



**UNIVERSIDAD TÉCNICA DE COTOPAXI**  
**FACULTAD DE CIENCIAS DE LA INGENIERÍA Y**  
**APLICADAS**  
**CARRERA DE INGENIERÍA INDUSTRIAL**

**Desarrollo de un modelo de visión artificial para la clasificación automática del chocho  
(Lupinus Mutabilis).**

PROPUESTA INVESTIGATIVA PREVIO A LA OBTENCIÓN DEL TÍTULO DE  
INGENIERO INDUSTRIAL

**AUTORES:**

Manuel Alejandro Vargas Figueroa  
Richard Steven Yanchaguano Nicolalde

**TUTOR:**

Ing. MSc. Ángel Guillermo Hidalgo Oñate

**MARZO 2026**

## DECLARACIÓN DE AUTORÍA

Nosotros **Vargas Figueroa Manuel Alejandro** con cedula de identidad No. 0504385063 y **Yanchaguano Nicolalde Richard Steven**, con cedula de identidad No. 1754136552, declaramos ser autores del presente” **DESARROLLO DE UN MODELO DE VISIÓN ARTIFICIAL PARA LA CLASIFICACIÓN AUTOMÁTICA DEL CHOCHO (LUPINUS MUTABILIS).**”, siendo el Ing. MSc. Ángel Guillermo Hidalgo Oñate Tutor del presente trabajo; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

Además, certifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de mi exclusiva responsabilidad.

Latacunga, marzo del 2026



Vargas Figuero Manuel Alejandro

C.C.: 0504385063




Yanchaguano Nicolalde Richard Steven

C.C.: 1754136552

Latacunga, Marzo 2026

### AVAL DEL TUTOR DEL PROYECTO DE INVESTIGACIÓN

En calidad de Tutor del Trabajo de Investigación sobre el título: “**Desarrollo de un modelo de visión artificial para la clasificación automática del chocho (Lupinus Mutabilis)**”, propuesto por el o la estudiante Vargas Figueroa Manuel Alejandro, Yanchaguano Nicolalde Richard Steven de la Carrera de Ingeniería Industrial, considero que dicho proyecto de titulación cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos al tribunal de lectores.



Ing. MSc. Angel Guillermo Hidalgo Oñate

C.C. 0503257404

TUTOR

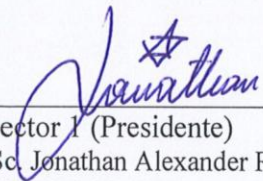
Latacunga, Marzo 2026

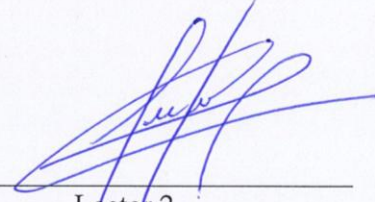
### AVAL DE APROBACIÓN DE LECTORES

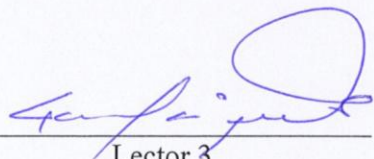
Cumpliendo con el Reglamento de Titulación de la Universidad Técnica de Cotopaxi, en calidad de Lectores de Tribunal de Proyecto de Investigación con el Título “**DESARROLLO DE UN MODELO DE VISIÓN ARTIFICIAL PARA LA CLASIFICACIÓN AUTOMÁTICA DEL CHOCHO (LUPINUS MUTABILIS)**”, propuesto por los estudiantes Vargas Figueroa Manuel Alejandro, Yanchaguano Nicolalde Richard Steven de la Carrera de Ingeniería Industrial, me permito indicar que los estudiantes han concluido todas las observaciones y realizado las correcciones señaladas por el Tribunal de Lectores, por lo cual presentamos el Aval de aprobación del Proyecto de Titulación correspondiente a la modalidad **Proyecto de Investigación** en virtud de lo cual los postulantes puede presentarse a la Defensa de su Proyecto de Titulación.

Particular que pongo en su conocimiento para los fines legales pertinentes.

Atentamente,

  
Lector 1 (Presidente)  
Ing. MSc. Jonathan Alexander Ruiz Carrillo, Dr.  
CC: 0703323824

  
Lector 2  
Ing. Diana Del Carmen Marín Vélez, MSc  
CC: 1204144503

  
Lector 3  
Ing. Josué Jonnatan Constante Armas, MSc.  
CC: 0502034564

## **AGRDECIMIENTO**

*En primer lugar, agradezco profundamente a Dios, por brindarme la salud, la fortaleza y la sabiduría necesarias para culminar esta importante etapa de mi formación profesional. Su guía ha sido mi apoyo constante en los momentos de dificultad y mi inspiración para no rendirme ante los desafíos presentados a lo largo de este camino.*

*Expreso mi sincero agradecimiento a la Universidad Técnica de Cotopaxi, institución que me abrió sus puertas y me permitió formarme académica y profesionalmente. Gracias por proporcionarme los conocimientos, las herramientas y el entorno adecuado para desarrollar esta investigación y fortalecer mis competencias como futuro profesional.*

*De manera especial, manifiesto mi más profundo reconocimiento al Ing. MSc. Angel Guillermo Idalgo Oñate, tutor de la presente tesis, por su orientación y acompañamiento durante todo el proceso investigativo. Finalmente, a mi amigo Richard Yanchaguano, con quien tuve la oportunidad de desarrollar este trabajo de tesis, gracias por el esfuerzo y compromiso compartido para culminar este proyecto.*

**Manuel Vargas**

## **AGRADECIMIENTO**

*En primer lugar, agradezco a Dios por su guía constante a lo largo de este camino, por brindarme la fortaleza, la salud y la sabiduría necesarias para culminar con éxito esta etapa tan importante de mi formación profesional.*

*Expreso mi más sincero agradecimiento a mi familia, por su amor incondicional, su apoyo constante y su confianza en mí. Gracias por acompañarme en cada paso de este proceso, por ser mi inspiración diaria y la principal motivación para seguir adelante y alcanzar esta meta.*

*Agradezco también a la Universidad Técnica de Cotopaxi, institución que me brindó la oportunidad de formarme profesionalmente, así como a sus docentes por los conocimientos, enseñanzas y experiencias compartidas durante mi formación académica. De manera especial, expreso mi sincero agradecimiento al Ing. MSc. Ángel Guillermo Hidalgo por su orientación y apoyo durante el proceso de desarrollo de este trabajo, los cuales contribuyeron para la culminación de esta investigación.*

*De igual manera, agradezco a mi amigo Manuel Vargas, con quien tuve la oportunidad de realizar este trabajo de titulación. Su compromiso, dedicación y colaboración fueron fundamentales durante el desarrollo de este proyecto. Asimismo, expreso mi agradecimiento a mi amigo Daniel Rodas, quien me ha acompañado desde el inicio de mi vida universitaria, brindándome su amistad y apoyo a lo largo de este proceso académico.*

**Richard Yanchaguano**

## **DEDICATORIA**

*Dedico el presente trabajo de tesis, en primer lugar, a mis queridos padres, la Sra. Blanca Figueroa y el Sr. Manuel Vargas, quienes con su amor, esfuerzo y apoyo incondicional han sido el pilar fundamental para alcanzar esta meta.*

*A mis hermanas, por su cariño, apoyo constante y palabras de aliento durante todo este proceso, siendo una motivación importante para seguir adelante y no rendirme ante las dificultades.*

*A mi primo hermano Luis Figueroa, quien me apoyó con su fortaleza en mis peores momentos, brindándome ánimo para continuar y no rendirme. A mis amigos Kevin Toapanta y Edgar Santucho, por su amistad y compañía a lo largo de mi formación.*

**Manuel Vargas**

## **DEDICATORIA**

*Dedico este trabajo de manera especial a mis padres, Angélica Nicolalde y Fabián Yanchaguano, por su amor, esfuerzo y apoyo incondicional a lo largo de toda mi formación profesional. Gracias por creer siempre en mí, por sus sacrificios y por enseñarme con su ejemplo el valor del esfuerzo y la perseverancia para alcanzar mis metas.*

*Dedico también este logro a mis hermanos, quienes con su cariño, apoyo y palabras de aliento estuvieron presentes durante este proceso, brindándome motivación en cada momento para continuar y no rendirme ante las dificultades.*

*De igual manera, dedico este trabajo a una persona muy especial que estuvo presente a lo largo de este camino, brindándome apoyo, motivación y confianza para seguir adelante y alcanzar esta meta tan importante en mi vida.*

*Finalmente, dedico este logro a mis amigos, quienes me acompañaron durante mi formación académica, compartiendo experiencias, aprendizajes y momentos que formaron parte importante de este proceso.*

**Richard Yanchaguano**

*AVAL DE TRADUCCIÓN*

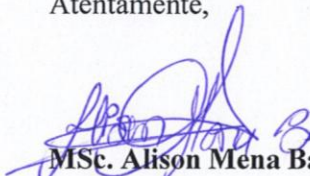
En calidad de Docente del Idioma Inglés del Centro de Idiomas de la Universidad Técnica de Cotopaxi; en forma legal **CERTIFICO** que:

La traducción del resumen al idioma Inglés del tema del proyecto de investigación cuyo título versa: **“DESARROLLO DE UN MODELO DE VISIÓN ARTIFICIAL PARA LA CLASIFICACIÓN AUTOMÁTICA DEL CHOCHO (LUPINUS MUTABILIS)”**, presentado por: **Vargas Figueroa Manuel Alejandro y Yanchaguano Nicolalde Richard Steven** egresados de la Carrera de Ingeniería Industrial perteneciente a la **Facultad de Ciencias de la Ingeniería y Aplicadas** lo realizaron bajo mi supervisión y cumple con una correcta estructura gramatical del Idioma.

Es todo cuanto puedo certificar en honor a la verdad y autorizo a los peticionarios hacer uso del presente aval para los fines académicos legales.

Latacunga, marzo de 2026

Atentamente,

  
MSc. Alison Mena Barthelotty

DOCENTE CENTRO DE IDIOMAS-UTC

CI: 0501801252



CENTRO  
DE IDIOMAS

# UNIVERSIDAD TÉCNICA DE COTOPAXI

## FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

**TEMA:** “DESARROLLO DE UN MODELO DE VISIÓN ARTIFICIAL PARA LA CLASIFICACIÓN AUTOMÁTICA DEL CHOCHO (*LUPINUS MUTABILIS*)”.

**Autores:** Vargas Figueroa Manuel Alejandro  
Yanchaguano Nicolalde Richard Steven

### RESUMEN

El presente trabajo de titulación abordó la problemática asociada a la clasificación manual de la calidad del *Lupinus Mutabilis* (chocho) en el cantón Saquisilí Provincia de Cotopaxi, caracterizada por alta variabilidad subjetiva, dependencia del criterio humano y baja eficiencia operativa en la etapa postcosecha. El objetivo general fue desarrollar un modelo de visión artificial, mediante algoritmos de aprendizaje automático, para la clasificación automática de granos en buen y mal estado a partir de sus características visuales. La investigación adoptó un enfoque de Investigación más Desarrollo (I+D), combinando la metodología Design Thinking para la caracterización del proceso y definición de parámetros, mientras que con la metodología Waterfall se desarrolló la parte técnica. Se diseñó el prototipo en el software Fusion 360 y se fabricó mediante impresión 3D en material PLA, integrando ambiente controlado de iluminación, sistema de captura de imágenes, banda transportadora y servomotores. Se generó un dataset propio; las imágenes fueron etiquetadas con la herramienta Make Sense y el programa se ejecutó en Python IDLE. Se entrenaron tres modelos de visión artificial con el algoritmo YOLOv11, destacándose el entrenamiento con 150 imágenes y 100 épocas, que alcanzó un mAP@0.5 de 0.995, superando a los modelos de 100 imágenes con 100 épocas y 250 imágenes con 150 épocas de entrenamiento. Con el modelo ganador se realizaron 10 pruebas en tiempo real en sistemas de procesamiento con computadora y Raspberry Pi, evaluando precisión, recall y F1-score. El sistema basado en computadora obtuvo los mejores resultados, con precisión de 0.92, recall de 0.97 y F1-score de 0.94. Se concluyó que la propuesta del modelo de visión artificial demostró alta viabilidad técnica para automatizar la clasificación del chocho en entornos controlados, mejorando la objetividad y trazabilidad del proceso.

**Palabras claves:** *Lupinus Mutabilis*, visión artificial, YOLOv11, procesamiento, F1-score, subjetividad.

# UNIVERSIDAD TÉCNICA DE COTOPAXI

## FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

**THEME:** DEVELOPMENT OF AN ARTIFICIAL VISION MODEL FOR THE AUTOMATIC CLASSIFICATION OF THE CHOCHO (LUPINUS MUTABILIS).

**Authors:** Vargas Figueroa Manuel Alejandro  
Yanchaguano Nicolalde Richard Steven

### ABSTRACT

This degree project addressed the problems associated with the manual classification of the quality of *Lupinus Mutabilis* (chocho) in the Saquisilí canton of Cotopaxi Province, characterized by high subjective variability, dependence on human judgement and low operational efficiency in the post-harvest stage. The overall objective was to develop a computer vision model, using machine learning algorithms, for the automatic classification of good and bad beans based on their visual characteristics. The research adopted a Research and Development (R&D) approach, combining the Design Thinking methodology for process characterization and parameter definition, while the technical part was developed using Waterfall methodology. The prototype was designed in Fusion 360 software and manufactured using 3D printing in PLA material, integrating a controlled lighting environment, image capture system, conveyor belt and servomotors. A proprietary dataset was generated; the images were labelled with the Make Sense tool and the program was run in Python IDLE. Three computer vision models were trained with the YOLOv11 algorithm, with the training with 150 images and 100 epochs standing out, achieving an mAP@0.5 of 0.995, surpassing the models with 100 images and 100 epochs and 250 images and 150 training epochs. Ten real-time tests were performed on the winning model using computer processing systems and Raspberry Pi, evaluating accuracy, recall, and F1-score. The computer-based system obtained the best results, with an accuracy of 0.92, recall of 0.97, and F1-score of 0.94. It was concluded that the proposed computer vision model demonstrated high technical feasibility for automating lupin classification in controlled environments, improving the objectivity and traceability of the process.

**KEYWORDS:** *Lupinus Mutabilis*, Computer vision, YOLOv11, Processing, F1-score, Subjectivity.

## ÍNDICE

1. INTRODUCCIÓN.....	2
1.1. SITUACIÓN PROBLEMÁTICA.....	3
1.2. FORMULACIÓN DEL PROBLEMA.....	3
1.3. OBJETO Y CAMPO DE ACCIÓN.....	3
1.3.1. Objeto de Investigación: Proceso de clasificación por categoría del Chocho (Lupinus Mutabilis) mediante visión artificial.....	3
1.3.2. Campo de Acción: 3311.01 Tecnología de la Automatización.....	3
1.4. BENEFICIARIOS.....	4
1.4.1. Directos.....	4
1.4.2. Indirectos.....	4
1.5. JUSTIFICACIÓN.....	4
1.6. OBJETIVOS.....	4
1.6.1. General.....	4
1.6.2. Específicos.....	5
1.7. HIPÓTESIS.....	5
1.8. ALCANCE.....	5
1.9. SISTEMA DE TAREAS.....	5
2. FUNDAMENTACIÓN TEÓRICA.....	7
2.1. ANTECEDENTES.....	7
2.2. MARCO TEÓRICO.....	8
2.2.1. Origen y distribución del Lupinus Mutabilis.....	8
2.2.1.1. Coloración del grano.....	9
2.2.1.2. Características de clasificación de proceso manual.....	10
2.2.1.3. Limitaciones del proceso manual.....	11
2.2.2. Fundamentos de la Inteligencia Artificial (IA).....	12

2.2.2.1.	Machine Learning y Deep Learning .....	14
2.2.3.	Sistemas inteligentes de visión para la automatización industrial.....	15
2.2.3.1.	Inteligencia artificial .....	16
2.2.3.2.	Visión por computador .....	17
2.2.3.3.	Visión Artificial .....	18
2.2.4.	Faces de la Visión artificial .....	21
2.2.4.1.	Recopilación de datos .....	21
2.2.4.2.	Procesamiento de datos.....	25
2.2.4.3.	Desarrollo del modelo.....	27
2.2.4.4.	Evaluación del modelo.....	32
2.2.4.5.	Implementación del modelo.....	35
2.2.4.6.	Investigaciones Similares.....	38
3.	MÉTODOS Y PROCEDIMIENTOS .....	40
3.1.	ENFOQUE DE LA INVESTIGACIÓN .....	40
3.2.	METODOLOGÍA APLICADA AL DESARROLLO DEL PROYECTO .....	40
3.3.	DELIMITACIÓN DEL ESTUDIO DE LA INVESTIGACIÓN .....	41
3.4.	MÉTODOS Y TÉCNICAS DE LA INVESTIGACIÓN .....	42
3.4.1.	Métodos teóricos de la investigación.....	42
3.4.2.	Métodos empíricos de la investigación .....	42
3.4.3.	Técnicas e instrumentos de la investigación.....	42
3.4.4.	Aplicación de la metodología Design Thinking .....	43
3.5.	METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EMPATIZAR .....	43
3.5.1.	Lugar de estudio: Plaza Kennedy del Cantón Saquisilí.....	43
3.5.2.	Situación actual y stakeholders del proceso de clasificación manual del chocho 44	
3.5.3.	Identificación y caracterización del proceso .....	48

3.5.3.1.	Caracterización general de los actores principales .....	48
3.5.3.2.	Propósito de la caracterización .....	48
3.5.4.	Herramienta para empatizar.....	50
3.5.4.1.	Procedimiento de levantamiento de información cualitativa.....	52
3.5.4.2.	Elaboración de mapas de empatía por stakeholder .....	53
3.6.	METODOLOGÍA DESIGN THINKING: REQUERIMIENTO PARA DEFINIR ..	53
3.6.1.	Lluvia de ideas de las dificultades en la clasificación manual .....	53
3.6.2.	Agrupación de información mediante diagrama de afinidad.....	55
3.6.3.	Profundización en causas con la técnica de los 5 Porqués .....	55
3.6.4.	Formulación del árbol de problemas .....	56
3.7.	METODOLOGÍA WATERFALL.....	58
3.8.	METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA IDEAR....	58
3.8.1.	Principios básicos de la fase de ideación.....	58
3.8.2.	Herramientas a utilizar para la fase de ideación .....	59
3.8.2.1.	Procedimiento para la generación de lluvias de ideas .....	59
3.8.3.	Documentación y registro de las ideas .....	59
3.8.4.	Evaluación y selección de las ideas .....	60
3.8.4.1.	Métodos y criterios de ponderación.....	60
3.8.5.	Metodología SCAMPER .....	61
3.8.5.1.	Propósito de la herramienta SCAMPER.....	61
3.8.5.2.	Análisis de los componentes SCAMPER .....	61
3.9.	METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EL DISEÑO	62
3.9.1.	Uso de software CAD para el modelado .....	62
3.9.2.	Recursos digitales de diseño provenientes de Thingiverse .....	63
3.9.3.	Diseño del prototipo en 3D.....	63
3.9.3.1.	Tolva .....	63

3.9.3.2.	Laterales de la banda transportadora.....	64
3.9.3.3.	Rodillos laterales y soporte triangular .....	65
3.9.3.4.	Ambiente controlado.....	66
3.9.3.5.	Divisiones para granos .....	66
3.9.3.6.	Paletas clasificadoras .....	67
3.9.4.	Metodología y definición de los componentes a utilizar .....	68
3.9.4.1.	Opciones de cámaras para visión artificial .....	68
3.9.4.2.	Selección de la tarjeta de control para servomotores.....	70
3.9.4.3.	Opciones de luminarias para el ambiente controlado .....	71
3.9.4.4.	Opciones para la elección de banda transportadora.....	72
3.9.4.5.	Opciones para la selección del servomotor para la clasificación.....	74
3.9.4.6.	Alternativas para selección de material para caja de visión artificial .....	75
3.10.	METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EL PROTOTIPADO .....	77
3.10.1.	Arquitecturas del modelo.....	77
3.10.2.	Requisitos y recursos para el prototipado .....	80
3.10.2.1.	Herramientas y software de construcción .....	80
3.10.3.	Proceso de construcción del prototipo .....	80
3.10.3.1.	Ensamblaje de piezas .....	80
3.10.3.2.	Integración de elementos electrónicos de control .....	81
3.11.	METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EL DESARROLLO.....	81
3.11.1.	Circuitos del modelo .....	81
3.11.2.	Parámetros del modelo de visión artificial.....	85
3.11.2.1.	Lenguaje y entorno de desarrollo Python.....	85
3.11.2.2.	Versión Python 3.13.2.....	85
3.11.2.3.	Entorno de programación IDLE.....	85

3.11.3.	Selección del algoritmo para entrenar el modelo.....	86
3.11.4.	Instalación de librerías en Python.....	86
3.11.4.1.	Parámetros importantes dentro de la programación.....	88
3.11.4.2.	Requerimiento para el entrenamiento .....	89
3.11.4.3.	Configuración de parámetros de la cámara.....	90
3.11.4.4.	Creación de carpetas.....	90
3.11.4.5.	Codificación para la captura automática de imágenes .....	91
3.11.4.6.	Ejecución para el entrenamiento en Windows PowerShell.....	92
4.	ANÁLISIS DE RESULTADOS.....	92
4.1.	EMPATIZAR.....	92
4.1.1.	Agricultores .....	92
4.1.2.	Comerciantes .....	95
4.1.3.	Consumidores .....	96
4.1.3.1.	Análisis de la información del proceso.....	98
4.2.	DEFINIR.....	98
4.2.1.	Lluvia de ideas de los problemas detectados.....	98
4.2.2.	Diagrama de Afinidad .....	100
4.2.2.1.	Evaluar.....	101
4.2.2.2.	Priorizar.....	101
4.2.2.3.	Seleccionar.....	101
4.2.2.4.	Justificar.....	101
4.2.3.	Aplicación de los 5 Porqués al problema central .....	102
4.2.4.	Árbol de problemas .....	103
4.3.	REQUERIMIENTOS .....	105
4.4.	IDEAR .....	106
4.4.1.	Lluvia de ideas.....	106
4.4.2.	Matriz de ponderación de ideas.....	107

4.4.3.	SCAMPER.....	107
4.5.	DISEÑO DEL PROTOTIPO EN 3D.....	109
4.5.1.	Selección de componentes.....	110
4.5.1.1.	Selección de la mejor alternativa para la cámara.....	110
4.5.1.2.	Selección de la mejor alternativa para el Microcontrolador .....	111
4.5.1.3.	Matriz de decisiones y justificación de la selección de la luminaria .....	112
4.5.1.4.	Matriz de decisiones y justificación de la selección de la banda.....	113
4.5.1.5.	Matriz de decisiones y justificación de la selección del servomotor .....	114
4.5.1.6.	Matriz de decisiones para selección de material para caja de Visión artificial 114	
4.6.	PROTOTIPAR.....	115
4.6.1.	Resultados de fabricación e impresión 3D .....	115
4.6.1.1.	Ensamblados laterales.....	116
4.6.1.2.	Ensamble de separación y soporte de laterales .....	116
4.6.1.3.	Ensamble de Rodillos .....	116
4.6.1.4.	acoplamiento de motor a los laterales.....	117
4.6.1.5.	Acoplamiento de Banda transportadora.....	117
4.6.1.6.	Ensamble de Ambiente controlado .....	118
4.6.1.7.	Acoplamiento del circuito al prototipo .....	118
4.6.1.8.	Ensamble de la tolva.....	119
4.6.1.9.	Ensamble de servomotores y paletas .....	120
4.7.	DESARROLLO DEL MODELO DE VISIÓN ARTIFICIAL.....	120
4.7.1.1.	Recolección de imágenes.....	120
4.7.1.2.	Etiquetado de imágenes .....	121
4.7.1.3.	Etiquetado de granos buenos y malos.....	121
4.7.1.4.	Exportaciones de anotaciones en Make Sense.....	122
4.7.1.5.	Entrenamiento del modelo .....	123

4.7.1.6.	Resultados del entrenamiento .....	124
4.7.1.7.	Implementación del código y entrenamiento del modelo .....	125
4.8.	RESULTADOS DE LAS FASES TESTEAR Y TESTEO .....	126
4.8.1.	Análisis de desempeño de los modelos .....	126
4.8.1.1.	Entrenamiento del modelo con variaciones de parámetros.....	126
4.8.1.2.	Evolución de la curva F1 en relación con el umbral de confianza .....	127
4.8.1.3.	Análisis de la curva de precisión según el umbral de confianza.....	128
4.8.1.4.	Análisis de la curva Precision–Recall Curve .....	130
4.8.1.5.	Análisis de la matriz de confusión .....	131
4.8.1.6.	Evaluación global del rendimiento de los modelos entrenados .....	132
4.8.2.	Validación del entrenamiento a través de pruebas experimentales .....	134
4.8.2.1.	Pruebas en tiempo real utilizando computadora .....	134
4.8.2.2.	Pruebas en tiempo real a través de la Raspberry Pi 5 .....	138
4.8.3.	Selección final del mejor sistema de procesamiento .....	142
4.8.4.	Impactos y limitaciones del modelo de visión artificial .....	142
5.	CONCLUSIONES.....	143
6.	RECOMENDACIONES .....	144
7.	REFERENCIAS .....	145
8.	ANEXOS .....	156
8.1.	ENTREVISTAS.....	156
8.1.1.1.	Agricultor.....	156
8.1.1.2.	Comerciante .....	157
8.1.1.3.	Consumidor.....	157
8.2.	Evidencia de las entrevistas realizadas .....	158
8.3.	PCB (Placa de circuito impreso del modelo).....	160
	Componente.....	161
	Función .....	161

Conector.....	161
Arduino Nano .....	161
Control central .....	161
USB .....	161
Puente H .....	161
Control del motor de banda .....	161
J1.....	161
Servomotor 1 .....	161
Paleta de clasificación .....	161
J2.....	161
Servomotor 2 .....	161
Paleta de clasificación .....	161
J3.....	161
Servomotor 3 .....	161
Paleta de clasificación .....	161
J4.....	161
LM2596 (DC1).....	161
Fuente regulador de voltaje .....	161
– .....	161
Computadora .....	161
Programación.....	161
USB .....	161
Alimentación .....	161
Suministro de energía .....	161
– .....	161
8.4. Diagrama de flujo del modelo.....	162
8.5. COSTOS DE LA INVESTIGACIÓN.....	163

8.5.1.1.	Sistema de procesamiento Raspberry pi 5 .....	163
8.5.1.2.	Sistema de procesamiento Computadora .....	164
8.6.	Prompt para la programación del Python de visión artificial .....	165
8.7.	Prompt para la programación del Arduino.....	165
8.8.	PROGRAMACIÓN DEL MODELO DE VISIÓN ARTIFICIAL .....	166

## ÍNDICE DE TABLAS

Tabla 1. Modalidad de titulación.....	1
Tabla 2. Áreas Conocimientos UNESCO.....	1
Tabla 3. Sistema de tareas .....	6
Tabla 4. Jerarquía entre aprendizajes automáticos .....	15
Tabla 5. Comparación de sistemas inteligentes.....	20
Tabla 6. Técnicas Comunes de Preprocesamiento en Análisis de Imágenes .....	25
Tabla 7. Técnicas de Aumento de Datos (Data Augmentation).....	26
Tabla 8. Características principales de lenguajes de programación .....	28
Tabla 9. Entornos de programación.....	29
Tabla 10. Librerías utilizadas en visión.....	29
Tabla 11. Diferentes versiones de YOLO .....	31
Tabla 12. Métricas de evaluación de un modelo .....	34
Tabla 13. Tipos de monitoreos Machine Learning.....	36
Tabla 14. Proyectos de Investigación similares.....	39
Tabla 15. Reglas para realizar lluvia de ideas .....	54
Tabla 16. Grupos de problemas.....	55
Tabla 17. Pasos para realizar un SCAMPER .....	62
Tabla 18. Resultados para desarrollar el modelo de visión artificial.....	105
Tabla 19. Ponderación de las ideas.....	107
Tabla 20. Criterios de ponderación de la cámara .....	110
Tabla 21. Criterios de ponderación del Microcontrolador .....	111
Tabla 22. Criterios de ponderación para la iluminación.....	112
Tabla 23. Criterios de ponderación de la banda .....	113
Tabla 24. Criterios de ponderación del servomotor .....	114
Tabla 25. Criterios de ponderación de material para el ambiente controlado .....	115
Tabla 26. Comparación del valor F1 y umbral de confianza.....	128
Tabla 27. Comparación de precisión según el umbral de confianza .....	129
Tabla 28. Comparación de las métricas de Precision–Recall Curve .....	130
Tabla 29. Comparación de las matrices de confusión .....	131
Tabla 30. Comparación del rendimiento global de los modelos .....	133
Tabla 31. Pruebas del modelo con computadora.....	135
Tabla 32. Métricas calculadas de las pruebas realizadas.....	137

Tabla 33. Resultados globales de la ejecución del modelo .....	138
Tabla 34. Pruebas del modelo con Raspberry .....	139
Tabla 35. Métricas calculadas de las pruebas realizadas .....	140
Tabla 36. Resultados globales de la ejecución del modelo .....	141
Tabla 37. Puntuación del mejor sistema de procesamiento .....	142
Tabla 38. Componentes y funciones del circuito .....	161
Tabla 39. Presupuesto utilizado con Raspberry pi 5 .....	163
Tabla 40. Presupuesto utilizado con computadora .....	164

## ÍNDICE DE FIGURAS

Figura 1. Arquitectura de la inteligencia artificial.....	12
Figura 2. Sistemas inteligentes para la automatización industrial.....	16
Figura 3. Fases para el modelo de visión artificial.....	19
Figura 4. Fases de la visión artificial[49].....	21
Figura 5. Procesamiento inicial de imagenes.....	23
Figura 6. Ejemplos de detección de objetos únicos y múltiples[62].....	27
Figura 7. Arquitectura YOLO.....	30
Figura 8. Construcción e implementación de modelos [86].....	32
Figura 9. Arquitectura de monitoreo de ML[93].....	35
Figura 10. Metodología del proyecto.....	40
Figura 11. Lugar de estudio.....	44
Figura 12. Diagrama de flujo del proceso del chocho.....	47
Figura 13. Granos con puntos negros.....	49
Figura 14. Granos dañados.....	49
Figura 15. Granos buenos.....	50
Figura 16. Plantilla de mapa de empatía.....	51
Figura 17. Estructura de los cinco porqués.....	56
Figura 18. Estructura del árbol de problemas.....	57
Figura 19. Estructura para la lluvia de ideas.....	60
Figura 20. Pieza exportada adaptada.....	64
Figura 21. Tolva dosificadora.....	64
Figura 22. Estructura lateral de la banda.....	65
Figura 23. Acoplamientos de la banda.....	65
Figura 24. Ensamblaje de la banda transportadora.....	66
Figura 25. Ambiente controlado.....	66
Figura 26. División interna de carriles.....	67
Figura 27. Paletas de clasificación.....	67
Figura 28. Cámara Logitech Brio 500.....	69
Figura 29. Cámara Argom Tech.....	70
Figura 30. Arduino Nano V3.0.....	71
Figura 31. Arduino UNO R3.....	71
Figura 32. Led de tres chips.....	72

Figura 33. Leds flexibles .....	72
Figura 34. Cuerina color blanco .....	73
Figura 35. Eslabones de plástico .....	74
Figura 36. Servomotor MG90S .....	74
Figura 37. Servomotor SG90.....	75
Figura 38. Material MDF para el ambiente controlado .....	76
Figura 39. Material PLA para el ambiente controlado .....	76
Figura 40. Arquitectura opción A.....	78
Figura 41. Arquitectura opción B .....	79
Figura 42. Circuitos opción A .....	82
Figura 43. Circuito opción B .....	84
Figura 44. Parámetros de captura .....	90
Figura 45. Estructura del dataset al iniciar el entrenamiento .....	91
Figura 46. Captura de imágenes mediante código.....	92
Figura 47. Mapa de empatía del agricultor .....	93
Figura 48. Mapa de empatía del comerciante.....	95
Figura 49. Mapa de empatía del consumidor .....	97
Figura 50. Problemas en la clasificación del grano .....	99
Figura 51. Diagrama de afinidad .....	100
Figura 52. 5 porqués de la clasificación manual del chocho .....	102
Figura 53. Árbol de problemas .....	104
Figura 54. Métodos de clasificación de granos .....	106
Figura 55. SCAMPER .....	108
Figura 56. Diseño final del prototipo.....	110
Figura 57. Laterales de la banda trasportadora .....	116
Figura 58. Soporte de los laterales.....	116
Figura 59. Montaje de rodillos .....	117
Figura 60. Acoplamiento del motor DC .....	117
Figura 61. Cuerina blanca.....	118
Figura 62. Pegado de ambiente controlado .....	118
Figura 63. Integración del sistema electrónico .....	119
Figura 64. Ensamblaje de todos los componentes de la tolva .....	120
Figura 65. Montaje de servomotores y paletas .....	120

Figura 66. Captura de imágenes en el ambiente controlado.....	121
Figura 67. Plataforma MAKE SENSE .....	121
Figura 68. Se muestra el etiquetado de los granos en buen estado.....	122
Figura 69. Se muestra el etiquetado de los granos en mal estado .....	122
Figura 70. Proceso de exportación de etiquetas para el entrenamiento.....	123
Figura 71. Entrenamiento del modelo de visión artificial .....	124
Figura 72. Estructura del dataset al finalizar el entrenamiento .....	125
Figura 73. Ejecución del entrenamiento con el código .....	126
Figura 74. F1-Confidence curve.....	128
Figura 75. Precision - confidence curve .....	129
Figura 76. Precision- recall curve.....	131
Figura 77. Matriz de confusión.....	132
Figura 78. Resultados del entrenamiento .....	134
Figura 79. Sistema de procesamiento computadora .....	135
Figura 80. Métricas de evaluación en tiempo real.....	138
Figura 81. Sistema de procesamiento Raspberry Pi 5 .....	139
Figura 82. Métricas de evaluación en tiempo real.....	141
Figura 83.....	158
Figura 84. Entrevista 2.....	159
Figura 85. Entrevista 3.....	159
Figura 86. Entrevista 4.....	160
Figura 87. Placa PCB.....	161
Figura 88. Diagrama del funcionamiento del prototipo .....	162

## INFORMACIÓN GENERAL

**Tema del proyecto:** Desarrollo de un modelo de visión artificial para la clasificación automática de la calidad del chocho (*Lupinus Mutabilis*).

