y operaciones sin comprometer demasiado la precisión [37]. Su diseño ligero permite ejecutar modelos de visión artificial en tiempo real con menor consumo de energía, facilitando aplicaciones como detección de objetos, reconocimiento facial y clasificación de imágenes en dispositivos

IoT. MobileNetV1 introduce un mecanismo de ajuste llamado factor de ancho (width multiplier) y factor de resolución (resolution multiplier), que permite balancear la velocidad y precisión del modelo según las necesidades del sistema. En el ámbito industrial, su implementación resulta clave para la optimización de procesos basados en visión artificial, como la clasificación automatizada de productos agrícolas. Su eficiencia y versatilidad la convierten en una opción ideal para sistemas de inteligencia artificial con restricciones de hardware.

*VII-H2. Red MOBILNETV2:* El diseño de MobileNetV2 responde a la necesidad de optimizar redes neuronales convolucionales optimizada para dispositivos con recursos computacionales limitados, mejorando el rendimiento de su predecesora MobileNetV1 [38]. Introduce el concepto de bloques de inversión de residual (inverted residual blocks) y utiliza convoluciones separables en profundidad, lo que reduce significativamente la cantidad de parámetros y cálculos, manteniendo una alta precisión en la clasificación de imágenes. Además, incorpora una capa de proyección lineal que minimiza la pérdida de información durante el procesamiento de características. Su eficiencia permite aplicaciones en visión artificial en tiempo real, como detección de objetos y reconocimiento de patrones en dispositivos móviles y sistemas embebidos. En el ámbito industrial, MobileNetV2 es ideal para la clasificación automatizada de productos, como la detección de defectos en frutas o el control de calidad en líneas de producción. Su capacidad de operar en hardware de bajo consumo energético la hace una alternativa viable para soluciones de inteligencia artificial en entornos con restricciones computacionales.

*VII-H3. Comparación entre MobileNetV1 y MobileNetV2:* Las redes neuronales MobileNetV1 y MobileNetV2 son arquitecturas optimizadas para dispositivos con recursos computacionales limitados, especialmente diseñadas para aplicaciones en visión artificial y clasificación de imágenes en tiempo real [39].

MobileNetV1 introduce una arquitectura ligera que reduce la carga computacional en comparación con modelos tradicionales, pero presenta limitaciones en la capacidad de extracción de características profundas, lo que puede afectar la precisión en tareas complejas. En cambio, MobileNetV2 mejora significativamente la eficiencia y precisión al introducir los bloques de inversión residual (inverted residual blocks), que optimizan la transmisión de información en la red y minimizan la pérdida de datos durante las transformaciones no lineales. También el MobileNetV2 incorpora una capa de proyección lineal, lo que permite conservar información útil en las capas más profundas sin distorsionar las características extraídas.

Dado que MobileNetV2 ofrece una mejor precisión con menor costo computacional, resulta la opción más adecuada para la clasificación de bananos en nuestra tesis. Su capacidad de equilibrar eficiencia y rendimiento permite su implementación en dispositivos embebidos o sistemas con recursos limitados, garantizando un procesamiento en tiempo real sin comprometer la exactitud del modelo.

### *VII-I. Selección de hardware*

Elegir el hardware correcto para clasificar bananos es como armar un rompecabezas tecnológico, cada pieza, desde la cámara hasta la computadora, tiene que encajar perfectamente para que todo funcione bien. Imagina que la cámara es el ojo que ve los bananos y la computadora es el cerebro que decide si están maduros o no. Si la cámara no tiene suficiente resolución, no podrá ver bien las manchas o los golpes en la piel del banano, y si la computadora no es lo suficientemente potente, se tardará mucho en tomar una decisión. En resumen, un buen hardware es fundamental para que la clasificación de bananos sea rápida y precisa.

VII-II. *Banda transportadora*: Las bandas transportadoras son sistemas mecánicos creados para trasladar materiales de un punto a otro de forma continua, su diseño y materiales varían significativamente según la aplicación específica, cada tipo de banda presenta características, ventajas y desventajas únicas [40]. A continuación, se describen los tipos más comunes y sus componentes principales.

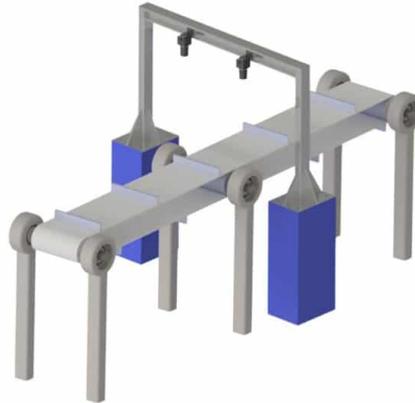


Figura 7. Banda transportadora [41].

Entre los tipos de bandas transportadoras, se destacan las de rodillos, modulares, de correa y de cadena. Las bandas de rodillos consisten en una serie de rodillos que giran sobre un eje para soportar la carga y moverla a lo largo de la banda [42]. Este tipo es ideal para cargas pesadas y grandes, ya que es versátil y económico, sin embargo, pueden no ser adecuados para productos frágiles y requieren mayor mantenimiento que otros tipos de bandas.

Las bandas modulares, por otro lado, están formadas por módulos individuales que se conectan entre sí para crear una superficie continua [40]. Estas bandas son flexibles, fáciles de limpiar y desinfectar, y se adaptan a distintos productos. No obstante, su capacidad de carga es menor en comparación con las bandas de rodillos, y suelen ser más costosas.

Otra alternativa son las bandas de correa, que emplean una correa continua de material flexible, como goma o PVC, para transportar la carga [43]. Este tipo de banda es ideal para productos delicados debido a su suavidad y la variedad de materiales y perfiles disponibles. Sin embargo, pueden estirarse o desgastarse con el tiempo, por lo que se requiere estarla tensionando de forma regular.

Por último, están las bandas de cadena, que emplean cadenas metálicas para soportar y mover la carga, estas son adecuadas para ambientes hostiles y altas temperaturas debido a su gran capacidad de carga y resistencia, sin embargo, suelen ser ruidosas y pueden dañar productos frágiles, además de requerir más mantenimiento [43].

Una banda transportadora cuenta con varios componentes comunes, como el bastidor, que sostiene toda la estructura; el motor, que proporciona la energía necesaria; y el reductor, que ajusta la velocidad de la banda. Los rodillos soportan la banda y la carga, mientras que los tensores mantienen la tensión adecuada. Las guías dirigen el movimiento de la banda, y los componentes de accionamiento, como engranajes, poleas y cadenas, permiten el funcionamiento del sistema.

Las ventajas de las bandas transportadoras son variadas. En primer lugar, permiten la automatización de procesos, reduciendo la necesidad de mano de obra, también aumentan la continuidad y la productividad al reducir los tiempos de ciclo y ofrecen flexibilidad al adaptarse a diferentes productos y procesos [40]. En cuanto a la seguridad, pueden equiparse con sistemas que protegen a los trabajadores. Además, muchas son fáciles de limpiar y desinfectar, lo

que es especialmente útil en industrias como la alimentaria.

No obstante, las bandas transportadoras también presentan desventajas. El costo inicial puede ser elevado, y requieren un mantenimiento regular para asegurar un rendimiento óptimo. Además, ocupan un espacio físico considerable y su capacidad de carga está limitada por el tipo de banda y su diseño. La elección del tipo adecuado de banda transportadora depende de factores como el tipo de producto a transportar (su tamaño, peso, forma y fragilidad), la capacidad de producción, el ambiente de trabajo (temperatura, humedad y agentes corrosivos) y el presupuesto disponible para inversión y mantenimiento.

*VII-I2. Cámara OV5647-62 FOV:* La OV5647-62 FOV es un módulo de cámara que integra el sensor de imagen OV5647 y una lente ojo de pez, capaz de capturar imágenes con un campo de visión de 62 grados [44]. Este ángulo es más amplio en comparación con cámaras convencionales permitiendo que el módulo abarque una porción mayor de la escena, lo cual resulta útil para aplicaciones que requieren una visualización extendida.



Figura 8. Cámara FOV [45].

Entre las características principales de este módulo de cámara destaca el sensor OV5647, reconocido por ofrecer una alta calidad de imagen y la capacidad de capturar imágenes detalladas con una resolución de 2592 x 1944 píxeles. Este sensor se combina con una lente ojo de pez, que otorga al módulo su amplio campo de visión, adecuado para diversas aplicaciones, como vigilancia, robótica y visión por computadora. Además, la OV5647-62 FOV es compatible con plataformas como Raspberry Pi 3B+ y 4B, lo que facilita su integración en proyectos de diferentes tipos [44].

Gracias a su campo de visión y la capacidad de capturar imágenes en alta resolución, esta cámara es ideal para varias aplicaciones. En vigilancia, su capacidad para cubrir áreas extensas la convierte en una opción efectiva para monitorear grandes espacios y detectar movimientos de manera eficiente. En robótica, se utiliza para proporcionar a los robots una vista panorámica de su entorno, mejorando su capacidad de navegación y toma de decisiones en tiempo real. En visión por computadora, su precisión y compatibilidad con plataformas como Raspberry Pi hacen de este módulo una herramienta útil en proyectos de investigación y desarrollo, mientras que en cámaras de acción su diseño compacto y resistente permite capturar imágenes en entornos desafiantes.

La OV5647-62 FOV ofrece ventajas importantes, como su amplio campo de visión, que permite capturar más detalles de una escena en una sola toma, y su alta resolución, que contribuye a la obtención de imágenes nítidas y detalladas. Además, su fácil integración con diferentes plataformas hace que sea sencilla de usar en una amplia variedad de proyectos.

No obstante, también presenta algunas desventajas. La lente ojo de pez, si bien aporta un campo de visión amplio, introduce una distorsión en las imágenes[46], lo que puede ser un inconveniente en aplicaciones que requieran imágenes rectilíneas, ya que podría ser necesaria la corrección posterior de las imágenes. Asimismo, la cámara tiene ciertas limitaciones en el enfoque, ya que la profundidad de campo tiende a ser menor en los bordes de la imagen, lo que puede afectar la claridad en zonas periféricas.

En conjunto, la OV5647-62 FOV es un módulo de cámara versátil, que se adapta bien a aplicaciones que demandan un ángulo de visión amplio y una alta resolución, con un diseño que facilita su integración en plataformas de hardware ampliamente usadas.

*VII-13. Grove - Vision AI Module V2:* El Grove Vision AI V2 es un módulo avanzado de visión por computadora diseñado para realizar procesamiento de inteligencia artificial directamente en el dispositivo, sin depender de servidores externos. Este módulo utiliza el microcontrolador Himax WiseEye2 HX6538, que cuenta con un núcleo dual Arm Cortex-M55 y una red neuronal Arm Ethos-U55 integrada. Esta arquitectura permite la ejecución local de modelos de aprendizaje automático, garantizando rapidez y autonomía en el procesamiento de datos visuales [47].



Figura 9. Grove - Vision AI Module V2 [48].

Una de las características más destacadas del Grove Vision AI V2 es su capacidad para ejecutar modelos de aprendizaje profundo, como MobileNet, EfficientNet y YOLO, de forma eficiente y precisa, además, es compatible con los frameworks TensorFlow y PyTorch, dos de las plataformas de aprendizaje automático más utilizadas, lo que facilita su integración en diversos proyectos. Su diseño se ha optimizado para el bajo consumo de energía, haciéndolo ideal para aplicaciones portátiles y proyectos que operan con baterías. También ofrece flexibilidad para conectar sensores y actuadores adicionales, permitiendo una personalización y expansión funcional para aplicaciones más complejas.

Este módulo se utiliza en una amplia gama de aplicaciones que incluyen el reconocimiento y clasificación de objetos en tiempo real, la detección de personas para sistemas de seguridad, el seguimiento de objetos en movimiento, y la gestión de gestos como método de control en dispositivos interactivos. Estas funcionalidades lo

hacen una herramienta valiosa tanto para proyectos de automatización como para sistemas de monitoreo o asistencia.

Lo que diferencia al Grove Vision AI V2 de otros módulos de visión artificial es su capacidad de integrar procesamiento potente y sensores de imagen en un solo dispositivo, con una eficiencia optimizada que permite la ejecución en tiempo real de modelos de IA. Además, la plataforma SenseCraft AI simplifica la implementación de modelos, lo que reduce la necesidad de conocimientos avanzados en programación y facilita su uso para desarrolladores con distintos niveles de experiencia.

El funcionamiento del módulo sigue un flujo claro y optimizado: primero, el sensor de imagen captura la imagen, que luego se somete a un preprocesamiento para mejorar la calidad y extraer características clave. Posteriormente, el modelo de aprendizaje automático realiza la inferencia sobre la imagen procesada, generando una predicción que puede mostrarse en pantalla, enviarse a otro dispositivo o activar un actuador según los requerimientos del proyecto.

En resumen, el Grove Vision AI V2 es una herramienta versátil y robusta para la creación de proyectos de visión por computadora, ofreciendo una combinación ideal de facilidad de uso, eficiencia y potencia de procesamiento. Esta integración de funcionalidades lo convierte en una opción atractiva tanto para quienes están empezando en el campo de la inteligencia artificial como para usuarios avanzados que buscan soluciones prácticas y efectivas para sus proyectos.

*VII-14. Xiao ESP32S3:* El Xiao ESP32-S3 es una popular placa de desarrollo, ampliamente utilizada por entusiastas de la electrónica y desarrolladores de proyectos de IoT (Internet de las Cosas). Este dispositivo compacto y económico destaca por su potencia y eficiencia, lo que lo hace ideal para aplicaciones que requieren un tamaño reducido y bajo costo [49].



Figura 10. Xiao ESP32S3 [50].

Basada en el chip ESP32-S3 de Espressif Systems, esta placa ofrece un alto rendimiento junto a un consumo de energía eficiente, además de contar con conectividad Wi-Fi de 2.4 GHz y Bluetooth 5.0. Su pequeño tamaño y asequible precio la convierten en una opción preferida para proyectos con restricciones de espacio y recursos limitados. Entre sus características principales, el Xiao ESP32-S3 integra un microcontrolador de doble núcleo, junto con múltiples interfaces como GPIO, UART, I2C, SPI y ADC, permitiendo la conexión de una gran variedad de sensores y actuadores. También es compatible con el entorno de desarrollo Arduino IDE, facilitando su uso para aquellos que ya están familiarizados con este software [49].



electrónica y la robótica lo utilizan para crear una gran variedad de sistemas personalizados.

Las ventajas del Tower Pro MG996R son numerosas: es fácil de controlar a través de microcontroladores como Arduino o Raspberry Pi, y ofrece un alto nivel de precisión en el ajuste del ángulo de rotación. Su robustez, gracias a los engranajes metálicos, asegura una larga vida útil, y su versatilidad permite su implementación en un amplio rango de aplicaciones. Sin embargo, presenta algunas limitaciones; el ángulo máximo de rotación es de 180 grados, lo que puede resultar insuficiente para ciertos proyectos que requieren un movimiento más amplio. Además, su velocidad de rotación es relativamente limitada, y su consumo de corriente puede ser alto, especialmente bajo cargas elevadas [51].