### Modalidad de Titulación:

Tabla 1. Modalidad de titulación

MODALIDAD DE TITULACIÓN	HOMOLOGACIONES PARA INFORME FINAL DE TITULACIÓN	SELECCIÓN
Propuesta tecnológica	Informe de propuesta tecnológica	
	Patente, Modelo de utilidad, Certificado de propiedad intelectual.	
	Artículo científico	
Proyecto de investigación	Informe de Proyecto de investigación	X
	Artículo científico	
	Patente, Modelo de utilidad, Certificado de propiedad intelectual.	
Exámen de indicadores de RDA		

**Trabajo de Titulación Vinculado al Proyecto:** Transformación Digital: El Impacto de las Tecnologías 4.0 en la Industria y la Academia

### Equipo de Trabajo de Titulación:

Manuel Alejandro Vargas Figueroa

Richard Steven Yanchaguano Nicolalde

**TUTOR:** Ing. MSc. Ángel Guillermo Hidalgo Oñate

**Área de Conocimiento:** Seleccionar el código de correspondiente UNESCO:

Tabla 2. Áreas Conocimientos UNESCO

07 ingeniería, Industria, Construcción	071 ingeniería y Profesiones Afines	0714 eléctrica y automatización
--	-------------------------------------	---------------------------------

**Línea de investigación:** Tecnología industrial.

**Sublíneas de investigación de la Carrera:** Sistemas integrados de producción y operaciones industriales para el desarrollo sostenible. Innovación tecnológica de los sistemas productivos.

## 1. INTRODUCCIÓN

El *Lupinus Mutabilis*, conocido comúnmente como chocho o tarwi, es una leguminosa proveniente de los Andes con alto valor nutricional y un creciente interés agroindustrial por su contenido proteico, aceites saludables y propiedades beneficiosas. En Ecuador, su producción se concentra principalmente en las provincias de Cotopaxi, Chimborazo y Tungurahua, donde representa un cultivo representativo tanto por su valor económico como por su relevancia cultural[1]. No obstante, uno de los principales obstáculos en su cadena de valor es la etapa de clasificación por calidad, comúnmente realizada de forma manual, lo que introduce altos niveles de variabilidad subjetiva, errores humanos y baja eficiencia operacional. Esta dificultad limita la competitividad del producto en mercados nacionales e internacionales donde la igualdad y valor agregado son factores determinantes[2]

El uso de tecnologías de visión artificial y aprendizaje profundo se ha consolidado como una herramienta eficiente en la automatización de procesos agroindustriales, logrando resultados comparables a los obtenidos por la percepción humana en tareas de detección de defectos y evaluación de calidad. En cultivos como arroz, maíz, frijoles o frutas como duraznos y peras, diversos estudios demuestran que los modelos basados en redes neuronales convolucionales (CNN),[3] combinados con técnicas de segmentación de imagen y aprendizaje transferido (ResNet, MobileNet, YOLO), alcanzan precisiones de entre el 94% y 99%, reduciendo significativamente el margen de error y los costos de operación[4][5] En particular, la investigación desarrollada por Freire Díaz et al. (2021) sobre la clasificación del chocho mediante visión artificial reporta un análisis de forma y color, demostrando la viabilidad técnica de aplicar estas metodologías en el contexto de clasificación automatizada[6].

Desde una perspectiva tecnológica y comunitaria, la automatización de la clasificación del chocho no solo permitiría mejorar la trazabilidad y estabilidad del producto, sino también contribuiría a la sostenibilidad laboral dentro del sector agrícola, al reducir los impactos ergonómicos del trabajo manual repetitivo integrando herramientas de aprendizaje automático (Machine Learning) y visión por computadora, se abren capacidad de monitoreo en tiempo real, trazabilidad de lotes y caracterización objetiva de la calidad visual, parámetros alineados con los estándares de la agroindustria moderna[7]. En este contexto, el presente proyecto de titulación tiene como objetivo desarrollar un modelo de visión artificial para la clasificación automatizada del *Lupinus Mutabilis*, mediante la implementación de algoritmos de aprendizaje profundo para detectar categorías de calidad del grano.

El alcance del estudio se centrará en la etapa postcosecha del cultivo, específicamente en la identificación visual de características físicas de un grano bueno o malo, utilizando imágenes digitales procesadas empleando estrategias de segmentación y redes neuronales convolucionales[8]. No se abordarán variables de tipo químico ni sensorial. El procedimiento incorporará fases de adquisición de imágenes, elaboración de dataset etiquetado, entrenamiento del modelo y valoración de métricas de desempeño, los hallazgos permitirán sentar las bases para el desarrollo de sistemas automatizados aplicables a otros cultivos andinos[9]. El estudio se enmarca dentro de las soluciones tecnológicas para la automatización agroindustrial, enfocándose a promover la innovación en la producción del *Lupinus Mutabilis* en Ecuador[10]. Su propósito principal es fortalecer la sostenibilidad del sector agrícola mediante la combinación de la ciencia y la ingeniería aplicada, promoviendo el desarrollo de recursos tecnológicos que optimicen los procesos productivos y garanticen un mayor rendimiento en la cadena de producción agroindustrial.

## **1.1. SITUACIÓN PROBLEMÁTICA**

En el Cantón Saquisilí de la provincia de Cotopaxi el proceso de clasificación del *Lupinus Mutabilis* (chocho) se desarrolla principalmente de forma manual debido a la limitada incorporación de herramientas tecnológicas en esta actividad. Esta situación genera variabilidad en los criterios de clasificación y dependencia humana, lo que dificulta la obtención de resultados uniformes. La escasa aplicación de tecnologías en la agroindustria local evidencia una brecha tecnológica en el proceso de clasificación del chocho, creando una investigación orientada al análisis y desarrollo de alternativas basadas en visión artificial.

## **1.2. FORMULACIÓN DEL PROBLEMA**

¿De qué manera un modelo de visión artificial puede ayudar al proceso de clasificación del Chocho (*Lupinus Mutabilis*), realizada por trabajadores del Cantón Saquisilí provincia de Cotopaxi?

## **1.3. OBJETO Y CAMPO DE ACCIÓN**

**1.3.1. Objeto de Investigación:** Proceso de clasificación por categoría del Chocho (*Lupinus Mutabilis*) mediante visión artificial.

**1.3.2. Campo de Acción:** 3311.01 Tecnología de la Automatización

## **1.4. BENEFICIARIOS**

### **1.4.1. Directos**

Pequeños productores agrícolas de chocho en la región, mediante la implementación de un sistema automatizado de clasificación

Universidad Técnica de Cotopaxi estudiantes de la carrera de Ingeniería Industrial podrán incorporar esta investigación como ejemplo práctico del uso de inteligencia artificial.

### **1.4.2. Indirectos**

Investigadores y desarrolladores en tecnologías agroindustriales, quienes contarán con un caso de estudio práctico de visión artificial y redes neuronales en el sector agrícola, que podrá ser utilizado como origen para el diseño, validación y mejora de futuros sistemas automatizados en clasificación y control de calidad.

## **1.5. JUSTIFICACIÓN**

El presente proyecto de titulación tiende al proceso de clasificación de calidad del chocho (*Lupinus Mutabilis*), un cultivo de gran relevancia económica y nutricional en la región andina. A pesar de su importancia, actualmente existen escasez de modelos que permitan clasificar este producto de manera automatizada.

Desde un enfoque tecnológico e innovador, la investigación propone el desarrollo de un modelo de visión artificial basado en redes neuronales. El uso de inteligencia artificial en el sector agroalimentario es una tendencia creciente a nivel mundial. En el ámbito académico, la propuesta permite integrar conocimientos de ingeniería industrial, inteligencia artificial, control de calidad y mejora de procesos productivos. También representa una oportunidad para contribuir al desarrollo de soluciones tecnológicas que respondan a las necesidades reales del entorno.

## **1.6. OBJETIVOS**

### **1.6.1. General**

Desarrollar un modelo de visión artificial aplicando algoritmos de aprendizaje automático, para la clasificación automática del chocho (*Lupinus Mutabilis*).

### **1.6.2. Específicos**

- Caracterizar el proceso de clasificación manual de la calidad del chocho (*Lupinus Mutabilis*) analizando cualitativamente el método de trabajo actual.
- Desarrollar un modelo de visión artificial utilizando un algoritmo de aprendizaje automático y herramientas computacionales para el procesamiento digital de imágenes, que permitan clasificar los estados de calidad del chocho (*Lupinus Mutabilis*)
- Analizar el desempeño del modelo de visión artificial en ambientes controlados, para la validación de su capacidad de clasificación.

### **1.7. HIPÓTESIS**

El desarrollo de un modelo de visión artificial permitirá demostrar la viabilidad de automatizar el proceso de clasificación manual del chocho (*Lupinus Mutabilis*) mediante el entrenamiento de imágenes en un entorno controlado.

### **1.8. ALCANCE**

El alcance de esta tesis se centra en la Investigación más el Desarrollo (I+D), de un modelo prototipo de visión artificial para la clasificación del *Lupinus Mutabilis* (chocho) en un entorno controlado. Dicho modelo no busca ser completamente funcional o definitivo, sino representar el punto de inicio que incentive la investigación y mejora tecnológica en el campo de la clasificación automatizada en la agroindustria ecuatoriana. La investigación se enfocará en la adquisición y procesamiento de imágenes digitales para evaluar propiedades visuales del chocho y en la aplicación de algoritmos de aprendizaje automático para diferenciar los estados de grano. La evaluación estará limitada a pruebas experimentales del modelo construido sin aplicación directa en línea de producción, este trabajo pretende contribuir al desarrollo tecnológico en la agroindustria y proporcionar información valiosa para futuros proyectos de automatización en cultivos andinos.

### **1.9. SISTEMA DE TAREAS**

A continuación, en la Tabla 3 se describen las actividades con los respectivos instrumentos que se utilizarán para obtener los resultados esperados.

Tabla 3. Sistema de tareas

Objetivo específico	Actividades (tareas)	Resultados esperados	Técnicas, Medios e Instrumentos
Caracterizar el proceso de clasificación manual de la calidad del chocho (Lupinus Mutabilis) analizando cualitativa y cuantitativamente el método de trabajo actual.	Investigación documental sobre producción, postcosecha y clasificación manual del chocho	Fundamentación teórica del proceso productivo y criterios de clasificación manual	Investigación bibliográfica, artículos científicos, normativas, bases de datos académicas (Scopus, Google Scholar)
	Identificación de actores principales involucrados en el proceso	Stakeholders claramente definidos para la caracterización del proceso	Observación directa, revisión documental y elaboración de preguntas
	Entrevista a los stakeholders en la plaza Kennedy del cantón Saquisilí	Mapas de empatía y análisis cualitativo	Grabadora de audio y fotografías
	Análisis de problemas mediante herramientas para definir el problema central	Diagrama de afinidad, 5 porqués, lluvia de ideas y árbol de problemas	Software Canva y Napkin para el desarrollo de las herramientas analizadas
	Definición de requerimientos del sistema de visión artificial	Requerimientos funcionales y técnicos del sistema	Análisis técnico, documentación
Entrenar un modelo de visión artificial con algoritmos de aprendizaje automático que clasifique los estados de la calidad del chocho (Lupinus Mutabilis).	Generación de alternativas de soluciones tecnológicas	Lluvia de ideas, matriz de ponderación y SCAMPER	Software Canva y Napkin para el desarrollo de las herramientas analizadas
	Diseño de la arquitectura para el modelo de visión artificial	Diseño digital del sistema de captura de imágenes en tiempo real	Software CAD, iluminación, cámara y estructura
	Construcción del prototipo físico del sistema	Prototipo funcional del sistema de clasificación	Impresión 3D, herramientas mecánicas
	Recolección de imágenes del chocho en entorno controlado	Dataset de imágenes representativas de los estados del grano	Cámara digital, ambiente controlado
	Etiquetado de imágenes (granos buenos y malos)	Dataset etiquetado listo para entrenamiento	Plataforma Make Sense, almacenamiento digital
	Selección y entrenamiento del modelo de aprendizaje automático	Modelo de visión artificial entrenado para clasificación	Python, librerías de Deep Learning, GPU/CPU
Analizar el desempeño del modelo de visión artificial en ambientes controlados, para la validación de su capacidad de clasificación automática.	Ejecución de pruebas del modelo en ambiente controlado	Resultados preliminares del desempeño del modelo	Pruebas experimentales, registros y excel
	Evaluación del modelo mediante métricas de desempeño	Métricas cuantitativas de desempeño del modelo	Python, análisis estadístico, precisión, recall y F1_score
	Validación del modelo con granos reales en tiempo real	Modelo validado en condiciones controladas	Computadora / Raspberry Pi 5
	Análisis comparativo entre pruebas y selección del mejor sistema	Tablas comparativas de las pruebas realizadas y selección del mejor sistema procesamiento.	Métricas de evaluación (precisión, recall, F1_score), Excel y revisión bibliográfica

## **2. FUNDAMENTACIÓN TEÓRICA**

### **2.1. ANTECEDENTES**

En Ecuador, la clasificación manual del grano de *Lupinus Mutabilis* (chocho) se realiza según su color y forma. Un estudio reciente presenta una alternativa utilizando visión artificial, desarrollada en la plataforma Simulink de Matlab y ejecutada en una Raspberry Pi. El sistema utiliza el modelo de color HSV para discriminar áreas en la imagen por su color y evalúa la forma del grano según su excentricidad. Con una precisión del 81.83% comparado con la clasificación humana, el sistema automatiza el proceso, mejorando la precisión y reduciendo la variabilidad del método manual [12].

La detección temprana de enfermedades en cultivos es un aspecto crucial para conservar la calidad y cantidad del producto. El ejemplo de las plantaciones de cacao, el reconocimiento de la enfermedad conocida como "mazorca negra" exige métodos avanzados para detectarla a tiempo mediante evolución visual directa. Bajo estas condiciones los modelos de visión artificial basados en redes neuronales profundas han demostrado progresos significativos. Estudios recientes que evaluaron modelos como YOLOv11 e InceptionV3 en imágenes de mazorcas afectadas mostraron precisiones de hasta un 79%, destacando la robustez y velocidad de estos enfoques para monitoreo y control fitosanitario [13].

El aprendizaje profundo de redes neuronales ha sido aplicado también en la detección de enfermedades en plantas empleado modelos preentrenados como AlexNet, VGG19, MobileNetV2 y ResNet50. Estos modelos han demostrado un rendimiento elevado en la clasificación de imágenes de hojas enfermas, superando los métodos convencionales de extracción manual de propiedades y logrando precisiones superiores al 95% en pruebas de detección de enfermedades foliares, como se evidencia en estudios recientes sobre papa y otros cultivos agrícolas [13], [14]. Estos estudios permiten analizar desafíos como la limitación de conjuntos de datos, mejorando la precisión en aplicaciones de agricultura, gracias a la capacidad de los modelos para aprender patrones complejos y generalizar en condiciones variables.

Las redes neuronales convolucionales (CNN) son fundamentales en la clasificación de imágenes mediante el aprendizaje automático su habilidad para aprender características espaciales complejas ha sido aplicada con éxito en la determinación del grado de fermentación de cacao mediante análisis de color RGB y técnicas de segmentación, logrando una certeza del

75% en la clasificación visual [14]. Esta misma estrategia es aplicable a la clasificación visual del *Lupinus Mutabilis* ya que ambos procesos se basan en el estudio de características visuales.

Diferentes investigaciones sobre la calidad de frutas y verduras han demostrado que algoritmos capaces de examinar atributos visuales como color, textura, tamaño, forma y defectos permiten una clasificación aceptable de los productos. Un ejemplo relevante es el estudio de Promboonruang y Boonrod (2023), donde se implementó un sistema basado en redes neuronales convolucionales (CNN) y aprendizaje profundo para clasificar la calidad de vegetales orgánicos, logrando una precisión del 85% con el modelo Inception V3. El proceso técnico habitual consiste en la captura de imágenes bajo condiciones controladas, seguido de técnicas de segmentación para aislar el objeto de interés y la extracción de atributos visuales relevantes [15].

A pesar de los avances tecnológicos existen carencias de investigación sobre el *Lupinus Mutabilis*, ya que la mayoría de los estudios se centran en cultivos más comunes, como el cacao y el maíz, y la falta de bases de datos etiquetadas limita el desarrollo de modelos robustos para la clasificación del chocho lo que abre un espacio de investigación en este campo.

## **2.2. MARCO TEÓRICO**

### **2.2.1. Origen y distribución del *Lupinus Mutabilis***

El chocho, también conocido como lupino andino, es una leguminosa originaria de los Andes, particularmente de países como Ecuador, Perú y Bolivia, donde ha sido cultivada desde tiempos preincaicos que no solo es valorada por su capacidad de adaptación a terrenos de altura [16], sino también por sus cualidades nutricionales y su utilidad en la gastronomía tradicional andina cuyo cultivo tiene su nivel de importancia económica y social en comunidades agrícolas de la Sierra ecuatoriana.

El chocho se desarrolla de forma óptima en zonas de altura entre los 2.000 y 3.800 metros sobre el nivel del mar, en zonas caracterizadas por climas templado-fríos, suelos bien drenados, buena exposición solar, suelos francos o franco-arenosos con un pH ligeramente ácido o neutro. Su resistencia a temperaturas bajas y su tolerancia a suelos pobres le otorgan una ventaja frente a otros cultivos, y además, como leguminosa, fija nitrógeno en el suelo, lo que mejora su fertilidad y beneficia a los cultivos posteriores [6], [17], [18].

Desde el punto de vista nutricional, el chocho es considerado un superalimento por su alto contenido de proteínas (alrededor del 40%), grasas saludables (especialmente omega-3 y

omega-6), fibra dietética, calcio, hierro, no contiene gluten lo que lo hace apto para personas celíacas; sin embargo, también contiene alcaloides amargos en estado natural, que deben eliminarse mediante procesos de lavado y desamargado para que el grano sea apto para el consumo humano [19].

El ciclo de vida del chocho inicia con la siembra directa en el campo y es relativamente corto por su capacidad de adaptación se convierte en una alternativa valiosa para la agricultura de altura en la región andina, cuyas principales fases se describen a continuación:

- Las semillas germinan en aproximadamente 8 a 10 días
- El crecimiento vegetativo ocurre durante las primeras 8 a 12 semanas
- La fase de floración suele iniciarse entre el segundo y tercer mes.
- La madurez fisiológica ocurre entre los 5 y 7 meses, dependiendo de la altitud y las condiciones climáticas.
- La cosecha se realiza cuando las vainas han secado, y posteriormente se procede al desgrane y selección del grano.

#### **2.2.1.1. Coloración del grano**

La coloración de la testa es uno de los rasgos morfológicos más relevantes del grano del chocho y es el primer parámetro que emplean los consumidores, comerciantes y agricultores para distinguir las calidades y determinar su preferencia al comprar. La variabilidad genética de *Lupinus Mutabilis* produce una extensa variedad de colores en la superficie de la semilla, que están relacionados con características estéticas y también con eventuales contrastes en términos de composición química, contenido de alcaloides y finalidad de uso. Dado que posibilita sustituir juicios subjetivos por criterios de uniformidad y tonalidad medibles, esta diversidad cromática hace del color un elemento fundamental para la creación de sistemas de visión artificial enfocados en la clasificación objetiva del grano [20].

Según las tesis y estudios más recientes, se pueden describir los grupos de coloración del grano de chocho de la siguiente forma [21]:

- **Blanco / color crema:** Semillas con una testa homogénea y clara, que son comunes en ciertas variedades comerciales; se vinculan con un mejor precio y mayor aceptación sensorial, ya que se consideran de mejor calidad y más "limpias".

- **Amarillo pálido:** Granos de color amarillento claro, que son comunes en los ecotipos tradicionales andinos; se aceptan con gusto para el consumo, aunque algunos mercados los distinguen del blanco debido a su aspecto un poco menos homogéneo.
- **Pardo moteado o beige:** Testa beige con vetas o manchas oscuras; estas generalmente son propias de materiales locales o mezclas varietales y, a pesar de que conservan un buen valor nutritivo, su aspecto dispar disminuye su preferencia comercial frente a los colores más claros.
- **Gris / grisáceo:** Semillas de colores opacos que están asociadas a lotes menos homogéneos o con cierto nivel de envejecimiento, por lo cual se utilizan más a menudo para la transformación industrial o el autoconsumo.
- **Negro / marrón oscuro:** Colores que tienen una baja demanda en el mercado fresco; algunos trabajos los asocian con la presencia de más compuestos fenólicos y, en algunos casos, con niveles más altos de alcaloides. Esto requiere procesos de desamargado más estrictos antes del consumo.

#### 2.2.1.2. Características de clasificación de proceso manual

Las características de clasificación responden a criterios visuales y táctiles aplicados tradicionalmente por operarios durante las etapas de selección postcosecha o postlavado que permiten contar con criterios para separar granos aptos para el consumo o comercialización de aquellos defectuosos o contaminados [23].

- **Tamaño del grano:** Se refiere a las dimensiones del chocho, considerando que los granos grandes son preferidos en el mercado por su mejor presentación y mayor rendimiento, mientras que los pequeños suelen ser considerados de menor calidad o destinados a otros usos.
- **Forma del grano:** Una forma regular indica un desarrollo adecuado, mientras que las deformaciones pueden ser signo de problemas genéticos, daños mecánicos o estrés ambiental durante el cultivo.
- **Color del grano:** El color óptimo del chocho es blanco cremoso uniforme, mientras que variaciones como manchas amarillas, grises u oscuras pueden indicar deterioro, fermentación, hongos o mala conservación.
- **Integridad del grano:** Hace referencia a si el grano está completo o roto, considerando que los granos enteros tienen mayor valor comercial, mientras que los partidos son descartados o destinados a procesamiento secundario.

- **Presencia de impurezas o cuerpos extraños:** Incluye la identificación de elementos ajenos al producto, como piedras, palos, tierra u otros residuos que afectan la inocuidad y presentación del producto.
- **Daños por plagas o enfermedades:** Se manifiestan como orificios, manchas o deformaciones visibles en el grano, causados por insectos, hongos u otras afecciones, lo que compromete la calidad sanitaria del producto.
- **Textura superficial:** Se percibe al tacto o visualmente, y evalúa si la superficie del grano es lisa (deseable) o presenta grietas, rugosidades o arrugas, lo cual puede estar relacionado con un secado inadecuado o envejecimiento del grano.

Estas características son evaluadas de forma visual y manual por operarios capacitados, quienes clasifican el chocho generalmente sobre bandejas o mesas de selección, utilizando su experiencia para identificar y separar los granos que cumplen con los estándares de calidad establecidos, mismo que puede ser bastante preciso cuando lo realiza personal entrenado pero que presenta limitaciones importantes en cuanto a eficiencia, consistencia y escalabilidad [24].

La clasificación manual es inherentemente lenta y laboriosa, lo que reduce la capacidad de procesamiento en operaciones de gran volumen, y además es subjetiva, ya que está influenciada por factores humanos como la fatiga, la variabilidad en el criterio de evaluación y las condiciones de iluminación del entorno lo que genera una mayor probabilidad de error o inconsistencia en los lotes clasificados, lo que puede afectar la uniformidad del producto final y, por ende, la satisfacción del cliente [25].

### **2.2.1.3. Limitaciones del proceso manual**

La clasificación manual, si bien ha sido una práctica tradicional en el proceso postcosecha, representa una limitante significativa para alcanzar altos niveles de productividad y calidad en la industria agroalimentaria ya que, es altamente dependiente del juicio humano y requiere de tiempo, esfuerzo y experiencia para lograr resultados consistentes [26].

Ante esta realidad, la automatización mediante tecnologías como la visión artificial se convierte en una necesidad estratégica que permite mejorar de manera significativa la eficiencia operativa, ya que estas nuevas tecnologías son capaces de procesar grandes volúmenes de granos en tiempos reducidos y con un margen de error considerablemente menor. Así también, es importante considerar que una de las características de estos sistemas es que no solo replican los criterios de calidad establecidos, sino que adicionalmente pueden ajustarse y escalarse según los requerimientos específicos de la producción [27].

Finalmente, la automatización contribuye a la reducción de costos operativos a largo plazo, al disminuir exponencialmente los errores de clasificación y al permitir una trazabilidad completa de productos y al contar con para la información para una documentación más precisa del proceso, lo cual es clave para acceder a mercados internacionales con políticas exigentes de importación de alimentos.

Se ha calculado que la inspección manual puede tener tasas de error de clasificación próximas al 5-15% en productos agrícolas, sobre todo cuando las jornadas son largas y hay fatiga visual. Asimismo, las comparaciones entre la inspección humana y los sistemas de visión artificial en granos y frutas indican que, al cambiar la selección manual por la clasificación automatizada sin perder ni disminuir la exactitud en el reconocimiento de fallos, se logra aumentar 2-3 veces el rendimiento en términos de volumen procesado por hora [25].

### 2.2.2. Fundamentos de la Inteligencia Artificial (IA)

La relación jerárquica y las interrelaciones entre el Machine Learning, la Inteligencia Artificial y el Deep Learning son multidimensionales en lugar de lineales, con numerosas aplicaciones especializadas que surgen de sus puntos de cruce. La arquitectura integrada de IA incluye muchas ramas especializadas que funcionan de manera autónoma y también interconectadas. La Figura 1 a continuación ilustra esta compleja arquitectura y sus campos de aplicación.

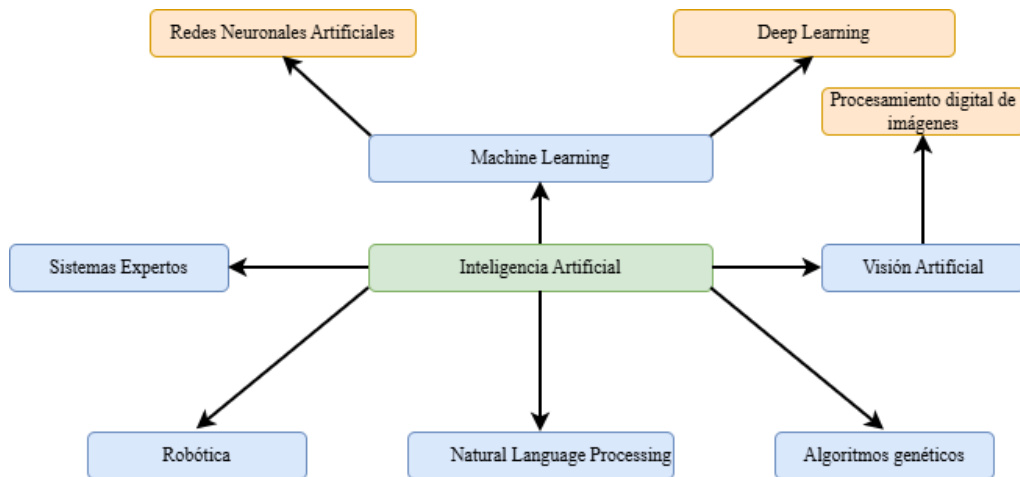


Figura 1. Arquitectura de la inteligencia artificial

En el ámbito de las Redes Neuronales Artificiales (RNA), se establece la estructura básica subyacente en el aprendizaje profundo, lo que posibilita modelar automáticamente relaciones no lineales complejas en los datos. Las RNA han mostrado una habilidad extraordinaria para clasificar, agrupar, predecir y reconocer patrones, en particular en las labores que requieren modelar fenómenos de alta complejidad [28]. Cuando se utilizan para el procesamiento de

imágenes, las RNA tienen la capacidad de hacer automáticamente la extracción y selección de las características, lo que permite obtener resultados más rápidos y precisos en comparación con los métodos manuales.

Por otro lado, el Aprendizaje Profundo (Deep Learning) es una subdisciplina de ML que emplea redes neuronales profundas (que tienen muchas capas, generalmente entre 8 y más de 152 en arquitecturas actuales) para realizar la extracción de características jerárquica. El deep learning ha transformado el análisis de imágenes médicas, proporcionando soluciones de diagnóstico automatizado que son precisas y eficientes. Los factores que han contribuido a su reciente éxito son los siguientes[29]:

- La aceleración mediante hardware (GPUs, chips de IA especializados)
- El acceso a extensos conjuntos de datos etiquetados (como ImageNet con más de 14 millones de imágenes etiquetadas)
- Avances en algoritmos para entrenar arquitecturas de redes.

El procesamiento digital de imágenes, en cambio, es la rama especializada que utiliza redes neuronales para realizar tareas concretas de visión computacional. Las CNN, a partir de píxeles en bruto, aprenden automáticamente representaciones por capas. Durante las capas iniciales se reconocen propiedades elementales (texturas, bordes) y en las más profundas detectan patrones complejos y estructuras a nivel de objetos. Cuando se utilizan para clasificar productos agrícolas, las CNN optimizadas logran una exactitud mayor al 98% en la identificación de fallos [30].

Los sistemas expertos son sistemas de inteligencia artificial que imitan la habilidad de los especialistas humanos para tomar decisiones en áreas específicas. Han experimentado un cambio importante al incorporar modelos híbridos, aprendizaje profundo y procesamiento de lenguaje natural, lo que ha optimizado su capacidad de procesar grandes cantidades de información, así como su adaptabilidad y precisión. Para finales de 2026, se prevé que el 90% de los sistemas expertos modernos contarán con elementos de Machine Learning, mientras que, en 2025, la cifra es del 84% [31].

Por otra parte, la robótica es un campo que emplea el aprendizaje automático (ML) y el aprendizaje profundo (DL) para posibilitar que los sistemas robotizados aprendan de su entorno, tomen decisiones por sí mismos y realicen tareas complejas con escasa supervisión humana [32]. La incorporación del aprendizaje profundo en la robótica ha hecho posible que existan sistemas autónomos más complejos en exploración, medicina, manufactura y servicios.

El Procesamiento de Lenguaje Natural (NLP), por otro lado, es una rama especializada de la IA que recurre al aprendizaje profundo (redes neuronales recurrentes, LSTMs y transformadores como BERT y GPT) para comprender y producir lenguaje humano. El deep learning ha revolucionado de manera radical el procesamiento del lenguaje natural (NLP): en la traducción automática con redes neuronales, ha sobrepasado las técnicas estadísticas anteriores; en la clasificación de textos, análisis de sentimientos y respuestas a preguntas, los modelos de deep learning exhiben un rendimiento sobresaliente. Modelos actuales, como GPT-3, cuentan con 175 billones de parámetros, lo que les permite llevar a cabo una amplia variedad de tareas lingüísticas [33].

Por último, los algoritmos genéticos tienen métodos de optimización que emplean la selección natural y la mutación para solucionar problemas de optimización complejos, inspirándose en la evolución biológica. Con frecuencia, se combinan con redes neuronales para optimizar arquitecturas (NAS - Neural Architecture Search) y seleccionar hiperparámetros en sistemas de aprendizaje automático y profundo [34].

#### **2.2.2.1. Machine Learning y Deep Learning**

El aprendizaje automático (Machine Learning, ML) es una rama de la inteligencia artificial que abarca la habilidad de los sistemas para identificar patrones particulares en datos de entrenamiento y automatizar el procedimiento de creación de modelos analíticos [35]. A diferencia de la programación convencional, donde cada regla se detalla, el aprendizaje automático (ML) posibilita que los algoritmos detecten patrones a partir de datos sin necesidad de ser programados con precisión para cada función particular. La capacidad de las máquinas para resolver problemas complejos ha sido transformada por el aprendizaje automático, lo que posibilita sistemas inteligentes en campos especializados como la predicción y clasificación de objetos, el reconocimiento de patrones y el diagnóstico médico [36].

El Deep Learning (DL) es un concepto que proviene de la inteligencia artificial, y se fundamenta en arquitecturas de redes neuronales artificiales (ANN) con varias capas de procesamiento. Los modelos de aprendizaje profundo, en numerosas aplicaciones, tienen un rendimiento superior al de los métodos convencionales de aprendizaje automático y a las técnicas tradicionales para el análisis de datos. El Deep Learning se ha consolidado como una tecnología revolucionaria, con un mercado mundial que alcanzó los \$10.2 billones de dólares en 2022 y que se estima llegará a \$93.8 billones de dólares para el año 2028, lo que representa una tasa de crecimiento anual compuesta (CAGR) del 39.2% [37].

Las redes neuronales artificiales son los elementos esenciales para construir modelos de aprendizaje profundo, y están formadas por nodos o "neuronas" interconectadas que gestionan información de forma distribuida, imitando las conexiones sinápticas del cerebro [28]. Una red neuronal es una función matemática que recibe entradas y genera salidas. Se trata de un grafo computacional en el que circulan arreglos multidimensionales. Las capas de las redes neuronales están compuestas por "neuronas", que son responsables de procesar y enviar señales a los nodos siguientes. En teoría, una red neuronal puede aproximar cualquier función y representar la solución a cualquier desafío de aprendizaje supervisado.

En resumen, el aprendizaje profundo ha generado diferentes arquitecturas especializadas en función del tipo de dato y de tarea, para imágenes y videos, se utilizan redes neuronales convolucionales (CNNs); para datos secuenciales, las redes recurrentes (RNNs) y sus versiones Long Short-Term Memory (LSTMs) para manejar comunicación escrita y verbal, los modelos de deep learning enfocados en el procesamiento del lenguaje natural (NLP). La Tabla 4 sintetiza de manera jerárquica la relación entre el aprendizaje automático, el aprendizaje profundo y la inteligencia artificial. Enfatiza que las arquitecturas profundas tienden a lograr niveles de precisión superiores al 95% en trabajos especializados, lo cual respalda su elección como fundamento del modelo de visión artificial para clasificar el chocho[29].

Tabla 4. Jerarquía entre aprendizajes automáticos

<b>Rol Jerárquico</b>	<b>Aplicaciones principales</b>	<b>Concepto</b>	<b>Elementos Clave</b>	<b>Precisión Típica</b>
<b>Inteligencia Artificial (IA)</b>	Rango extenso: diagnóstico, autonomía, PLN, visión.	Habilidad de las máquinas para llevar a cabo funciones cognitivas (razonamiento y la creatividad).	Visión, procesamiento del lenguaje, sistemas expertos, DL y ML	La variabilidad es del 70-99% según la aplicación.
<b>Machine Learning (ML)</b>	Predicción, detección de patrones, agrupamiento y clasificación.	Sistemas sin necesidad de una programación explícita, aprenden patrones a partir de los datos	Sistemas de soporte vectorial, algoritmos supervisados y no supervisados	Por lo general, 80-95% típicamente
<b>Deep Learning (DL)</b>	Reconocimiento de objetos, diagnóstico médico, NLP, visión por computadora.	Redes neuronales profundas (con varias capas) que extraen rasgos de manera jerárquica	CNNs, RNNs, LSTMs, Transformers, redes generativas	En tareas especializadas, un porcentaje de 95-99% o más

### 2.2.3. Sistemas inteligentes de visión para la automatización industrial

La convergencia de la inteligencia artificial (IA), la visión artificial (VA) y la visión por computador (VC) ha dado lugar a sistemas inteligentes de visión que cambian el modo en que las máquinas analizan datos visuales para decidir de manera autónoma. Estos sistemas

constituyen una transformación paradigmática que supera la simple captación de imágenes e incluye habilidades de toma de decisiones, razonamiento y aprendizaje que imitan funciones cognitivas propias del ser humano[38]. En la Figura 2 que se presenta a continuación ilustra cómo estos tres pilares se unen para lograr la automatización industrial.




Figura 2. Sistemas inteligentes para la automatización industrial

### 2.2.3.1. Inteligencia artificial

La inteligencia artificial (IA) se define como la habilidad de los sistemas y las máquinas para llevar a cabo tareas cognitivas vinculadas con mentes humanas, como son: razonar, percibir, aprender, interactuar con el medio ambiente, solucionar problemas, tomar decisiones e incluso mostrar creatividad [39]. La Unión Europea, según la definición contemporánea del High-Level Expert Group (HLEG), considera que los sistemas de IA son software (y tal vez hardware) creados por seres humanos. Estos sistemas operan en esferas digitales o físicas y se percatan de su entorno mediante la recolección de datos, el análisis de datos estructurados y no estructurados, el razonamiento basado en el conocimiento obtenido y la elección de las acciones más adecuadas para alcanzar la meta establecida [40].

- La IA constituye un modelo esencial en la investigación científica actual. El desarrollo de sistemas de inteligencia artificial (IA) abarca tres aspectos esenciales:
- La inteligencia perceptual, que es la capacidad de las máquinas para tener habilidades elementales de visión, audición y tacto al igual que los seres humanos.
- La inteligencia cognitiva, que se refiere a capacidades superiores como el razonamiento, la inducción y la adquisición del conocimiento.
- La capacidad de decidir, que es la habilidad para actuar y decidir por sí mismas.

Los sistemas de IA, en el ámbito agroindustrial, posibilitan la automatización de labores difíciles como la detección de fallas, la clasificación de productos y el control de calidad en tiempo real sin requerir una intervención humana continua [41].

### 2.2.3.2. Visión por computador

La Visión por Computador (Computer Vision, CV) es una rama especializada de la Inteligencia Artificial que tiene como objetivo capacitar a las máquinas para que analicen, interpreten y entiendan datos visuales obtenidos de videos e imágenes, extrayendo información relevante para tomar decisiones fundamentadas en datos [42]. La visión por computadora, a diferencia del procesamiento clásico de imágenes que trabaja a nivel de píxeles, se basa en redes neuronales y algoritmos de aprendizaje automático para extraer significado de datos visuales reales.

El campo de la visión por computadora es intrínsecamente interdisciplinario, ya que abarca disciplinas como la biología, la psicología, las matemáticas, la física y la ingeniería. Este campo utiliza métodos de procesamiento de señales, aprendizaje automático y ciencia cognitiva con el fin de enfrentar los retos relacionados con la percepción visual. En cuanto a la operación, un sistema de visión por computadora opera en una serie de pasos claramente establecidos, que se describen a continuación:

- **Obtención de la imagen:** se refiere a la toma de datos visuales a través de cámaras u otros sensores ópticos, teniendo en cuenta elementos como el enfoque, la resolución y la iluminación para asegurar que los registros sean lo suficientemente nítidos para un análisis posterior.
- **Preprocesamiento:** Para unificar el conjunto de datos y disminuir los artefactos que podrían afectar el funcionamiento de los algoritmos, las imágenes se someten a procesos de optimización y normalización (ajustes en brillo y contraste, disminución del ruido, modificación del tamaño, correcciones geométricas).
- **Extracción de características:** en este paso, las imágenes que han sido preprocesadas se convierten en representaciones más condensadas que describen propiedades visuales significativas para el trabajo a realizar, tales como bordes, colores, formas, texturas o descriptores producidos automáticamente por redes convolucionales.
- **Análisis mediante aprendizaje automático:** se integran estas propiedades en modelos de Machine Learning o Deep Learning, que tienen la capacidad de aprender a definir

límites decisionales entre clases. Esto posibilita clasificar los objetos que contiene la imagen, calcular probabilidades, identificar anomalías o tomar decisiones.

En 2025, la visión por computador ha llegado a tener aplicaciones transformadoras en áreas como el diagnóstico médico (análisis de imágenes radiológicas con precisión casi humana), los vehículos autónomos (detección de objetos, peatones y señales de tráfico), la vigilancia inteligente (identificación de irregularidades en tiempo real), el comercio minorista (sistemas automatizados para pagos) y la agricultura de precisión (seguimiento de cultivos por medio de drones). En particular, en la agricultura hace posible la clasificación automática de los productos, el hallazgo de plagas y enfermedades en las cosechas, así como la supervisión de calidad de granos en las líneas productivas [43].

### **2.2.3.3. Visión Artificial**

Se trata de una rama de la inteligencia artificial que permite a las máquinas “ver” e interpretar el entorno a través de imágenes o secuencias de video mediante el uso de cámaras, sensores y algoritmos informáticos que procesan datos visuales con el fin de extraer información significativa, reconocer patrones, identificar objetos o realizar tareas específicas, como clasificación, inspección o detección de anomalías. A diferencia de la visión humana, que está limitada por factores como la fatiga, subjetividad o condiciones ambientales, la visión artificial ofrece un análisis objetivo, rápido y continuo, ideal para entornos industriales o automatizados [44].

En el ámbito de la calidad industrial, los errores generados por la inspección manual, que es costosa, laboriosa y propensa a la fatiga visual, se reducen considerablemente gracias a la visión artificial automatizada. Investigaciones recientes indican que los flujos de procesamiento de inspección visual inteligente llegan a un mAP@0.5 (precisión promedio media) de  $0.94 \pm 0.10$  en situaciones realistas, con una tasa de falsos positivos de solo  $0.05 \pm 0.08$  [45]. En la clasificación automática de productos agrícolas, las arquitecturas optimizadas de redes neuronales con 244 filtros estratégicos e integración de técnicas de regularización (normalización por lotes y dropout al 20%) exhiben una mejor capacidad de adaptación y robustez en comparación con los métodos tradicionales cuando se enfrentan a cambios en la perspectiva, la oclusión y la iluminación [46].

Un sistema de visión artificial se compone de diversos elementos interconectados que trabajan juntos para capturar, procesar, analizar y tomar decisiones basadas en imágenes del ambiente. A continuación, la Figura 3 muestra estos componentes de forma ordenada[47].




Figura 3. Fases para el modelo de visión artificial

- **Fuente de iluminación:** Un sistema de visión artificial requiere una iluminación uniforme y controlada para resaltar las características que se desean analizar (color, textura, forma, etc.), ésta puede ser luz blanca, infrarroja, LED, entre otros, dependiendo del uso que se le vaya a dar.
- **Sistema óptico (lentes):** Los lentes se encargan de enfocar la imagen en el sensor de la cámara, por lo que la calidad del lente y el tipo de enfoque determinan la resolución, el campo de visión y la profundidad de campo, los cuales deben ser configurados según el tamaño del objeto y la distancia de captura.
- **Sensor de imagen (cámara):** Es el dispositivo encargado de capturar las imágenes para su posterior procesamiento, en el mercado actualmente existe: Cámaras monocromáticas o a color, Cámaras lineales (para objetos en movimiento como bandas transportadoras), Cámaras matriciales (capturan imágenes completas de una escena).
- **Adquisición de datos (hardware de captura):** El hardware de adquisición puede incluir tarjetas capturadoras o interfaces digitales (como USB, GigE, Camera Link) que reciben y transfieren la imagen capturada al sistema de procesamiento.
- **Procesador o sistema de cómputo:** Es el núcleo del sistema, donde se realizan los cálculos y análisis de las imágenes. Puede ser, Computadora industrial, Microcontrolador o FPGA, Sistema embebido (como Raspberry Pi, Jetson Nano).
- **Sistema de actuación o salida:** Una vez que el sistema analiza la imagen y toma una decisión, se genera una salida. Esta puede ser: Señal a un actuador, Clasificación visual en una pantalla, Registro en una base de datos, Respuesta automática en una línea de producción.
- **Interfaz de usuario:** En muchos sistemas se incluye una interfaz visual (GUI) que permite al operador visualizar los resultados, ajustar parámetros del sistema, revisar imágenes procesadas o generar reportes.

En el contexto agroindustrial, la visión artificial permite automatizar procesos que antes requerían intervención humana, como la clasificación de granos, frutas o vegetales según parámetros de calidad visual, convirtiéndose en una herramienta poderosa para mejorar la eficiencia del proceso de selección, mediante la detección precisa de defectos, variaciones de color, forma o tamaño, lo que garantiza mayor uniformidad y valor comercial en el producto final.

En la Tabla 5 que se muestra a continuación se resume estas diferencias mediante la comparación de la visión artificial, la visión por computadora y la inteligencia artificial en términos de enfoque, práctica, campo de aplicación y ámbito [48]. Se muestran que los sistemas de visión que se utilizarán en esta tesis.

Tabla 5. Comparación de sistemas inteligentes

<b>Características</b>	<b>Inteligencia Artificial</b>	<b>Visión por Computador</b>	<b>Visión Artificial</b>
<b>Planteamiento (enfoque)</b>	Razonamiento, capacidad de decisión y habilidades cognitivas	Análisis e interpretación de videos/imágenes	Hardware, sensores, aplicaciones prácticas
<b>Practica vs teoría</b>	Ambas (teórica y aplicada)	Énfasis en teoría y algoritmos	Enfoque en la implementación a nivel operativo
<b>Campo de aplicación</b>	Visión, sistemas expertos, robótica	Seguridad, medicina, análisis de tipo médico	Control de calidad, inspección y fabricación
<b>Ámbito (Alcance)</b>	Campo extenso de máquinas inteligentes	Área de IA dedicada a los datos visuales	Aplicación práctica en el sector industrial

Al comparar los tres niveles que se muestran en la tabla anterior, se puede observar que la visión artificial, la visión por computadora y la inteligencia artificial no son tecnologías independientes, sino componentes de una misma jerarquía que va desde los modelos de razonamiento abstracto hasta su implementación física en planta. La inteligencia artificial contribuye con algoritmos para aprender y tomar decisiones; la visión por computador ofrece las técnicas para examinar los datos visuales a nivel matemático; mientras que la visión artificial implementa estas metodologías en hardware, sensores y aplicaciones operativas de control de calidad e inspección, como clasificar automáticamente el chocho según categorías de defectos. En un ambiente industrial, estos tres elementos se combinan a través de un proceso organizado que empieza con la recolección y el preprocesamiento de datos visuales, prosigue con la creación, evaluación e implementación de modelos y finaliza con el control de su desempeño en la operación. La Figura 4 muestra la jerarquía de desarrollo de IA, en la que cada nivel depende del anterior, se asegura primero una adquisición sólida de imágenes después, los

modelos de visión son entrenados y validados, por último, se implementan dentro de un sistema automatizado que puede tomar decisiones sobre el producto inspeccionado en tiempo real [49].

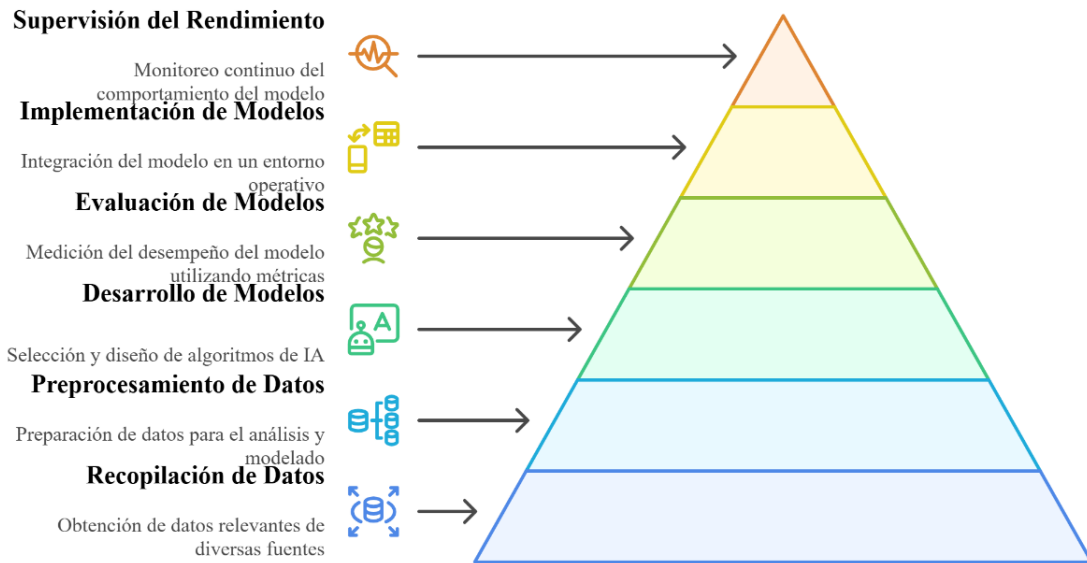


Figura 4. Fases de la visión artificial[49]

## 2.2.4. Faces de la Visión artificial

### 2.2.4.1. Recopilación de datos

- **Métodos y especificaciones de captura de imágenes**

La captura de imágenes requiere equipamiento industrial especializado que garantice consistencia entre todas las imágenes recolectadas. Las especificaciones técnicas mínimas recomendadas para este proyecto incluyen cámaras industriales con resolución de al menos 2 megapíxeles, velocidad de captura de 30 fotogramas por segundo, y sensor tipo CMOS para mayor sensibilidad. Estas especificaciones aseguran que las características visuales del chocho se capturen con suficiente detalle para que el modelo pueda distinguir diferencias sutiles entre categorías de calidad [51].

La calidad y la consistencia de las imágenes obtenidas dependen en gran medida de la iluminación. Un ambiente regulado con iluminación estandarizada asegura que las diferencias en la textura, el color y el contraste de los granos de chocho sean debidas exclusivamente a sus rasgos internos y no a cambios del entorno.

Se sugiere un sistema de luz LED de espectro completo (full-spectrum) con intensidad regulable, que elimine las sombras y ofrezca una iluminación uniforme desde diversos ángulos. Para obtener los colores naturales del grano de manera precisa, la temperatura ideal de color es

entre 5000K y 6500K (equivalente a la luz del día). El sistema tiene que estar diseñado para impedir la aparición de reflejos especulares que distorsionen los rasgos visuales [52].

- **Características visuales del chocho a capturar**

El dataset debe incluir representación completa de la variabilidad natural del chocho clasificado por categorías de calidad. En el contexto de sistemas de clasificación agrícola, típicamente se utilizan tres categorías: premium (sin defectos o defectos imperceptibles), selecta (defectos menores que no afectan funcionalidad), y rechazo (defectos mayores que hacen inutilizable el producto). Es crítico que el dataset capture esta variabilidad completa, no solo ejemplos perfectos o extremadamente defectuosos [53].

Los tipos específicos de defectos a capturar incluyen decoloración (cambios en pigmentación natural), grietas estructurales (fracturas en la cubierta), daño mecánico (abrasiones, magulladuras), y malformación (formas anómalas respecto a la forma esperada del chocho). Cada tipo de defecto debe estar representado en múltiples ejemplares para que el modelo aprenda a reconocerlo en contextos variados. Aunque pueda parecer que los defectos son obvios a ojo humano, su representación visual en imágenes digitales varía significativamente dependiendo de iluminación, ángulo, y características específicas del espécimen.

Más allá de variabilidad en defectos, es fundamental capturar variabilidad en tamaño, forma y color dentro de cada categoría de calidad. El chocho natural presenta variabilidad genética que resulta en especímenes de tamaño desde 8-15 mm de diámetro, con variaciones sutiles en forma y tonalidad de color. Un modelo entrenado solo con especímenes de tamaño similar o color muy uniforme podría fallar al clasificar especímenes de tamaño extremo o tonalidad diferente, incluso si tienen la misma calidad. Capturar múltiples ángulos (mínimo 3-4 ángulos diferentes) para cada espécimen asegura que el modelo no desarrolle dependencia sobre un solo ángulo de visualización [54].

- **Adquisición de imágenes**

El primer paso fundamental en todo sistema de visión artificial es la adquisición de imágenes, que marca el comienzo de toda la cadena subsiguiente de procesamiento. Una imagen digital es una representación informática de una escena visual que se ha registrado y guardado en formato numérico, lo cual la convierte en un elemento esencial de los sistemas de visión artificial. Una imagen, desde el punto de vista del procesamiento digital, es una matriz bidimensional compuesta por valores numéricos que simbolizan la intensidad de la luz o los colores en áreas espaciales distintas [55]. Esta conceptualización habilita que las máquinas

entiendan información visual de la misma forma en que los sistemas informáticos procesan otros géneros de datos.

En el contexto específico del procesamiento digital de imágenes y la visión artificial, se entiende por imagen al producto de transformar estímulos lumínicos provenientes del mundo real en señales eléctricas digitales a través de sensores especializados, como las cámaras CCD o CMOS[55]. Este procedimiento de captura convierte una escena física tridimensional en una representación bidimensional discreta, en la que cada punto de la imagen alberga datos codificados numéricamente.




Figura 5. Procesamiento inicial de imágenes

La Figura 5 muestra el proceso de adquisición de imágenes en un sistema de visión artificial para la clasificación de productos agrícolas como el chocho, que sigue una secuencia nítida y bien establecida: primero, se coloca el objeto frente a la cámara con iluminación controlada; después, la cámara toma la escena y convierte la luz reflejada en señales digitales; estas señales luego se transforman en datos numéricos que producen gráficos de intensidad; a continuación, se utilizan algoritmos para procesar y segmentar que detectan los píxeles importantes (región de interés); por último, la imagen procesada se guarda en formatos estándar como PNG o JPEG para su análisis posterior o para ser introducida en modelos de aprendizaje automático[55].

- **Píxeles**

El píxel, que es una abreviatura de "elemento de imagen", representa la unidad más pequeña que se utiliza para crear una imagen digital. Un píxel, desde el punto de vista estructural, es un punto discreto en una imagen que tiene una posición específica determinada por coordenadas cartesianas (x, y) y alberga un valor numérico que refleja la intensidad de la luz o los datos del color en esa posición concreta [56]. Los píxeles son adimensionales, lo que significa que no tienen una altura o una longitud definidas físicamente. Su dimensión relativa está determinada por la resolución de la imagen y el tamaño del sensor de la cámara.

El nivel de detalle que se puede capturar está determinado por la resolución de una imagen, la cual se mide en píxeles. Representar detalles más pequeños de la escena capturada es posible

con imágenes de mayor resolución [57]. La resolución debe ser suficiente para capturar características visuales críticas (como el color, la forma, el tamaño o las manchas) sin ser excesiva, lo que podría incrementar de manera innecesaria las exigencias computacionales. Esto es especialmente importante en aplicaciones de inspección y clasificación automática de productos agrícolas como el chocho. Se emplean, normalmente, cámaras con resoluciones que oscilan entre 2 y 5 megapíxeles en los sistemas de visión para la agricultura de precisión. Esto logra un balance adecuado entre el poder de detección y la velocidad del procesamiento [56].

- **Espacios de color RGB**

El modelo de color más frecuentemente empleado en la captura digital de imágenes es el espacio RGB (rojo, verde y azul, por sus siglas en inglés), que a su vez es el formato nativo tanto de las pantallas de visualización como de las cámaras digitales. El modelo RGB define todos los colores como una mezcla aditiva de tres canales primarios independientes, que son el rojo (R), el verde (G) y el azul (B). Desde el punto de vista matemático, cada píxel en una imagen RGB se representa con una tupla (R, G, B). Cada componente suele tener valores numéricos que oscilan entre 0 y 255, lo que da lugar a un total de  $256^3 = 16.777.216$  combinaciones cromáticas posibles [58].

Aunque el modelo RGB es sencillo y eficaz para capturar y visualizar imágenes, su uso en el análisis de imágenes para aplicaciones de visión artificial tiene limitaciones importantes. Una limitación importante es que el modelo RGB mezcla la información de luminancia y la cromática: las alteraciones en la iluminación ambiental tienen un efecto proporcional en los tres canales, por lo cual los sistemas que se fundamentan exclusivamente en RGB son susceptibles a cambios en las condiciones lumínicas [59]. En la clasificación del chocho, esto quiere decir que un grano de color blanco bajo una luz intensa puede registrarse con valores RGB completamente distintos a los de ese mismo grano bajo una luz más fuerte, a pesar de que el color intrínseco de dicho grano sea el mismo.

- **Entorno controlado**

La calidad de las imágenes obtenidas en sistemas de visión artificial para clasificar productos agroindustriales tiene una relación directa con la estabilidad y el control que se ejerce en el entorno óptico donde se lleva a cabo la adquisición. Un espacio controlado es un lugar físico creado con el propósito de proteger el objeto que se va a inspeccionar (en este caso, los granos de chocho) de factores ambientales que podrían perjudicar la uniformidad de las imágenes:

cambios en la luz natural, sombras inconsistentes, reflejos parásitos y alteraciones térmicas que incidan en la sensibilidad del sensor de la cámara [61].

#### 2.2.4.2. Procesamiento de datos

- **Preprocesamiento en análisis de imágenes**

El preprocesamiento de imágenes es la primera etapa fundamental en cualquier proceso de visión artificial. El procesamiento de imágenes médicas, se refiere a la obtención de imágenes de los órganos internos con fines terapéuticos. El propósito fundamental del análisis de dichas imágenes es optimizar las alternativas de tratamiento y la efectividad de la investigación clínica[63].

Las técnicas de preprocesamiento comprenden diversos procedimientos esenciales que acondicionan las imágenes para un análisis posterior y que visualiza en la siguiente Tabla 6:

Tabla 6. Técnicas Comunes de Preprocesamiento en Análisis de Imágenes

Descripción	Propósito	Referencia
Normalización de Intensidad	Ajusta valores de píxeles a rango estándar (ej: [0,1])	Estabilidad numérica, convergencia rápida en entrenamiento
Redimensionamiento (224×224)	Convierte todas imágenes a dimensión estándar	Compatibilidad con modelos reentrenados
Remoción de Fondo (ROI)	Aísla estructuras relevantes del fondo	Mejora eficiencia y precisión del análisis
Skull Stripping	Extrae tejido cerebral eliminando cráneo (MRI)	Análisis específico de imágenes cerebrales
Recorte (Cropping)	Extrae región específica de interés	Elimina partes irrelevantes de la imagen
Denoising (Filtros)	Reduce ruido usando filtros adaptativos	Mejora calidad de imagen para análisis posterior

- **Aumento de datos (Data Augmentation)**

La ampliación de datos es un método de preprocesamiento que produce nuevas muestras para el entrenamiento por medio de transformaciones sistemáticas sobre los datos ya existentes. Su finalidad es incrementar la diversidad y el tamaño del conjunto de datos de entrenamiento. Cuando se trabaja con modelos de aprendizaje profundo que necesitan grandes volúmenes de datos para alcanzar una generalización óptima, esta técnica es especialmente relevante.

Resalta que, para optimizar el rendimiento del modelo, particularmente cuando los sets de datos accesibles son escasos, es fundamental contar con más datos. Las transformaciones que mantienen la etiqueta semejante de la imagen, a la vez que modifican su aspecto, son algunas

de las técnicas de aumento utilizadas en imágenes [65]. Las principales técnicas de aumento de datos (Data Augmentation) que se incluyen se visualizan en la siguiente Tabla 7.

Tabla 7. Técnicas de Aumento de Datos (Data Augmentation)

Técnica	Descripción	Impacto en Modelo
<b>Rotación Aleatoria</b>	Rota imagen entre $-\theta$ y $+\theta$ grados	Mejora invariancia a rotaciones
<b>Flip Horizontal/Vertical</b>	Refleja imagen horizontalmente o verticalmente	Aumenta variedad visual simétrica
<b>Zoom y Scale</b>	Amplía o reduce imagen aleatoriamente	Mejora robustez a cambios de escala
<b>Recorte Aleatorio (Crop)</b>	Extrae región aleatoria de imagen	Aumenta variedad de composición visual
<b>Ajuste de Brillo/Contraste</b>	Modifica valores de intensidad	Mejora adaptabilidad a variaciones de iluminación
<b>Corrección Gamma</b>	Ajusta relación no lineal de intensidad	Simula condiciones de iluminación variable
<b>Aumento con GANs</b>	Genera imágenes sintéticas realistas	Aumenta datos sin pérdida de diversidad
<b>Mixup</b>	Combina dos imágenes con interpolación	Regularización, mejora suavidad de decisiones
<b>CutMix</b>	Mezcla características de regiones de dos imágenes	Aprendizaje de características más robustas
<b>Cutout</b>	Enmascara región cuadrada aleatoria	Fuerza modelo a usar características variadas

- **herramientas de etiquetado de datos**

El etiquetado de datos es un paso esencial en la creación de modelos de aprendizaje automático supervisado, porque establece el vínculo entre los datos que entran y las categorías que el modelo tiene que aprender. En proyectos de visión artificial, la calidad del etiquetado tiene un impacto directo en el desempeño del sistema. Esto es porque fallos como etiquetas inexactas, ambigüedades o incongruencias pueden generar sesgos durante el proceso de entrenamiento y perjudicar indicadores como la exactitud, la precisión y la habilidad de generalización del modelo. La anotación de datos es uno de los procesos más delicados y costosos del ciclo de vida de los sistemas de visión por computadora, según una variedad de investigaciones. Por eso, necesita que se empleen herramientas apropiadas que aseguren confiabilidad y coherencia [66].

Make Sense es una herramienta de etiquetado de imágenes de código abierto que posibilita hacer anotaciones manuales desde el navegador de forma intuitiva y sencilla. Esta plataforma posibilita la elaboración de etiquetas personalizadas y admite una diversidad de formatos de anotación, incluyendo polígonos y cuadros delimitadores. Asimismo, permite exportar los datos en formatos que son compatibles con modelos de visión artificial como YOLO. Su simplicidad

de uso y su enfoque manual la hacen una opción apropiada para proyectos académicos y prototipos experimentales, en los cuales es necesario un control directo del proceso de etiquetado y una definición nítida de las clases, como sucede en la clasificación de la calidad del chocho [67].

Roboflow, por su parte, es una plataforma integral que se enfoca en la gestión, anotación y preparación de conjuntos de datos para visión artificial. Esta incluye características avanzadas como detección de incoherencias, validación de etiquetas, balanceo de clases y uso de métodos de aumento de datos. Estas habilidades posibilitan que la calidad del conjunto de datos se optimice y que el modelo se vuelva más sólido a medida que avanza el entrenamiento. Asimismo, Roboflow posibilita que el dataset sea exportado en formatos que son compatibles con arquitecturas actuales de aprendizaje profundo, lo cual hace más rápida la integración entre el etiquetado y la capacitación del modelo. La bibliografía técnica subraya que, mediante el empleo de plataformas de anotación estructuradas y con soporte para el análisis del conjunto de datos, se logra la construcción de conjuntos de datos más fiables [67].




Figura 6. Ejemplos de detección de objetos únicos y múltiples[62]

### 2.2.4.3. Desarrollo del modelo

- **Lenguajes programación para visión artificial**

La elección del lenguaje de programación es una decisión clave al desarrollar sistemas de visión artificial, pues impacta de manera directa en la rapidez con la que se desarrolla, el rendimiento al ejecutarse y la disponibilidad de bibliotecas especializadas. La sintaxis intuitiva de Python, así como su gran ecosistema de bibliotecas especializadas (OpenCV, NumPy, Tensor Flow y Pitarch), lo han convertido en el lenguaje más usado por la comunidad de visión artificial y aprendizaje profundo [68].

Sin embargo, otros lenguajes se mantienen significativos dependiendo de las necesidades particulares del proyecto: Java es la opción preferida para aplicaciones empresariales de gran tamaño, C++ se emplea cuando se necesita el mayor rendimiento y procesamiento en tiempo real, mientras que MATLAB continúa siendo un referente en ámbitos académicos de investigación [69]. La Tabla 8 presenta un resumen de las características distintivas de los cuatro lenguajes fundamentales para el desarrollo en visión artificial:

Tabla 8. Características principales de lenguajes de programación

Lenguaje	Características Principales
<b>Java</b>	Capacidad de escalar a nivel empresarial, portabilidad en varias plataformas, recolección automática y robustez para sistemas complejos.
<b>Matlab</b>	Herramientas visuales, integración del análisis matemático y prototipado veloz. Es muy utilizado en la investigación académica.
<b>Python</b>	Con una sintaxis clara, un ecosistema amplio (como PyTorch y TensorFlow), es fácil de aprender; es perfecto para la investigación y el prototipado.
<b>C++</b>	Eficiencia al computar, control de bajo nivel de la memoria, rendimiento óptimo; fundamental para lo embebido y el tiempo real.

- **Entornos de programación con Python**

Los entornos de programación constituyen el fundamento para la creación, ejecución y depuración de algoritmos de visión artificial en Python. Se incluyen desde editores ligeros hasta entornos integrados de desarrollo (IDE por sus siglas en inglés: Integrated Development Environment [70]. Visual Studio Code, que fue desarrollado por Microsoft, sobresale por su popularidad debido a su estructura modular con extensiones que lo transforman en un IDE integral mediante paquetes como Python, Pylance e IntelliCode, todo ello utilizando pocos recursos. Esta flexibilidad lo convierte en una opción ideal para flujos diversos en visión computacional, incluyendo desde prototipos rápidos hasta implementaciones complejas.