*VII-16. Módulos Led Luz Blanca 5050:* Los módulos LED de luz blanca 5050 son una tecnología de iluminación altamente eficiente, caracterizada por su bajo consumo energético y alta intensidad lumínica. Su diseño compacto y versátil permite su aplicación en diversos sectores, desde la iluminación arquitectónica hasta sistemas de visión artificial en la industria. Gracias a su estabilidad y uniformidad en la emisión de luz, estos módulos son ideales para mejorar la precisión en procesos de inspección y clasificación automatizada. En entornos industriales, su uso optimiza la captura de imágenes en algoritmos de procesamiento, reduciendo interferencias causadas por sombras o cambios en la iluminación ambiental [53]. Además, su larga vida útil y resistencia los convierten en una alternativa rentable para aplicaciones de alto rendimiento. En la industria alimentaria, su implementación en líneas de producción permite una evaluación más precisa de la calidad del producto, asegurando estándares óptimos para el mercado. Estos módulos representan una solución tecnológica clave para la modernización de procesos industriales.



Figura 12. Módulos Led [54].

*VII-17. Sistema de alimentación:* Las fuentes de alimentación AC-DC son dispositivos esenciales en sistemas electrónicos, ya que convierten la corriente alterna de la red eléctrica (110V-220V) en una salida de corriente continua estable, como 5V o 12V, dependiendo de los requerimientos del sistema. Estas fuentes son ampliamente utilizadas en aplicaciones industriales, automatización y sistemas embebidos, proporcionando un voltaje regulado que garantiza el funcionamiento seguro y eficiente de circuitos electrónicos sensibles [55].



Figura 13. Fuente AC-DC [56].

Existen diferentes tipos de fuentes de alimentación, entre ellas las lineales y conmutadas. Las fuentes lineales ofrecen una regulación de voltaje precisa, pero con menor eficiencia energética, mientras que las fuentes conmutadas optimizan el consumo eléctrico al reducir las pérdidas de energía [57]. Su diseño compacto y alta eficiencia permiten minimizar fluctuaciones en el suministro eléctrico, lo que es fundamental en sistemas de visión artificial, donde alimentan cámaras, sensores y procesadores sin interferencias que afecten la calidad de captura de imágenes.



Figura 14. Fuente de alimentación 12v [58].

Además, estas fuentes incorporan protecciones contra sobrecarga, cortocircuito y sobrecalentamiento, asegurando la estabilidad y fiabilidad del sistema. Su implementación en entornos industriales permite una alimentación continua y confiable para equipos de automatización, optimizando la eficiencia energética y la seguridad en los procesos productivos. Gracias a su versatilidad, las fuentes AC-DC de 5V y 12V son componentes clave en la modernización de sistemas electrónicos, facilitando su integración en infraestructuras industriales y de investigación avanzada.

#### VII-J. Selección de software

La selección adecuada de un software en los procesos de clasificación de banano es un factor crucial para optimizar la eficiencia y la calidad en la producción. Un software especializado permite automatizar tareas, mejorar la precisión en la clasificación, generar datos precisos para el análisis y control de calidad, y facilitar la toma de decisiones basadas en información real. Al integrar sistemas de visión artificial, aprendizaje automático y bases de datos robustas, estos programas permiten clasificar los bananos según diversos criterios como madurez, tamaño,

color y defectos superficiales, asegurando que solo los frutos de mayor calidad lleguen al mercado. Además, estos sistemas pueden integrarse con otros software de gestión de la producción, permitiendo un control integral de todo el proceso, desde la cosecha hasta la distribución.

*VII-11. Edge impulse:* La plataforma Edge Impulse ofrece una solución avanzada para el desarrollo de modelos de aprendizaje automático específicamente diseñados para dispositivos edge [59]. Esto permite procesar y analizar datos directamente en el dispositivo, sin necesidad de depender de la nube, lo cual resulta útil en aplicaciones que requieren respuestas rápidas y funcionan en entornos con conectividad limitada. Al simplificar el flujo de trabajo en la inteligencia artificial para el edge, Edge Impulse se convierte en una herramienta ideal para aquellos que buscan crear sistemas inteligentes de forma eficiente.



Figura 15. Edge impulse [60].

Una de las cualidades más destacadas de Edge Impulse es su capacidad para gestionar el proceso de adquisición y etiquetado de datos. Esto permite a los desarrolladores reunir información desde una variedad de sensores y dispositivos, organizándola intuitivamente. La plataforma también facilita la ingeniería de características, extrayendo de forma automática las características más relevantes de los datos sin procesar, lo que agiliza el análisis. A continuación, Edge Impulse permite el entrenamiento de modelos de aprendizaje automático, empleando diversas técnicas, incluidas redes neuronales, para ajustarse a las necesidades específicas del proyecto.

La implementación de modelos en dispositivos edge es otra función esencial de la plataforma, ya que permite desplegar modelos de aprendizaje automático directamente en microcontroladores y computadoras de placa única, lo cual reduce la dependencia de infraestructura externa. Estos modelos pueden ejecutar inferencias en tiempo real, procesando datos en el momento para tomar decisiones instantáneas, lo cual es especialmente útil en sistemas que necesitan respuesta inmediata. Aunque Edge Impulse se centra en el procesamiento local, también se integra con plataformas en la nube, facilitando almacenamiento adicional, análisis de datos y entrenamiento de modelos cuando se requiere.

Las aplicaciones de Edge Impulse abarcan múltiples sectores. En el ámbito del hogar inteligente, la plataforma es útil para desarrollar asistentes de voz, electrodomésticos inteligentes y sistemas de seguridad. En la industria, resulta valiosa para implementar soluciones de mantenimiento predictivo, control de calidad y detección de anomalías. Además, en el área de dispositivos wearables, Edge Impulse facilita el monitoreo de salud, el seguimiento de la actividad física y el reconocimiento de gestos.

Entre sus principales ventajas, Edge Impulse ofrece una interfaz amigable que simplifica el aprendizaje y uso de la plataforma, haciendo que el desarrollo sea accesible incluso para usuarios sin experiencia avanzada [61]. La plataforma acelera el proceso de desarrollo mediante flujos de trabajo optimizados y herramientas automatizadas, lo cual reduce significativamente el tiempo necesario para crear prototipos y pasar a la implementación. Además, Edge Impulse es escalable, lo que permite adaptarse tanto a proyectos pequeños como a despliegues de gran escala. La compatibilidad con una amplia gama de hardware, desde microcontroladores hasta aceleradores de IA, añade

flexibilidad y asegura que el sistema pueda integrarse en diferentes entornos tecnológicos.

La implementación de modelos de aprendizaje automático en dispositivos edge con Edge Impulse implica un proceso técnico que abarca la optimización, conversión y despliegue del modelo en el hardware específico del dispositivo. Este proceso permite ejecutar inferencias en tiempo real en dispositivos de bajo consumo y recursos limitados, como microcontroladores y computadoras de placa única, sin depender de la infraestructura en la nube.

*VII-J2. SenseCraft AI:* SenseCraft AI ofrece un conjunto de herramientas avanzadas que facilitan el desarrollo de aplicaciones de inteligencia artificial (IA) específicamente diseñadas para dispositivos de Internet de las Cosas (IoT). Su principal función es permitir que estos dispositivos IoT se transformen en agentes inteligentes, capaces de percibir su entorno, tomar decisiones y ejecutar acciones basadas en datos del mundo real [62].



Figura 16. SenseCraft [63].

Una de las características más destacadas de SenseCraft AI es su capacidad para integrar modelos de aprendizaje automático en dispositivos IoT, lo cual los dota de inteligencia y autonomía. Esto resulta especialmente útil en contextos donde los dispositivos deben operar en tiempo real y tomar decisiones de forma independiente, sin depender de una conexión constante con la nube. Además, la plataforma ha sido diseñada para ser intuitiva, facilitando el desarrollo de aplicaciones de IA incluso para aquellos que no tienen una formación técnica avanzada en el campo de la inteligencia artificial [64]. SenseCraft AI ofrece una interfaz amigable y herramientas preconfiguradas que permiten a los usuarios construir aplicaciones sin tener que diseñar modelos de IA desde cero.

Para proyectos con necesidades específicas, SenseCraft AI también permite la personalización de modelos. La plataforma cuenta con un conjunto de modelos preentrenados para tareas comunes, como detección de objetos, reconocimiento facial y clasificación de imágenes, que pueden ser adaptados para usos específicos. Esta flexibilidad es particularmente útil para aplicaciones personalizadas, ya que facilita el entrenamiento de modelos propios para responder a desafíos específicos.

En cuanto a su funcionalidad en el mundo IoT, SenseCraft AI ofrece una compatibilidad amplia con diferentes tipos de hardware. Es posible integrarla en dispositivos que utilizan desde microcontroladores hasta cámaras y sensores avanzados, lo que permite a los desarrolladores elegir el equipo adecuado según el tipo de aplicación que quieran implementar.

Las aplicaciones de SenseCraft AI abarcan diversos sectores. En hogares inteligentes, se pueden desarrollar sistemas capaces de reconocer personas, ajustar la iluminación y la temperatura, y responder a comandos de voz. En la industria, los sensores inteligentes pueden monitorear procesos, detectar anomalías y contribuir a optimizar

la producción. En la agricultura, se pueden usar dispositivos equipados con IA para monitorear cultivos, detectar plagas o enfermedades a partir de imágenes y mejorar la gestión de los recursos agrícolas. La robótica también se beneficia al utilizar SenseCraft AI para integrar visión artificial y toma de decisiones, permitiendo a los robots ejecutar tareas complejas de manera autónoma.

El funcionamiento de SenseCraft AI combina tanto hardware como software para ofrecer una solución completa y eficiente. En el aspecto de hardware, dispositivos como el SenseCAP Watcher incluyen sensores, cámaras y un procesador optimizado para ejecutar modelos de IA en el propio dispositivo. En cuanto al software, la plataforma proporciona herramientas de entrenamiento y despliegue de modelos, que simplifican la implementación de sistemas inteligentes.

*VII-J3. Arduino IDE:* El Arduino Integrated Development Environment (IDE) es un entorno de desarrollo diseñado para programar y cargar código en microcontroladores Arduino. Su interfaz intuitiva permite a los desarrolladores escribir, compilar y transferir programas con facilidad, facilitando el acceso a herramientas de programación tanto para principiantes como para expertos en automatización y robótica.[65]



Figura 17. Arduino IDE [66].

El entorno de desarrollo del Arduino IDE utiliza el lenguaje de programación C/C++ con una sintaxis simplificada para facilitar su uso. Además, dispone de una extensa biblioteca de funciones predefinidas que permiten la interacción con sensores, actuadores y módulos de comunicación, reduciendo la complejidad del desarrollo y fomentando la innovación.

Una de sus características más destacadas es su compatibilidad con múltiples sistemas operativos, incluyendo Windows, macOS y Linux. Su naturaleza de código abierto permite a la comunidad global de desarrolladores modificar y expandir sus funcionalidades, promoviendo la colaboración en la mejora del entorno de desarrollo.[67]

El Arduino IDE incluye un gestor de bibliotecas y una función de autocompletado que optimizan el proceso de codificación. La posibilidad de agregar bibliotecas externas agiliza la implementación de nuevas funcionalidades sin necesidad de programarlas desde cero, facilitando la creación de sistemas más complejos.

Adicionalmente, el monitor serie del Arduino IDE permite la depuración en tiempo real mediante la comunicación con la placa. Esta herramienta es crucial para el análisis de datos de sensores y la verificación del correcto funcionamiento del código, asegurando la confiabilidad del sistema.[68]

En conclusión, el Arduino IDE es una herramienta esencial para el desarrollo de proyectos basados en microcontroladores. Su accesibilidad, flexibilidad y compatibilidad con diversos dispositivos lo convierten en una opción ideal para la educación, la investigación y la innovación en electrónica y automatización.

### VII-K. Selección de Materiales Eléctricos

En sistemas eléctricos y de automatización, la selección de materiales adecuados es crucial para garantizar la seguridad, eficiencia y durabilidad de las instalaciones. Entre los elementos esenciales se encuentran las cajas de conexiones para intemperie, los rieles DIN, los tomacorrientes simples y los conductores eléctricos, cada uno con características específicas que permiten su integración en distintos entornos industriales y comerciales.

Las cajas de conexiones para intemperie están diseñadas para proteger conexiones y dispositivos eléctricos de factores ambientales adversos como humedad, polvo, radiación UV y variaciones de temperatura. Fabricadas en policarbonato, ABS o aluminio, garantizan un aislamiento seguro, evitando cortocircuitos y fallos eléctricos en entornos exteriores o industriales. Además, su diseño facilita el montaje de dispositivos electrónicos y la organización del cableado, reduciendo el riesgo de daños por exposición directa.



Figura 18. Cajas de conexiones [69].

El riel DIN es un soporte metálico estandarizado ampliamente utilizado para la instalación de dispositivos eléctricos y electrónicos en tableros de control y cuadros de distribución. Su diseño modular permite la fijación segura de fuentes de alimentación, relés, interruptores, PLCs y protectores eléctricos, optimizando el orden y el mantenimiento de las instalaciones [70]. Fabricado en acero galvanizado o aluminio, ofrece alta resistencia mecánica y protección contra la corrosión, asegurando durabilidad en entornos exigentes. Su uso optimiza el espacio dentro de los paneles eléctricos, reduciendo la complejidad en el cableado y mejorando la accesibilidad para futuras modificaciones.



Figura 19. Riel DIN [71].

El tomacorriente simple es un dispositivo fundamental en instalaciones eléctricas, ya que proporciona una conexión segura y estable a la red de suministro eléctrico. Su diseño compacto y estandarizado permite su instalación en muros, paneles o cajas de distribución, garantizando compatibilidad con enchufes convencionales [72]. Fabricado con materiales aislantes y contactos de alta conductividad, minimiza el riesgo de cortocircuitos y sobrecalentamiento, siendo esencial en entornos industriales para la conexión de herramientas, sistemas de automatización y dispositivos de medición.



Figura 20. Toma corriente [73].

Por último, el conductor eléctrico de calibre 16 es ampliamente utilizado en la transmisión de corriente para aplicaciones de baja y media potencia. Con un diámetro de 1.29 mm, permite manejar cargas eléctricas moderadas

con baja resistencia, reduciendo la pérdida de energía y garantizando una conducción estable [74]. Fabricado en cobre de alta pureza, ofrece excelente conductividad y minimiza el calentamiento. Su aislamiento en PVC o materiales dieléctricos avanzados protege contra variaciones de temperatura, humedad y agentes químicos, aumentando su durabilidad y seguridad. Su flexibilidad facilita la instalación en espacios reducidos sin comprometer su rendimiento, y su correcta selección evita caídas de voltaje, mejorando la eficiencia del sistema.