Google Colab es una opción en la nube que ha hecho accesible a todos el uso de hardware acelerado, como las unidades de procesamiento gráfico (GPU) NVIDIA Tesla y las unidades de procesamiento tensorial (TPU), lo cual elimina la necesidad de inversión en equipos caros y posibilita el entrenamiento de modelos complejos de visión artificial directamente desde los navegadores web sin requerir configuraciones locales [71]. En la Tabla 9 que se presenta a continuación, se pueden ver los entornos más utilizados y sus características principales [72].

Tabla 9. Entornos de programación

Entornos	Características Principales
<b>Google Colab</b>	Plataforma gratuita en la nube, con TPU/GPU integradas, sin necesidad de instalación y adecuada para el prototipado y conjuntos de datos grandes.
<b>Visual Studio Code</b>	Con extensiones, un editor ligero con depuración nativa y control completo del código; ideal para el desarrollo local profesional.

- **Librerías de visión artificial**

El acceso a bibliotecas especializadas que simplifican la complejidad de los algoritmos de procesamiento y aprendizaje profundo es esencial para el desarrollo eficaz de sistemas de visión artificial [73]. La siguiente Tabla 10 resume las librerías más utilizadas de las cuales desempeña un rol particular en la cadena de desarrollo: OpenCV brinda instrumentos algorítmicos para la visión clásica y el preprocesamiento de imágenes. TensorFlow y PyTorch, por su parte, ofrecen marcos integrales para el entrenamiento de modelos de redes neuronales profundas. Finalmente, bibliotecas complementarias como NumPy, Pandas y Matplotlib constituyen el conjunto esencial de herramientas para la gestión de datos y la visualización de resultados [73].

Tabla 10. Librerías utilizadas en visión

Librería	Descripción
<b>TensorFlow</b>	Marco de Google para el aprendizaje profundo que incorpora Keras como API simplificada, lo que posibilita la implementación, definición y entrenamiento de redes neuronales convolucionales (CNN) con soporte para implementar en varias plataformas.
<b>PyTorch</b>	Marco de trabajo dinámico que es el favorito en las comunidades de investigación, se distingue por la ejecución eager y la creación de gráficos computacionales durante la ejecución, lo que permite una depuración intuitiva y una iteración rápida.
<b>OpenCV</b>	Con más de 2,500 funciones optimizadas para la detección de rasgos y la segmentación de imágenes en tiempo real, así como para el procesamiento algorítmico y la captura, es una biblioteca abierta de visión por computadora.
<b>Pandas</b>	Biblioteca de visualización gráfica de datos de alto rendimiento y análisis predictivo
<b>NumPy</b>	NumPy proporciona manipulación eficiente de datos y arrays multidimensionales[74]
<b>YOLO</b>	Poner en marcha el algoritmo (You Only Look Once) de manera optimizada con el fin de detectar objetos en tiempo real, consiguiendo pronósticos concurrentes de clases y ubicaciones de objetos en una única pasada por la red neuronal.
<b>Matplotlib</b>	Biblioteca de visualización que posibilita la representación de análisis de predicciones, gráficas de entrenamiento, resultados intermedios del procesamiento y evaluación de métricas de rendimiento.

La incorporación de estas bibliotecas crea un entorno interoperable que mejora la precisión y escalabilidad de sistemas de visión artificial, simplificando desde el preprocesamiento hasta la validación de modelos en labores como la clasificación agrícola. Esta colección, al combinar funciones de procesamiento clásico con análisis de datos y entrenamiento profundo, disminuye significativamente los tiempos de desarrollo y mejora el rendimiento en hardware acelerado. Así, se vuelven fundamentales para las innovaciones en el procesamiento inteligente de productos agrícolas.

- **Modelos de detección basados en YOLO**

YOLO es un algoritmo de detección de objetos que tiene una sola fase y convierte el problema de detección en uno de regresión utilizando aprendizaje profundo, fue desarrollado para mejorar el rendimiento en tiempo real, la eficiencia y la precisión de las técnicas convencionales de detección de objetos[75].

Contrario a los métodos tradicionales que dividen la detección en varias etapas (región de generación, clasificación y regresión), YOLO concentra todo el proceso de detección en un solo problema de regresión[75]. El algoritmo segmenta la imagen de entrada en una cuadrícula con un tamaño determinado, donde cada celda tiene la responsabilidad de prever la categoría y localización de los objetos que se encuentren dentro de esa área como se muestra en la Figura 7. Esta técnica permite que YOLO incremente de manera notable la rapidez de detección al tiempo que conserva una gran precisión, lo cual es particularmente apropiado para situaciones en tiempo real como la vigilancia de seguridad y la gestión autónoma.




Figura 7. Arquitectura YOLO

Una propiedad fundamental de YOLO (You Only Look Once) es su proceso de entrenamiento end-to-end (extremo a extremo). En contraste con los métodos tradicionales, que necesitan entrenar varios módulos de red en pasos independientes, YOLO incorpora todo el procedimiento de detección en una sola red neuronal convolucional unificada [75]. Esta perspectiva no solamente optimiza la eficacia de la inferencia y del entrenamiento, sino que también posibilita que se realice una optimización simultánea de toda la imagen.

La Tabla 11 muestra cómo ha ido evolucionando la familia YOLO desde YOLOv1 hasta YOLOv11, resumiendo para cada una de las versiones el año en que se lanzó, las innovaciones arquitectónicas más relevantes y las restricciones que busca solventar. En resumen, la tabla que se muestra a continuación ilustra cómo el algoritmo ha ido incorporando perfecciones en resolución, estrategias de backbone y neck, funciones de pérdida y optimizaciones de entrenamiento para conseguir una detección más rápida y exacta en cada ocasión, manteniendo su enfoque en la predicción en una sola etapa[76].

Tabla 11. Diferentes versiones de YOLO

<b>Versión</b>	<b>Año</b>	<b>Innovaciones Importantes</b>	<b>Limitaciones presentadas</b>
YOLOv1	2015	Detección directa mediante regresión única	Bajo rendimiento en objetos pequeños, baja precisión de ubicación
YOLOv2	2017	Resolución más alta, cajas ancla, nuevas funciones de pérdida	Mayor rapidez y exactitud, aunque con una capacidad de adaptación limitada a escenas cambiantes
YOLOv3	2018	Predicciones a múltiples escalas	Mejor desempeño en objetos de pequeño tamaño
YOLOv4	2020	SPP, BoF, mejoras en la velocidad	Un equilibrio más adecuado entre celeridad y exactitud
YOLOv5	2020	Implementación en PyTorch, modelos más pequeños	Accesibilidad en varios tamaños para aparatos edge
YOLOv6	2022	Backbone y neck optimizados	Mayor exactitud manteniendo la velocidad
YOLOv7	2022	Marco de trabajo YOLO Panóptico (segmentación + detección).	Incremento en la complejidad computacional
YOLOv8	2023	Entrenamiento utilizando varias GPUs, funciones de pérdida CIoU y BiFPN	Mejora en la agregación de atributos
YOLOv9	2024	Arquitectura GELAN y sistema PGI para optimizar el rendimiento y el flujo de gradientes.	Mayor precisión y velocidad; en capas profundas, pérdida de información reducida
YOLOv10	2025	Arquitectura sin NMS, optimización completa de los elementos	Disminuye la carga de computación y optimiza la latencia en tiempo real
YOLOv11	2025	Mejor optimización para dispositivos edge y soporte avanzado de poda y cuantización	Mejor rendimiento en escenas densas y objetos de menor tamaño

En aplicaciones agrícolas recientes, varias investigaciones comparan versiones más avanzadas de YOLO, resaltando que han aumentado tanto la velocidad como la precisión. Un modelo optimizado que se basa en YOLOv8 y que tiene como objetivo detectar enfermedades foliares en cinco cultivos básicos logró un mAP del 98,3% y un F1-score del 97%, lo cual es mejor que las versiones previas en lo que respecta a la precisión de la identificación de enfermedades de campo [77]. En el caso de YOLOv9, propuestas como MAR-YOLOv9, que están destinadas a detectar estructuras de cultivo (mazorcas, espigas y panículas) en condiciones ambientales complicadas, son capaces de conservar una alta precisión con arquitecturas ligeras adecuadas para equipos agrícolas con recursos escasos[78].

#### 2.2.4.4. Evaluación del modelo

Antes de que una solución se implemente en situaciones reales, la etapa de evaluación de modelos de visión artificial y aprendizaje automático es crucial para determinar su aplicabilidad y confiabilidad. En esta etapa se confirma que un modelo entrenado no solamente retiene patrones particulares de los datos de entrenamiento, sino que también desarrolla habilidades de generalización, lo cual posibilita que realice pronósticos exactos en datos nuevos y desconocidos. Para asegurarnos de que las métricas de rendimiento informadas representen el funcionamiento real del sistema en producción, es indispensable hacer una evaluación rigurosa y bien fundamentada [86].

El proceso de evaluación de los modelos de aprendizaje automático presenta limitaciones, pues en cada fase del ciclo de vida del modelo se pueden introducir diversas fuentes de sesgo. Para crear metodologías de evaluación que aseguren resultados equitativos, fiables y reproducibles, es fundamental entender estas formas de sesgo. Esto permite prever eventuales fallos antes de implementar el modelo en contextos reales.

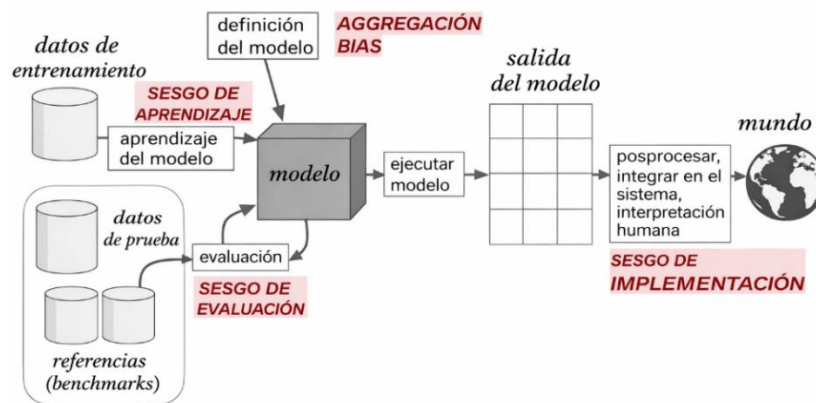


Figura 8. Construcción e implementación de modelos [86].

En la Figura 8 ,se pueden ver las fuentes de sesgo a través del ciclo vital de creación y análisis de modelos de aprendizaje automático. Estas fuentes abarcan el sesgo de despliegue, el sesgo de evaluación, el sesgo de aprendizaje y el sesgo de agregación [86], posibilita la detección de las áreas críticas donde se deben implementar estrategias de mitigación con el objetivo de garantizar evaluaciones más sólidas y éticas.

- **División de datos en conjuntos de entrenamiento, validación y prueba**

Dividir un conjunto de datos en tres secciones diferentes (prueba, validación y entrenamiento) es una práctica esencial del diseño experimental riguroso en el aprendizaje automático. Cuando el modelo se enfrenta a datos que no fueron usados en su construcción, esta estratificación es crucial para conseguir estimaciones justas de cómo se comporta realmente el modelo.

La matriz de confusión es el instrumento más claro y esencial para evaluar el rendimiento de modelos de clasificación, pues posibilita un análisis pormenorizado del comportamiento del modelo ante cada clase, en vez de restringirse a una única métrica global. Se organiza en forma de tabla, donde las filas normalmente corresponden a las clases reales y las columnas a las clases predichas (o viceversa); esto simplifica la identificación de patrones sistemáticos de error, como confusiones frecuentes entre categorías particulares o una actuación irregular entre categorías mayoritarias y minoritarias. Esta estructura no solo proporciona una interpretación intuitiva del modelo, sino que además es útil para calcular las métricas derivadas. Presenta una visualización tabular de los resultados de predicción en relación con las etiquetas verdaderas, desglosando todos los resultados en cuatro categorías mutuamente excluyentes [88].

- **Verdaderos positivos (TP):** Ejemplos de la clase positiva que se clasifican adecuadamente como tal. Simboliza la identificación satisfactoria de situaciones que efectivamente son parte de la clase de interés.
- **Negativos verdaderos (TN):** Ejemplos de la clase negativa que han sido clasificados como negativos de manera correcta. Supone la correcta y legítima negación de casos que no pertenecen a la clase de interés.
- **Falsos positivos (FP):** Ejemplos de la clase negativa que se han clasificado erróneamente como positivos. En la terminología estadística tradicional, estos son un Error Tipo I (Type I Error), que se produce cuando el modelo emite una alarma falsa al indicar algo como positivo cuando en realidad no lo es.
- **Falsos negativos (FN):** Ejemplos de la clase positiva que están erróneamente etiquetados como negativos. En la jerga estadística, esto se conoce como un Error Tipo

II (Type II Error), en el que el modelo no logra detectar algo que es verdaderamente positivo y deja que pase sin identificación.

De los elementos de la matriz de confusión se originan diversas medidas que cuantifican varios aspectos del rendimiento del modelo, como se expone en la Tabla 12. Estas métricas posibilitan no solamente la evaluación del porcentaje total de aciertos, sino también de la calidad de las predicciones positivas, el equilibrio entre diferentes tipos de error y la habilidad para detectar la clase que se desea estudiar; todo esto es particularmente importante en situaciones con clases desbalanceadas o costos asimétricos de error [88].

Tabla 12. Métricas de evaluación de un modelo

Métrica	Contexto de uso	Interpretación
<b>Exactitud (Accuracy)</b>	Válida solo cuando las clases están balanceadas; engañosa en datos desbalanceados	Proporción total de predicciones correctas sobre todas las predicciones realizadas
<b>Precisión</b>	Crítica cuando los falsos positivos tienen costo alto	De todas las instancias predichas como positivas, qué fracción eran verdaderamente positivas
<b>Exhaustividad (Recall)</b>	Crítica cuando los falsos negativos tienen costo alto	De todas las instancias positivas reales, qué fracción fue detectada por el modelo
<b>F1-Score</b>	Óptima para evaluar modelos en escenarios con datos desbalanceados o costos asimétricos	Media armónica de precisión y recall; equilibra ambas métricas

A pesar de ser la métrica más intuitiva, la exactitud puede ser muy engañosa en conjuntos de datos desequilibrados. Si un modelo predice sistemáticamente la clase mayoritaria para todos los casos, es posible que alcance una exactitud del 95% sin haber desarrollado ninguna capacidad discriminativa real. La precisión responde a la pregunta: "¿Cuántos de los casos que fueron clasificados como positivos por mi modelo eran efectivamente positivos?" Esta métrica es fundamental cuando el costo de generar alertas falsas es elevado, como en sistemas de control de calidad en los que un falso positivo implica la negativa a un producto de alta calidad[88], [89].

La exhaustividad (recall) responde: "¿Qué proporción de todos los casos positivos reales en el conjunto de datos fue identificada con precisión por mi modelo?" Es crucial cuando no detectar un caso positivo tiene un costo elevado. En la detección de fallos, un falso negativo posibilita que un producto defectuoso llegue al cliente final, lo que tiene graves consecuencias en términos de calidad y economía. El F1-score, en cambio, funciona como una media armónica

que necesita que la precisión y el recall sean altos al mismo tiempo para llegar a un valor alto. Que el modelo no sacrifique un indicador a costa de otro se demuestra con un F1-score elevado[88], [89].

#### 2.2.4.5. Implementación del modelo

Uno de los retos más difíciles en la ingeniería de sistemas de visión artificial es pasar un modelo de aprendizaje automático del contexto de laboratorio a una aplicación que funcione y esté disponible en producción. A diferencia de lo que ocurre en el laboratorio, donde los científicos pueden realizar experimentos con diversas configuraciones, modificar parámetros de manera iterativa y no tener que preocuparse por la disponibilidad constante del sistema, en producción hay exigencias mucho más notables el modelo tiene que funcionar de forma confiable todos los días (24/7), responder dentro de plazos determinísticos, ajustarse a las cambiantes condiciones ambientales y ofrecer una trazabilidad total de sus decisiones [87].

Esta fase trata los elementos esenciales para implementar sistemas de clasificación automática que se basan en visión por computadora, indagando sobre la forma de convertir un modelo validado en uno sólido, escalable y mantenible que tenga la capacidad de operar con eficacia en entornos industriales reales[90].

- **Arquitectura de Monitoreo en Sistemas ML**

Para supervisar los sistemas de ML, es necesaria una arquitectura particular que incorpore diversos componentes trabajando en equipo. La Figura 9 que se muestra a continuación representa la arquitectura fundamental, que incluye un módulo de componentes de ML (modelo + preprocesamiento) que recibe datos iniciales, produce pronósticos y es supervisado constantemente por un monitor especializado.

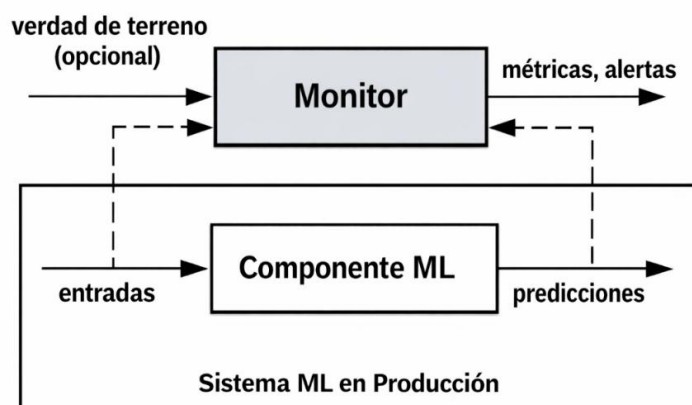


Figura 9. Arquitectura de monitoreo de ML[93]

El monitor funciona como un sistema de supervisión que examina constantemente el componente de Machine Learning (ML), recibiendo los mismos datos iniciales, las predicciones generadas y, cuando está disponible, la verdad fundamental (ground truth) para cotejar resultados. Utilizando estas tres fuentes, calcula las métricas establecidas de antemano sobre la calidad de los datos, el rendimiento del modelo y las posibles alteraciones en el concepto (concept drift). Además, cuando encuentra desvíos con respecto a lo que se preveía en producción, genera alertas y métricas[93].

- **Aspectos monitoreados en sistemas ML (Machine Learning)**

La investigación sobre el monitoreo de sistemas de aprendizaje automático distingue diversas formas de supervisión que se utilizan en producción de manera complementaria. La Tabla 13 ,que se presenta a continuación, resume las categorías más comunes y sus técnicas principales asociadas. Siguiendo esta categorización, el seguimiento del rendimiento se enfoca en continuar con métricas como la exactitud, la precisión, el recall y el F1 a través del tiempo. Se detectan descensos anómalos en comparación con los valores históricos y se generan alertas cuando hay un deterioro del desempeño [94].

Tabla 13. Tipos de monitoreos Machine Learning

Tipo de monitoreo	Descripción	Técnicas utilizadas
Monitoreo del rendimiento	Seguimiento de cómo los modelos se desempeñan según métricas predefinidas como exactitud y precisión.	Seguimiento del rendimiento, detección de anomalías
Monitoreo de deriva de datos	Detección de cambios en la distribución subyacente de los datos a lo largo del tiempo.	Pruebas estadísticas (por ejemplo, Kolmogórov–Smirnov), algoritmos de detección de deriva
Monitoreo de deriva del modelo	Seguimiento de cómo el rendimiento del modelo se degrada a medida que cambian los datos de entrada.	Monitoreo de la exactitud a lo largo del tiempo, pruebas de regresión
Monitoreo en tiempo real	Seguimiento continuo de las predicciones del modelo y del comportamiento del sistema en producción.	Paneles de control, sistemas de alertas

El seguimiento del drift de datos utiliza pruebas estadísticas para detectar alteraciones en la distribución de las entradas, lo que permite reconocer modificaciones estructurales en los datos que podrían ser responsables de una disminución de la calidad del modelo, como cambios estacionales en el color o la apariencia del producto [94].

De manera adicional, el seguimiento del drift de modelo examina la tendencia del rendimiento total durante semanas o meses con el fin de identificar degradaciones graduales, incluso cuando los datos parecen estables, utilizando análisis de series temporales acerca de las métricas principales. Por último, el seguimiento en tiempo real incluye paneles de control y sistemas de alertas automáticas que exhiben constantemente la condición del modelo, los datos y la infraestructura. Esto facilita que los grupos técnicos respondan con rapidez si alguna de las otras modalidades de monitoreo identifica un inconveniente significativo en producción [94].

- **Estrategias de Reentrenamiento y Mantenimiento del Modelo**

Cuando los sistemas de monitoreo identifican un deterioro en el desempeño del modelo o modificaciones relevantes en los datos (data drift, feature drift, concept drift), aparece la pregunta operacional principal: ¿cuándo y de qué forma se debe actualizar el modelo? El reentrenamiento constante es el proceso que permite a los sistemas de aprendizaje automático (ML) en producción ajustarse a situaciones fluctuantes, sin que se pierda la estabilidad ni se acumulen fallos del pasado. No obstante, el reentrenamiento no es simplemente un procedimiento de "volver a entrenar con datos recientes". Se sugiere un marco integral que combina la detección de drift, el análisis de causa raíz y el reentrenamiento continuo en un ciclo único para gestionar el ciclo de vida del modelo [95]. La literatura de MLOps señala dos maneras fundamentales de reentrenamiento, cada una con distintas consecuencias en términos operacionales.

**Reentrenamiento programado:** Se trata de actualizar el modelo en intervalos determinados (semanales, mensuales o trimestrales), sin importar el rendimiento actual del modelo. Este método es beneficioso en situaciones donde el drift de datos se puede prever y ocurre de manera gradual, como en los modelos de pronóstico económico, donde las circunstancias económicas cambian con lentitud. Evita decisiones automáticas que pudieran causar inestabilidad y, en gran medida, es predecible computacionalmente. Por otro lado, si el drift se presenta con más rapidez de la prevista, el modelo podría tener un rendimiento inferior al aceptable hasta la próxima actualización programada. En cambio, si el drift es mínimo, los reentrenamientos innecesarios podrían generar ruido en el modelo y elevar los costos computacionales [95].

**Reentrenamiento adaptativo:** Lanza actualizaciones del modelo únicamente cuando los mecanismos de umbrales dinámicos identifican que el rendimiento desciende por debajo de niveles aceptables. Este método supervisa de manera constante indicadores tales como precisión, exactitud, exhaustividad (recall) y F1-score, y vuelve a entrenar cuando estos

indicadores superan límites preestablecidos. Es especialmente eficaz en aplicaciones en las que el drift es impredecible o su velocidad cambia, como la detección de fraude, donde las estrategias de los defraudadores cambian sin un patrón establecido. La eficiencia de recursos es el principal beneficio, solo se lleva a cabo el reentrenamiento cuando es necesario. El riesgo de reentrenar con excesiva frecuencia es la desventaja, ya que puede ocasionar que el modelo adquiera patrones de corto plazo que no se adaptan adecuadamente a los datos futuros, lo cual disminuye la fiabilidad del sistema [95].

#### **2.2.4.6. Investigaciones Similares**

La clasificación automática de productos agrícolas a través de visión artificial es el foco de varias investigaciones. Un estudio que identifica enfermedades en hojas de maíz a través de modelos de Deep Learning, empleando la metodología CRISP-ML y logrando precisiones como InceptionV3 como se muestra en la revista de Investigación, Tecnología e Innovación [97]. Esto demuestra el poder de las redes neuronales convolucionales (CNN) en situaciones agrícolas. Una investigación de la UPS establece y lleva a cabo un sistema de identificación de componentes eléctricos en módulos didácticos por medio de visión artificial, organizando el proyecto en etapas: obtención de imágenes, etiquetado, formación de un modelo clasificatorio y validación en laboratorio. Esta tesis prueba que es factible emplear el aprendizaje automático para automatizar procedimientos de reconocimiento visual en contextos educativos [98].

Otras investigaciones se centran específicamente en la clasificación y el control de calidad de los alimentos. Una investigación que se publicó en las memorias del congreso IIIS presenta un sistema de visión artificial para la evaluación y análisis de calidad en procesos industriales [99]. Este trabajo explica una estructura común que incluye cámara, iluminación controlada, procesamiento de imágenes y un clasificador que determina si los productos deben ser aceptados o rechazados. En la publicación de la UPSE se muestra el diseño de un prototipo para clasificar manzanas usando visión artificial. Este sistema, que utiliza una red neuronal entrenada con atributos obtenidos de imágenes, tiene como finalidad disminuir la subjetividad del trabajador y optimizar la estandarización al categorizar las frutas según su calidad [100]. Por último, un prototipo para detectar enfermedades en el cultivo de chocho a partir de imágenes obtenidas en campo es desarrollado por una tesis de la Universidad Técnica de Cotopaxi. Se evidencia así que los modelos visuales pueden respaldar decisiones en cuanto al manejo agrícola y a la disminución de pérdidas [101].

Un estudio que está más vinculado con el proyecto actual trata sobre el diseño y la construcción de un sistema automatizado para clasificar chochos a través de visión artificial, implementado en un entorno productivo real. El sistema creado incluye una fase inicial de preclasificación del tamaño a través de un mecanismo vibratorio, y después utiliza una cinta transportadora que organiza el flujo de granos hasta una estación de visión. En este momento se utiliza un aparato de procesamiento embebido que lleva a cabo algoritmos para la segmentación y el análisis de rasgos visuales como el tamaño y el color, lo que posibilita determinar la calidad del chocho y su aceptación o rechazo posterior [102].

Las siguientes investigaciones de proyectos similares se detallan a continuación en la siguiente Tabla 14.

Tabla 14. Proyectos de Investigación similares

Proyectos similares	Objeto de estudio	Técnica principal	Aporte relevante para esta tesis
Reconocimiento de enfermedades en hojas de maíz (2025)	Detección de enfermedades foliares en maíz	Deep learning (CNN, InceptionV3) con metodología CRISP-ML	Demuestra alta precisión de CNN en agricultura y sirve como referencia para el diseño del pipeline de entrenamiento y evaluación
Sistema de identificación de componentes eléctricos mediante visión artificial (2024)	Identificación de componentes en módulos didácticos	Visión artificial con modelo de clasificación supervisado	Aporta una estructura de proyecto en fases (dataset, etiquetado, modelo, validación) similar a la seguida en la presente investigación
Sistema de evaluación de calidad basado en visión artificial (2025)	Inspección de calidad en línea de producción	Sistema de visión con procesamiento de imagen y clasificador	Referente para el diseño de arquitecturas de inspección automatizada orientadas a control de calidad
Prototipo de sistema de clasificación de manzanas con visión artificial (2024)	Clasificación de manzanas por calidad	Visión artificial y red neuronal	Muestra la aplicación de redes neuronales al control de calidad de frutas, análogo al problema de clasificación de granos
Prototipo para detectar enfermedades en cultivo de chocho con IA (tesis UTC) (2024)	Detección de enfermedades en plantas de chocho	Técnicas de inteligencia artificial sobre imágenes móviles	Evidencia el interés en aplicar IA al chocho; tu trabajo complementa al centrarse en la etapa postcosecha y clasificación de grano
Diseño y construcción de un sistema automatizado de clasificación de chochos mediante visión artificial (2023)	Clasificación de chocho por tamaño y calidad para la empresa CORI	Zaranda mecánica + banda transportadora + sistema de visión artificial en Jetson Nano	Confirma que la automatización del proceso de selección de chocho reduce el tiempo de clasificación en más de cinco veces respecto al método manual, validando el uso de visión artificial y etapas mecánicas.

### 3. MÉTODOS Y PROCEDIMIENTOS

#### 3.1. ENFOQUE DE LA INVESTIGACIÓN

El presente estudio utiliza un enfoque mixto combinando métodos cualitativos y cuantitativos para alcanzar los objetivos planteados. El primer y segundo objetivo se abordan desde una perspectiva cualitativa orientada a caracterizar el proceso manual de clasificación y a definir el modelo de visión artificial y sus algoritmos de aprendizaje automático a partir del análisis del trabajo actual y de las características del chocho. El tercer objetivo se desarrolla con un enfoque cuantitativo enfocado en medir el desempeño del modelo en ambientes controlados mediante métricas estadísticas que validen su capacidad de clasificación automática.

#### 3.2. METODOLOGÍA APLICADA AL DESARROLLO DEL PROYECTO

En la Figura 10, donde se puede observar las metodologías integradas para la investigación de este proyecto ya que posibilitan tratar el problema desde dos perspectivas complementarias: por un lado, Design Thinking brinda una perspectiva centrada en las personas, lo cual ayuda a entender a fondo las vivencias y necesidades de los consumidores, comerciantes y agricultores; por el otro lado, Waterfall proporciona un marco secuencial y organizado para planificar, diseñar, desarrollar y valorar la solución tecnológica. La combinación de ambas perspectivas contribuye a que el desarrollo del modelo de visión artificial no sea únicamente sólido en términos técnicos, sino también relevante y beneficioso para los participantes implicados.

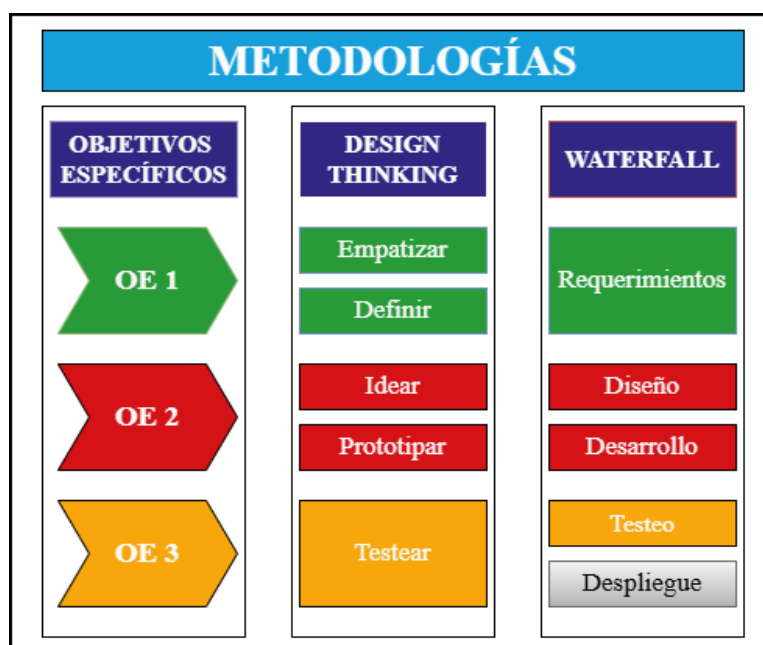


Figura 10. Metodología del proyecto

Para poder inicial con el estudio se utilizará las etapas de Empatizar, Definir y Requerimientos, estas fases son un apoyo claro para alcanzar el primer objetivo, ya que se examina y estudia la clasificación manual, las condiciones reales del trabajo y los criterios de calidad. Esto permite convertirlos en necesidades y requisitos precisos que guían el proyecto en su totalidad, llevando a cabo una caracterización apropiada del proceso, lo cual es lo que se propone fundamentalmente en dicho objetivo.

A continuación, se demuestra que el segundo objetivo se llevará a cabo basándose en las fases de prototipado e ideación del método Design Thinking, que están asociadas con las etapas de diseño y desarrollo de Waterfall. En estas fases, se proponen soluciones alternativas, se diseña la arquitectura del sistema y se crea un modelo de visión artificial mediante una secuencia organizada, pero siempre guiados por lo que los usuarios han aprendido.

Para poder lograr el tercer objetivo, se puede demostrar que las etapas de prueba del Design Thinking tienen similitudes con la etapa de prueba del Waterfall, en la que el modelo es sometido a pruebas en condiciones controladas para evaluar su capacidad de clasificación y su adecuación a los requisitos establecidos al comienzo. En esta propuesta no se incorpora la etapa de Despliegue, que es parte del modelo Waterfall y también interactúa con las últimas fases, porque el trabajo se centra en el diseño, la construcción y validación controlada del modelo, sin haber alcanzado todavía su implementación final en un contexto real.

### **3.3. DELIMITACIÓN DEL ESTUDIO DE LA INVESTIGACIÓN**

La población de estudio está constituida por los agricultores actores principales del proceso de clasificación del chocho (*Lupinus Mutabilis*) comercializados en la plaza Kennedy del cantón Saquisilí, donde se identificó la problemática de clasificación manual durante las jornadas habituales de venta. En este contexto se trabajó con los lotes pertenecientes a los agricultores que brindaron acceso para la observación y el registro del proceso, considerando tanto los granos aceptados para la venta como aquellos descartados por defectos visibles.