Figura 21. Conductor eléctrico [75].

La selección e integración adecuada de materiales en sistemas eléctricos y de automatización desempeña un papel crucial en el rendimiento y la fiabilidad de los equipos industriales. La elección de conductores, aislamientos y dispositivos de protección influye directamente en la eficiencia del flujo de energía, minimizando pérdidas y mejorando la estabilidad operativa. Además, la compatibilidad entre los distintos componentes eléctricos y electrónicos asegura una transmisión de señales sin interferencias, lo que es esencial en entornos donde la automatización requiere precisión y respuesta inmediata. Un sistema bien diseñado no solo extiende la vida útil de los equipos, sino que también reduce costos de mantenimiento y tiempo de inactividad, contribuyendo así a una mayor productividad y rentabilidad en las operaciones industriales.

Por otro lado, la correcta integración de estos materiales también es determinante para la seguridad operativa y el cumplimiento de normativas internacionales. Un sistema eléctrico optimizado minimiza el riesgo de fallas como sobrecargas, cortocircuitos o recalentamientos, protegiendo tanto a los operarios como a la infraestructura de la planta. La eficiencia energética es otro factor clave en la industria moderna, donde el uso de materiales con baja resistencia eléctrica y alta conductividad permite un mejor aprovechamiento de la energía y una reducción en el consumo eléctrico. De esta manera, la implementación de tecnologías avanzadas y materiales innovadores no solo favorece un desempeño más confiable, sino que también contribuye a la sostenibilidad y la reducción de la huella de carbono en los procesos industriales.

## VII-L. Selección de Materiales Mecánicos

En la construcción de estructuras modulares y sistemas de automatización, la selección de materiales mecánicos adecuados es esencial para garantizar resistencia, estabilidad y facilidad de ensamblaje. Componentes como el perfil de aluminio tipo V 20×20, el soporte de esquina y la tuerca T rectangular M5 son ampliamente utilizados en aplicaciones industriales debido a su versatilidad y eficiencia en el montaje de estructuras robustas y funcionales.

El perfil de aluminio tipo V 20×20 es un elemento fundamental en estructuras modulares, caracterizado por su sección transversal cuadrada de 20 mm × 20 mm con ranuras en forma de “V” a lo largo de sus lados. Estas ranuras permiten la integración sencilla con otros elementos mediante fijaciones estándar, como tornillos, tuercas T y placas de unión. Fabricado generalmente con aleaciones de aluminio 6063-T5, ofrece una combinación óptima de ligereza, resistencia mecánica y resistencia a la corrosión [76] Su acabado anodizado mejora la durabilidad y proporciona un aspecto profesional, siendo ideal para marcos de máquinas, sistemas de transporte, robótica y automatización.



Figura 22. Perfil de aluminio [77].

El soporte de esquina, también conocido como escuadra, juega un papel fundamental en la estabilidad de ensamblajes modulares, proporcionando una conexión robusta y precisa entre perfiles estructurales. Gracias a su diseño en forma de “L.” triangular, con perforaciones estratégicamente ubicadas, facilita la fijación de los componentes mediante tornillos y tuercas, garantizando una unión resistente en ángulos de 90 grados [78]. Este elemento es ampliamente utilizado en sectores como la ingeniería mecánica, la industria manufacturera y la construcción, donde la rigidez estructural y la precisión en los ensamblajes son aspectos clave. Su aplicación se extiende desde la fabricación de marcos para maquinaria hasta la construcción de estaciones de trabajo modulares y sistemas de automatización, contribuyendo a la optimización del espacio y la eficiencia operativa.

Además de su versatilidad en diversas aplicaciones industriales, el soporte de esquina destaca por su durabilidad y facilidad de reutilización. Fabricado generalmente en aluminio o acero, ofrece una excelente resistencia mecánica sin comprometer la ligereza de la estructura, lo que resulta especialmente beneficioso en proyectos donde el peso es un factor determinante. Su capacidad para reforzar las conexiones y mantener la alineación de los perfiles permite crear estructuras desmontables o ajustables sin comprometer la estabilidad del ensamblaje. Esto lo convierte en una solución ideal para sistemas modulares que requieren modificaciones frecuentes, como exhibiciones comerciales, laboratorios de investigación y líneas de producción flexibles, donde la adaptabilidad es esencial para responder a

cambios en los procesos o configuraciones del espacio.



Figura 23. Soporte de esquina [77].

La tuerca T rectangular M5 es un elemento clave en los sistemas de ensamblaje de perfiles de aluminio, ya que permite una fijación firme y ajustable dentro de las ranuras del perfil [79]. Fabricada en acero inoxidable o galvanizado, su diseño optimizado y su rosca M5 garantizan una conexión segura y resistente. Su facilidad de instalación y reutilización la hacen ideal para aplicaciones industriales como la construcción de marcos, sistemas de automatización y muebles modulares, proporcionando flexibilidad en el diseño y montaje de estructuras.



Figura 24. Tuerca T [77].

En conjunto, estos materiales mecánicos permiten la construcción de estructuras robustas, modulares y fácilmente ensamblables, facilitando la integración de sistemas de automatización en diversos entornos industriales. Su correcta selección e implementación garantizan eficiencia, seguridad y durabilidad, contribuyendo a la optimización de procesos y a la mejora del rendimiento en aplicaciones industriales y de ingeniería.

## VIII. MARCO METODOLÓGICO

El proyecto sigue una estructura de trabajo organizada en cinco fases principales: análisis, diseño, simulación, prototipo y validación. Cada fase representa un conjunto de actividades y decisiones técnicas fundamentales para lograr un sistema confiable. A continuación, se describe el procedimiento de cada una de estas etapas.

### VIII-A. Fase de Análisis

La fase de análisis constituye el primer paso hacia la implementación del sistema, en la que se examinan los requisitos específicos del proyecto. En esta fase, se identifica la necesidad de un sistema capaz de clasificar bananos en función de su madurez, distinguiendo entre aquellos aptos para el proceso de comercialización y los que deben ser desviados a una sección de rechazo. Dado que el criterio principal para la clasificación es el color del banano, que se asocia con su estado de maduración, se opta por el uso de un sistema de visión artificial capaz de reconocer el color amarillo en tiempo real.

Para cumplir con estos objetivos, se selecciona el Grove Vision AI Module v2 como el dispositivo de procesamiento central del sistema. Este módulo es capaz de integrar procesamiento y sensores de imagen, ejecutando modelos de IA con eficiencia y en tiempo real. Adicionalmente, se opta por el microcontrolador Xiao ESP32-S3 para la gestión y control del sistema, debido a sus ventajas en conectividad y compatibilidad con el entorno de desarrollo Arduino IDE. La configuración incluye un mecanismo de desvío controlado por un servomotor Tower Pro MG996R encargado de accionar la compuerta que permite redirigir los bananos según su clasificación.

### VIII-B. Diseño

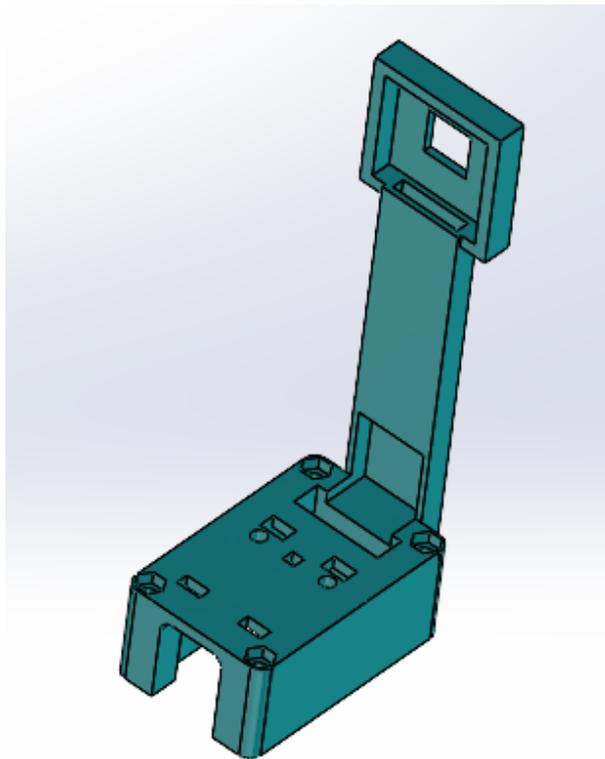


Figura 25. Diseño del case para el modulo de visión artificial [80].

*VIII-B1. Diseño Mecánico:* La selección de materiales adecuados es esencial para garantizar eficiencia y durabilidad en sistemas industriales. Para la base de la estructura que se instalará sobre la banda transportadora,

se han escogido perfiles de aluminio de 20 x 20 cm, los cuales ofrecen una combinación óptima de bajo peso, alta resistencia y costo reducido, asegurando una instalación práctica y estable. Estos perfiles destacan por su capacidad de soportar cargas sin comprometer la estabilidad estructural, a la vez que su bajo costo contribuye a la optimización del presupuesto. Además, su resistencia a la corrosión y su carácter reciclable los convierten en una solución rentable y sostenible a largo plazo, adecuada para el entorno industrial.

Con esta elección, se garantiza una base confiable y funcional que cumple con los requisitos del proyecto, permitiendo una integración eficiente con la banda transportadora y asegurando el correcto desempeño del sistema en su conjunto.

El control de las condiciones externas es esencial para garantizar la precisión de un sistema de clasificación automatizado basado en visión artificial. Factores como la iluminación inadecuada o la intervención humana pueden afectar el rendimiento del sistema, por lo que se requiere un entorno controlado para minimizar estas interferencias.

Para ello, se propone construir un cuarto oscuro empleando una estructura de aluminio cubierta con lámina galvanizada de 2 mm de espesor. Este diseño permite aislar eficazmente el sistema de la luz ambiental, asegurando un entorno óptimo para el funcionamiento de cámaras y sensores. Además, el cuarto oscuro reduce las posibilidades de errores derivados de la intervención de operadores.

Esta solución no solo mejora la calidad del procesamiento de imágenes y la precisión de la clasificación, sino que también asegura la estabilidad y fiabilidad del sistema en entornos industriales. De este modo, se optimizan las condiciones de operación, contribuyendo al éxito de la implementación de la visión artificial en la industria bananera.

Aunque la creación de un cuarto oscuro pueda parecer una limitación, su implementación ofrece beneficios cruciales para el control de la iluminación en un sistema de clasificación basado en visión artificial. Este diseño elimina la influencia de luces externas y permite regular la cantidad de luminosidad mediante la incorporación de luces LED, garantizando imágenes de alta calidad y consistencia para un procesamiento preciso.

El uso de luces LED dentro del cuarto oscuro no solo asegura una iluminación estable y adaptable a las necesidades del sistema, sino que también mejora la eficiencia energética. Esta solución optimiza las condiciones de operación, aumentando la fiabilidad y precisión del proceso de clasificación en entornos industriales.

La estructura que sostendrá el Groove AI v2 juega un papel fundamental en el sistema de clasificación. Gracias a la manufactura aditiva y el modelado 3D, es posible desarrollar un diseño personalizado que se adapte al perfil de aluminio, garantizando estabilidad e integración óptima dentro del sistema.

Ubicar el Groove AI v2 en el punto más alto de la estructura amplía su campo de visión, lo que permite a la cámara capturar una mayor cantidad de detalles en el área de clasificación. Esta posición estratégica optimiza la detección de características del producto, mejorando la precisión del proceso.

En conclusión, el uso de manufactura aditiva y modelado 3D no solo facilita la creación de una estructura adaptable, sino que también maximiza el rendimiento del Groove AI v2. Su ubicación elevada mejora la calidad del procesamiento de imágenes, asegurando una clasificación más eficiente y precisa.

VIII-B2. *Diseño Electrónico:* El diseño electrónico del sistema se fundamenta en la utilización de dos tipos de fuentes reductoras para garantizar una alimentación estable y eficiente. La primera fuente es de tipo transformador, la cual proporciona una salida de 12V DC, permitiendo la alimentación del sistema de iluminación dentro del cuarto oscuro. Esta configuración asegura que la iluminación sea constante y adecuada para la captura de imágenes en el entorno de trabajo. La segunda fuente reductora es de tipo conmutada y se encarga de suministrar la energía necesaria para el sistema de visión artificial, compuesto por el módulo Grove Vision AI, el Xiao ESP32-S3 y el servomotor. Esta elección de fuentes de alimentación permite una distribución eficiente de la energía, reduciendo el riesgo de fluctuaciones que puedan afectar el desempeño del sistema.

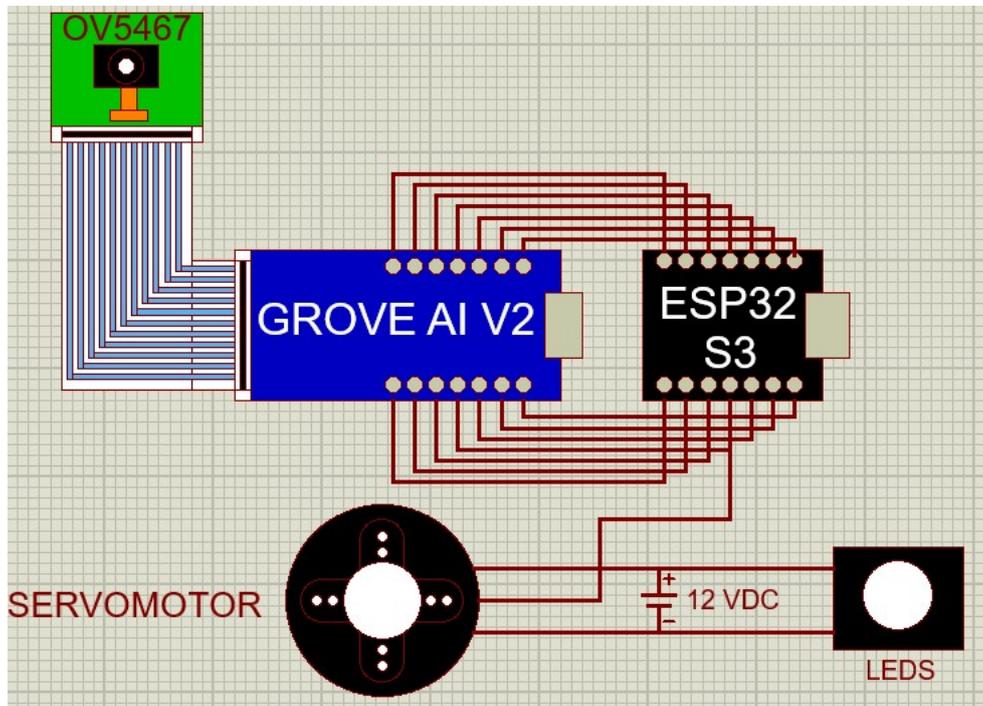


Figura 26. Esquema de conexiones entre los equipos [80].

La integración del módulo Grove Vision AI v2 con la cámara OV5467 se realiza a través de un cable flex, lo que posibilita una transmisión de datos rápida y libre de interferencias electromagnéticas. Esta conexión es crucial para garantizar un procesamiento de imágenes en tiempo real con alta precisión, ya que cualquier retraso en la transmisión de datos podría comprometer la efectividad del sistema. Además, el montaje del Xiao ESP32-S3 se lleva a cabo mediante pines macho, lo que minimiza el uso de cables adicionales y optimiza la comunicación entre los diferentes componentes electrónicos. Esta configuración no solo mejora la estabilidad del circuito, sino que también facilita su mantenimiento y posibles modificaciones futuras.

El control del servomotor se basa en la señal de salida generada por el Xiao ESP32-S3, la cual determina la acción a ejecutar sobre la banda transportadora. Dependiendo del resultado del procesamiento de imágenes realizado por el módulo de visión artificial, el servomotor puede desviar el banano de la banda o permitir su paso continuo. Este mecanismo de actuación es fundamental para la automatización del proceso, ya que garantiza una clasificación eficiente de los objetos en función de los criterios preestablecidos. La precisión en la activación del servomotor permite optimizar el rendimiento del sistema y asegurar que la toma de decisiones se realice de manera ágil y precisa.

En términos de eficiencia energética, la elección de una fuente conmutada para la alimentación del sistema de visión artificial permite un menor consumo eléctrico en comparación con otras alternativas. Además, esta fuente

garantiza un voltaje estable para el funcionamiento del Grove Vision AI, el ESP32-S3 y el servomotor, evitando problemas asociados a variaciones en la tensión de alimentación. Asimismo, el uso de una fuente transformadora para la iluminación en el cuarto oscuro garantiza que las condiciones lumínicas sean óptimas para la captura de imágenes, mejorando así la precisión del análisis visual realizado por el sistema.

En conclusión, el diseño electrónico del sistema ha sido estructurado con el propósito de garantizar una alimentación estable, una comunicación eficiente entre los componentes y un control preciso del servomotor. La combinación de fuentes reductoras adecuadas, junto con una integración optimizada del hardware, permite desarrollar un sistema de visión artificial robusto y eficiente. Esta implementación facilita la automatización del proceso de clasificación, asegurando que el sistema pueda operar de manera confiable en entornos industriales donde la precisión y rapidez son aspectos fundamentales.

*VIII-B3. Control:* El sistema de control se basa en la capacidad del microcontrolador Xiao ESP32-S3 para procesar en tiempo real la señal del Grove Vision AI Module v2. Este procesamiento permite tomar decisiones rápidas y precisas, asegurando que el mecanismo de clasificación opere de manera eficiente. La comunicación fluida entre los componentes garantiza que el servomotor ejecute correctamente las acciones de desvío, permitiendo una correcta separación de los objetos sin interrupciones.

Una vez interpretada la señal, el Xiao ESP32-S3 genera las instrucciones necesarias para activar el servomotor en el momento exacto. Esto permite un control preciso del mecanismo de clasificación, reduciendo errores y optimizando la eficiencia del proceso. La velocidad de respuesta del sistema es crucial para mantener un flujo de trabajo continuo y evitar retrasos en la separación de los objetos.

El servomotor juega un papel esencial en la ejecución del desvío, ya que su activación o inactivación determina el destino del objeto en la línea de clasificación. Gracias a su precisión en el movimiento, se logra una correcta selección basada en los criterios establecidos, asegurando que cada objeto sea redirigido de acuerdo con el resultado del procesamiento de imágenes.

El Xiao ESP32-S3, además de gestionar el control del servomotor, administra la comunicación con los demás componentes para garantizar una operación estable y eficiente. La sincronización entre la inferencia del modelo de visión artificial y la ejecución mecánica es fundamental para mantener la exactitud en el proceso de clasificación.

Otro aspecto relevante del sistema de control es la eficiencia energética del Xiao ESP32-S3, que ajusta el consumo de energía según la demanda operativa. Esta optimización reduce el desperdicio de energía y contribuye a la estabilidad del sistema, asegurando que el mecanismo de clasificación funcione de manera continua sin afectar el rendimiento de los componentes.

En conclusión, el sistema de control basado en el Xiao ESP32-S3 permite una automatización precisa del mecanismo de clasificación mediante el uso de un servomotor. Su capacidad de procesamiento en tiempo real y su integración eficiente con el modelo de visión artificial garantizan una operación confiable y efectiva. Este enfoque mejora la productividad y asegura un alto grado de precisión en la separación de los objetos dentro del proceso de clasificación automatizada.

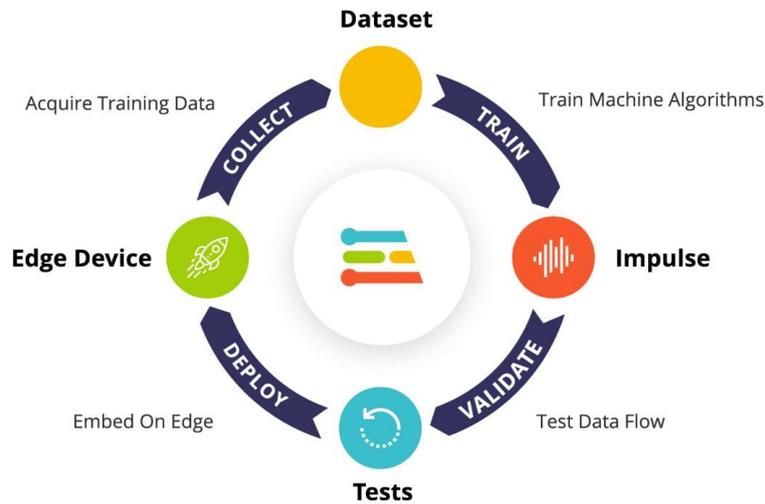


Figura 27. Esquema de conexiones entre los equipos [80].

*VIII-B4. Software:* El sistema de clasificación automatizada emplea Edge Impulse para entrenar y desplegar un modelo de aprendizaje automático en el Grove Vision AI Module v2. A través de esta plataforma, se recopilan y etiquetan imágenes de bananos en distintas etapas de maduración, lo que permite el desarrollo de un modelo capaz de identificar con precisión el color amarillo característico de los frutos maduros. Esta integración optimiza la detección y mejora la eficiencia en la automatización del proceso, reduciendo errores y aumentando la productividad en entornos industriales.

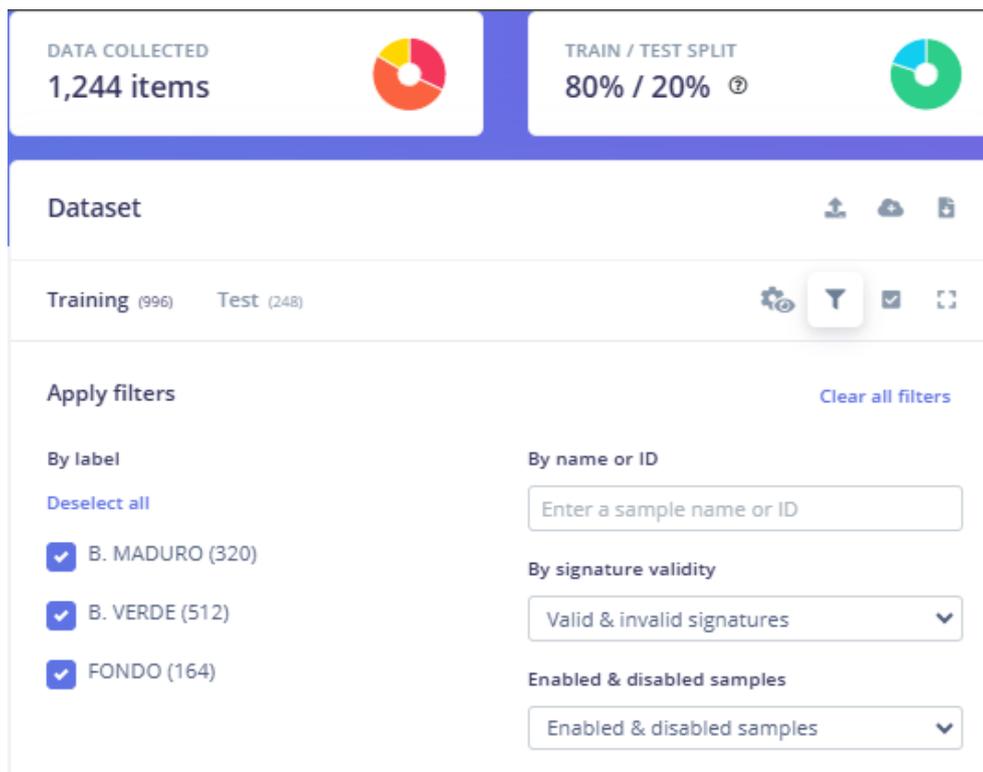


Figura 28. Elaboración del Dataset [80].

Para el entrenamiento, se utiliza la arquitectura MobileNetV2 debido a su eficiencia en dispositivos con recursos limitados. Se configura con 20 épocas, un dropout de 0.2 y una tasa de aprendizaje de 0.0001, logrando un equilibrio entre precisión y rendimiento. Posteriormente, el modelo se convierte a TensorFlow Lite, reduciendo su tamaño y optimizando su ejecución en hardware de baja capacidad. Esta conversión permite el procesamiento en tiempo real con un consumo energético mínimo, asegurando que el sistema funcione de manera estable y eficiente.

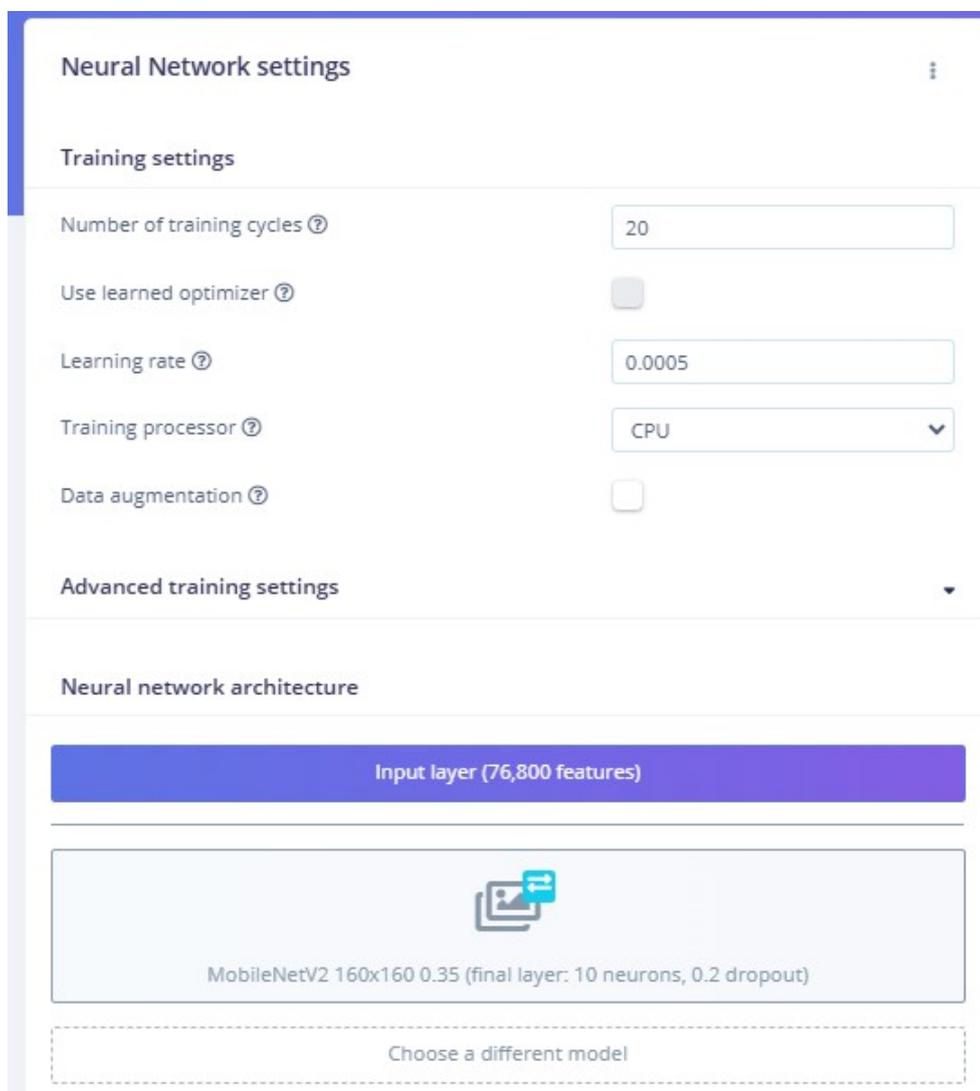


Figura 29. Elaboración del Dataset [80].

Durante la optimización, se implementa la técnica de cuantización, la cual reduce la latencia y mejora la eficiencia energética del modelo. Esta optimización es clave para entornos industriales donde la rapidez y confiabilidad son esenciales. Gracias a estas mejoras, el sistema puede realizar inferencias precisas y responder de manera inmediata, asegurando que la clasificación de los bananos ocurra sin interrupciones y con alta exactitud en el proceso de selección.