Para la fase experimental se aplicó un muestreo intencional de tipo censal sobre los lotes disponibles de los productores participantes, es decir, se incluyeron todos los sacos de chocho a los que se tuvo acceso en la plaza durante el trabajo de campo. La única condición de inclusión fue que el grano se encontrara en etapa de comercialización y fuera sometido al proceso de selección manual tradicional, lo que permitió documentar el estado real del producto y los criterios empíricos utilizados por los agricultores.

Paralelamente a la caracterización de los granos, se entrevistó a los productores que participaron en el estudio, con el fin de identificar qué consideran como chochos “buenos” o “dañados”, las características específicas asociadas a cada defecto y las molestias que estos generan en la venta. Optar por abarcar la totalidad de los lotes accesibles en este entorno permitió obtener información exhaustiva sobre la variabilidad del grano y reducir sesgos en la conformación del conjunto de datos, lo cual resulta fundamental para la posterior construcción y validación del modelo de visión artificial.

### **3.4. MÉTODOS Y TÉCNICAS DE LA INVESTIGACIÓN**

#### **3.4.1. Métodos teóricos de la investigación**

Revisión bibliográfica: Se recopiló y analizó literatura sobre calidad del grano, cultivo y características del chocho (*Lupinus Mutabilis*), así como sobre visión artificial, procesamiento digital de imágenes y algoritmos de aprendizaje automático aplicados a la agroindustria con el fin de sustentar conceptualmente el modelo de clasificación automático.

Análisis comparativo: Se comparó los criterios de clasificación manual observados con los enfoques y resultados reportados en estudios previos identificando oportunidades de mejora que orienten al diseño del sistema de visión artificial.

#### **3.4.2. Métodos empíricos de la investigación**

Observación directa: Se realizó trabajo de campo en la plaza Kennedy y en el área de clasificación de un agricultor, registrando paso a paso cómo identificar granos “buenos” y “dañados” y las condiciones reales de trabajo.

Entrevistas: Se realizaron entrevistas semiestructuradas a los productores para recoger su experiencia en la clasificación del chocho y sus opiniones sobre la incorporación de un modelo de sistema automatizado.

#### **3.4.3. Técnicas e instrumentos de la investigación**

Métodos visuales: Registro fotográfico y de video del proceso de clasificación del chocho.

Criterios técnicos: Determinación de criterios de aceptación y rechazo del grano basada en defectos visuales de productores y comerciantes.

Entrevistas: Orientadas a comerciantes, consumidores y agricultores.

#### **3.4.4. Aplicación de la metodología Design Thinking**

La metodología Design Thinking se considera en este estudio como una herramienta apta que permite abordar problemas reales combinando análisis técnico y comprensión profunda del usuario. Su estructura por fases permite realizar un estudio que permite pasar de la observación del contexto a la formulación de soluciones concretas, siempre tomando en cuenta cómo las personas ejecutan el proceso.

A partir de este enfoque centrada en el usuario, Design Thinking se utiliza para la identificación del problema, la construcción de una visión clara de las oportunidades de mejora y la generación de una solución basada en visión artificial que responda a las condiciones reales de trabajo de los agricultores.

### **3.5. METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EMPATIZAR**

La primera etapa para alcanzar el primer objetivo se considera la empatía, porque esta investigación se basa en entender a fondo el contexto humano del proceso de clasificación manual del chocho. En este momento, se crea primero un diagrama de flujo general del proceso de clasificación y comercialización para distinguir con claridad a todos los involucrados dentro de este proceso y sus interacciones. Esta representación gráfica hace posible ver cómo el producto se desplaza desde la selección manual hasta la venta, así como los momentos en que surgen decisiones vinculadas con la excelencia.

El trabajo de campo orientado a identificar las sensaciones, experiencias y criterios de calidad de cada participante se elabora siguiendo este esquema. Para lograrlo, se utilizan observaciones directas, entrevistas y mapas de empatía, principalmente con los agricultores como encargados de la clasificación manual. Sin embargo, también se toma en cuenta el punto de vista de los consumidores y comerciantes. Así, la etapa de empatizar no solo reúne datos descriptivos, sino que también posibilita entender las necesidades, incomodidades y expectativas relacionadas con el chocho. Este insumo es esencial para definir el método de trabajo actual y guiar las fases posteriores del estudio.

#### **3.5.1. Lugar de estudio: Plaza Kennedy del Cantón Saquisilí**

El lugar de estudio es la plaza Kennedy, situada en el cantón Saquisilí, que pertenece a la provincia de Cotopaxi. Se encuentra a unos 200 metros al oeste del parque central y está acotada por las calles Gonzales Suárez, Barreno, Mariscal Sucre y Pullupaxi como se puede observar

en la Figura 11. Este lugar es parte de las siete plazas que componen el mercado indígena de Saquisilí y se caracteriza por ofrecer la venta, tanto al por mayor como al por menor, de cereales y granos secos, incluyendo chocho, maíz, morocho, quinua y otros productos agrícolas que proveen a los visitantes de comunidades cercanas y a la población local.




Figura 11. Lugar de estudio

Durante la feria, sobre todo los jueves, la plaza Kennedy se vuelve un lugar de mucha actividad comercial. En este sitio se colocan vehículos y puestos con sacos de granos, se realizan movimientos comerciales desde las primeras horas del día y conviven métodos más actuales de comercio con prácticas tradicionales de intercambio. La proximidad entre los productores, los intermediarios y los compradores, así como la distribución física de los puestos, permiten observar de forma directa las operaciones habituales de descarga, revisión, clasificación y venta del chocho en condiciones normales de trabajo. Por lo tanto, este contexto es apropiado para llevar a cabo la fase de empatizar del presente estudio.

El siguiente apartado muestra un diagrama de flujo que ilustra el proceso del chocho en la plaza Kennedy, desde que llega en sacos hasta que es adquirido por el cliente final, según este contexto visual y funcional. Este esquema posibilitará representar la situación del proceso de clasificación manual del grano en este momento y servirá como fundamento para una determinación más específica de los actores implicados y de los aspectos críticos del procedimiento.

### 3.5.2. Situación actual y stakeholders del proceso de clasificación manual del chocho

En este apartado se estudiará la visión general de la manera en que se lleva a cabo hoy en día el proceso de clasificación manual del chocho en la plaza Kennedy, tomando en cuenta las acciones que se realizan desde que el producto sale del área agrícola hasta que llega al

consumidor final en el mercado. El propósito es ilustrar este recorrido de forma clara y ordenada a través de un diagrama de flujo, para que la secuencia de pasos, los puntos de decisión y las interacciones entre los miembros de la cadena sean visibles. Esto servirá como fundamento para analizar el proceso en sí y sus posibilidades de mejora posteriormente.

El diagrama de flujo presentado en la Figura 12, permite identificar a los actores principales en el proceso de clasificación manual del chocho en la plaza Kennedy: comerciantes, agricultores y consumidores. La imagen gráfica ilustra la intervención de cada uno en distintas etapas del trayecto del grano, lo que constituye la base para el desarrollo futuro de los mapas de empatía y para identificar las zonas críticas donde se decide la calidad del producto.

En la etapa del agricultor, el procedimiento comienza con la recolección de las vainas de chocho, el traslado a un espacio de trabajo y la adquisición del grano a través de los métodos tradicionales de secado y trillado. Posteriormente, el productor abre los sacos, coloca el grano en la zona de clasificación y lleva a cabo una selección manual grano por grano. Con base en consideraciones empíricas como color, tamaño y defectos visibles, separa lo que considera adecuado para la venta de lo que se destina a semilla u otros fines.

Cuando concluye la selección, el agricultor recoge el chocho clasificado, ordena los quintales y los lleva a la plaza Kennedy para venderlos a los comerciantes durante la feria realizada los jueves de cada semana. En este momento se determina el volumen de producto que está disponible para vender y la calidad inicial del grano cuando entra al mercado; por ello, constituye un aspecto fundamental para entender el esfuerzo físico empleado y la variabilidad que los otros participantes del proceso observarán más adelante.



Figura 12. Diagrama de flujo del proceso del chocho

Posteriormente en la sección del comerciante, el procedimiento comienza cuando recibe los sacos de chocho provenientes de las áreas de cultivo y los ubica en la zona de comercialización ubicada en la plaza Kennedy. A continuación, el comerciante, abre un saco y toma una muestra de grano. Después, realiza un rápido examen visual del lote, prestando atención principalmente al color, el tamaño, la limpieza y si hay impurezas o granos deteriorados. Este análisis empírico actúa como un primer filtro que determina si se acepta o se rechaza la mercancía.

Si el comerciante considera que la calidad es aceptable, procede a pesar los sacos y discutir con el agricultor acerca del precio, tomando en cuenta tanto el peso total como la apariencia de los granos. En esta fase, la calidad observada se convierte directamente en valor monetario. En los casos en que el producto tiene defectos a la vista, se abre una oportunidad de negociación adicional. Esta puede terminar con una rebaja del precio o con la devolución del lote. Si se acepta el lote, el comerciante puede hacer limpieza o reclasificación complementaria antes de organizar el chocho y ponerlo en recipientes y fundas para luego exhibirlo y venderlo al detalle en su espacio de mercado.

Siguiendo con la sección dedicada al consumidor, el flujo comienza cuando el individuo va a los mercados o a las tiendas donde normalmente adquiere chocho y examina los diversos puestos disponibles en la plaza Kennedy. Posteriormente, se acerca a un punto de venta particular y realiza una inspección visual del producto, enfocándose en el color, las dimensiones, la limpieza y la apariencia general de los granos para determinar si le inspira confianza y si lo considera un alimento excelente.

Si le parece apropiado el chocho, el comprador verifica las condiciones de venta y el precio, escoge la cantidad que quiere comprar y paga, para al final llevarse el producto a su casa, donde lo lava, lo enjuaga y lo prepara de acuerdo a sus hábitos alimenticios. Después de consumir, califique su experiencia en función del gusto, la textura y la presencia de granos defectuosos; si el producto no satisface sus expectativas, puede presentar una queja al vendedor. De lo contrario, si está satisfecho, es probable que vuelva a comprar en el mismo lugar y lo recomiende a otros, proporcionando así comentarios directos al comerciante y indirectamente al agricultor.

El Design Thinking se basa en esta comprensión minuciosa de la situación presente, pues permite establecer mapas de empatía y entrevistas que explorarán las percepciones, necesidades y problemas de cada conjunto de actores implicados en la clasificación manual del grano.

### **3.5.3. Identificación y caracterización del proceso**

#### **3.5.3.1. Caracterización general de los actores principales**

Para caracterizar cada uno de los grupos, se utilizarán los datos adquiridos a través de entrevistas semiestructuradas llevadas a cabo por separado con comerciantes, agricultores y consumidores. Para los agricultores, las preguntas se enfocan en detallar cómo realizan la trilla y la clasificación manual, cuánto tiempo toman por quintal, a dónde va el grano no apto, qué criterios táctiles y visuales emplean para distinguir la calidad del producto, los efectos físicos de su labor y cuántos años llevan realizando esta actividad. Se observó en el trabajo de campo que la mayoría de quienes se dedican a la clasificación manual tiene entre 35 y 60 años y cuenta con una experiencia laboral de entre 8 y 20 años, pero los jóvenes son escasos.

En los comerciantes, las entrevistas investigan el proceso que llevan a cabo para comprar y vender chocho, los inconvenientes que surgen al recibir productos mal clasificados, cómo estos errores impactan sus ventas y qué información y mejoras consideran necesarias para simplificar la comercialización. En última instancia, se recopilan en los consumidores percepciones sobre la apariencia y condiciones del chocho que sean deseables, experiencias negativas vinculadas a su presentación, respuestas ante granos defectuosos y expectativas con respecto al empleo de tecnología para optimizar la elección del producto.

#### **3.5.3.2. Propósito de la caracterización**

El objetivo de esta identificación y caracterización es confrontar las experiencias y perspectivas de los agricultores, los comerciantes y los consumidores con respecto al proceso manual de clasificación del chocho, los obstáculos que afrontan y la manera en que la calidad del grano influye en sus ingresos o en cómo toman decisiones los compradores. El propósito es comprender cómo cada grupo determina qué es un grano "bueno" o "defectuoso", a partir de las similitudes y diferencias que se encuentran en la Plaza Kennedy.

Esta comprensión posibilita que el modelo de visión artificial se ajuste a las exigencias concretas del entorno local, incorporando las percepciones de los participantes. Esto fue el resultado directo del trabajo de campo realizado en la Plaza Kennedy, donde los procesos manuales llevados a cabo con los productores fueron observados y discutidos, se establecieron tres categorías visuales fundamentales, que se basan en criterios prácticos de color, forma y defectos superficiales y que pueden aplicarse directamente a la clasificación:

- Granos con puntos negros: Como se puede observar en la Figura 13. Esta categoría agrupa aquellos granos que presentan manchas oscuras visibles, las cuales son indicativas de deterioro o contaminación superficial que afecta su calidad para el consumo.



Figura 13. Granos con puntos negros

- Granos dañados: En esta categoría se incluyen los granos que presentan daños físicos como grietas, deformaciones o signos de insectos o enfermedades, como se muestra en la Figura 14 lo que compromete su integridad y aptitud para su uso.



Figura 14. Granos dañados

- Granos buenos: Esta categoría representa los granos en óptimas condiciones, sin manchas ni daños visibles, considerados aptos para el consumo y comercialización como se muestra en la Figura 15.



Figura 15. Granos buenos

Estas categorías, que se han validado en situaciones reales de la plaza a través de la observación directa y el acuerdo con los agricultores, constituyen la base estructurada para etiquetar datasets de manera precisa, entrenar el modelo de visión artificial bajo supervisión y validarlo. Esto garantiza una precisión acorde con los estándares locales y reduce al mínimo los errores en contextos con iluminación.

#### **3.5.4. Herramienta para empatizar**

En esta sección se detallan los recursos empleados para convertir la información cualitativa obtenida del trabajo de campo en insumos ordenados que posibiliten entender la experiencia de los participantes durante el proceso de clasificación manual del chocho. Para este propósito, se unen conversaciones y entrevistas semiestructuradas a consumidores, agricultores y comerciantes con un modelo de mapa de empatía. Este último ayuda a sintetizar visualmente las emociones, percepciones, necesidades y problemas relacionados con el manejo del grano. En la Figura 16 se presenta el modelo del mapa de empatía que será utilizado para organizar los datos recolectados.

## Mapa De Empatía

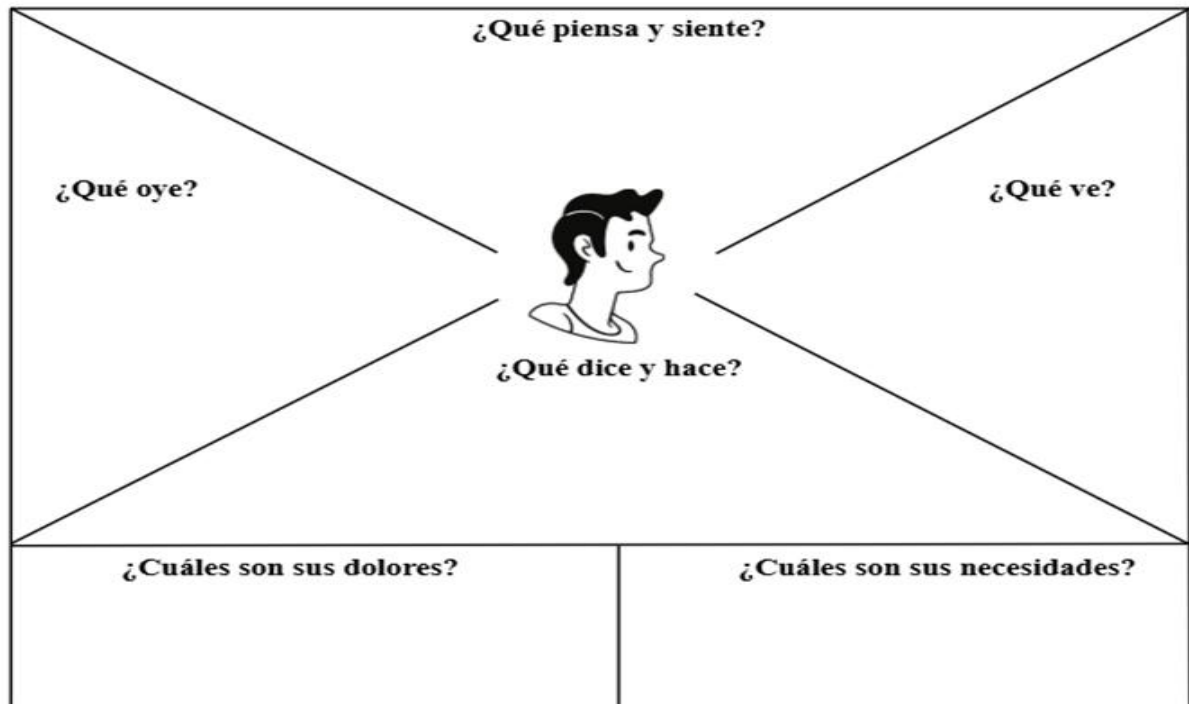


Figura 16. Plantilla de mapa de empatía

El mapa de empatía que se muestra en la Figura 16 está organizado en seis partes, lo que facilita la organización diferenciada de la información. En "¿Qué piensa y siente?", se anotan las inquietudes del participante respecto a su trabajo, sus temores sobre el futuro y lo que espera con respecto a la venta o consumo del chocho. En "¿Qué ve?", se incluyen las cosas que nota en su entorno, como la manera en la que llega el grano, si hay otros comerciantes presentes, cómo está organizada la plaza o cómo reaccionan los clientes frente a la calidad del producto.

En lo que respecta a lo que oyen, se refiere a las opiniones e influencias que reciben de otros seres humanos, como por ejemplo críticas o sugerencias de clientes y comentarios de familiares, otros comerciantes o agricultores. También incluye mensajes transmitidos por medios locales o de boca en boca. En "¿Qué dice y hace?", se sintetizan las expresiones verbales y los actos que pueden ser observados en relación con la compra, el consumo o la clasificación del chocho [103].

Las respuestas de los comerciantes, consumidores y agricultores se transcribirán y codificarán después de realizar las entrevistas. Se agruparán las frases en función de su contenido temático. En la sección de "piensa y siente", se incluirán los elementos relacionados con emociones, inquietudes o expectativas; en la sección de "ve", las descripciones del ambiente físico y el

funcionamiento de la feria; en "oye", los comentarios sobre lo que dicen o recomiendan otros; y en "dice y hace", los comportamientos descritos u observados.

Las referencias a problemas, fatiga, pérdidas financieras o incomodidades se agruparán como "dolores", mientras que las sugerencias de mejora, los anhelos de cambio o las evaluaciones sobre el soporte tecnológico se clasificarán como "necesidades". Esto posibilitará la creación de mapas de empatía separados para cada grupo y la comparación subsiguiente de los patrones detectados.

#### **3.5.4.1. Procedimiento de levantamiento de información cualitativa**

Se llevó a cabo la recolección de información cualitativa a través de entrevistas semiestructuradas que se realizaron en la plaza Kennedy, en el marco de las ferias del jueves, en el mismo lugar donde tienen lugar las actividades de clasificación y venta del chocho. Se trabajó con tres grupos de participantes: ocho consumidores, que tenían entre 25 y 45 años y fueron escogidos por ser el grupo poblacional que va más a menudo a adquirir chocho en la plaza; y seis comerciantes y seis agricultores, cuyas edades iban de los 35 a los 60 años, un intervalo de edad en el cual se concentra la mayor experiencia en la clasificación manual del grano.

Siguiendo el criterio de saturación teórica, se estableció el tamaño de la muestra como un número intencionado de entrevistas, propio de estudios cualitativos, se siguió recogiendo información hasta que las respuestas recientes empezaron a reiterar patrones previamente detectados, sin ofrecer datos significativamente distintos [104].

Las entrevistas se llevaron a cabo de manera presencial en los puntos de venta o zonas de tránsito del mercado, pidiendo primero la autorización de los participantes para contestar las preguntas y permitir que se grabara el audio. Las conversaciones duraron entre 12 y 16 minutos cada una, y se acompañaron de notas de campo que incluían el contexto del proceso de clasificación manual del chocho.

Se eligieron a los entrevistados de manera conveniente, contactando a los consumidores que iban a comprar chocho en la plaza y estaban dispuestos a colaborar, así como a los comerciantes y agricultores presentes. De esta forma se pudieron obtener testimonios directamente relacionados con las decisiones diarias sobre la calidad del grano y con el estado real del procedimiento de clasificación manual.

### **3.5.4.2. Elaboración de mapas de empatía por stakeholder**

Se elaborará un mapa de empatía para cada uno de los grupos de interesados definidos (consumidores, comerciantes y agricultores) con el fin de resumir la información recopilada a través de entrevistas y observaciones. Se llenarán sistemáticamente las seis partes del modelo elegido, que son "piensa y siente", "ve", "oye", "dice y hace", "dolores" y "necesidades".

Esto se logrará a partir de la codificación temática de las respuestas. Así, cada mapa capturará en una sola representación visual las expectativas, emociones, problemas y percepciones más significativas de ese grupo. Estos mapas constituirán el recurso de referencia principal para examinar los resultados en el capítulo 5, donde se analizarán patrones entre actores y se obtendrán conclusiones sobre la experiencia actual de clasificación manual del chocho.

## **3.6. METODOLOGÍA DESIGN THINKING: REQUERIMIENTO PARA DEFINIR**

La fase Definir, de la metodología Design Thinking, se establece como el vínculo entre la etapa de empatizar y la definición exacta del problema que se tratará en el estudio. En esta etapa, se pretende estructurar, depurar e interpretar los hallazgos obtenidos a través de entrevistas, observaciones y mapas de empatía. El objetivo es convertir las percepciones dispersas en afirmaciones claras sobre los principales obstáculos para clasificar manualmente el chocho en la plaza Kennedy.

La lluvia de ideas, el diagrama de afinidad, la técnica de los 5 porqués y el árbol de problemas son algunas de las herramientas que se emplean para sintetizar las causas y efectos más significativos, con el objetivo final de identificar un problema principal. Este problema central será la base para guiar tanto el diseño de una solución como las decisiones metodológicas en las etapas posteriores del estudio.

### **3.6.1. Lluvia de ideas de las dificultades en la clasificación manual**

En este apartado se expone el procedimiento implementado para ampliar y clarificar los problemas identificados de manera preliminar en la fase de empatizar. Con base en las necesidades y dificultades identificadas a través de las entrevistas y los mapas de empatía, se llevará a cabo una sesión de lluvia de ideas.

En esta sesión, se generarán enunciados que reflejen, de manera clara y concisa como se muestra en la Tabla 15, las diversas dificultades asociadas al proceso de clasificación manual del chocho. Entre estas dificultades se incluyen el tiempo requerido, el esfuerzo físico, la

variabilidad en los criterios de calidad y las pérdidas económicas resultantes de errores en la selección.

Tabla 15. Reglas para realizar lluvia de ideas

<b>Reglas</b>	<b>Descripción</b>
Regla 1: Suspensión de juicio	Con el fin de promover la creatividad y la participación equitativa, durante la sesión no se descarta ni critica ninguna idea; todas las contribuciones se anotan tal como son expresadas.
Regla 2: Cantidad antes de calidad	Se fomenta la producción de tantas ideas como sea posible, aunque parezcan imprecisas o semejantes, teniendo en cuenta que posteriormente serán organizadas y perfeccionadas.
Regla 3: Construcción de colectiva	Se tiene la posibilidad de enriquecer o rehacer ideas previas, lo cual posibilita que se pase de problemas sencillos a formulaciones más complejas acerca de las dificultades de clasificación.
Regla 4: Enfoque en la expresión	Las ideas deben fundamentarse en situaciones auténticas que los integrantes de la cadena de valor del chocho hayan experimentado, evitando así suposiciones o puntos de vista que no estén respaldados por las experiencias recolectados en los mapas de empatía.

Las normas básicas que guían la lluvia de ideas acerca de los problemas con la clasificación manual del chocho se pueden ver en la Tabla 15. Estas normas se fundamentan en directrices que poseen un amplio respaldo para la implementación del brainstorming en entornos investigativos.

Algunas de estas reglas son: la suspensión del juicio, el afán por generar numerosas ideas y el desarrollo colectivo basado en las contribuciones de los miembros participantes, elementos que promueven un ambiente de respeto y creatividad entre los actores implicados. En el capítulo 5, se aplicará esta tabla como una referencia metodológica para analizar los resultados gráficos de la lluvia de ideas [105].

El propósito de este ejercicio es conseguir la mayor cantidad posible de formulaciones problemáticas que representen el punto de vista de los comerciantes, los consumidores y los agricultores, preservando la riqueza de sus expresiones originales. Por esta razón, no se analizará ni se priorizará ninguna idea de sus expresiones originales.

### 3.6.2. Agrupación de información mediante diagrama de afinidad

En esta sección se explica cómo se utiliza el diagrama de afinidad para clasificar las dificultades detectadas durante la lluvia de ideas sobre la clasificación manual del chocho. Se organizaron las ideas en tres grupos principales de problemas, basándose en los enunciados de los agricultores, los comerciantes y los consumidores. Estas agrupaciones reflejan el impacto de estos inconvenientes en el mercado, las restricciones sobre la calidad obtenida y la carga física del método manual a continuación, en la Tabla 16, se puede evidenciar los nombres de los grupos identificados.

Tabla 16. Grupos de problemas

<b>Categoría de afinidad</b>	<b>Descripción de los problemas agrupados</b>
Categoría física y limitaciones del método manual	Agrupación de afirmaciones vinculadas con el cansancio físico, la fatiga visual y la necesidad de que el agricultor esté en buena condición física para sostener la dinámica de clasificación.
Calidad y eficiencia del agricultor	Incorpora inconvenientes como la ausencia de criterios definidos, la necesidad de tiempo extra para finalizar la selección, la presencia de granos dañados y la calidad inestable entre lotes.
Impacto en el mercado	Engloba los problemas relacionados con la ausencia de tecnología de apoyo, la desconfianza del cliente y las pérdidas financieras que surgen por vender productos de calidad variable.

En la Tabla 16, se presentan categorías de afinidad, que permite registrar de forma concisa la organización de los datos cualitativos obtenidos en la lluvia de ideas y muestra qué clases de problemas suelen coexistir y cómo se interpretan según ejes temáticos. Para abordar un problema central que esté basado en el diagrama de afinidad, se deben llevar a cabo cuatro pasos fundamentales: evaluar, priorizar, seleccionar y justificar; estos se aplican a los tres conjuntos de problemas detectados.

Según estos pasos, se busca pasar de una organización general con problemas a la identificación del grupo que tiene el conflicto operativo más importante, lo cual se refleja en los hallazgos de estas investigaciones en el capítulo 5 de análisis de resultados.

### 3.6.3. Profundización en causas con la técnica de los 5 Porqués

La técnica de los cinco porqués es utilizada en este subtema para investigar más a fondo las causas de los problemas que se han encontrado en la clasificación manual del chocho. Se

plantearán preguntas del tipo "¿por qué ocurre esto?" hasta cinco veces, basándose en el problema principal establecido por el diagrama de afinidad [106]. En cada nivel, se documentarán las conclusiones del equipo investigador y las respuestas brindadas por los participantes.

### Aplicación de los 5 Porqués



Figura 17. Estructura de los cinco porqués

En la Figura 17 se puede observar el esquema donde se aplicará los 5 porqués, el objetivo de este procedimiento es detectar las causas raíz que no resultan evidentes en la descripción inicial de los problemas, haciendo una distinción entre síntomas superficiales (como puede ser la lentitud o la calidad variable) y elementos estructurales, como por ejemplo la falta de criterios formales o de respuestas tecnológicas de soporte.

El capítulo 5 mostrará los resultados de la implementación del método, incluyendo un esquema gráfico de los cinco porqués. Esto hará posible justificar racionalmente la necesidad de crear un sistema de visión artificial para optimizar y normalizar el proceso de clasificación.

#### 3.6.4. Formulación del árbol de problemas

El árbol de problemas es un instrumento que permite ilustrar gráficamente la conexión causa-efecto entre una problemática central y las diferentes circunstancias que provocan y producen dicha problemática en un contexto específico. Este estudio emplea para sintetizar la

información recopilada en las técnicas anteriores y estructurarla de manera que se facilite entender cómo la clasificación manual del chocho está relacionada con sus causas fundamentales y sus efectos en el mercado y en la calidad [107]. En este subtema se expone la formulación del árbol de problemas vinculado a dicha clasificación manual, basándose en los datos obtenidos a partir de la lluvia de ideas, el diagrama de afinidad y la técnica de los 5 porqués.

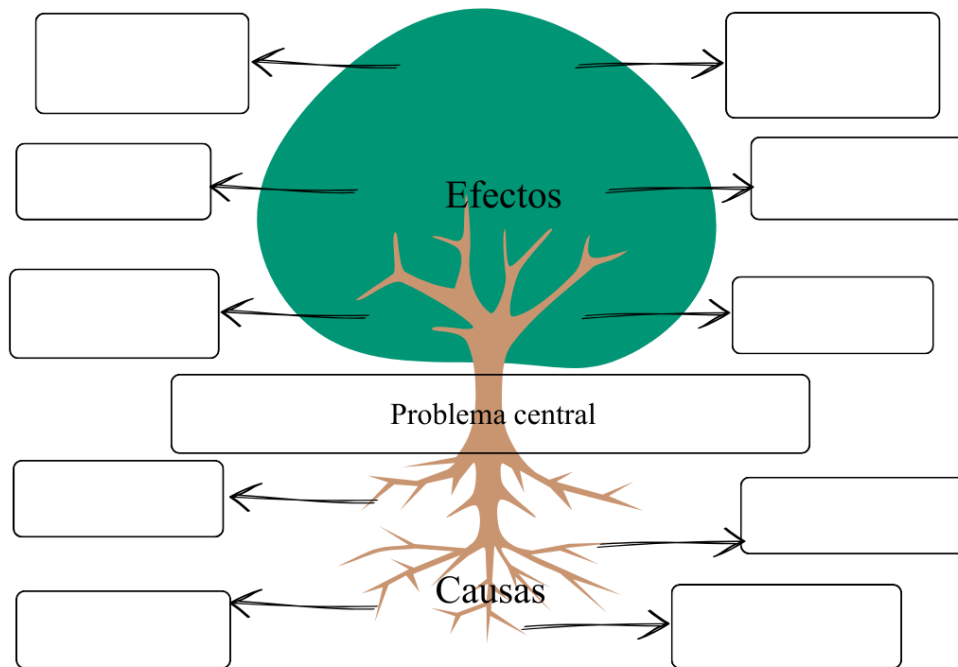


Figura 18. Estructura del árbol de problemas

El esquema del árbol de problemas de la clasificación manual del chocho se ilustra en la Figura 18. En este, los cuadros que están por debajo representan las causas; el cuadro central sintetiza el problema principal y los recuadros superiores muestran los diferentes efectos que se han observado. Esta representación facilita ver de manera ordenada la manera en que las causas se vinculan con el problema principal y cómo este afecta a los consumidores, a los comerciantes y a los agricultores.

El proceso de creación del árbol de problemas posibilita que las conexiones de causa y efecto entre los problemas observados sean organizadas lógicamente, lo que ayuda a apreciar cómo factores como la falta de criterios formales, el agotamiento físico del agricultor y la falta de tecnología de apoyo. La figura esquemática del árbol de problemas de la clasificación manual del chocho se presenta en el capítulo 4, mientras que en el capítulo 5, este esquema será utilizado nuevamente como base para examinar los resultados finales.

### **3.7. METODOLOGÍA WATERFALL**

En la etapa de requerimientos de la metodología Waterfall, se determina lo que se necesita para que un modelo de visión artificial pueda ofrecer una mejora efectiva en comparación con la clasificación manual del chocho. Con base en el problema principal y las causas detectadas en el árbol de problemas donde se propone como condición general tener una solución que respalde la estandarización visual del grano. Esto permitirá reducir la variabilidad entre los agricultores y disminuir la dependencia única de la vista y experiencia personal.

Estos requerimientos se definen como condiciones generales de rendimiento y utilidad, para brindar soporte de apoyo a la estandarización visual, hacer más fácil la identificación sistemática de variaciones en la apariencia del chocho y producir información que sea susceptible de comparación con la técnica manual para apreciar su contribución al procedimiento de clasificación.

En el capítulo 5, se analizarán estas circunstancias con base en los resultados obtenidos al caracterizar el proceso actual, para evaluar la viabilidad de crear un modelo de visión artificial que esté acorde con las necesidades identificadas en el contexto de estudio.

### **3.8. METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA IDEAR**

#### **3.8.1. Principios básicos de la fase de ideación**

La etapa de ideación la metodología Design Thinking se entiende como el momento en que después de comprender el proceso de clasificación y las necesidades de los productores se proponen soluciones potenciales al problema de clasificar a mano el grado del chocho. En esta fase se fomenta Intencionalmente la creación de múltiples opciones al combinar propuestas tecnológicas, Organizativas y de optimización de procesos sin restringir al principio la creatividad ni la variedad de ideas propuestas.

Dentro del marco de tesis, la ideación se enfoca en convertir el diagnóstico de la ineficiencia del método manual en propuestas específicas para la automatización a través del sistema mecánico y visión artificial. Para ello la etapa tiene en cuenta no solo las limitaciones reales, sino también los avances actuales en aprendizaje automático y el procesamiento de imágenes para las ideas que surjan, sean relevantes para el entorno de clasificación de *Lupinus Mutabilis* y se puedan conseguir soluciones de forma técnica.

### **3.8.2. Herramientas a utilizar para la fase de ideación**

#### **3.8.2.1. Procedimiento para la generación de lluvias de ideas**

El proceso de generación de ideas se organiza en varias fases posteriores que garantiza la claridad y el orden durante la etapa de ideación. En primer lugar, se muestra una breve contextualización del problema enfatizando las restricciones en términos del tiempo, precisión y carga laboral del operario que se identificaron durante el problema, esto ayuda a que los que forman parte de la lluvia de ideas orienten sugerencias hacia soluciones que aporten directamente al propósito de optimizar y automatizar el proceso a través de sistemas mecatrónicos y visión artificial.

A continuación, se lleva a cabo la charla de generación de ideas de esta etapa Promoviendo un número alto de propuestas que permitan la combinación y mejora de ideas anteriores, cada participante del proyecto propone diferentes soluciones de forma lógica y estructurada para la solución del problema Permitiendo que la fase de selección y evaluación puedan ser analizadas agrupando todas las ideas Propuestas en la fase de ideación.

#### **3.8.3. Documentación y registro de las ideas**

Para garantizar la claridad y la trazabilidad del proceso de ideación es fundamental registrar y documentar las ideas, cada idea se registra en una matriz durante las sesiones de lluvia de ideas. Esta matriz abarca el nombre de la idea y un breve resumen del enfoque del proceso de clasificación del chocho, con este formato se evita que se pierdan aportes significativos y se facilita la organización de las opciones de automatización y clasificación.

Adicionalmente el registro de ideas incluye observaciones sobre los medios posibles que se requieren en la relación de cada propuesta como se muestra en la Figura 19 con los objetivos particulares de la tesis especialmente en relación con el desarrollo del modelo de Visión artificial y su integración del sistema de clasificación, esta modalidad de documentación proporciona un insumo estructurado para la implementación de instrumentos como la matriz de ponderación y SCAMPER, lo que facilita que la selección y evaluación de opciones se sustente con información exacta y apropiados con el entorno técnico del proyecto.

### Métodos de clasificación de granos




Figura 19. Estructura para la lluvia de ideas

### 3.8.4. Evaluación y selección de las ideas

#### 3.8.4.1. Métodos y criterios de ponderación

Se utiliza técnicas de ponderación que permiten la comparación de las opciones producidas durante el proceso de ideación en la etapa de evaluación y selección de ideas. El método principal se basa en construir una matriz de decisión, que cada idea recibe un valor numérico conforme a un conjunto de criterios que se establecieron, y se obtiene una puntuación total al sumar estas calificaciones ponderadas. Este método permite clasificar las sugerencias y elegir las que tienen un equilibrio más adecuado entre el rendimiento técnico, costo y la factibilidad de implementación en el prototipo de visión artificial para la clasificación del chocho.

Los criterios que se tienen en cuenta en la matriz son entre, la viabilidad técnica, la compatibilidad de los recursos existentes, el grado de dificultad para llevarlo a cabo y el precio proyectado en el software y hardware al clasificar granos buenos y defectuosos. La capacidad de ampliar se hace entornos productivos reales y el efecto en su disminución del tiempo de procesamiento. Se asigna un peso a cada criterio de acuerdo con su importancia relativa para el proyecto y se clasifica cada idea en una escala ideal lo que facilita conseguir una puntuación adecuada para cada alternativa.

### **3.8.5. Metodología SCAMPER**

#### **3.8.5.1. Propósito de la herramienta SCAMPER**

La idea con mayor puntuación busca a través de la herramienta SCAMPER, fortalecer el proceso de ideación con un esquema organizado de preguntas que facilite la transformación del método convencional de clasificación manual del *Lupinus Mutabilis* en un sistema automatizado fundamentado en visión artificial. SCAMPER Se utiliza para analizar fundamentalmente la mejor idea obtenida en la lluvia de ideas, centrandose en el análisis del proceso que podrían ser modificados o reestructurados para mejorar la precisión, acortar tiempos y disminuir la dependencia de personal o trabajadores [107].

La metodología SCAMPER tiene como objetivo Eliminar e incrementar las propuestas iniciales al aplicar sistemáticamente sus 7 operaciones (sustituir, combinar, adaptar, modificar, poner a otro uso, eliminar y reordenar o revertir). Esto promueve que la solución final elegida cumpla más adecuadamente con el objetivo de desarrollar un modelo de visión artificial integrado a un prototipo funcional de clasificación automática del chocho.

#### **3.8.5.2. Análisis de los componentes SCAMPER**

El estudio de los elementos de SCAMPER tiene como objetivo implementar cada una de sus operaciones en la técnica de clasificación del chocho y en las soluciones sugeridas para la automatización como se muestra en la Tabla 17 las diferentes etapas. Durante la fase de “Sustituir” se investigan componentes del proceso manual que tienen el potencial de ser reemplazados por tecnologías de visión artificial y aparatos electrónicos. Esto incluye la posibilidad de reemplazar el reconocimiento visual humano con un modelo para detectar y clasificar imágenes, así como la separación mediante servomotores que son controlados por un microcontrolador. En” Combinar” se tienen en cuenta las conexiones entre los componentes.

La operación “Adaptar” se enfoca en modificar las tecnologías actuales de automatización y visión artificial para que se adapten a las condiciones específicas del *Lupinus Mutabilis* por ejemplo, adecuando elementos como la arquitectura de la red neuronal, la iluminación y los parámetros para capturar imágenes de acuerdo con el ambiente productivo local y con las características físicas del grano. En “Modificar” se examinan las alteraciones en términos de dimensiones y configuraciones del sistema. Por ejemplo, se puede modificar la velocidad de la banda transportadora, la resolución de la cámara o los límites de confianza del modelo para lograr un balance óptimo entre el tiempo de procesamiento.

Tabla 17. Pasos para realizar un SCAMPER

<b>ETAPA</b>	<b>DESCRIPCIÓN</b>
<b>Sustituir</b>	Trocar un elemento por otro
<b>Combinar</b>	Unir dos o más elementos
<b>Adaptar</b>	Ajustar un elemento para un nuevo uso
<b>Modificar</b>	Alterar un elemento para mejorarlo
<b>Proponer otros usos</b>	Encontrar nuevas aplicaciones para un elemento
<b>Eliminar</b>	Remover un elemento innecesario
<b>Reorganizar</b>	Mudar el orden de los elementos

Con “Poner a otros usos” se examina la forma de utilizar tecnologías o componentes existentes en escenarios diferentes haciendo uso de cámaras comerciales y microcontroladores de propósito general como elementos de un sistema de visión artificial para clasificar granos. La operación de “Eliminar” tiene como objetivo detectar acciones adicionales o innecesarias en el método manual como inspecciones repetidas o manipulaciones intermedias que pueden eliminarse si se dispone de un sistema automatizado. Por último, en “Reordenar o revertir”, se analizan nuevas secuencias de ejecución de las actividades.

### **3.9. METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EL DISEÑO**

#### **3.9.1. Uso de software CAD para el modelado**

Fusion 360, un software de modelado CAD, es empleado para diseñar el prototipo en detalle. Este programa posibilita la creación de los componentes en tres dimensiones junto con sus cotas, tolerancias y condiciones de ensamble adecuadas. En este ambiente se modelan la tolva dosificadora, los laterales de la banda, los rodillos, el medio controlado, las divisiones internas y las paletas clasificadoras. Antes de iniciar la producción, se revisan alineaciones, interferencias y rutas de movimiento. Además, la utilización de Fusion 360 permite crear archivos que pueden ser exportados a programas de impresión en tres dimensiones, lo que garantiza una conexión entre el diseño virtual y las piezas tangibles del prototipo.

### **3.9.2. Recursos digitales de diseño provenientes de Thingiverse**

Para ayudar en el proceso de diseño, se utilizan las plantillas y modelos de cintas transportadoras y mecanismos parecidos que ya han sido creados por la comunidad y se encuentran disponibles en la plataforma digital Thingiverse. Estas referencias se utilizan como punto de partida para determinar proporciones, configuraciones de rodillos, métodos de tensado y detalles constructivos, que posteriormente se ajustan a los requerimientos particulares de la clasificación del chocho en términos de tamaño, capacidad y clase de material. Así, el diseño del prototipo combina ideas propias con prácticas efectivas de diseños abiertos, lo que disminuye el tiempo de desarrollo y optimiza la viabilidad de construcción del sistema.

### **3.9.3. Diseño del prototipo en 3D**

El diseño del prototipo se basó en una capacidad inicial de una libra considerando que esta cantidad resulta óptima para la realización de pruebas experimentales antes de desarrollar una máquina a escala industrial. Esta elección permite validar el funcionamiento de los mecanismos e identificar posibles mejoras y ajustar parámetros. Trabajar con una libra de producto minimiza el desperdicio de materia prima durante el proceso de ensayo y facilita múltiples iteraciones de ajuste y evaluación asegurando que los resultados obtenidos sean aplicables y confiables para futuras ampliaciones del proyecto. En la Figura 56 se presenta el modelo 3D del diseño propuesto el cual servirá como base para la construcción y validación del proyecto.

#### **3.9.3.1. Tolva**

- **Adaptación de pieza exportada de Thingiverse**

La Figura 20 muestra la pieza con mallas que fue exportada de Thingiverse, la cual se ha modificado para operar como tolva en el prototipo. Esta pieza de diseño abierto tiene agujeros calibrados que posibilitan el flujo controlado de granos de chocho hacia la banda transportadora inferior.

La pieza fue importada en formato STL y se hicieron ajustes en las dimensiones mediante el software Fusion 360 para asegurar que fuera compatible con el sistema de visión artificial, mientras se conserva su geometría optimizada para una carga uniforme de media libra de chochos.




Figura 20. Pieza exportada adaptada

- **Diseño y montaje de tolva final**

La Figura 21 ilustra la tolva final, que fue diseñada en Fusion 360 (pieza sólida) e incluye el componente exportado de Thingiverse, creando así un sistema híbrido. Esta robusta estructura brinda el soporte estructural y orienta el tránsito de granos desde la tolva hacia la zona de inspección visual.




Figura 21. Tolva dosificadora

### 3.9.3.2. Laterales de la banda transportadora

En la Figura 22 se muestra la vista de los laterales de la estructura de la banda transportadora diseñada para soportar el peso de sus componentes anclados como también su fuerza de la banda. Los laterales tienen una medida de 10 cm de alto y 53 cm de largo. En uno de los extremos se observa claramente el soporte específico para un motor DC, el cual se fija al lateral de la pieza mediante unos orificios para tornillos, este diseño permite que el eje del motor este

alineada facilitando el acoplamiento con el sistema del rodillo. Los laterales tienen un espesor de 0.5 cm lo que permite tener una estabilidad.




Figura 22. Estructura lateral de la banda

### 3.9.3.3. Rodillos laterales y soporte triangular

En la Figura 23 se evidencia la integración de dos cilindros ubicados en cada extremo de los laterales, estos rodillos aseguran el desplazamiento de la banda ya que estos rodillos aseguran la tensión adecuada de la tela para que pueda girar la banda. Adicionalmente se puede observar un soporte triangular atornillado a cuatro piezas en cada extremo lo que permite que estén unidas y firmes durante el proceso.



Figura 23. Acoplamiento de la banda

En la Figura 24 se observa el conjunto final con la banda transportadora ya ensamblada sobre la estructura mencionada anteriormente. La banda transportadora cuenta con unas dimensiones de 50 cm de largo y 15 cm de ancho, lo cual tiene un espacio óptimo para el traslado de los granos de chochos, el montaje de la banda transportadora sobre los rodillos facilita un desplazamiento lineal y continuo.



Figura 24. Ensamblaje de la banda transportadora

#### 3.9.3.4. Ambiente controlado

En la Figura 25 se evidencia el diseño de un ambiente controlado que dispone de una cámara y luces led en su interior para una mejor captura de imágenes en tiempo real durante el proceso de clasificación.

Las dimensiones de 40 cm de alto y 20 cm de ancho han sido elegidas para asegurar que la cámara tenga un campo visual suficiente como también se puede modificar la posición de altura de la cámara mediante los orificios laterales.




Figura 25. Ambiente controlado

#### 3.9.3.5. Divisiones para granos

En la Figura 26 se observa una estructura diseñada para dividir la banda transportadora en dos carriles independientes de los cuales circularan los granos de chocho cuando el sistema se encuentra funcionando, cada carril tiene una dimensión de separación de 8 cm lo cual permite pasar con facilidad los granos de chochos. Las dimensiones de cada pieza son de 30 cm de largo y 3 cm de alto. Se utiliza dos carriles para aumentar la eficiencia del proceso, al dividir los granos en dos rutas, se puede procesar un mayor volumen de chochos, la dimensión de los 30

cm de largo permite cubrir la mayor parte del trayecto que deben desplazarse los granos de chochos.




Figura 26. División interna de carriles

### 3.9.3.6. Paletas clasificadoras

En la Figura 27 se observa que al final de la banda transportadora se encuentra unas paletas clasificadoras que están diseñadas para golpear a los granos que llegan en mal estado. Cada paleta tiene una dimensión de 4cm de ancho y 8 cm de largo, estas paletas están ancladas a un servomotor que permite su giro controlado de 90 grados cuando el sistema detecte señales mediante un Arduino para que los granos malos sean golpeados y no entren al recipiente de los granos buenos. El diseño de las dos paletas clasificadoras se realizó por la división de la banda de dos carriles permitiendo el control independiente al momento de clasificar los granos, las dimensiones escogidas de 4 y 8 cm son por la dimensión del carril para que los granos puedan llegar a cualquier posición de la paleta y desviar el grano.




Figura 27. Paletas de clasificación

### **3.9.4. Metodología y definición de los componentes a utilizar**

Se utilizó una metodología de selección multicriterio basada en matrices de ponderación para determinar los elementos físicos del prototipo de visión artificial durante la etapa de diseño del método Waterfall. Se determinó primero los requisitos funcionales del sistema de resolución de imagen, como la fuerza de giro, la velocidad de captura, el consumo energético, el costo y el comportamiento lumínico, entre otros. Estos requisitos surgieron a partir de las metas particulares del proyecto y del proceso de clasificación automática del chocho. Se utilizó un método de selección multicriterio similar al que empleó Asqui Vaca Xavier Alejandro en 2023 para la creación de las matrices de ponderación con este método, se establecen escalas valorativas y pesos con el fin de cotejar diferentes opciones de componentes dentro de sistemas automatizados de clasificación [102].

Después, se utilizó una escala de calificación discreta para evaluar cada opción, en esta escala, un valor más elevado representa un mejor rendimiento con respecto al criterio examinado. El producto del peso por la calificación resultó en un puntaje ponderado y al final, el total obtenido de este cálculo permitió una comparación objetiva entre las alternativas y poder elegir la opción que presentaba más adecuación técnica y económica.

Dado que cada decisión se basa en estándares medibles y directamente relacionados con la calidad de las imágenes, la estabilidad mecánica del sistema y la posibilidad de implementación en un ambiente agroindustrial, este método asegura trazabilidad y transparencia al seleccionar componentes. Asimismo, el hecho de que las matrices tengan una estructura repetitiva hace más fácil replicar el proceso para rediseños o ampliaciones futuras del prototipo, lo cual asegura la coherencia con la metodología Waterfall empleada en el desarrollo integral del proyecto.

#### **3.9.4.1. Opciones de cámaras para visión artificial**

La cámara es un componente fundamental en el sistema de visión artificial, ya que se encarga de captar las imágenes necesarias para la clasificación de los chochos. Una correcta elección de la cámara facilita la obtención de imágenes de calidad y reduce la complejidad del procesamiento posterior. Es importante que la cámara sea compatible con el sistema y permita una transferencia de datos eficiente. Por ello, se analizaron las siguientes opciones.

- **Opción1: Logitech Brio 500**

La Figura 28 es una cámara USB-C de alta gama diseñada para aplicaciones exigentes como el sistema de clasificación de chochos mediante visión artificial. Cuenta con un sensor CMOS de

4 MP que permite grabar vídeo en resoluciones de hasta 4K a 30 FPS o 1080p a 60 FPS, lo cual asegura una excelente precisión en la captura de objetos en movimiento sobre la cinta transportadora. Incorpora enfoque automático, que optimiza la calidad de imagen bajo condiciones variables de iluminación, facilitando la detección precisa de defectos en los productos. Su campo de visión ajustable (65°, 78° y 90°) mejora la flexibilidad en el cuadro, mientras que su interfaz USB 3.0 garantiza una transferencia de datos rápida y sin latencia, ideal para procesamiento en tiempo real. Además, es compatible con plataformas como Jetson Nano gracias a sus controladores oficiales, permitiendo una fácil integración y desarrollo de aplicaciones basadas en inteligencia artificial. Fabricada con una carcasa metálica resistente, ofrece durabilidad en entornos industriales y agrícolas con presencia de polvo o humedad. Aunque su costo es mayor al de otras opciones, sus prestaciones técnicas la convierten en una inversión justificada en proyectos donde la calidad de imagen y la confiabilidad son prioritarias.



Figura 28. Cámara Logitech Brio 500

- **Opción 2: Argom Tech 1080p**

La Figura 29 (modelo CAM40) cuenta con un sensor CMOS de 1/3" y una resolución Full HD de hasta 2 megapíxeles, permitiendo capturar video a 30 cuadros por segundo (fps) para transmisiones fluidas. Su enfoque es manual, ajustable mediante un anillo en la lente, con un rango desde 30 cm hasta infinito. Ofrece adaptabilidad lumínica gracias a la compensación automática de exposición y ajustes automáticos de balance de blancos, contraste, saturación y nitidez, lo que garantiza imágenes claras en distintas condiciones de iluminación. La interfaz de conexión es USB 2.0, lo que facilita su instalación plug-and-play. Es altamente compatible con los principales sistemas operativos y aplicaciones de videoconferencia. Incluye un micrófono integrado con aislamiento de ruido para mejorar la calidad del audio. Su base multipropósito permite montarla en portátiles, monitores o trípodes, y ofrece un campo de

visión ajustable de hasta 120°. Finalmente, su costo es muy accesible, posicionándola como una opción económica y funcional para videollamadas y transmisiones en línea.



Figura 29. Cámara Argom Tech

#### 3.9.4.2. Selección de la tarjeta de control para servomotores

La tarjeta de control es esencial para gestionar los actuadores encargados de la clasificación automática de los chochos. La elección adecuada de la placa permite un control preciso de los servomotores y una integración eficiente en el prototipo. Se consideraron aspectos como el tamaño, el consumo energético y la cantidad de pines disponibles. A continuación, se presentan las alternativas evaluadas.

- **Opción 1: Arduino Nano v3.0**

La Figura 30 es una tarjeta compacta basada en el microcontrolador ATmega328, que destaca por su reducido tamaño (18 x 45 mm), ideal para aplicaciones donde el espacio es limitado. Posee 22 pines de entrada/salida (14 digitales y 8 analógicas), suficientes para el control de múltiples servomotores y sensores. Su consumo energético es bajo, con un promedio de 19 mA en funcionamiento estándar y un rango de operación de 7 a 12 V, lo que permite optimizar la eficiencia del sistema. Además, la placa es totalmente compatible con las librerías estándar de Arduino, lo que facilita la programación y el control preciso de actuadores. El costo del Nano suele ser inferior al de otras placas de mayor tamaño, y su integración en prototipos compactos es sencilla gracias a su conector mini-USB.




Figura 30. Arduino Nano V3.0

- **Opción 2: Arduino UNO R3**

La Figura 31 es una de las placas más populares y robustas del ecosistema Arduino, también basada en el microcontrolador ATmega328. Ofrece 20 pines de entrada/salida (14 digitales y 6 analógicas), suficiente para aplicaciones estándar, aunque su tamaño (68.6 x 53.4 mm) puede dificultar la integración en sistemas con restricciones de espacio. Su consumo energético es ligeramente mayor que el del Nano, con un promedio de 46 mA en funcionamiento estándar y un rango de operación de 7 a 12 V, lo que puede incrementar la demanda de energía y la disipación térmica en el sistema. La placa es compatible con todas las librerías de Arduino y se programa fácilmente mediante el puerto USB tipo B, aunque su precio suele ser más elevado y su formato está más orientado a prototipos de escritorio o pruebas de laboratorio.



Figura 31. Arduino UNO R3

### 3.9.4.3. Opciones de luminarias para el ambiente controlado

La elección adecuada de la luminaria es fundamental para garantizar una iluminación uniforme y suficiente dentro de la caja de visión, lo que permite capturar imágenes de alta calidad y facilita el procesamiento y la clasificación de los chochos mediante visión artificial. A continuación, se presentan las opciones evaluadas.

- **Opción 1: Módulo LED de 3 chips**

Durante las pruebas realizadas, la Figura 32 demostró un tamaño compacto de 6 cm de longitud, lo que facilitó su integración en la caja de visión del prototipo. El acople fue sencillo y estable, permitiendo una fijación segura en el interior del sistema. En cuanto al brillo, este módulo generó una iluminación alta y uniforme, adecuada para la obtención de imágenes nítidas sin provocar distorsiones ni zonas de sobreexposición en la captura.



Figura 32. Led de tres chips

- **Opción 2: Tiras de LED flexibles**

Las Tiras de LED flexibles, con una longitud de 10 cm por segmento, permitieron una instalación adaptable a diferentes formas internas del prototipo. El acople fue fácil gracias a su flexibilidad como se muestra en la Figura 33, aunque en algunos puntos se requirió fijación adicional para evitar desplazamientos. El brillo proporcionado fue elevado, pero en ciertas zonas generó reflejos y distorsiones en la imagen, dificultando la captura homogénea en toda la superficie de inspección.



Figura 33. Leds flexibles

#### **3.9.4.4. Opciones para la elección de banda transportadora**

La banda transportadora es un elemento clave en el sistema de clasificación, ya que sobre su superficie se desplazan los chochos para ser capturados por la cámara y analizados mediante visión artificial. Para garantizar imágenes nítidas y sin distorsiones, se evaluaron dos

alternativas. En ambos casos, se analizaron aspectos como el tamaño, facilidad de acople al prototipo y el comportamiento frente a la iluminación durante la captura de imágenes.

- **Opción 1: Banda de cuerina de color blanco**

Durante las pruebas, la Figura 34 demostró un tamaño adecuado para el prototipo y un acople sencillo a la estructura. Su superficie mate evitó reflejos y permitió una iluminación uniforme, lo que facilitó la obtención de imágenes claras y precisas de los chochos en movimiento. Gracias a estas características, se logró minimizar la distorsión y mejorar la detección de defectos en los granos.



Figura 34. Cuerina color blanco

- **Opción 2: Banda hecha de eslabones plásticos**

La banda hecha de eslabones plásticos, fabricados mediante impresión 3D, también presentó un tamaño compatible y un acople aceptable al sistema. Sin embargo, durante las pruebas, la superficie plástica generó reflejos y brillos excesivos bajo la iluminación como se muestra en la Figura 35, lo que provocó distorsión en las imágenes capturadas por la cámara. Esta condición dificultó la identificación precisa de los chochos y afectó negativamente la calidad del procesamiento por visión artificial.




Figura 35. Eslabones de plástico

### 3.9.4.5. Opciones para la selección del servomotor para la clasificación

El servomotor es el componente encargado de accionar el mecanismo de clasificación, por lo que su elección debe considerar tanto el desempeño como la fiabilidad y el costo. Para el prototipo se analizaron dos alternativas ampliamente utilizadas en sistemas de automatización: el MG90S y el SG90, evaluando criterios como velocidad de actuación, torque, tamaño y peso, durabilidad, facilidad de acople y costo.

- **Opción 1: Servomotor MG90S**

La Figura 36 ofrece una velocidad de actuación rápida ( $0.1 \text{ s}/60^\circ$  a  $4.8\text{V}$ ) y un torque máximo de  $2.2 \text{ kg}\cdot\text{cm}$ , características que lo hacen adecuado para tareas que requieren movimientos precisos y fuerza suficiente para accionar mecanismos de clasificación. Su tamaño compacto y peso ligero facilitan la integración en espacios reducidos, y su construcción con engranajes metálicos proporciona mayor durabilidad frente al uso continuo. El costo promedio de este servomotor es de aproximadamente 15 dólares.



Figura 36. Servomotor MG90S

- **Opción 2: Servomotor SG90**

La Figura 37 es una alternativa popular y económica, con una velocidad de actuación de 0.12 s/60° a 4.8V y un torque de hasta 1.8 kg·cm, lo que puede ser suficiente para aplicaciones de baja carga. Su tamaño y peso son similares al MG90S, pero la carcasa y engranajes plásticos lo hacen menos resistente al desgaste y al uso prolongado. La facilidad de acople es buena debido a su formato estándar, y su principal ventaja es el bajo costo, que suele rondar los 5 dólares.



Figura 37. Servomotor SG90

#### **3.9.4.6. Alternativas para selección de material para caja de visión artificial**

La caja de visión artificial es un componente esencial para garantizar un ambiente controlado de iluminación y evitar interferencias externas durante la captura de imágenes. Para el prototipo se analizaron dos alternativas. Se consideró criterios como facilidad de construcción, costo, tiempo de fabricación, resistencia mecánica, facilidad de montaje y capacidad para bloquear la luz externa.

- **Opción 1: Ambiente controlado de madera MDF**

El ambiente controlado de madera MDF se diseñó con dimensiones de 12 cm de ancho por 25 cm de largo, permitiendo una integración eficiente en el prototipo. Este material se caracteriza por su bajo costo (aproximadamente 8 dólares), fácil disponibilidad y rapidez en la fabricación, ya que se puede cortar y ensamblar en poco tiempo utilizando herramientas básicas como se puede observar en la Figura 38. La madera MDF ofrece una buena resistencia mecánica y permite aislar eficazmente la luz externa, asegurando condiciones óptimas para la captura de imágenes. Además, su superficie puede ser pintada o forrada para mejorar la reflexión interna y evitar sombras, y su montaje es sencillo gracias a su peso ligero y facilidad de manipulación.




Figura 38. Material MDF para el ambiente controlado

- **Opción 2: Impresión 3D de caja de iluminación**

La alternativa de fabricar la caja de visión artificial mediante impresión 3D permite obtener geometrías personalizadas y acabados precisos como se muestra en la Figura 39. Sin embargo, este método implica un mayor costo (alrededor de 25 dólares en material y tiempo de máquina), así como un tiempo de fabricación considerablemente mayor, especialmente para piezas de gran tamaño. Aunque los plásticos utilizados en impresión 3D ofrecen resistencia aceptable, pueden ser menos robustos ante impactos o deformaciones, y la unión entre capas puede dejar pasar luz si no se realiza un acabado adicional. El montaje puede ser más complejo debido a la necesidad de ensamblar varias piezas impresas y asegurar un sellado adecuado para bloquear la luz externa.



Figura 39. Material PLA para el ambiente controlado

## **3.10. METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EL PROTOTIPADO**

### **3.10.1. Arquitecturas del modelo**

En esta investigación se plantea dos arquitecturas del prototipo para la clasificación del grano de chocho (*Lupinus Mutabilis*), dichos modelos generales se presentan en las siguientes opciones donde se combinan elementos físicos y digitales conectados entre sí permitiendo tanto la adquisición y procesamiento de imágenes como el control físico de los elementos del sistema. Estas arquitecturas ilustran el recorrido que sigue el producto desde su entrada hasta su selección final, permitiendo apreciar en detalle el funcionamiento innovador del modelo propuesto.

- **Opción A**

En la Figura 40 se muestra la primera alternativa que inicia con el uso de una computadora donde se abre la plataforma Make Sense para proceder con el etiquetado de imágenes y desarrollo de modelos de aprendizaje profundo utilizando Python. La laptop funciona como el centro de control desde donde se envían las instrucciones necesarias al microcontrolador Arduino Nano a través del entorno Arduino IDE. El Arduino Nano sirve como puente entre los componentes físicos y el procesamiento computacional, recibiendo las órdenes y ejecutando el control directo del sistema.




Figura 40. Arquitectura opción A

La tolva se utiliza para la alimentación inicial de los granos que es accionada por un servomotor a la banda permitiendo que estos pasen de manera dosificada hacia la banda transportadora. Esta banda es accionada por un motor DC y puede ser regulada por un servomotor controlado por el Arduino Nano, lo que garantiza el movimiento preciso de los granos a lo largo del proceso. Los granos ingresan a un ambiente controlado, donde se estabilizan las condiciones de iluminación mediante LEDs, para asegurar la calidad de las imágenes captadas. Una cámara posicionada en este entorno controlado registra imágenes de los granos en tiempo real que envía estos datos a la laptop para su procesamiento.

El resultado del análisis visual realizado por el modelo de clasificación determina la activación de los servomotores, permitiendo seleccionar automáticamente el destino de cada grano en tiempo real. Esta arquitectura modular permite la interacción eficiente entre los componentes físicos y digitales, sentando las bases para futuros desarrollos y mejoras en la automatización de procesos agroindustriales.

- **Opción B**

En la Figura 41 se muestra la segunda alternativa que inicia con el uso de una Raspberry Pi 5 como centro de control principal, donde se abre la plataforma Make Sense para el etiquetado de imágenes, Thonny para ejecutar la programación en Python y Arduino IDE para cargar las instrucciones en el microcontrolador Arduino Nano. La Raspberry Pi 5 integra estas

herramientas digitales y envía las instrucciones necesarias al Arduino Nano, que actúa como puente entre los componentes físicos y el procesamiento computacional.




Figura 41. Arquitectura opción B

La tolva se utiliza para la alimentación inicial de los granos de chocho (*Lupinus Mutabilis*), accionada por un servomotor hacia la banda transportadora, permitiendo que pasen de manera dosificada. Esta banda es accionada por un motor DC controlado por el Arduino Nano, garantizando el movimiento preciso de los granos a lo largo del proceso. Los granos ingresan a un ambiente controlado, donde se estabilizan las condiciones de iluminación mediante LEDs para asegurar la calidad de las imágenes captadas; una cámara posicionada en este entorno registra imágenes en tiempo real que envía a la Raspberry Pi para su procesamiento.

El resultado del análisis visual realizado por el modelo de clasificación determina la activación de los servomotores al final de la banda, permitiendo seleccionar automáticamente el destino de cada grano (buenos o malos) en tiempo real mediante paletas de control. Esta arquitectura modular con Raspberry Pi favorece la interacción eficiente y compacta entre componentes físicos y digitales, sentando las bases para desarrollos portátiles y mejoras en la automatización de procesos agroindustriales.

### **3.10.2. Requisitos y recursos para el prototipado**

#### **3.10.2.1. Herramientas y software de construcción**

Herramientas y software creados para convertir el diseño en tres dimensiones en elementos físicos que se pueden ensamblar y probar de forma controlada se utilizan durante la fase de prototipado. Para producir las partes estructurales del prototipo, como los laterales de la banda, la tolva, los soportes de rodillos, el ambiente controlado y las divisiones internas, se usan impresoras 3D con el programa Ultimaker Cura para laminado. Este último posibilita ajustar parámetros como la temperatura y velocidad de impresión, así como el porcentaje de relleno y la altura de capa, garantizando que cada elemento tenga una resistencia mecánica apropiada. Esta combinación de software y hardware hace más fácil el proceso en la creación, la optimización del uso de materiales a lo largo de la construcción del prototipo y la corrección de daños o deformaciones.

Además, se emplean instrumentos de diseño asistido por computadora para modelar las partes en tres dimensiones, y equipos de medición básicos (como escuadras, calibradores y reglas) para comprobar las tolerancias y dimensiones durante el ensamblaje físico. Además, se emplean instrumentos manuales de ensamblaje, como llaves, taladros y destornilladores, que son necesarias para unir a la estructura impresa las paletas clasificadoras, los motores, soportes y rodamientos. Estas herramientas y programas de construcción en su conjunto aseguran que el prototipo final cumpla con las características geométricas establecidas durante la fase de diseño y que esté listo para que, en la etapa de desarrollo, se instalen el modelo de visión artificial y el sistema de control.