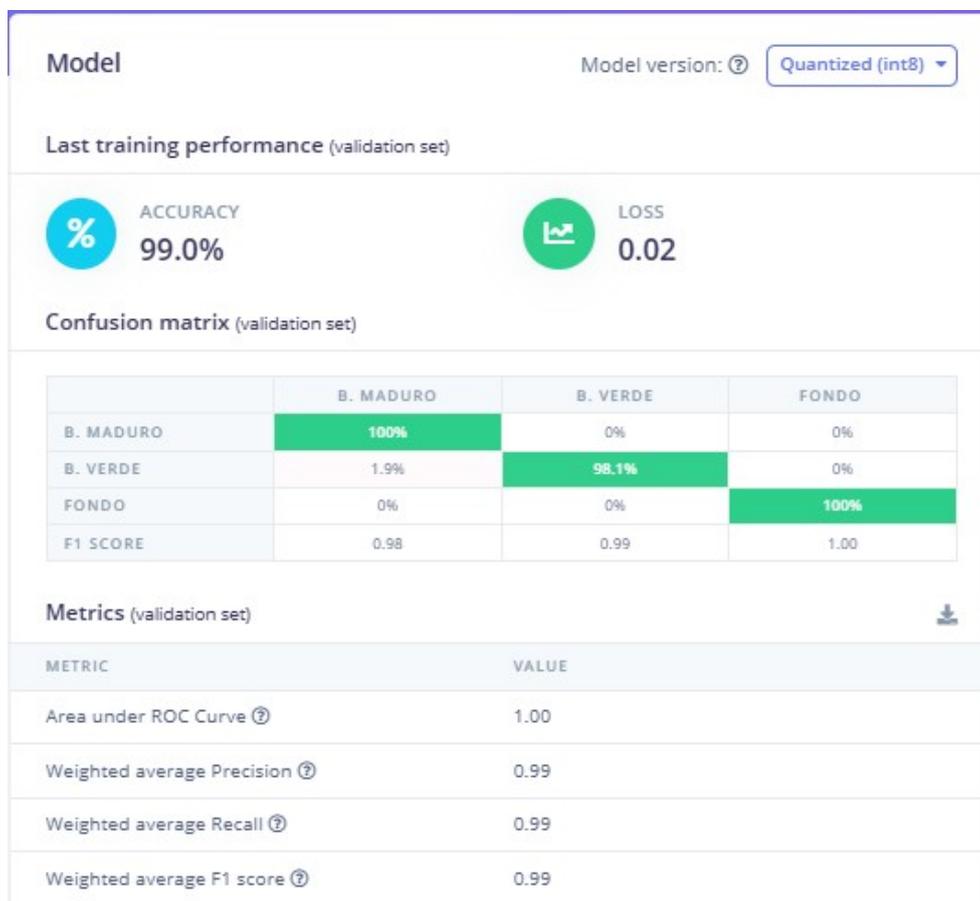


Figura 30. Elaboración del Dataset [80].

El modelo procesado se ejecuta de manera autónoma en el Grove Vision AI Module v2, eliminando la necesidad de conexión constante con servidores externos. Esto permite un procesamiento local más rápido y reduce la dependencia de infraestructuras complejas. Además, Edge Impulse facilita la actualización y optimización del modelo, permitiendo ajustes en función de cambios en las condiciones del entorno, como variaciones en la iluminación o diferencias en la apariencia de los frutos.

Para garantizar la estabilidad del sistema, se realizan pruebas en condiciones reales de operación, ajustando parámetros para optimizar su precisión. Se consideran factores como la calidad de las imágenes, la iluminación y la posición de la cámara, aplicando técnicas de preprocesamiento para mejorar la detección. Estas pruebas permiten perfeccionar el rendimiento del modelo y asegurar que la clasificación se lleve a cabo con la menor cantidad de errores posible.

En conclusión, la combinación de Edge Impulse, TensorFlow Lite y el Grove Vision AI Module v2 proporciona una solución eficiente y adaptable para la automatización de la clasificación de bananos. Su capacidad para realizar inferencias en tiempo real con bajo consumo energético y su facilidad de actualización lo convierten

en una herramienta versátil para diversas aplicaciones industriales. Gracias a su precisión y escalabilidad, este sistema representa un avance tecnológico en la optimización de procesos automatizados, mejorando la eficiencia y confiabilidad en la producción.

### VIII-C. Simulación



Figura 31. Elaboración del Dataset [80].

Durante la fase de simulación, se valida preliminarmente el modelo de visión artificial utilizando datos de prueba que simulan diversos estados de maduración del banano, así como diferentes condiciones de iluminación y ángulos de visión. Este proceso permite evaluar la precisión del modelo en la clasificación, asegurando que sea capaz de manejar las variaciones que podrían ocurrir en un entorno de producción real. La simulación identifica posibles errores y ayuda a ajustar los parámetros del modelo antes de su implementación en el prototipo físico.

El objetivo principal es garantizar que el modelo pueda clasificar con precisión los bananos maduros bajo diversas circunstancias. Se ajustan parámetros como la tasa de aprendizaje y el número de épocas para mejorar el rendimiento y minimizar fallos. La simulación también permite verificar la robustez del modelo ante variaciones, como cambios en la luz o deformaciones de los bananos, lo que asegura su efectividad en un entorno de producción real.

Al finalizar la simulación, se corrigen los errores detectados, optimizando el modelo para su implementación en el prototipo físico. Este proceso mejora la fiabilidad y eficiencia del sistema, asegurando que el modelo de visión artificial sea adecuado para la clasificación automatizada de bananos en condiciones reales de operación. De esta manera, se garantiza una transición fluida hacia la fase de implementación.

### VIII-D. Proceso post-entrenamiento

**VIII-D1. Optimización y Compresión del Modelo:** Una vez entrenado el modelo en Edge Impulse, se optimiza automáticamente para reducir su tamaño y demanda de cómputo. Este proceso es esencial para garantizar que el modelo funcione de manera eficiente en dispositivos con recursos limitados. La optimización incluye técnicas como

la cuantización, que reduce el tamaño de los pesos y parámetros del modelo, sin comprometer significativamente su precisión. La conversión de los valores de 32 bits a 8 bits asegura que el modelo ocupe menos espacio y sea más fácil de ejecutar en dispositivos pequeños.

La cuantización mejora la eficiencia en el uso de memoria, lo que permite que el modelo se ejecute con mayor rapidez y menor consumo de energía. Al reducir la complejidad del modelo, se logra mantener la latencia baja, lo que es crucial para aplicaciones que requieren respuestas en tiempo real, como la clasificación de los bananos. Esto asegura que el sistema sea ágil y eficiente, adaptándose a las limitaciones de los dispositivos edge sin afectar su rendimiento.

Gracias a la optimización y cuantización, el modelo final es más adecuado para ser desplegado en dispositivos con capacidad limitada, como el Grove Vision AI Module v2. Esta reducción en el tamaño y la complejidad del modelo no solo mejora su eficiencia, sino que también asegura una clasificación precisa y rápida, lo que es fundamental en la automatización de procesos industriales como la selección de bananos. De esta forma, el sistema optimizado ofrece una solución robusta para la clasificación en tiempo real.

*VIII-D2. Conversión a Formato TensorFlow Lite :* Una vez finalizado el entrenamiento, Edge Impulse transforma el modelo a un formato optimizado para dispositivos edge, empleando principalmente TensorFlow Lite. Esta versión compacta de TensorFlow está diseñada para entornos de bajo consumo, permitiendo una ejecución eficiente tanto en almacenamiento como en procesamiento. La conversión ajusta el modelo a las especificaciones del microcontrolador o procesador de destino, como el Grove Vision AI Module v2 , garantizando su operatividad en sistemas con capacidades limitadas.

Durante esta fase, Edge Impulse genera archivos binarios adaptados al hardware específico, optimizando el rendimiento y reduciendo el consumo de energía. En dispositivos con unidades especializadas, como DSPs o NPUs, el modelo se ajusta para explotar al máximo estos componentes, incrementando la velocidad y eficiencia en el procesamiento de datos. Esta optimización permite ejecutar algoritmos de inteligencia artificial de manera ágil y efectiva en plataformas con capacidades avanzadas.

La flexibilidad de Edge Impulse para adaptar modelos a diversas arquitecturas y aprovechar recursos especializados garantiza un desempeño óptimo en entornos edge. Esto posibilita la implementación de soluciones de IA con alta precisión y eficiencia energética, aspectos esenciales en aplicaciones industriales como la clasificación automatizada de productos. Gracias a esta optimización, los modelos pueden desplegarse en hardware con restricciones sin afectar su funcionalidad, facilitando su integración en distintos sectores tecnológicos.

*VIII-D3. Implementación en el Hardware:* Una vez optimizado, el modelo se implementa en el ESP32-S3 como parte de un firmware completo que incluye el código de inferencia, el sistema operativo y los controladores de hardware. En microcontroladores, esta integración es esencial para garantizar la compatibilidad y optimizar el uso de los recursos disponibles, permitiendo que el dispositivo ejecute predicciones de manera eficiente sin necesidad de servidores externos.

La ejecución del modelo en el ESP32-S3 se realiza en tiempo real, lo que minimiza la latencia y reduce la dependencia de la conectividad. Esto resulta crucial en aplicaciones como la automatización industrial, la monitorización de variables o el reconocimiento de patrones, donde una respuesta rápida es indispensable. Además, el uso de técnicas de optimización como la cuantización permite que el procesamiento se realice con un consumo energético reducido, optimizando el rendimiento del sistema.

Gracias a esta implementación, la inteligencia artificial en microcontroladores amplía sus posibilidades en la computación edge. La combinación de optimización de modelos, integración eficiente y ejecución local permite desarrollar dispositivos inteligentes con capacidad de procesar datos en tiempo real. Esto facilita su aplicación en

sectores como la domótica, la salud y la industria, impulsando soluciones autónomas y eficientes sin comprometer el rendimiento del hardware.

*VIII-D4. Ejecución de Inferencia en Tiempo Real:* Tras su implementación, el Grove AI v2 recibe datos en tiempo real desde la cámara OV5467, los cuales deben ser preprocesados para ajustarse al formato requerido por el modelo. Este procedimiento incluye normalización y transformación de escala, garantizando que la información se adapte correctamente antes de la inferencia. La optimización de estos datos es fundamental para maximizar la precisión del modelo y evitar distorsiones en los resultados, permitiendo un análisis más eficiente.

Una vez acondicionados los datos, el modelo ejecuta la inferencia para generar una predicción basada en el aprendizaje previo. La optimización del hardware del Grove AI v2 permite que este proceso ocurra con un bajo consumo de recursos y en el menor tiempo posible. Gracias a Edge Impulse, la inferencia se realiza con una latencia reducida, lo cual es crucial en aplicaciones que requieren respuestas instantáneas, como el reconocimiento de objetos y el procesamiento de imágenes en tiempo real.

La capacidad del dispositivo para operar sin depender de servidores externos lo convierte en una solución ideal para entornos donde la conectividad es limitada o la velocidad de respuesta es prioritaria. Esta independencia mejora la confiabilidad del sistema y minimiza los retrasos en la transmisión de datos. Su capacidad de procesamiento en el borde permite desarrollar soluciones autónomas con alta precisión y eficiencia operativa.

La implementación del sistema maestro-esclavo mediante el ESP32-S3 permite gestionar de manera eficiente la ejecución de inferencias y la coordinación de tareas en función de los resultados obtenidos. Este microcontrolador define los intervalos de tiempo en los que se realizan las predicciones y sincroniza la comunicación con los dispositivos esclavos. Su capacidad de procesamiento y conectividad garantiza una ejecución precisa, lo que es fundamental en sistemas donde la rapidez y la respuesta en tiempo real son prioritarias.

Además de regular la frecuencia de las inferencias, el ESP32-S3 determina las acciones a ejecutar según las predicciones del modelo, permitiendo una respuesta dinámica y adaptativa. La distribución de tareas entre distintos dispositivos optimiza el rendimiento, evitando la sobrecarga de un solo componente y asegurando un flujo de trabajo eficiente. Esta arquitectura es clave en aplicaciones que requieren procesamiento descentralizado, como la automatización industrial y la robótica, donde la coordinación entre múltiples unidades es esencial.

Gracias a este enfoque, se logra un control preciso sobre el proceso de inferencia, mejorando la interacción entre el hardware y el modelo de inteligencia artificial. La capacidad del ESP32-S3 para administrar múltiples dispositivos facilita la escalabilidad del sistema, permitiendo su expansión sin afectar el desempeño general. Esta solución proporciona una mayor precisión y rapidez en la toma de decisiones, haciéndola ideal para entornos donde la eficiencia y la autonomía son fundamentales.

#### *VIII-E. Prototipo*

El ensamblaje de los componentes mecánicos y electrónicos sigue un diseño estructurado para garantizar su integración óptima. En esta fase, se montan el Grove Vision AI Module v2, la cámara OV5467, el ESP32-S3 y el servomotor dentro de un entorno controlado, permitiendo evaluar su funcionamiento conjunto. Esta configuración es esencial para verificar la compatibilidad de los dispositivos y optimizar la comunicación entre ellos, minimizando posibles fallos en el sistema.

Una vez ensamblado, se realizan ajustes en la estructura que alberga el sistema de reconocimiento y control. Se optimiza el diseño del case para asegurar estabilidad y protección, además de garantizar una ventilación adecuada que evite el sobrecalentamiento. Asimismo, se acondiciona el cuarto oscuro, un espacio diseñado para mejorar la captura de imágenes mediante una iluminación regulada, lo que contribuye a la precisión del modelo de inteligencia

artificial en la clasificación de los bananos.

Otro aspecto clave es la colocación estratégica de la cámara OV5467, cuya altura y ángulo de visión se ajustan para maximizar la calidad de las imágenes capturadas. Este posicionamiento previene obstrucciones y optimiza la detección del objeto a analizar, garantizando que el modelo opere con datos consistentes. De manera complementaria, se calibra el servomotor para que ejecute giros precisos, asegurando la sincronización de la compuerta con el momento exacto de detección de un banano maduro.

Las pruebas de integración permiten evaluar la comunicación entre los componentes y detectar posibles retrasos en la ejecución de comandos. Se ajusta la velocidad de respuesta del sistema para que la inferencia y la acción mecánica ocurran de manera sincronizada. Estas verificaciones son fundamentales para garantizar un flujo de trabajo ágil y eficiente, identificando y corrigiendo errores antes de la implementación en la operación.

Finalmente, tras validar el rendimiento del sistema, se documentan los parámetros de calibración y las configuraciones óptimas para su funcionamiento. Esta información es esencial para el mantenimiento y futuras mejoras del dispositivo. Con una integración exitosa y ajustes precisos, el sistema se consolida como una solución confiable y eficiente para la clasificación automatizada de bananos, permitiendo su aplicación en entornos industriales con alta precisión y rapidez.

### VIII-F. Validación

La validación del sistema se realiza en un entorno operativo real, donde se prueba su capacidad para clasificar bananos según su madurez mientras son transportados en una banda. Se analizan la precisión del modelo de visión artificial, el tiempo de respuesta y la consistencia en la identificación de los frutos. Para garantizar un funcionamiento óptimo, se ejecutan pruebas repetitivas que permiten medir la efectividad en la detección y el desvío de los bananos maduros, asegurando que la clasificación ocurra de manera fluida y sin interrupciones.

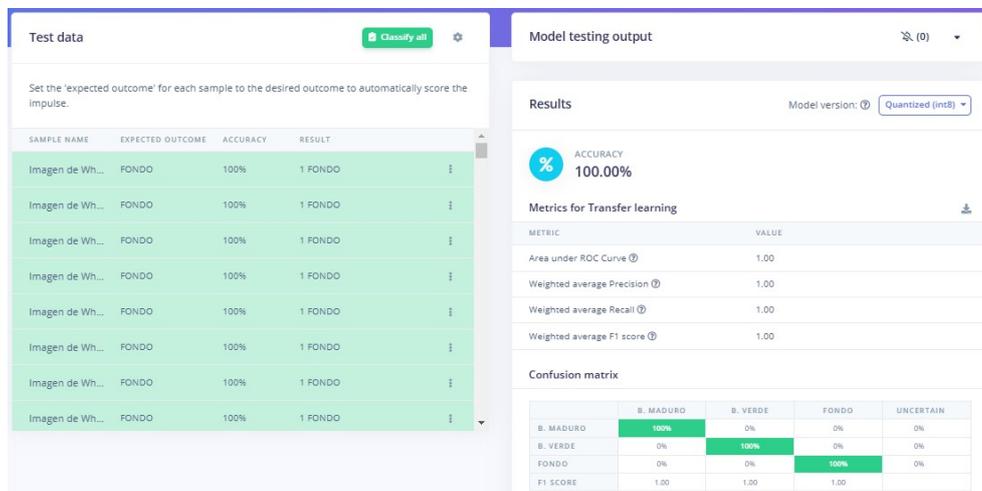


Figura 32. Elaboración del Dataset [80].

Durante este proceso, se ajustan parámetros clave de la visión artificial, como la calidad de las imágenes capturadas y la influencia de las condiciones lumínicas en la detección. Se optimizan filtros y algoritmos para garantizar que el modelo trabaje con datos claros y uniformes, minimizando errores causados por variaciones en la iluminación o imperfecciones en la superficie de los bananos. Esta calibración es esencial para mantener la fiabilidad del sistema en distintas condiciones de operación.

Además de la optimización del modelo, se supervisa el desempeño mecánico, especialmente la sincronización entre el procesamiento digital y la respuesta física. Se evalúa el funcionamiento del servomotor encargado de accionar la compuerta de desvío, verificando que su velocidad y precisión permitan una clasificación eficiente sin afectar la continuidad del proceso. Cualquier irregularidad detectada se corrige en tiempo real para garantizar que la operación se mantenga estable y sincronizada.

El método de entrenamiento del modelo es otro factor crucial en la precisión de la clasificación, por lo que se revisa la representatividad del conjunto de datos utilizado. Si es necesario, se incorporan nuevas muestras y se ajustan los hiperparámetros para mejorar el rendimiento en la identificación de los distintos estados de madurez. Asimismo, se comparan las métricas obtenidas con los valores esperados, identificando áreas de mejora en el sistema para maximizar su operabilidad en condiciones industriales.

Finalmente, una vez completadas las pruebas y ajustes, se documentan las configuraciones óptimas para su implementación a largo plazo. Esta validación garantiza que el sistema funcione con alta precisión y estabilidad en entornos de producción, proporcionando una solución automatizada confiable. Con ello, se logra un equilibrio entre velocidad, exactitud y adaptabilidad, asegurando un desempeño eficiente en la clasificación de bananos a gran escala.

## IX. RESULTADOS

La evaluación del sistema de clasificación de bananos basado en visión artificial se llevó a cabo en un entorno de prueba controlado, donde se analizaron las métricas de precisión, sensibilidad, especificidad, y tiempo de procesamiento. A continuación, se describen los resultados obtenidos en cada uno de estos aspectos.

En primer lugar, los resultados revelaron que el sistema alcanzó una precisión sobresaliente del 99 %. Este elevado porcentaje indica la notable capacidad del sistema para realizar clasificaciones correctas y consistentes entre los diferentes estados de madurez de los bananos, minimizando errores y garantizando una alta fiabilidad en su funcionamiento. Además de la precisión, se evaluó la sensibilidad del modelo, también conocida como recall, obteniendo un valor de 0.99. Este resultado subraya la habilidad del sistema para identificar correctamente el 99 % de los bananos que realmente estaban maduros, lo que es crucial para minimizar los falsos negativos, es decir, evitar clasificar erróneamente bananos maduros como no maduros. Paralelamente, la especificidad del sistema se mantuvo igualmente alta, demostrando su eficiencia para evitar clasificaciones incorrectas de bananos verdes, asegurando que no se cataloguen erróneamente como maduros. En conjunto, estos valores altamente positivos de precisión, sensibilidad y especificidad reflejan la notable efectividad del modelo en la clasificación precisa de los frutos, garantizando un nivel excepcional de acierto y precisión en sus predicciones sobre el estado de madurez de los bananos.

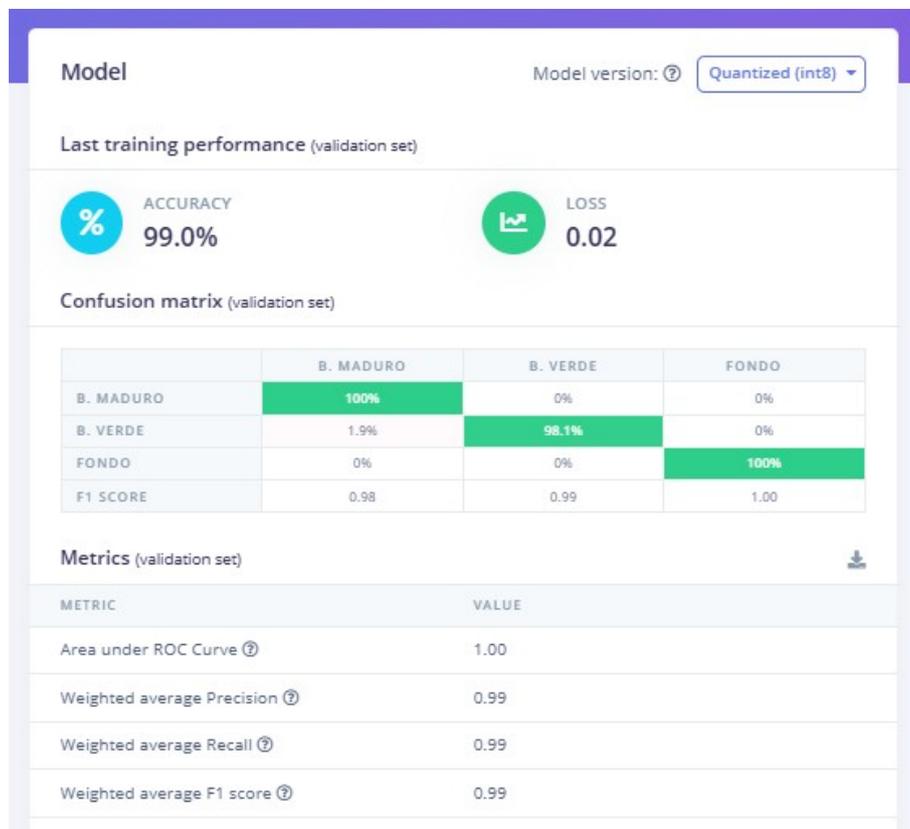


Figura 33. Métricas del entrenamiento [80].

En cuanto al tiempo de procesamiento, se observó una mejora significativa gracias a la implementación del modelo MobileNetV2, en comparación con la versión anterior, MobileNetV1. Las pruebas revelaron que al utilizar MobileNetV1, el tiempo de procesamiento por imagen era de 38 milisegundos. Sin embargo, al migrar al modelo más avanzado MobileNetV2, este tiempo se redujo drásticamente a tan solo 13.36 milisegundos. Gracias a esta enorme disminución en el tiempo de procesamiento se demuestra una mejora sustancial en la velocidad de clasificación al emplear la versión más reciente y eficiente del modelo MobileNet, lo que se traduce en un procesamiento más rápido y ágil de los bananos.



Figura 34. Tiempo por inferencia [80].

Un aspecto crucial para garantizar la consistencia en el rendimiento del sistema fue el control de las condiciones de iluminación. Mediante la implementación de un cuarto oscuro especialmente acondicionado, se logró controlar rigurosamente las variables lumínicas durante las pruebas. Gracias a este entorno controlado, las fluctuaciones o variaciones en las condiciones de luz no tuvieron un impacto significativo en el rendimiento general del sistema de clasificación. Esta estabilidad en las condiciones de iluminación permitió obtener resultados consistentemente altos en términos de precisión y sensibilidad, asegurando que los factores ambientales, como la luz, no afectaran de manera considerable la capacidad del sistema para clasificar los bananos de forma precisa y fiable.

El sistema de activación del servomotor, encargado de la función mecánica de desviar físicamente los bananos maduros hacia la sección correspondiente en la línea de producción, también fue objeto de evaluación. Las pruebas realizadas en lotes de 20 iteraciones, el mecanismo de desvío se activó de manera correcta y en el momento preciso, logrando la segregación o separación adecuada de los frutos maduros del resto. Aunque la tasa de activación es alta, existe un margen de mejora para optimizar aún más la fiabilidad del sistema de desvío.

Durante la fase de entrenamiento del modelo de clasificación, se definieron y configuraron una serie de hiperparámetros clave para optimizar su rendimiento. Se establecieron 20 épocas de entrenamiento, representando el número de veces que el algoritmo recorrió el conjunto de datos de entrenamiento para ajustar sus parámetros internos. Adicionalmente, se fijó una tasa de aprendizaje (learning rate) de 0.0005, que controla la magnitud de los ajustes realizados en los pesos del modelo en cada época de entrenamiento. En cuanto a la distribución de los datos, el conjunto de datos original fue dividido estratégicamente: el 80 % se destinó al entrenamiento del modelo, mientras que el 20 % restante se reservó para las pruebas y evaluación final de su rendimiento. A su vez, dentro del 80 % asignado para el entrenamiento, se realizó una subdivisión interna: el 80 % se utilizó para el entrenamiento directo del modelo, y el 20 % restante se empleó para la validación durante el entrenamiento. Esta meticulosa división de los datos y la cuidadosa configuración de los hiperparámetros permitieron una evaluación adecuada y rigurosa del modelo, asegurando que el proceso de entrenamiento se optimizara en función de los datos disponibles y del aprendizaje efectivo alcanzado por el sistema.

## Neural Network settings



### Training settings

Number of training cycles <sup>?</sup>	<input type="text" value="20"/>
Use learned optimizer <sup>?</sup>	<input type="checkbox"/>
Learning rate <sup>?</sup>	<input type="text" value="0.0005"/>
Training processor <sup>?</sup>	<input type="text" value="CPU"/>
Data augmentation <sup>?</sup>	<input type="checkbox"/>

### Advanced training settings



Validation set size <sup>?</sup>	<input type="text" value="20"/>	%
Split train/validation set on metadata key <sup>?</sup>	<input type="text"/>	
Batch size <sup>?</sup>	<input type="text" value="32"/>	
Auto-weight classes <sup>?</sup>	<input type="checkbox"/>	
Profile int8 model <sup>?</sup>	<input checked="" type="checkbox"/>	

Figura 35. Ajuste de hiperparametros [80].

Al comparar el sistema de clasificación automatizado con los métodos tradicionales de clasificación manual, se hicieron evidentes ventajas notables a favor del sistema automatizado. Se observó que los operadores humanos, al realizar la clasificación de bananos de forma manual, tendían a cometer errores de manera ocasional, especialmente al clasificar bananos maduros y ubicarlos incorrectamente en la sección destinada a los bananos verdes. Este tipo de errores humanos introducía inconsistencias y variabilidad en el proceso de clasificación. En contraste, el prototipo automatizado demostró una consistencia y rapidez superiores en la clasificación de bananos. Su rendimiento no se veía afectado por factores subjetivos, fatiga o la variabilidad inherente al trabajo manual. Esta objetividad y constancia del sistema automatizado representan una mejora significativa en comparación con la clasificación manual.

Comparación entre Clasificación Manual y Automatizada de Bananos

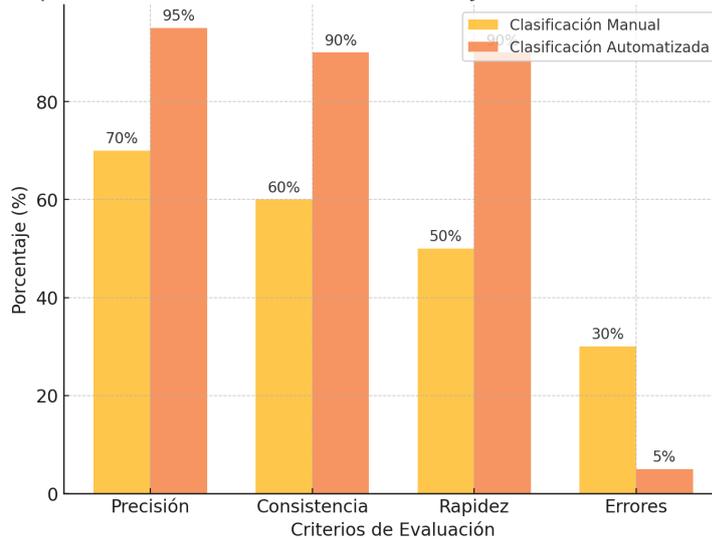


Figura 36. Comparación entre procesos de clasificación [80].

Finalmente, los resultados obtenidos evidencian la viabilidad del sistema de clasificación automatizado, destacando su alta precisión, eficiencia en tiempo de procesamiento y capacidad para mantener una clasificación consistente. Estas características permiten optimizar el flujo de trabajo en las líneas de producción de la industria bananera, asegurando una clasificación eficiente y confiable de los frutos. Este sistema no solo mejora la productividad, sino que también reduce los costos operativos y el desperdicio de productos que no cumplen con los estándares de calidad requeridos.

En conclusión, los resultados obtenidos a lo largo de esta evaluación demuestran de manera contundente la viabilidad y el potencial del sistema de clasificación automatizado de bananos. El sistema destaca por su precisión en la clasificación, su eficiencia en términos de tiempo de procesamiento, y su notable capacidad para mantener una clasificación consistente. Estas características lo convierten en una herramienta valiosa para optimizar significativamente el flujo de trabajo en las líneas de producción de la industria bananera. Al implementar este sistema, se asegura una clasificación de los frutos más eficiente y confiable, lo que no solo conduce a una mejora sustancial en la productividad general de la industria, sino que también contribuye a la reducción de costos operativos y a la disminución del desperdicio de productos que no cumplen con los rigurosos estándares de calidad requeridos por el mercado.

## X. CRONOGRAMA

A continuación se muestra el cronograma de trabajo en la figura I.

Tabla I  
CRONOGRAMA

CRONOGRAMA		
Semana	Fase	Actividad
1-2 de diciembre	Análisis	Análisis del problema y recopilación de requisitos.
1-2 de diciembre	Análisis	Revisión de especificaciones del Grove Vision AI Module v2 y del sistema de transporte (banda transportadora).
3-4 de diciembre	Diseño	Diseño mecánico: planificación del montaje de la compuerta y disposición del sistema de transporte.
3-4 de diciembre	Diseño	Diseño electrónico: selección de componentes adicionales (relé, motor, etc.).
3-4 de diciembre	Diseño	Diseño de control y software: planificación de la estructura de código y algoritmos de detección de madurez del banano.
1-2 de enero	Simulación	Configuración del entorno de simulación de visión artificial con TensorFlow Lite.
1-2 de enero	Simulación	Simulación del funcionamiento de los algoritmos en el Grove Vision AI Module v2 para pruebas de precisión de clasificación.
3-4 de enero	Prototipo	Montaje de componentes mecánicos y electrónicos.
3-4 de enero	Prototipo	Programación y pruebas iniciales del sistema de visión artificial y del control de salida del relé.
3-4 de enero	Prototipo	Ajustes de software para la detección y clasificación de bananos maduros.
1-2 de febrero	Prototipo	Integración del sistema en la banda transportadora y pruebas de funcionamiento.
3 de febrero	Validación	Validación de la precisión del sistema en la clasificación de bananos.
3 de febrero	Validación	Análisis de resultados, ajuste de parámetros y optimización.
4 de febrero	Documentación	Finalización de la documentación de resultados y elaboración del informe de proyecto.