### **3.10.3. Proceso de construcción del prototipo**

#### **3.10.3.1. Ensamblaje de piezas**

La etapa de ensamblaje se realiza cuando se unen las partes impresas en PLA y los componentes comerciales seleccionados para crear el prototipo físico completo. En esta etapa se ensamblan los rodillos, la tolva dosificadora, las paletas clasificadoras, la banda transportadora, el ambiente controlado y los costados de la estructura. Todo esto es de acuerdo con las medidas y configuraciones definidas en el diseño en 3D. Para asegurar que el montaje sea adecuado, se utilizan tornillos, tuercas, soportes metálicos y adhesivos de acuerdo con lo que cada unión necesita, controlando de manera continua la estabilidad de la estructura y la alineación de los ejes.

### **3.10.3.2. Integración de elementos electrónicos de control**

La finalidad de incorporar los componentes electrónicos de control consiste en brindarle al prototipo mecánico la capacidad de activar, sincronizadamente, las paletas clasificadoras y la banda transportadora. En esta fase se utiliza una computadora, un controlador de potencia del motor de la banda, los servomotores responsables del movimiento de las paletas, la fuente de alimentación y el cableado pertinente, según el esquema eléctrico establecido en la etapa de diseño. Para hacer más corto el cableado y reducir pérdidas y desórdenes, los componentes se instalan en lugares estratégicos de la estructura del prototipo que permiten ingresar sin dificultad para mantenimiento.

Después, se instalan y ejecutan los programas en la computadora para controlar el encendido del motor de la banda, la velocidad de desplazamiento y la colocación de los servomotores, definiendo rutinas elementales de operación y ensayos manuales de movimiento. Se comprueba la dirección de rotación del motor, los límites de recorrido de las paletas y cómo responde el sistema a las señales simuladas de activación, para que el prototipo esté listo para conectar estos actuadores con las salidas generadas por el modelo de visión artificial durante la etapa de desarrollo y llevar a cabo la clasificación automática de los granos chochos.

## **3.11. METODOLOGÍA DESIGN THINKING: REQUERIMIENTOS PARA EL DESARROLLO**

### **3.11.1. Circuitos del modelo**

Con el fin de comprender más a detalle se desarrolló en dos opciones los diagramas de conexión capaz de garantizar la integración coordinada de cada uno de sus componentes. Para lograr el funcionamiento en tareas de clasificación automática, se requiere de un diseño que priorice tanto la gestión energética como la comunicación estable entre sensores, actuadores y el microcontrolador central. En las siguientes opciones se ilustran los diagramas de las arquitecturas del prototipo, evidenciando de forma detallada todas las conexiones.

- **Opción A**

La alimentación eléctrica en este sistema de visión artificial parte de una fuente de 12 V conectada mediante un adaptador AC-DC al módulo regulador LM2596. El terminal IN+ y el IN- del LM2596 reciben la alimentación, que luego se estabiliza a 5 V en los terminales OUT+ y OUT-, ajustados previamente con el potenciómetro para asegurar la protección de los elementos conectados. Desde OUT+, se distribuye hacia tres puntos fundamentales: el pin VIN

del Arduino Nano, garantizando energía independiente y estable para el microcontrolador, el pin 8 (VS) del L293D, que alimenta al motor DC, y los pines VCC de ambos servomotores, permitiendo el funcionamiento de sus componentes internos.

El terminal OUT- del LM2596 se conecta al punto común de tierra, al cual también llegan los pines GND del Arduino, los cables GND de los servos y los pines 4, 5, 12 y 13 del L293D, de modo que todo el sistema comparte una sola referencia eléctrica para minimizar interferencias y errores.




Figura 42. Circuitos opción A

El pin 5V del Arduino se destina exclusivamente al pin 16 (VSS) del L293D para abastecer la lógica interna del driver, separando la alimentación de señal de la de potencia. El motor DC se vincula a los pines 3 y 6 del L293D, y su control se ejerce desde el Arduino mediante el pin D11, que entrega señal PWM al pin 1 para la regulación de velocidad, y los pines D6 al pin 2 y D7 al pin 7, que definen dirección o frenado según sus combinaciones HIGH/LOW.

Los tres servomotores funcionan con alimentación de 5 V y tierra común, recibiendo las señales de control de los pines D8, D9 y D10 del Arduino. Estos envían pulsos PWM, ajustando la duración para determinar el ángulo de giro entre 0° y 180°.

La laptop, conectada a una cámara por USB, captura video en tiempo real y procesa las imágenes mediante un modelo YOLOv11 previamente entrenado. Seguidamente una LED de 12 V se conecta entre IN+ y el IN- del LM2596, encendiéndose únicamente cuando el sistema está alimentado, a modo de indicador visual. La arquitectura, basada en conexiones directas fue diseñada para comprender la estabilidad del sistema y facilitar la integración y el control de los componentes dentro del enfoque de visión artificial como se puede observar en la Figura 42.

- **Opción B**

En la Figura 43 se muestra el sistema de alimentación en esta arquitectura que se divide en dos fuentes independientes para garantizar estabilidad operativa. La Raspberry se alimenta mediante una conexión USB-C desde una fuente de 5 V dedicada exclusivamente a energizar al microcontrolador de placa única para el procesamiento visual sin interferencias.

De forma paralela, una segunda fuente de 12 V se conecta mediante un adaptador AC-DC al módulo regulador LM2596. El terminal IN+ y el IN- del LM2596 reciben esta alimentación, que luego se estabiliza a 5 V en los terminales OUT+ y OUT-, ajustados previamente con el potenciómetro para asegurar la protección de los elementos conectados. Desde OUT+, se distribuye hacia dos puntos fundamentales: el pin VIN del Arduino Nano, garantizando energía independiente y estable para el microcontrolador, y los pines VCC de los tres servomotores, permitiendo el funcionamiento de sus componentes internos. El terminal OUT- del LM2596 se conecta al punto común de tierra, al cual también llegan los pines GND del Arduino Nano, los cables GND de los servomotores y los pines 4, 5, 12 y 13 del L293D.




Figura 43. Circuito opción B

El pin 5V del Arduino se destina exclusivamente al pin 16 (VSS) del L293D para abastecer la lógica interna del driver, separando la alimentación de señal de la de potencia. El motor DC se vincula a los pines 3 y 6 del L293D, y su control se ejerce desde el Arduino mediante el pin D11, que entrega señal PWM al pin 1 para la regulación de velocidad, y los pines D6 al pin 2 y D7 al pin 7, que definen dirección o frenado según sus combinaciones HIGH/LOW.

Los tres servomotores funcionan con alimentación de 5 V y tierra común proporcionados por el LM2596, recibiendo las señales de control desde el Raspberry Pi 5 mediante los pines GPIO 17, GPIO 18 y GPIO 22. Estos envían pulsos PWM, ajustando la duración para determinar el ángulo de giro entre 0° y 180°. La Raspberry Pi 5 se comunica con el Arduino Nano exclusivamente mediante conexión USB, utilizada durante la fase de programación inicial para configurar los parámetros del microcontrolador.

La Raspberry Pi 5, conectado a una cámara mediante cable USB, captura video en tiempo real y procesa las imágenes mediante un modelo YOLOv11 previamente entrenado, generando en tiempo real las señales PWM de control para los servomotores. Una LED de 12 V se conecta entre IN+ e IN- del LM2596, encendiéndose únicamente cuando el sistema está alimentado, a modo de indicador visual. La arquitectura, basada en la separación de fuentes de alimentación y la centralización del procesamiento visual en la Raspberry que fue diseñada para optimizar la autonomía del sistema y garantizar la estabilidad en la captura, procesamiento y control de los componentes dentro del enfoque de visión artificial.

### **3.11.2. Parámetros del modelo de visión artificial**

#### **3.11.2.1. Lenguaje y entorno de desarrollo Python**

En la actualidad Python es un lenguaje de programación de código abierto más utilizado en proyectos científicos e ingenieriles, gracias a su codificación clara y su extenso ecosistema de librerías enfocadas en el aprendizaje automático análisis de datos y procesamiento de imágenes. Su característica de multiplataforma con acceso libre al código hace que sea más fácil adaptarse a distintos ambientes y requisitos académicos.

Además, Python ofrece una integración directa con las principales herramientas utilizadas en el proyecto como bibliotecas para procesamiento de imágenes, manejo de matrices y ejecución de modelos de aprendizaje profundo lo que permite implementar todo el flujo de visión artificial dentro de un mismo entorno. Su compatibilidad con diferentes sistemas de operativos y con plataformas de hardware Como computadoras personales de dispositivos embebidos facilita la conexión con diferentes equipos electrónicos, Simplificando el desarrollo y mantenimiento del Código fuente del modelo de clasificación automática del chocho

#### **3.11.2.2. Versión Python 3.13.2**

El modelo de visión artificial que se está desarrollando se ejecuta sobre la versión 3.13.2 de Python que incluyen optimizaciones en términos del rendimiento, gestión de memoria y compatibilidad con las bibliotecas modernas de inteligencia artificial. Esta versión es apropiada para proyectos que necesitan un procesamiento intensivo de datos e imágenes, puesto a que proporciona soporte total a los paquetes que son usados con frecuencia en contextos científicos e ingenieriles. Así mismo su estabilidad posibilita disminuir inconvenientes de incompatibilidad y fallos no previsto mientras se desarrollan scripts de entrenamiento, validación y progreso del modelo.

Utilizar una versión moderna de Python también asegura que hay actualizaciones de seguridad y arreglos de errores además de la oportunidad de incorporar nuevas funcionalidades que se necesiten en fases futuras del proyecto.

#### **3.11.2.3. Entorno de programación IDLE**

El desarrollo del modelo se realiza utilizando IDLE (Integrated Development and Learning Environment), el entorno de desarrollo integrado que incluye por defecto las distribuciones oficiales de Python. IDLE sobresale por brindar un editor de texto con funciones como injección inteligente, coloreado de sintaxis, autocompletado, además de un shell interactivo

para la ejecución inmediata de comandos y scripts. De igual manera ejecuta el código usuario en un proceso separado, lo que permite depuración sencilla y útil para la experimentación en visión artificial y el manejo de grandes volúmenes de datos. La elección de IDLE responde a su robustez, facilidad de uso y adecuada integración con las bibliotecas empleadas en el proyecto.

### **3.11.3. Selección del algoritmo para entrenar el modelo**

Elegir el algoritmo es un paso crucial en el proceso de creación del modelo de visión por computadora, ya que esta elección afecta directamente el rendimiento del sistema en aspectos como precisión, rapidez y factibilidad de uso en un ambiente controlado. En este estudio, el propósito central del algoritmo es identificar y clasificar de forma automática la calidad del grano de chocho, separándolo en las clases de “bueno” y “malo” basándose en sus atributos visuales.

Con base en estos requisitos, se optó por el algoritmo YOLO (You Only Look Once), que forma parte de la categoría de modelos de aprendizaje profundo basados en redes neuronales convolucionales, se distingue por llevar a cabo la identificación y clasificación de objetos en un único paso, analizando la imagen en su totalidad lo que lo posiciona como una opción eficaz y sólida para aplicaciones que requieren una respuesta rápida. La decisión de utilizar YOLO se fundamenta principalmente en las siguientes consideraciones técnicas.

- Permite la identificación y categorización de los granos de chocho en una sola imagen.
- Su empleo es común en el ámbito industrial y agroindustrial, lo que avala su eficacia y consistencia.
- Permite conectarse con sistemas de acción, como servomotores y microcontroladores, facilitando la automatización del proceso de separación del producto clasificado.

Es importante señalar que, en el marco de este proyecto, YOLO es el único algoritmo de aprendizaje profundo que se ha entrenado y se encarga de clasificar automáticamente el grano. Los demás algoritmos en el sistema son solo para tareas secundarias de procesamiento de imágenes, control lógico y comunicación, los cuales no llevan a cabo aprendizaje o clasificación por sí solos, sino que ayudan al funcionamiento global del modelo de visión artificial.

### **3.11.4. Instalación de librerías en Python**

Python es reconocido como uno de los mejores lenguajes de programación de código abierto para el desarrollo de aplicaciones de visión artificial, gracias a su amplia compatibilidad con

diversas librerías especializadas en inteligencia artificial. Esta flexibilidad convierte a Python en una buena opción para proyectos que requieren procesamiento avanzado de imágenes y análisis en tiempo real.

Por esta razón, se seleccionó Python para el desarrollo del presente modelo, iniciando con la instalación de librerías elementales que garantizan el correcto funcionamiento del código y facilitan la implementación de algoritmos complejos, como YOLOv11, para la detección y clasificación automática de objetos en imágenes. Estas herramientas proporcionan un soporte robusto para manejar flujos de datos, manipulación de imágenes y ejecución eficiente de modelos de redes neuronales convolucionales.

- Import os y sys:

Estas librerías se utilizan para interactuar con el sistema operativo y acceder a las rutas de los archivos para lograr hacer la ejecución de la información en la programación.

- Import time:

Esta librería se utiliza para manejar operaciones relacionadas con el tiempo permitiendo que el procesamiento de las imágenes sea eficiente

- Import numpy:

Esta librería se utiliza para realizar operaciones matemáticas avanzadas y el manejo de matrices esto nos ayuda a identificar las coordenadas de los píxeles en las imágenes

- cv2:

Esta librería es de visión artificial que permite capturar, procesar y analizar las imágenes y videos en tiempo real

- Ultralytics (YOLO v11):

Esta librería es un modelo de red neuronal para detección de objetos en tiempo real, en este caso se utiliza la versión v11 proporcionada por ultralytics.

- Import serial:

Se utiliza para establecer la comunicación por puerto serie entre el Arduino y los dispositivos externos permitiendo enviar y recibir datos de control hacia los actuadores del prototipo.

- Import tkinter:

Tkinter se emplea para construir la interfaz gráfica de usuario en Python, creando ventanas, botones y otros elementos que permiten gestionar y monitorear el funcionamiento del sistema de clasificación.

#### 3.11.4.1. Parámetros importantes dentro de la programación

```
# --- PARÁMETROS DE CÁMARA ---
```

```
ID_CAMARA = 0 # ID de la cámara o archivo de video
```

```
ANCHO_FRAME_CAMARA = 640
```

```
ALTO_FRAME_CAMARA = 480
```

Este código se utiliza para la conexión de la cámara de la computadora o Raspberry y también el tamaño del ancho y alto de las imágenes capturadas, además.

```
# PARAMETROS DE YOLOv11 #
```

```
RUTA_MODELO_YOLO = "runs/detect/entrenamiento_chochos_final/weights/best.pt"
```

```
NOMBRES_CLASES_YOLO = ["malo", "bueno"]
```

```
CONFIDENCIA_MINIMA_YOLO = 0.55
```

Este código se utiliza para encontrar la ruta del modelo entrenado de YOLO, detectando los granos de chochos buenos y malos definiendo el umbral de confianza para determinar qué tan confiable debe ser la predicción del modelo para sus detecciones validas.

```
def accionar_actuador_canal_simulado(canal_index, es_chocho_malo):
```

```
def procesar_video_con_yolo(fuente_video=ID_CAMARA):
```

```
    # Carga el modelo YOLO y procesa los frames de la fuente de video.
```

Este código verifica si el archivo del modelo YOLO existe y lo carga para hacer las predicciones.

```
modelo_yolo = YOLO(RUTA_MODELO_YOLO)
```

Este código se utiliza para la lectura de los frames (imágenes detectadas por segundo 60 fps) para la detención de los objetos.

```
results = modelo_yolo.predict(frame_orig_color, conf=CONFIDENCIA_MINIMA_YOLO, verbose=False)
```

Se utiliza para su clasificación si el grano es bueno o malo mediante la posición de las coordenadas de la imagen.

```
if abs(cx - LINEA_DETECCION_X_SIM) < MARGEN_LINEA_DETECCION_SIM_PX:
```

```
# Lógica para manejar objetos que cruzan la línea.
```

Se utiliza para identificar los granos clasificados como buenos y malos de los que cruzaron la línea.

```
cv2.putText(frame_display, f"Buenos: {stats['buenos']}", (10, 30),  
cv2.FONT_HERSHEY_SIMPLEX, 0.7, (0, 255, 0), 2)
```

Se utiliza para la interfaz visual que muestra las predicciones de los granos buenos y malos en cuadrados con su línea de detección.

```
if __name__ == "__main__":
```

```
    verificar_dependencias_basicas()
```

```
    inicializar_hardware_simulado()
```

```
    procesar_video_con_yolo(fuente_para_procesar)
```

```
    limpiar_gpio_simulado()
```

```
    print("Simulación con YOLOv11 finalizada.")
```

Este código tiene como objetivo identificar cuándo un objeto (chocho) supera una línea virtual en la imagen, categorizarlo como "bueno" o "malo" de acuerdo con la predicción de YOLO, y prevenir la reprocesamiento de objetos que ya han traspasado la línea. Si se clasifica el objeto como "malo", se simula el uso de un actuador para desviar su atención. Adicionalmente, las estadísticas se actualizan, anotando la cantidad de objetos "buenos" y "malos" que han traspasado la línea, lo que facilita la administración de la detección y acción en tiempo real dentro del sistema.

#### **3.11.4.2. Requerimiento para el entrenamiento**

El proceso de entrenamiento de imágenes es fundamental para el desarrollo de modelos de visión artificial que permiten la clasificación automática de objetos mediante algoritmos de aprendizaje automático. En el presente estudio, se utiliza el entrenamiento de imágenes para identificar y categorizar granos de chochos (*Lupinus Mutabilis*), con el objetivo de mejorar la eficiencia y precisión en la clasificación de su estado. Este proceso implica la recopilación,

etiquetado y preparación de conjuntos de imágenes que alimentan el modelo, permitiéndole aprender las características distintivas de cada categoría para una correcta detección posterior.

### 3.11.4.3. Configuración de parámetros de la cámara

Para asegurar la calidad y uniformidad en la captura de imágenes, la cámara se configuró específicamente con parámetros que optimizan la nitidez y contraste de los granos fotografiados. Los ajustes utilizados fueron los siguientes:

- Zoom: 0, para mantener el enfoque original sin acercamiento que pueda distorsionar la imagen.
- Brillo: 8, para adecuar la luminosidad de la escena evitando que la imagen esté ni demasiado oscura ni demasiado iluminada.
- Contraste: 95, para maximizar la diferenciación visual entre granos y fondo, resaltando detalles importantes.
- Nitidez: 50, para asegurar que los contornos de los granos sean claros y definidos.
- Saturación: 95, para mantener colores naturales pero vibrantes que faciliten la identificación de características visuales distintivas.

Estos parámetros configuran la cámara para capturar imágenes consistentes y de alta calidad como se muestra en la Figura 44 que es ideal para el proceso de clasificación automatizada.

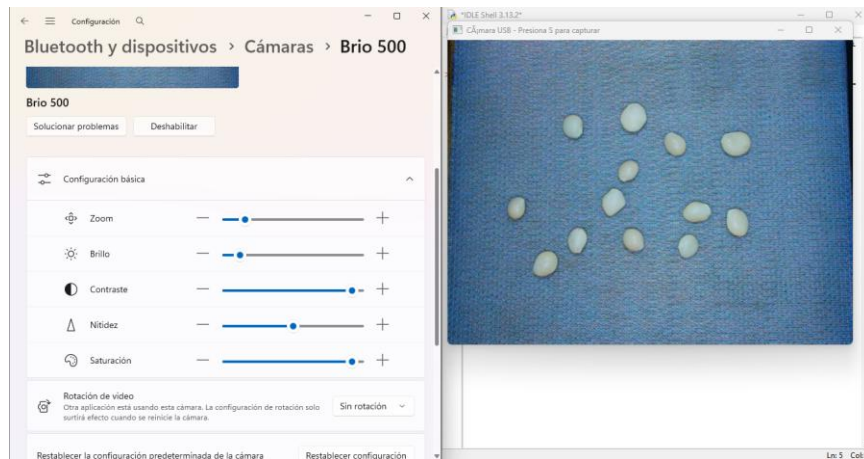


Figura 44. Parámetros de captura

### 3.11.4.4. Creación de carpetas

Para organizar adecuadamente las imágenes utilizadas en el entrenamiento del modelo, se creó inicialmente una carpeta principal denominada “CHOCHOS\_2”. Dentro de esta carpeta, se generó una subcarpeta llamada “chochos\_yolo\_dataset”, que funciona como contenedor

principal para el conjunto de datos, y también se generó en la misma un archivo llamado “Chochos11\_data.yaml”, Este archivo .yaml le dice a YOLO dónde están las imágenes de entrenamiento y validación, cuantas clases hay (2) y como se llaman (“malo” y “bueno”), para poder entrenar correctamente el modelo. Posteriormente, dentro de “chochos\_yolo\_dataset”, se crearon dos carpetas: “Images” y “Labels”. Cada una de estas carpetas contiene a su vez dos subcarpetas, denominadas “Train” y “Val”, que corresponden respectivamente a las particiones de entrenamiento y validación del conjunto de datos. De este modo, la estructura de carpetas queda organizada como se muestra en la Figura 45, para facilitar el almacenamiento y la manipulación eficiente de las imágenes y sus etiquetas respectivas.




Figura 45. Estructura del dataset al iniciar el entrenamiento

#### 3.11.4.5. Codificación para la captura automática de imágenes

En la Figura 46 se muestra el conjunto de datos que se desarrolló en un código en Python que permite tomar fotos directamente desde la cámara y guardarlas en carpeta definidas para chochos buenos y chochos malos. El programa utiliza la tecla (Q) como disparador de captura, por lo que cada vez que el usuario la presione se almacena la imagen en la ruta especificada, llegando acumular las fotografías por categorías ya establecidas y necesarias para el entrenamiento del modelo. Este método posibilita la creación ordenada del conjunto de datos etiquetados, garantizando que cada archivo se encuentre en la carpeta correspondiente a su clase y pueda ser utilizado para el proceso de entrenamiento del modelo de visión artificial.

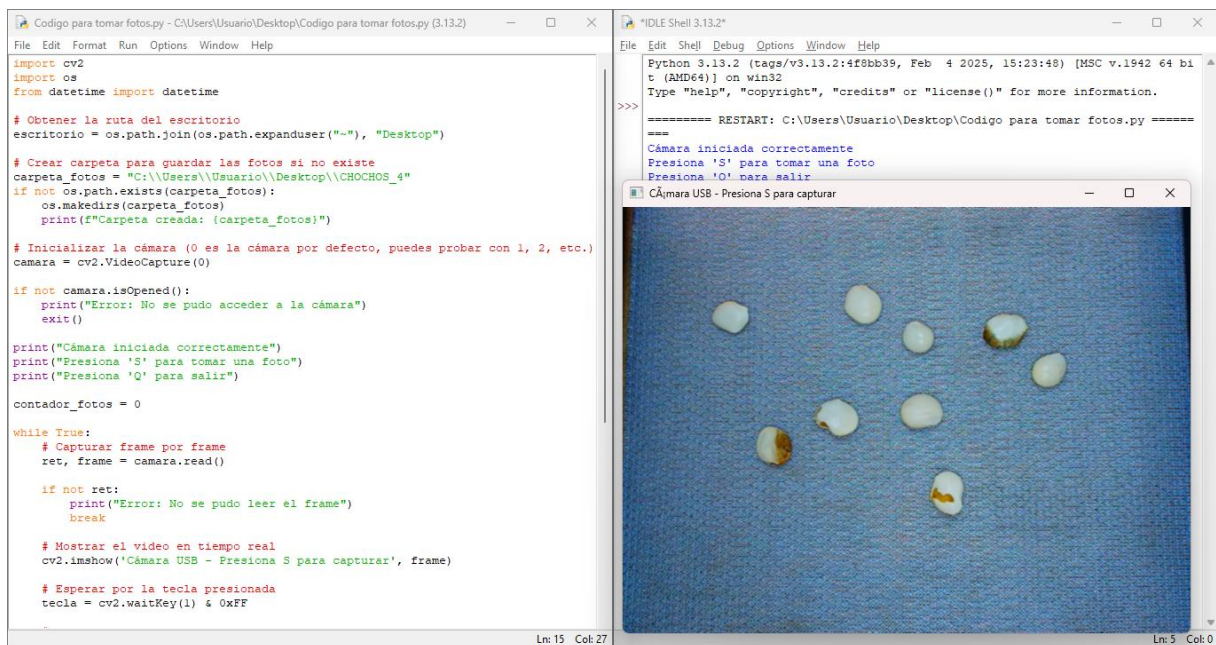


Figura 46. Captura de imágenes mediante código

#### 3.11.4.6. Ejecución para el entrenamiento en Windows PowerShell

La principal herramienta utilizada para la ejecución de los comandos de entrenamiento del modelo YOLOv11 durante la creación del sistema de visión artificial para clasificar chochos fue Windows Powershell, esta consola nativa de Windows Posibilitó que se instalaran dependencias de Python (ultralytics), así ejecutando el comando yolo train con parámetros concretos del conjunto de datos chochos y se supervisaran en tiempo real las métricas de pérdida y precisión a lo largo de las épocas de aprendizaje, garantizando el control preciso de cómo va la ejecución del entrenamiento.

## 4. ANÁLISIS DE RESULTADOS

### 4.1. EMPATIZAR

#### 4.1.1. Agricultores

El mapa de empatía aplicado al agricultor de la plaza Kennedy permitió comprender a detalle sus problemas, necesidades y preocupaciones respecto al trabajo de clasificación manual del chocho y a la posible incorporación de apoyo tecnológico. Esta herramienta fue esencial para identificar no solo lo que menciona de manera explícita en la entrevista, sino también lo que piensa, siente y teme en relación con el esfuerzo físico el tiempo invertido y la calidad del producto que ofrece.

De esta manera se elaboró un mapa de empatía, presentado en la Figura 47, el cual fue elaborado a partir de una entrevista y de las interacciones sostenidas de manera continua con el agricultor. Como parte de estos resultados se obtuvo que durante la etapa de clasificación el agricultor piensa constantemente en terminar la clasificación lo más rápido posible para reducir el cansancio, en mantener una buena calidad del grano para conseguir mejores precios y en cómo el trabajo manual y repetitivo afecta su salud y su ritmo de clasificación diaria del producto.




Figura 47. Mapa de empatía del agricultor

El mapa de empatía presentado en la Figura 47, permite profundizar el proceso de clasificación manual del chocho que factores influyen en su disposición a incorporar soluciones tecnológicas. Como se puede observar en el apartado “¿Qué ve?”, el agricultor observa que muchas personas de las comunidades del cantón Saquisilí que siguen utilizando métodos tradicionales y que llegan otros productores con distintos tipos de granos. También puede ver que los comerciantes reclaman cuando la calidad del chocho no es la adecuada. Esto le muestra un entorno competitivo, donde la apariencia del producto y la forma de trajo siguen siendo mayoritariamente manuales.

Por otro lado, en lo que oye, que los precios de los quintales de chocho son bajos y que, aunque la tecnología podría ser una buena opción de ayuda podría resultar costosa. También, logra escuchar que otros productores ofrecen productos alternativos, de esta manera su preocupación es mayor debido a que debe mantener un buen nivel de calidad para no quedar rezagado en el mercado.

Respecto a “¿Qué dice y hace?”, el agricultor expresa que si el producto se encuentra bien clasificado esto aumenta su precio de esta manera utiliza su experiencia para separar el chocho y llevar sus quintales al mercado donde negocia directamente con los comerciantes y, en algunos casos, opta por vender sin clasificar a intermediarios cuando el tiempo o el cansancio lo superan. Sus acciones reflejan que debe tener un esfuerzo constante por equilibrar de calidad, tiempo de trabajo y necesidades de ingreso.

En “¿Qué piensa y siente?”, el análisis muestra un fuerte cansancio físico al clasificar manualmente los granos el deseo de terminar rápido el proceso y el miedo a que, aun realizado todo ese esfuerzo, la cosecha se venda a un precio muy bajo. En estas emociones se muestra la tensión entre la necesidad de mantener la calidad y la presión por reducir el tiempo.

En el apartado “¿Cuáles son sus dolores?”, se pudo evidenciar que principalmente sus preocupaciones principales son el desgaste visual, el dolor físico por pasar muchas horas sentado agachado seleccionando el grano y una frustración preocupante cuando, aun realizado la clasificación los compradores ofrecen precios muy bajos. Estos dolores revelan sus límites del método manual y el impacto directo sobre su salud.

Finalmente, dentro del apartado “¿Cuáles son sus necesidades?”, el mapa de empatía evidencia que el agricultor requiere una forma más adecuada de clasificar el chocho manteniendo una buena calidad del producto y disponer de herramientas o tecnologías fáciles de usar que no le quiten el control sobre su producción. En esencia, busca reducir el esfuerzo físico y el tiempo que invierte, sin perder la capacidad de decidir sobre la calidad del grano que entrega.

Comprender este conjunto de percepciones, dolores y necesidades fue de gran ayuda para poder proponer una solución basada en visión artificial que actúe como apoyo al agricultor dentro de este proceso, respetando su forma de trabajo y respondiendo a problemas que él mismo reconoce.

#### 4.1.2. Comerciantes

El mapa de empatía del comerciante permitió entender las tensiones que enfrenta los días de comercialización de chocho en el mercado. Dicha información se obtuvo mediante conversaciones informales en la plaza Kennedy y entrevistas de su dinámica de trabajo, lo que permitió identificar sus verdaderas preocupaciones, conductas y expectativas frente al producto que adquiere y ofrece.

En la Figura 48, se puede observar el mapa de empatía del comerciante el cual permite comprender con mayor detalle cómo interactuar con la compra y venta del chocho en el mercado y qué espera de los agricultores que le proveen el producto.

En el apartado “¿Qué piensa y siente?”, cuando sus clientes reclaman por productos defectuosos el comerciante desea contar con proveedores confiables que entreguen chochos bien clasificados, para así poderlos vender de una forma rápida y sin devoluciones. También piensa en llevar un precio justo para el agricultor con la posibilidad de obtener una ganancia razonable con sus consumidores.

En cuanto a “¿Qué ve?”, observa que los consumidores se deciden por un chocho más limpio y blanco, se asegura que todo el producto llegue clasificado de forma manual y que algunos sacos llegan sin clasificar lo que reduce su valor, y le obliga a invertir tiempo adicional en reclasificarlos.

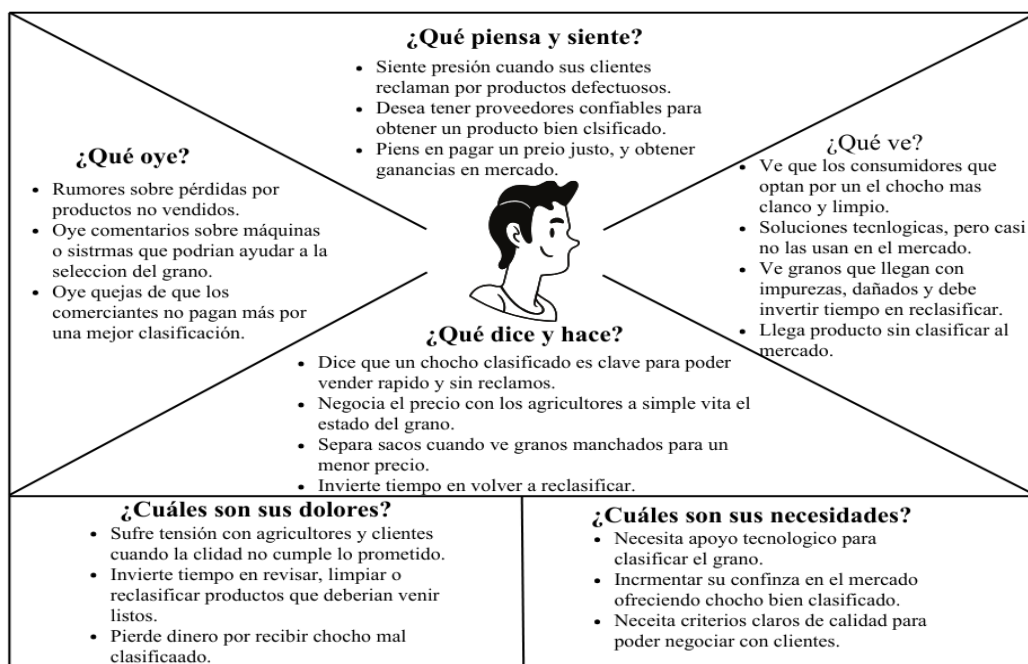


Figura 48. Mapa de empatía del comerciante

En “¿Qué oye?”, escucha comentarios pérdidas por productos no vendidos, referencias a posibles herramientas o maquinas que podrías ayudar con el proceso de selección del grano y quejas que vienen de otros comerciantes por la mala clasificación de ciertos lotes lo que generaría pérdidas en sus ganancias.

Respecto a “¿Qué dice y hace?”, sostiene que un saco de chocho bien clasificado es esencial para vender rápido y sin reclamos, trata de obtener un mejor precio a través de la negociación con los agricultores según la apariencia del grano, los sacos con mayor cantidad de defectos los separa para ofrecerles un precio más baratos y después realizar una reclasificación antes de ofrecer el producto a sus clientes.