A través de un proceso de cotización a nivel nacional, se han obtenido los datos que conforman la tabla presupuestaria, la cual servirá como guía financiera para la implementación de la tesis.

## XI. PRESUPUESTO

Nombre del elemento	Descripción	Cantidad	Valor total
Cámara OV5647-62 FOV	Módulo de cámara	1	20\$
Grove - Visión AI Module V2	Módulo avanzado de visión	1	60 \$
Xiao Espe32S3	Placa de desarrollo	1	20 \$
Servomotor	Tower Pro MG996R STANDARD	1	20\$
Estructura	Material metálico	1	50\$
Chasis	Playwood	1	5\$
Compuerta	Estructura para clasificar	1	20\$
Perfil de Aluminio V 20x20	LE-6-2020V	2	18\$
Perno allen cabeza plana	M5x08 INOX	30	5\$
Soporte de esquina	Serie 20 NEGRO	15	15\$
Tuerca T rectangular	M5 serie 20	30	7\$
Tira de Led	Led blanca	20	9\$
Fuente conmutada	5v	1	11\$
Adaptador	12v	1	4\$
Caja	Conexiones para intemperie	1	15\$
Riel din	1mts	1	3\$
Spray	Negro	1	8\$
Toma corriente	Simple	1	3\$
Bloques terminales	para riel Din	1	30\$
Cable concéntrico	3 en 1 #14	1	10\$
Clavija	3 patas	1	3\$
<b>SUBTOTAL MAQUETA</b>			<b>336\$</b>
Transporte	Transporte y gasolina	4	45\$
Transporte	Envío de muestras o equipos	4	25\$
Imprevistos	Gastos emergentes en nuevas pruebas del proyecto	4	35\$
<b>SUBTOTAL COSTOS LOGÍSTICOS</b>			<b>105\$</b>
<b>TOTAL(MAQUETA + COSTOS LOGÍSTICOS)</b>			<b>441\$</b>

## XII. CONCLUSIONES

El desarrollo e implementación de un sistema automatizado para la clasificación de productos ha demostrado ser una solución efectiva para mejorar la precisión y eficiencia de los procesos productivos. La integración de técnicas avanzadas de análisis y herramientas automatizadas ha permitido optimizar la identificación de características clave, reduciendo la variabilidad y los errores asociados a la inspección manual. Además, la automatización ha generado una mejora significativa en la velocidad de clasificación, lo que se traduce en una mayor productividad y competitividad en el sector.

Los resultados obtenidos reflejan que la combinación de procesamiento avanzado con mecanismos de acción rápida permite lograr una clasificación estandarizada y objetiva. La eliminación de la subjetividad humana en la evaluación ha sido un factor determinante en la mejora de la calidad del proceso, garantizando que el producto cumpla con los estándares exigidos. Asimismo, la optimización del tiempo de respuesta del sistema ha facilitado una mayor adaptabilidad a distintos escenarios operativos, lo que resalta su aplicabilidad en diversos entornos industriales.

Otro aspecto relevante de esta investigación ha sido la evaluación del impacto de la automatización en la reducción del desperdicio de productos. La implementación de este sistema ha permitido minimizar la cantidad de productos rechazados por errores de clasificación, contribuyendo a la optimización de los recursos y la sostenibilidad del proceso productivo. Esto demuestra que la incorporación de nuevas tecnologías no solo tiene beneficios económicos, sino que también promueve prácticas más eficientes y responsables con el entorno.

Finalmente, este estudio sienta las bases para futuras investigaciones en el campo de la automatización de procesos productivos. La combinación de herramientas avanzadas y estrategias innovadoras representa una oportunidad para seguir perfeccionando la clasificación automatizada y extender su aplicación a otros sectores. La continua evolución tecnológica permitirá mejorar aún más la precisión y eficiencia de estos sistemas, consolidando su papel en la modernización de la industria.

### XIII. RECOMENDACIONES

Para mejorar el desempeño del sistema automatizado, es fundamental ampliar y diversificar los conjuntos de datos utilizados en su entrenamiento, asegurando que incluyan una mayor variedad de condiciones operativas para optimizar la precisión del modelo. Asimismo, se recomienda la implementación de hardware más eficiente que permita mejorar el tiempo de procesamiento sin comprometer la estabilidad del sistema, ya que la selección de componentes adecuados es clave para garantizar un rendimiento óptimo.

Es esencial establecer un proceso de monitoreo continuo del desempeño del sistema, realizando pruebas periódicas para identificar áreas de mejora y ajustar los parámetros de clasificación según sea necesario. Además, la automatización de la clasificación puede extenderse a otros sectores productivos, por lo que se sugiere investigar su aplicabilidad en industrias similares donde la inspección y selección de productos sean factores clave para la calidad y eficiencia operativa.

La integración del sistema con otras tecnologías como la inteligencia artificial y el aprendizaje profundo puede mejorar aún más su rendimiento, por lo que se recomienda explorar nuevas metodologías que permitan potenciar su efectividad. También es importante que el personal involucrado en los procesos productivos reciba la capacitación adecuada sobre el uso y mantenimiento del sistema automatizado, lo que facilitará una transición eficiente hacia la automatización y garantizará su correcta operación.

Finalmente, se sugiere evaluar constantemente los beneficios económicos y ecológicos de la automatización, asegurando que las mejoras implementadas contribuyan a la sostenibilidad del proceso productivo. Mediante un análisis detallado del impacto del sistema en la reducción del desperdicio y el ahorro de recursos, se podrá optimizar su implementación y garantizar su viabilidad a largo plazo.

## REFERENCIAS

- [1] A. C. Bayas Arcos, «El gasto en tecnología y la sustitución de la mano de obra en el sector textil ecuatoriano,» B.S. thesis, 2024.
- [2] M. Q. C. Fernando, «Aplicación en realidad aumentada para Cafés de Origen (Vive la Experiencia de un buen café a través de tus ojos.) BAR-ING,» 2019.
- [3] E. Chunga Rojas, A. J. O. Cong Artaza y H. J. Miranda Sánchez, «Propuesta de proyecto de implementación de una herramienta de inteligencia artificial para la gestión de la calidad según el PMBOK® Sexta Edición en el proceso de exportación en una asociación de productores de banano orgánico en Querecotillo, en el año 2023,» 2024.
- [4] K. J. Tamayo Zapata, *Sistema de reconocimiento de billetes para personas con discapacidad visual mediante visión artificial*, 2018.
- [5] M. C. Villasana-Montes, E. Hernández-Rojas, R. L. Palomino-Reséndiz, K. F. Maya-Gress, S. I. Palomino-Reséndiz et al., «Diseño de sistema de monitoreo para detección temprana de enfermedades y plagas superficiales en plantas mediante visión artificial,» *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, vol. 11, n.º Especial4, págs. 221-230, 2023.
- [6] J. F. Vásquez Vanegas, «Diseño conceptual de un robot móvil enfocado a la agricultura de precisión en campo abierto para la eliminación de malezas en el cultivo de palma de aceite,» 2020.
- [7] V. E. Ube Guerrero, «Innovaciones tecnológicas en agroecosistemas de piña (Ananas comosus) en el Ecuador,» B.S. thesis, BABAHOYO: UTB, 2024, 2024.
- [8] S. F. Jamed Veliz y A. d. R. Unda Murillo, «E-commerce para la mejora de la comercialización de productos agrícolas, cantón Nobol,» B.S. thesis, Guayaquil: ULVR, 2022., 2022.
- [9] J. Miravet Tenés, «Generación automatizada de descripciones de imágenes mediante inteligencia artificial,» Tesis doct., Universitat Politècnica de València, 2024.
- [10] A. G. B. Plata y S. I. Araujo, «Sistema de visión artificial para la clasificación de Uchuva basado en forma y color,» *Ciencia e Ingeniería: Revista de investigación interdisciplinaria en biodiversidad y desarrollo sostenible, ciencia, tecnología e innovación y procesos productivos industriales*, vol. 6, n.º 1, pág. 1, 2019.
- [11] D. Margüelles Ansorena, «Detección en tiempo real de comida: Un enfoque innovador para la clasificación automatizada de alimentos con CNN,» 2023.
- [12] L. J. Aguilar, *Internet de las cosas: un futuro hiperconectado: 5G, Inteligencia Artificial, Big data, Cloud, Blockchain, Ciberseguridad*. Alpha Editorial, 2021.
- [13] J. D. Pedraza Caro, «La inteligencia artificial en la sociedad: explorando su impacto actual y los desafíos futuros,» 2023.
- [14] E. Tenés Trillo, «Impacto de la Inteligencia Artificial en las Empresas,» 2023.
- [15] Coba. «Imagen.» (2022).
- [16] AHK Ecuador, «Informe sector bananero,» 2023. dirección: <https://ecuador.ahk.de/es/infoteca/noticias/news-details/informe-sector-bananero>.
- [17] Spingarn, «Ecuador: de una "banana republic" a una "innovative republic",» 2023. dirección: <https://www.spingarn.ec/blog/ecuador-de-una-banana-republic-a-una-innovative-republic>.
- [18] B. Ebizor, «Usan nuevas tecnologías para aumentar la producción del banano,» 2023. dirección: <https://banano.ebizor.com/usan-nuevas-tecnologias-para-aumentar-la-produccion-del-banano/>.
- [19] I. y. P. d. E. Ministerio de Producción Comercio Exterior, «Ecuador, líder en exportaciones de banano orgánico hacia la Unión Europea,» 2023. dirección: <https://www.produccion.gob.ec/ecuador-lider-en-exportaciones-de-banano-organico-hacia-la-union-europea/>.
- [20] ResearchGate, «Transformación Digital en el Sector Bananero: Análisis de Adopción Tecnológica y Barreras en ASOPROBALI S.A.,» 2023. dirección: [https://www.researchgate.net/publication/387063574\\_Transformacion\\_Digital\\_en\\_el\\_Sector\\_Bananero\\_Analisis\\_de\\_Adopcion\\_Tecnologica\\_y\\_Barreras\\_en\\_ASOPROBALI\\_SA\\_Digital\\_Transformation\\_in\\_the\\_Banana\\_Sector\\_Analysis\\_of\\_Technological\\_Adoption\\_and\\_Barriers\\_in](https://www.researchgate.net/publication/387063574_Transformacion_Digital_en_el_Sector_Bananero_Analisis_de_Adopcion_Tecnologica_y_Barreras_en_ASOPROBALI_SA_Digital_Transformation_in_the_Banana_Sector_Analysis_of_Technological_Adoption_and_Barriers_in).
- [21] Siara. «Imagen.» (2020).

- [22] L. E. Romero Ayala, «La inteligencia artificial en la proyección de su producción de cultivo de Caña de Azúcar en el Ecuador,» B.S. thesis, BABAHOYO: UTB, 2023, 2023.
- [23] W. T. Chávez Loor y F. D. Mendoza Zambrano, «Determinación de las competencias organizacionales en las empresas agroproductivas procesadoras de plátano y banano de la zona norte de Manabí,» Tesis de mtría., Calceta: ESPAM MFL, 2020.
- [24] M. V. León Cuzco et al., «Diseño e Implementación de un Sistema de Visión Artificial usando un Brazo Robótico Niryo One, Cámara RGB-D y Redes Neuronales Artificiales aplicado a la Robótica Colaborativa,» *ESPOL. FIEC*, 2024.
- [25] Ibertrónica. «Imagen.» (2023).
- [26] M. E. Barberis, J. P. Real y S. D. Palma, «Impresión 3D en tecnología farmacéutica: MESO PP® un proceso simplificado de obtención de formas farmacéuticas sólidas,» 2020.
- [27] C. A. Avila Castellano, «Influencia de la tasa de calentamiento en las propiedades mecánicas de piezas de alúmina, obtenidas por impresión 3D mediante la técnica fused filament fabrication con filamento compuesto,» 2022.
- [28] P. Aguilar Urquidez, «Impresión 3D cerámica de densidad variable controlada,» 2024.
- [29] A. J. Tomalá Malavé, «Modelo de reconocimiento de pigmentación y detección de objetos en plantaciones para determinar la temporada de cosecha,» B.S. thesis, La Libertad: Universidad Estatal Península de Santa Elena, 2024., 2024.
- [30] J. E. Soto Sogamoso, J. E. Pinto Lopera y E. E. Millán Rojas, «Micorrizas arbusculares y las técnicas de visión artificial para su identificación,» *TecnoLógicas*, vol. 25, n.º 54, 2022.
- [31] D. A. Basantes Varela y E. A. Chalaco Chamba, «Desarrollo de un prototipo de gafas para lectura de texto con visión artificial que asista a personas con discapacidad visual,» B.S. thesis, 2019.
- [32] Euroforum. «Imagen.» (2017).
- [33] B. E. Marconi Narváez, «Diseño y evaluación de un sistema de inteligencia artificial (IA) basado en redes neuronales convolucionales (CNN) para la detección y clasificación de nódulo tiroideo por ultrasonido,» 2022.
- [34] C. Bits. «Imagen.» (2022).
- [35] S. Sanchez Pardo y F. J. More Villegas, «Desarrollo de métodos para la clasificación por madurez de la fresa utilizando procesamiento de imágenes digitales y machine learning,» 2024.
- [36] S. X. Sánchez Garcés y J. S. Ramírez García, «Uso de Aeronaves y Tratamiento Digital de Imágenes para Diagnóstico y Rendimiento de la Producción Agrícola,»
- [37] O. Segura-Quesada, «Optimización de redes neuronales para ejecución eficiente de aplicaciones de inteligencia artificial en GPUs embebidos,» 2021.
- [38] A. Meza-Bautista, L. E. Ñahui-Vargas y E. Mamani-Vilca, «Comparativa de Modelos basados en redes neuronales convolucionales: ResNet-50V2, MobileNetV2 e EfficientNetB0 en la detección de Malaria,» *Micaela Revista de Investigación-UNAMBA*, vol. 5, n.º 1, págs. 42-49, 2024.
- [39] O. M. Coello Camacho et al., «Clasificación de defectos en manzanas usando aprendizaje profundo con imágenes del espectro visible y del espectro infrarrojo cercano,» *ESPOL. FIEC*, 2023.
- [40] H. A. Auris Aguilar y F. R. Cardenas Cuya, «Diseño y automatización de un sistema de bandas transportadoras modulares para la distribución de jabas en la empresa Supermercados Peruanos SA,» 2019.
- [41] Aguilar. «Imagen.» (2021).
- [42] D. L. Guerrero Galvez, J. F. Capelo Garcia, B. Puruncajas et al., «Diseño de un sistema para la identificación y clasificación de encomiendas,» Tesis doct., ESPOL. FIMCP, 2021.
- [43] D. A. Gutiérrez Díaz et al., «Construcción de un banco de automatización basado en una cinta transportadora horizontal,» Tesis doct., Universidad de Talca. Facultad de Ingeniería, 2019.
- [44] L. A. Soto Valqui y W. Valdez Jimenez, «Diseño de un prototipo domótico asistencial para adultos mayores, con sistemas embebidos para conectarse con plataformas basadas en Internet Of Things (IOT),» 2023.
- [45] Mendez. «Imagen.» (2022).
- [46] J. D. Uribe Osorio et al., «Medición de calibre de plantas en viveros frutales con visión estereoscópica y procesamiento digital de imágenes,» Tesis doct., Universidad de Talca. Facultad de Ingeniería, 2021.

- [47] S. Bouaouda et al., «Desarrollo de un sistema de Visión Artificial para ayuda a personas con dificultad motora en las extremidades superiores,» 2022.
- [48] X. Electronic. «Imagen.» (2024).
- [49] H. Nuñez Flores et al., «Sistema de navegación para una plataforma robótica de autobalance,» 2023.
- [50] R. Shop. «Imagen.» (2022).
- [51] J. A. Tapia Peña, «Automatización del sistema de regulación del tamaño de grano para un molino eléctrico de granos secos SVM-160,» B.S. thesis, 2023.
- [52] Gutierrez. «Imagen.» (2019).
- [53] M. A. Giraldo Duque, «Adquisición y procesamiento de imágenes multiespectrales enfocado en la reproducción y corrección de color en entornos de iluminación controlados,» Tesis doct., Universidad Nacional de Colombia.
- [54] Q. led. «Imagen.» (2025).
- [55] A. P. Maspud Castro y S. J. Yanchaluisa Sánchez, «Implementación de un módulo didáctico para el montaje de embolo, vástago y tapa de actuador neumático para un sistema de montaje de cilindros neumáticos.,» 2024.
- [56] G. Electrostore. «Imagen.» (2019).
- [57] A. D. CHANCAY SANCAN, «IMPLEMENTACIÓN DE FUENTE DE ALIMENTACIÓN DUAL PARA ANÁLISIS DE PARÁMETRO DE CIRCUITOS EMBEBIDOS EN EL LABORATORIO DE ELECTRÓNICA DE LA CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN,» B.S. thesis, Jipijapa-Unesum, 2024.
- [58] AMPUL. «Imagen.» (2024).
- [59] E. I. Cisneros Sigcha, «Prototipo de asistencia visual para detectar objetos en espacios de aprendizaje aplicando redes neuronales convolucionales,» B.S. thesis, 2024.
- [60] E. V. Summit. «Imagen.» (2019).
- [61] C. X. GENDE SILVA, «IMPLEMENTACIÓN DE UN SISTEMA WEB MULTIPLATAFORMA PARA POTENCIAR SERVICIOS TECNOLÓGICOS EN LA EMPRESA ITyA DEL CANTÓN JIPIJAPA,» B.S. thesis, Jipijapa-Unesum, 2025.
- [62] R. Ward, «Sense, Craft, Art,» *Multimodal and Digital Creative Writing Pedagogies*, pág. 149,
- [63] sense craft seed. «Imagen.» (2025).
- [64] H. Vartiainen y M. Tedre, «Using artificial intelligence in craft education: crafting with text-to-image generative models,» *Digital Creativity*, vol. 34, n.º 1, págs. 1-21, 2023.
- [65] .., «ARDUINO INTEGRATED DEVELOPMENT ENVIRONMENT,»
- [66] PNGWing. «Imagen.» (2025).
- [67] C. Peña, *Arduino IDE: Domina la programación y controla la placa*. RedUsers, 2020.
- [68] F. A. Galárraga Alarcón y P. I. Inaquiza Tipán, «Diseño y construcción de un vehículo autónomo a escala equipado con tecnología LIDAR 2d para la navegación autónoma en un entorno con obstáculos preestablecidos para el Laboratorio de Autotrónica de la Universidad Politécnica Salesiana sede Quito campus Sur,» B.S. thesis, 2023.
- [69] Novex. «Imagen.» (2023).
- [70] J. D. León Callupe, «Diseño e implementación de un PLC basado en Raspberry Pi & Node-RED para aplicaciones industriales IoTT,» 2021.
- [71] Ingelcom. «Imagen.» (2021).
- [72] A. SHIGUANGO, J. GABRIEL y M. A. MASAMBA CAIZA, «DISEÑO DEL CABLEADO ESTRUCTURADO DE DATOS Y TENSIÓN PARA EL LABORATORIO ESPECIALIZADO DEL “INSTITUTO SUPERIOR TECNOLÓGICO TENA”,» Tesis doct., 2023.
- [73] DELUXE. «Imagen.» (2025).
- [74] J. A. Y. Morón, *Sistemas eléctricos de distribución*. Reverté, 2021.
- [75] E. center. «Imagen.» (2024).
- [76] B. H. N. Olmedo y H. A. N. Moscoso, «Incremento de la productividad en proceso de extrusión de perfiles de aluminio con billets de aleación experimental 6063,» *Ingeniería Industrial*, n.º 35, págs. 11-25, 2017.
- [77] P. CNC. «Imagen.» (2025).

- [78] W. J. López Povis, «Análisis comparativo entre el sistema de encofrado de aluminio y encofrado metálico para viviendas de interés social. Caso: Condominio Ciudad Verde–Puente Piedra–Lima,» 2015.
- [79] A. R. García Ibarra, A. Hernández González, J. Ramírez Beltrán, R. Reina Muñoz y E. Charry Rodríguez, «De tamaño estándar de aluminio aleación extrusión tubo cuadradoon diferencial de muy alta precisión y estabilidad,» *Ingeniería Electrónica, Automática y Comunicaciones*, vol. 35, n.º 1, págs. 57-77, 2014.
- [80] L. y Cantos. «Imagen.» (2025).

## ANEXO A PROGRAMACIÓN

```
CODIGO_TESIS
1 #include <Seeed_Arduino_SSCMA.h>
2
3 SSCMA AI;
4 const int LEDR = D10;
5
6 void setup()
7 {
8     AI.begin();
9     Serial.begin(115200);
10    while (!Serial);
11    Serial.println("Inferencing - Grove AI V2 / XIAO Sense with RGB LEDs");
12    pinMode(LEDR, OUTPUT);
13    digitalWrite(LEDR, HIGH);
14 }
15
16 void loop()
17 {
18     if (!AI.invoke())
19     {
20         Serial.println("\nInvoke Success");
21         Serial.print("Latency [ms]: preprocess=");
22         Serial.print(AI.perf().preprocess);
```

Figura 37. Programación en ARDUINO [80].

```
CODIGO_TESIS
22     Serial.print(AI.perf().preprocess);
23     Serial.print(", inference=");
24     Serial.print(AI.perf().inference);
25     Serial.print(", postprocess=");
26     Serial.println(AI.perf().postprocess);
27
28     int pred_index = AI.classes()[0].target;
29     Serial.print("Result= Label: ");
30     Serial.print(pred_index);
31     Serial.print(", score=");
32     Serial.println(AI.classes()[0].score);
33
34     turn_on_leds(pred_index);
35 }
36 }
37
38 void turn_off_leds() {
39     digitalWrite(LEDR, HIGH);
40 }
41
42 void turn_on_leds(int pred_index) {
43     switch (pred_index)
```

Figura 38. Programación en ARDUINO [80].

## CODIGO\_TESIS

```
42 void turn_on_leds(int pred_index) {
43     switch (pred_index)
44     {
45         case 0:
46             turn_off_leds();
47             digitalWrite(LED1, HIGH);
48             delay(1000);
49             digitalWrite(LED1, LOW);
50             break;
51
52         case 1:
53             turn_off_leds();
54             digitalWrite(LED1, HIGH);
55             delay(4000);
56             digitalWrite(LED1, LOW);
57             break;
58
59         case 3:
60             turn_off_leds();
61             break;
62     }
63 }
```

Figura 39. Programación en ARDUINO [80].

## ANEXO B PROTOTIPO

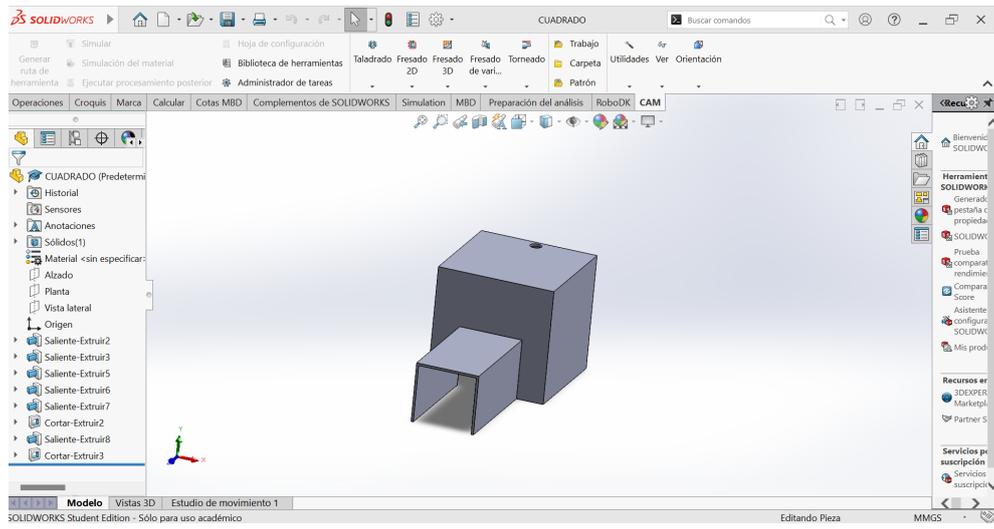


Figura 40. Prototipo en solidworks [80].



Figura 41. Prototipo en playwood [80].



Figura 42. prototipo de base [80].

ANEXO C  
ARMADO

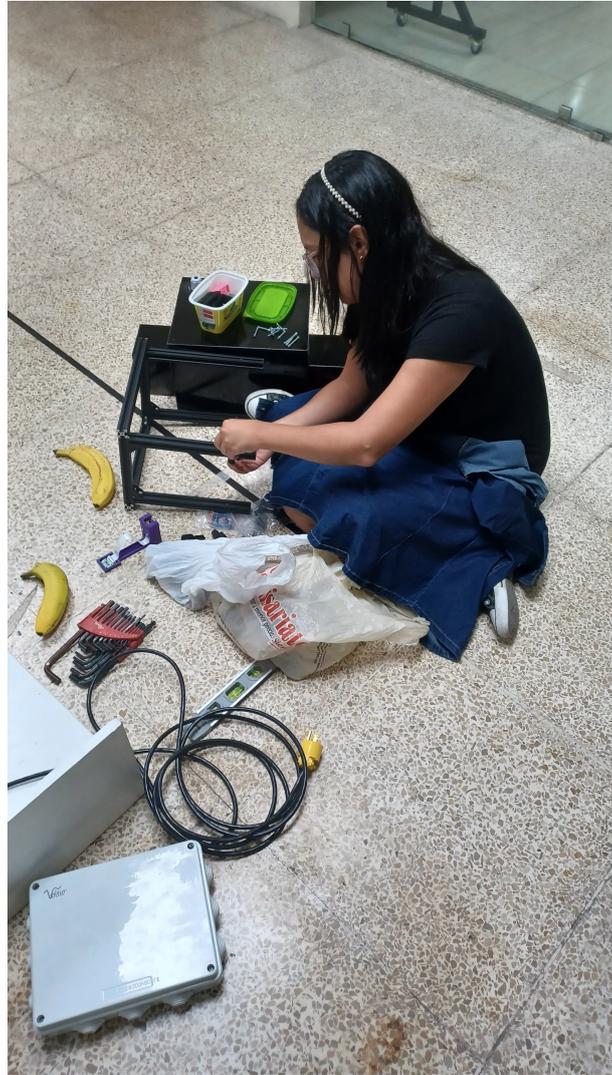


Figura 43. Programación en ARDUINO [80].



Figura 44. Armado de estructura para soportes [80].

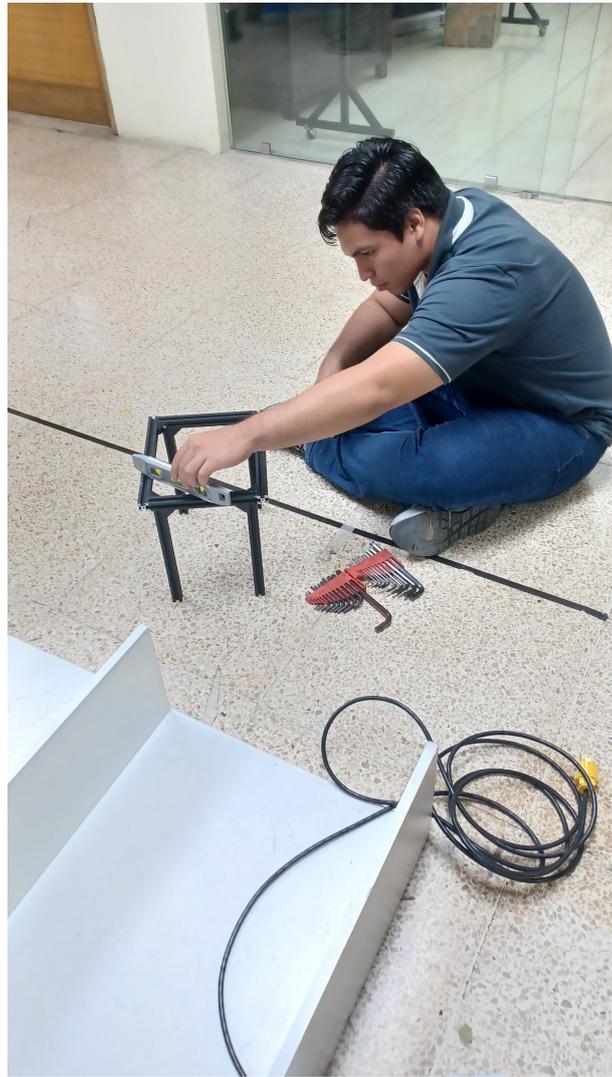


Figura 45. Nivelación de estructura [80].



Figura 46. Nivelación de estructura [80].



Figura 47. Creación de dataset [80].