En el apartado de “¿Cuáles son sus dolores?”, se manifiesta la tensión que sufre cuando la calidad del grano no es la prometida por el agricultor, el tiempo adicional que debe dedicar a revisar y reclasificar lotes que deberían estar listos para sus clientes, y la pérdida económica asociada aceptar producto mal clasificado que solo puede vender a menor precio.

Por último, en “¿Cuáles son sus necesidades?”, el comerciante muestra interés en adquirir proveedores que utilicen métodos de clasificación más confiables, reducir el trabajo en la relación del grano y disponer de un producto más adecuado que le permita atraer ms clientes y disminuir reclamos. Este mapa refuerza el conocimiento de los problemas que enfrenta el comerciante y de esta manera comprender mejor que una solución de visión artificial aplicada a la clasificación del chocho generaría beneficios tanto para el agricultor como para el comerciante, reduciendo los problemas de cansancio físico que genera este proceso.

#### **4.1.3. Consumidores**

El mapa de empatía de los consumidores refleja las expectativas y preocupaciones de quienes compran y consumen chocho, considerando aspectos que van más allá de la compra en sí. En la Figura 49, se presenta información que se obtuvo a partir de comentarios y encuestas, realizados en la plaza Kennedy y de la observación del comportamiento de los clientes frente a diferentes puestos, lo que permitió identificar qué valoran lo que les incomoda y qué necesitan para confiar en el producto.

Se pudo identificar claramente que el consumidor valora que el chocho debe ser sano y limpio para poder consumirlo con tranquilidad. Existe ocasiones donde encuentra granos dañados o con mal aspecto lo que le genera incomodidad, por lo que lo obliga a buscar un lugar donde no tenga que revisar el grano nuevamente en la casa.




Figura 49. Mapa de empatía del consumidor

En lo que ven, los resultados muestran que los consumidores visualizan diferencias en color, tamaño y limpieza entre los puestos de trabajo, también los granos de chochos exhibidos en sacos o baldes en el mercado o en tiendas y nota que algunos vendedores cuidan más la presentación del producto que otros. Respecto a lo que oyen, reciben recomendaciones sobre lugares donde el producto se encuentra más bien clasificado y rico, escucha que existen tecnologías que podrían ayudar a clasificar el producto y oye quejas de otros consumidores cuando encuentra granos dañados en sus compras.

Frente a lo “¿Qué dice y hace?”, el consumidor prefiere comprar donde el chocho es más blanco y fresco, dejando de comprar en lugares donde la calidad no es buena y recomendando a amigos y familiares los puestos donde ha encontrado mejor sabor y presentación.

En el apartado de sus dolores, se identificaron molestias al encontrar granos amargos o negros que generan desconfianza para el comerciante y pérdida de tiempo cuando debe separar en casa los granos buenos de los defectuosos.

Finalmente, en cuanto a las necesidades, el consumidor prefiere chochos visualmente atractivos desde el momento de la compra, confianza que el proceso fue clasificado previamente a la venta y que el producto conserve su calidad en cada compra. Estos resultados refuerzan una mejor

obtención del problema en el estudio de la clasificación del chocho no solo beneficiando agricultores y comerciantes, sino que también responde directamente a las expectativas del consumidor final.

#### **4.1.3.1. Análisis de la información del proceso**

El estudio de los tres actores involucrados en el proceso, evidencian que el problema de la clasificación manual del chocho no se limita a una sola etapa del procedimiento, sino que genera efectos conectados en todos los actores. En cuanto al agricultor enfrenta cansancio físico, desgaste visual y presión por una clasificación más rápida, el comerciante recibe producto con calidad variable que lo obliga a reclasificar y a asumir pérdidas, y el consumidor capta desconfianza cuando impurezas o granos dañados de esta manera afectando la imagen de los puntos de venta. Este acuerdo de las percepciones muestra que la falta de estandarización en la selección del grano impacta tanto a la productividad del trabajo como en la imagen del producto final.

A partir de esta comprensión detallada, se evidencia una oportunidad conjunta donde todos los actores valoran un chocho visualmente uniforme, limpio y consistente dando paso a mejoras tecnológicas que sean sencillas de usar y no afecten su dinámica de trabajo. Los mapas de empatía permitieron concluir que una propuesta de un modelo basado en visión artificial tiene posibilidades para responder conjuntamente las necesidades detectadas, al reducir el esfuerzo manual del agricultor, mejorar la confiabilidad de la clasificación para el comerciante y ofrecer al consumidor un producto más estable.

## **4.2. DEFINIR**

### **4.2.1. Lluvia de ideas de los problemas detectados**

Con el análisis realizado y la información recopilada en la fase de empatía con agricultores, comerciantes y consumidores, se procede a realizar una lluvia de ideas con el propósito de identificar de manera global todos los problemas, molestias y limitaciones vinculadas a la clasificación manual del chocho. Esta acción permitió resumir las ideas de cada actor en enunciados concreto del problema, sin priorizarlos ni seleccionarlos en una primera instancia, con el fin de tener una visión amplia de la situación operativa actual.




Figura 50. Problemas en la clasificación del grano

En la Figura 50, se muestran los resultados de esta lluvia de ideas, donde se estructuraron los problemas detectados en referencia al proceso de clasificación del grano. Entre los resultados más relevantes de este análisis se encontraron aspectos físicos (cansancio y fatiga visual), operativos (tiempo extra, calidad inconsistente, granos dañados) y estructurales (falta de tecnología, ausencia de criterios claros y desconfianza del consumidor).

En general, esta lluvia de ideas pone de afirmación que la clasificación manual del chocho genera una cadena de consecuencias negativas que afectan a los integrantes principales de este proceso, que va desde el cansancio físico del agricultor hasta la pérdida de confianza del consumidor. Este insumo se convierte así en la base para aplicar las herramientas posteriores de la fase de definición y encontrar el problema central de la investigación.

#### 4.2.2. Diagrama de Afinidad

La herramienta de Diagrama de Afinidad (método KJ) se aplicó para organizar y estructurar todos los problemas abordados en la lluvia de ideas, agrupándolos según su relación y similitud. Esta fase permitió pasar de una lista dispersa de problemas a una lista organizada en temáticas más manejables, permitiendo entender de mejor manera la situación actual de la clasificación manual del chocho preparando el camino para la definición del problema central.

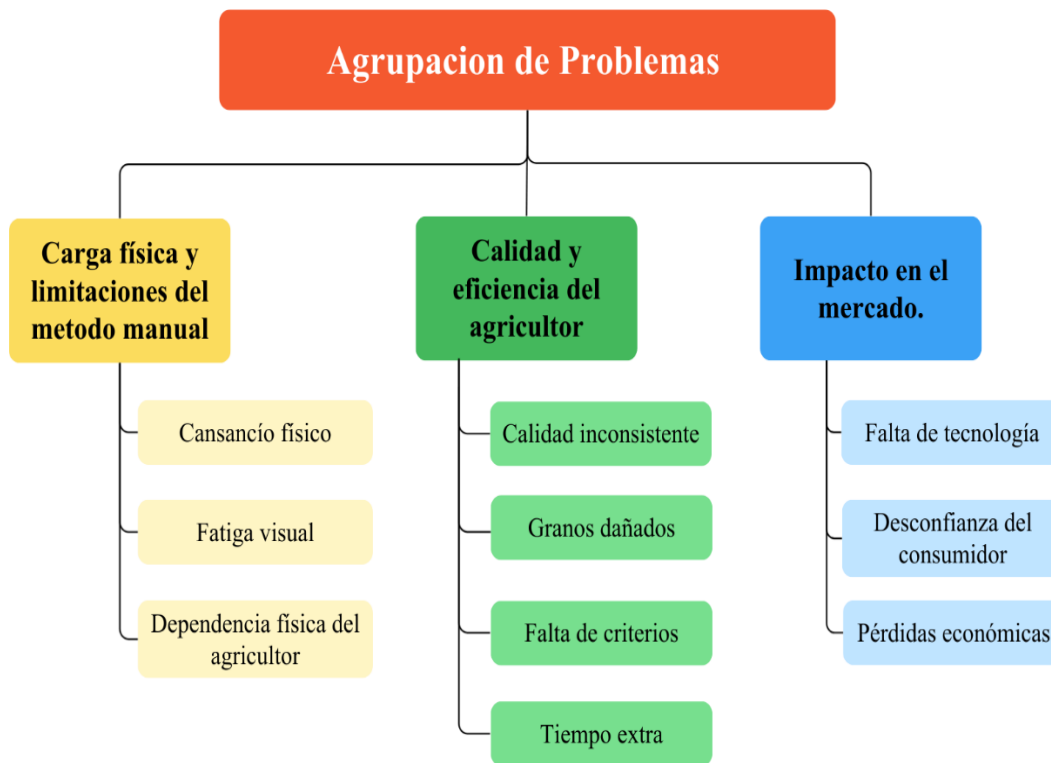


Figura 51. Diagrama de afinidad

En la Figura 51, se puede observar el diagrama de afinidad donde se identificaron tres grupos principales. La carga física y limitaciones del método manual es la principal, donde se reúnen los problemas como el cansancio físico, la fatiga visual y la alta dependencia del esfuerzo del agricultor, demostrando que el método actual requiere un trabajo repetitivo y poco sostenible en el tiempo.

En cuanto al segundo grupo de “calidad y eficiencia del agricultor”, se puede notar la inconsistencia en la calidad del producto, la presencia de granos dañados, la falta de criterios claros y el tiempo extra invertido en la selección del grano, lo que revela que el proceso manual no garantiza uniformidad. El tercer grupo, “Impacto en el mercado”, integra la falta de

tecnología, la desconfianza del consumidor y las pérdidas económicas a causa de una mala clasificación, reflejando las consecuencias que estos problemas generan en la comercialización y en la imagen del producto.

#### **4.2.2.1. Evaluar**

En este punto se procedió a evaluar de forma crítica los tres grupos de problemas identificados, comprendiendo el tipo de problema que contiene cada uno, su secuencia en las entrevistas y los mapas de empatía realizados, permitió reconocer que todos los grupos están conectados entre sí debido a que contienen un orden secuencial, pero no todos contienen el mismo peso en el origen del conflicto operativo que se busca abordar.

#### **4.2.2.2. Priorizar**

Dentro de esta etapa se valoró que grupo tiene mayor impacto sobre el desempeño del proceso de clasificación y sobre la calidad final del chocho. Se considero problemas que afecten directamente al flujo de trabajo, cuales generan más retrabajo y cuales se encuentran dentro de las quejas de los comerciante y consumidores. Este análisis llevo a ubicar al grupo de “Calidad y eficiencia del agricultor” como el más influyente en la cadena de efectos observados.

#### **4.2.2.3. Seleccionar**

El grupo anteriormente mencionado fue seleccionado como punto central del estudio, al reconocerse que los problemas de calidad inconsistente, granos dañados, falta de criterios y tiempos prolongados de clasificación están en el centro de la mayoría de los problemas globales identificados. Es decir, son problemas que nacen en la etapa de clasificación manual proyectando hacia el mercado y al consumidor final.

#### **4.2.2.4. Justificar**

De esta forma se optó primero por atacar el grupo “Calidad y eficiencia del agricultor” permitiendo incidir simultáneamente en los otros grupos: por una clasificación más uniforme y eficiente reduce el esfuerzo físico innecesario también disminuyendo las pérdidas y la desconfianza en el mercado. Por tal razón, este grupo se elige como base para formular el problema operativo central de la investigación, que posteriormente será profundizado mediante la herramienta de los 5 Porqués en la siguiente sección.

**El problema central se sintetiza de la siguiente forma:**

El hecho de depender de un procedimiento de clasificación manual del chocho, que es lento, físicamente exigente y poco uniforme, genera lotes con calidad visual irregular y largos tiempos de selección. Impactando negativamente la eficiencia del agricultor y la confiabilidad del producto a través de la cadena de comercialización.

### 4.2.3. Aplicación de los 5 Porqués al problema central

Para entender la causa raíz que sostiene los problemas de clasificación manual del chocho y para poder analizar más a fondo el problema detectado en la fase de Definición, se utilizó en esta investigación la herramienta de los 5 Porqués. Se formularon preguntas consecutivas con el fin de ir más allá de las manifestaciones inmediatas y describir las causas estructurales que tan origen a este problema central. Esta técnica posibilito convertir un estudio completo del problema en una secuencia lógica de causas y consecuencias, la cual era necesaria para respaldar el diseño de la solución sugerida.

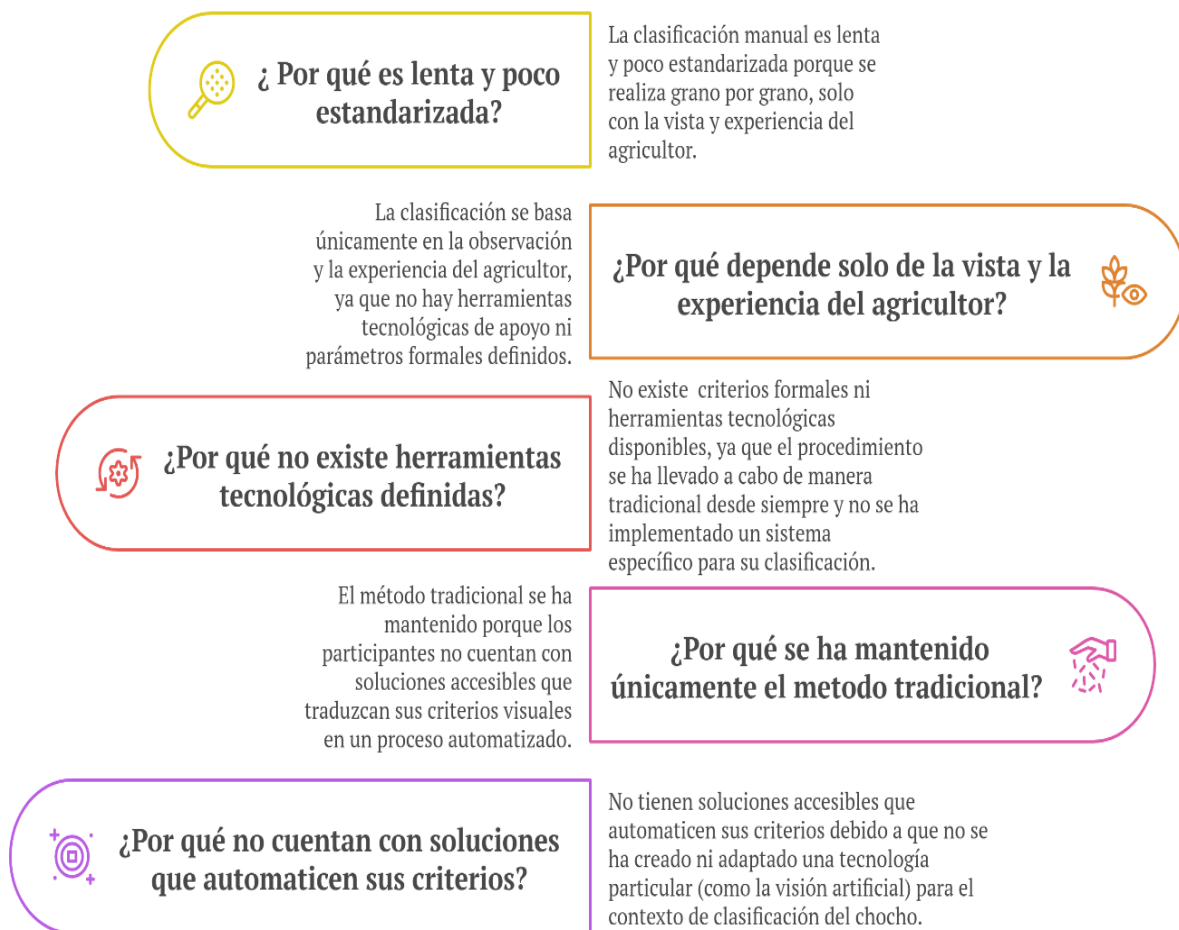


Figura 52. 5 porqués de la clasificación manual del chocho

En la Figura 52, se muestra la utilización de los 5 Porqués aplicados al problema principal. Para ello se formularon 5 preguntas sucesivas del tipo “¿Por qué?”, empleando como base la información recopilada durante la fase de empatía, la lluvia de ideas y el diagrama de afinidad. Cada respuesta fue elaborada basándose en los resultados obtenidos en las entrevistas, evitando suposiciones y manteniendo la coherencia con lo que piensan los agricultores, comerciantes y consumidores.

De esta manera, los 5 Porqués contribuyeron para eliminar las expresiones superficiales y conectar los las dificultades operativas cotidianas con causas más profundas. De esta manera esta herramienta permitió ordenar las causas en un recorrido lógico desde los síntomas visibles (cansancio, lentitud, calidad variable) hacia factores relacionados con la falta de soporte tecnológico adecuado relacionado con la manera tradicional de trabajo.

Por lo tanto, la causa raíz identificada es la ausencia de soluciones tecnológicas accesibles que traduzcan los estándares visuales de calidad empleados por los agricultores. Esta causa se transforma en el punto de partida para la creación del árbol de problemas, con el que se ilustrara como esta falta genera problemas en el proceso de clasificación manual del chocho y por lo tanto defectos en el mercado. Por lo tanto, los 5 Porqués brindan coherencia metodológica al vincular el problema principal con su raíz más profunda y justifican la conveniencia de sugerir un modelo de clasificación basada en visión artificial.

#### **4.2.4. Árbol de problemas**

Con el fin de agrupar y resumir toda la información obtenida en las fases anteriores, se empleó el Árbol de Problemas. El objetivo fue ilustrar de forma visual y ordenada la relación causa-efecto en torno a la clasificación manual del chocho, recorriendo desde una perspectiva fragmentada de obstáculos hasta un esquema que evidencie que causa el problema operativo y cuáles son las repercusiones a lo largo de la cadena productiva. De esta forma, el Árbol de Problemas creado para este estudio se muestra en la Figura 53.

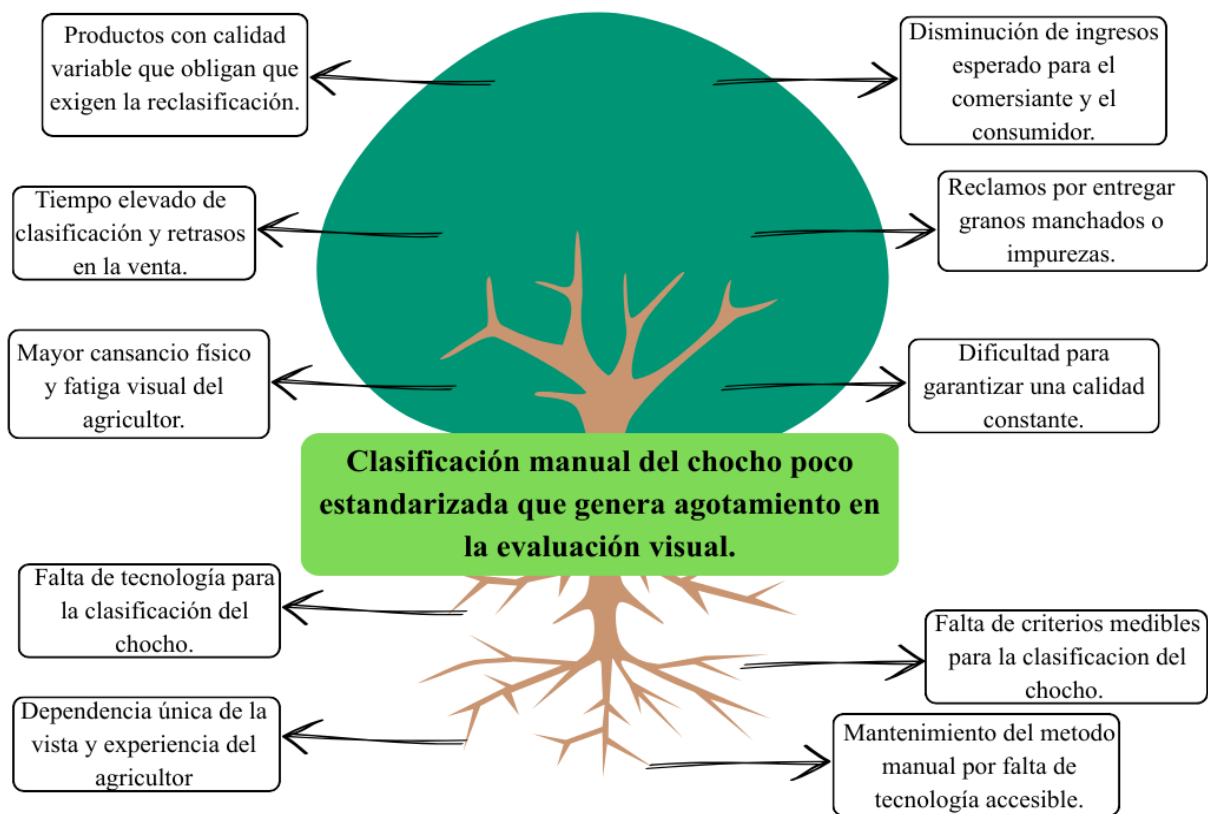


Figura 53. Árbol de problemas

En la estructura del árbol, el tronco representa el problema principal: una clasificación manual del chocho que no está estandarizada que requiere un esfuerzo físico considerable y es demorada, esto genera una calidad visual irregular y afecta la confiabilidad del producto. Las razones inferiores se encuentran las causas raíz, incluyendo la falta de tecnología específica para respaldar la clasificación manual, el depender únicamente de la vista y la experiencia del agricultor, la ausencia de criterios de calidad que puedan medirse y el conservar el método manual por falta de alternativas accesibles.

Los efectos se encuentran en la parte superior del árbol, donde se puede evidenciar resultados como el cansancio físico y fatiga visual, demoras en la venta, tiempos de clasificación más prolongados, granos con calidad inestables que requieren reclasificación, dificultad para generar una seguridad estable, disminución de las ganancias esperadas y quejas por granos manchados o con impurezas.

En resumen, este Árbol de Problemas demuestra que los problemas detectados no son sucesos aislados, sino el producto de un sistema de trabajo manual sin estandarización y con falta de apoyo tecnológico. Además, guía directamente el diseño de la solución: cualquier

planteamiento que quiera mejorar la situación debe abordar la causa fundamental, que es la falta de una herramienta capaz de automatizar la clasificación visual del chocho.

automatizar la clasificación visual del chocho.

### 4.3. REQUERIMIENTOS

En el análisis de resultados se relacionan los elementos principales del árbol de problemas con los requerimientos generales del modelo de visión artificial, con el objetivo de demostrar de forma estructurada la manera en que el diagnóstico del proceso manual de clasificación del chocho conduce a lo que se prevé para el futuro modelo. Al relacionar la cuestión principal y sus causas más significativas con requisitos que tienen como objetivo respaldar la estandarización de la evaluación visual y disminuir las restricciones encontradas en el método actual, la Tabla 18 resume esta relación.

Tabla 18. Resultados para desarrollar el modelo de visión artificial

<b>Problemas identificados (proceso manual)</b>	<b>Requerimientos del modelo a desarrollar</b>
Clasificación manual del chocho poco estandarizada que genera agotamiento en la evaluación visual.	El modelo debe apoyar a la estandarización de la evaluación visual del chocho
Dependencia exclusiva desde punto de vista y conocimiento del agricultor.	El modelo tiene que disminuir la dependencia absoluta de la opinión del ser humano en cuanto a decisiones de calidad.
Falta de criterios medibles para clasificar el chocho.	El modelo debe basarse en parámetros visuales que se puedan medir y comparar de manera consistente.

Esta Tabla 18, se muestra que los requisitos del modelo de visión artificial se originan directamente del problema principal y de las causas más importantes del árbol de problemas, por lo que cada uno de ellos es una respuesta directa a un obstáculo específico del método manual. Al asociar la falta de estandarización, la dependencia de los criterios del agricultor y la ausencia de parámetros medibles con el requerimiento de respaldo para la evaluación visual.

El modelo se presenta como una herramienta útil para apoyar a los agricultores en la adopción de decisiones más adecuadas sobre la calidad del chocho y para producir información objetiva

que posibilite evaluar, en fases futuras, si es ventajoso progresar hacia un desarrollo más integral de la visión artificial en este contexto.

#### 4.4. IDEAR

##### 4.4.1. Lluvia de ideas

La lluvia de ideas que se realizó con el fin de identificar maneras alternativas de solucionar el problema del chocho clasificado manualmente se muestra en la Figura 54. Se presentan siete propuestas las cuales van desde optimizaciones estructurales del proceso actual, como la clasificación manual estandarizada, hasta alternativas de automatización avanzada por medio de visión artificial, sistemas de monitoreo estadístico del rendimiento y sensores. Cada idea viene con una breve descripción que resume el funcionamiento básico y la particularidad del proceso de clasificación que se busca optimizar; estas descripciones son el insumo fundamental para la siguiente fase, la cual consiste en evaluar y ponderar alternativas.



Figura 54. Métodos de clasificación de granos

#### 4.4.2. Matriz de ponderación de ideas

La matriz de ponderación es una herramienta que se emplea para examinar comparativamente las ideas propuestas en la lluvia de ideas, asignándole a cada opción una puntuación numérica basada en criterios establecidos con anterioridad y valorados por su relevancia para el proyecto. Se tienen en cuenta criterios como se muestra en la Tabla 19, que empieza desde la viabilidad técnica, el costo estimado de implementación, la exactitud prevista para clasificar los granos, lo fácil que resulta integrar con el prototipo sugerido y la capacidad de influir en la disminución del tiempo de proceso al analizar esta matriz. Se logra una puntuación total para cada idea al multiplicar las calificaciones por los pesos de cada criterio y sumar los resultados. Esto permite que se clasifiquen jerárquicamente y se seleccione, de manera fundamentada, la opción más apropiada para la evolución del sistema automatizado de clasificación del chocho.

Tabla 19. Ponderación de las ideas

N.º idea	Criterio / Peso	Factibilidad técnica (4)		Costo (3)		Integración con prototipo (4)		Impacto en tiempo de proceso (4)		Puntaje Total
1	Clasificación por peso con celdas	3	12	3	9	3	12	3	12	45
2	Clasificación por tamaño con sensores	3	12	3	9	3	12	3	12	45
3	Visión artificial con CNN + línea automatizada (banda y servos)	4	16	3	9	5	20	5	20	65
4	Sistema semi automatizado, operador + visión artificial	3	12	3	9	4	16	4	16	53
5	Clasificación por escáner de color o espectro	3	12	2	6	3	12	3	12	42

Al analizar la matriz de ponderación de la Tabla 19 se nota que la opción con el puntaje total más alto es la idea 3: "Sistema de visión artificial con CNN incorporado en una línea automatizada de banda y servomotores". Esta propuesta logra las mejores calificaciones respecto a precisión esperada, integración con el prototipo y efecto en la disminución del tiempo del proceso, sin dejar de lado una factibilidad técnica apropiada y un costo razonable frente a otras alternativas. Por esta razón, la idea número 3 se escoge como la principal para ser trabajada en la tesis, ya que proporciona el fundamento para crear el modelo de visión artificial y el sistema mecatrónico de clasificación automática del chocho.

#### 4.4.3. SCAMPER

La idea ganadora, elegida tras la utilización de la matriz de ponderación, fue Visión artificial con CNN + línea automatizada (banda y servos). Para mejorar y optimizar esta propuesta, se

empleó la herramienta SCAMPER que se muestra en la Figura 55. Esta permitió examinar la idea escogida desde diferentes perspectivas, descubriendo oportunidades para perfeccionar, adaptar y optimizar el sistema sugerido.

Durante la etapa de Sustitución, se propuso sustituir la inspección visual manual por un sistema de visión artificial que utiliza redes neuronales convolucionales y que se complementa con un sistema automático de separación a través de servomotores. Esta sustitución posibilita que la dependencia del criterio humano disminuya y que el proceso de clasificación sea más consistente. Con respecto a la combinación del microcontrolador la cámara en un ambiente controlado, la banda transportadora y el modelo de clasificación se incorporaron para crear un sistema sincronizado que asegura una operación ininterrumpida y eficaz.

En lo que se refiere a Adaptar, se contempló la necesidad de modificar los parámetros de captura de imagen (por ejemplo, el fondo de la banda, la altura del dispositivo fotográfico y la iluminación), así como la configuración del modelo CNN, en función de las propiedades físicas del chocho: su tamaño, forma y color. La propuesta para la fase de modificar o magnificar fue mejorar la resolución de las imágenes, la rapidez del transportador y los niveles de confianza del modelo buscando alcanzar un balance apropiado entre el tiempo de procesamiento y la precisión en la clasificación.

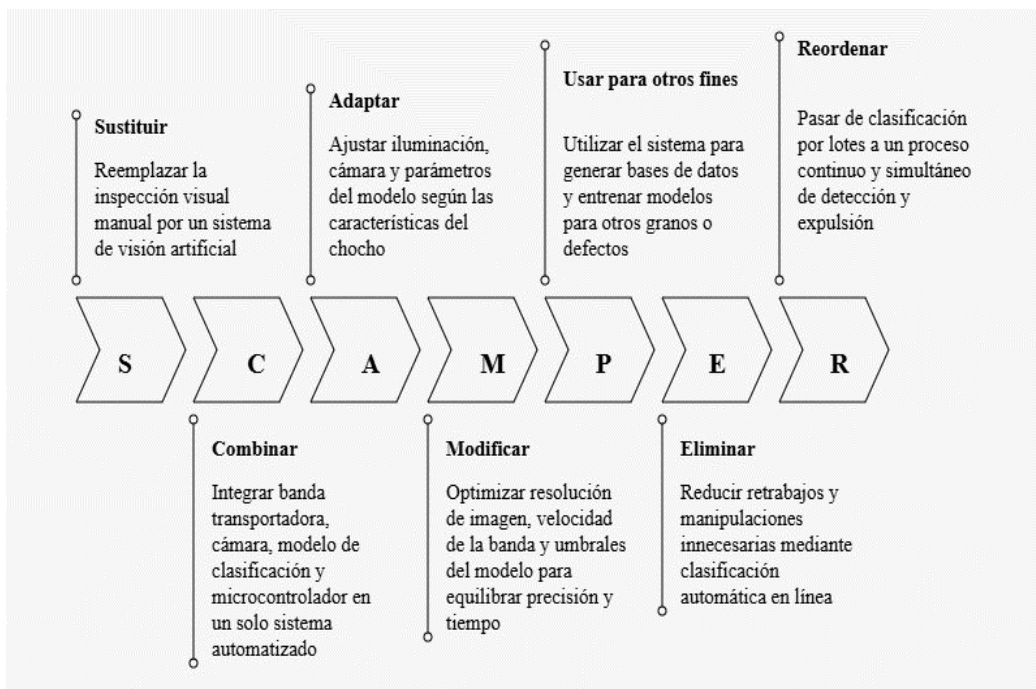


Figura 55. SCAMPER

Desde la perspectiva de Poner en otros usos se observó que se podría utilizar la infraestructura de banda transportadora y cámara para crear bases de datos fotográficas. Este recurso podría usarse para entrenar nuevos modelos o descubrir otros defectos específicos del producto. En la etapa de eliminar o reducir, se propuso suprimir los reprocesos y las revisiones manuales repetidas con el propósito de optimizar la eficiencia del sistema y disminuir manipulaciones innecesarias del chocho.

Por último, en Reordenar o revertir, se sugirió cambiar el procedimiento de clasificación por lotes a uno continuo en línea. En esta nueva organización, las fases de detección y expulsión del grano se llevan a cabo al mismo tiempo.

#### **4.5. DISEÑO DEL PROTOTIPO EN 3D**

En la etapa de resultados del diseño, el modelado en 3D del prototipo muestra que se establece una solución compacta, diseñada en un principio para procesar cerca de una libra de chocho por ciclo de prueba. Esto permite comprobar el desempeño de los mecanismos antes de ampliar el sistema a la escala industrial. Esta decisión de capacidad permite llevar a cabo múltiples iteraciones de ajuste con un uso controlado de materia prima, manteniendo el valor representativo de las condiciones reales de operación.

Las figuras pertinentes muestran los resultados de diseño mecánico, que incluyen una tolva dosificadora, laterales de banda transportadora diseñados para resistir el conjunto, rodillos de arrastre con soportes en forma de triángulo, la banda instalada, las divisiones internas en dos carriles y las paletas clasificadoras finales. Cada uno de estos componentes se basa en criterios establecidos durante la fase de ideación y selección de alternativas: alimentación controlada del grano, transporte lineal estable, capacidad para procesar dos flujos a la vez y separación física diferente entre granos defectuosos y buenos por medio de servomotores.

Por último, el diseño del entorno controlado es un resultado crucial porque incorpora luces y cámara en una estructura de tamaño adecuado para garantizar la uniformidad de la iluminación y la flexibilidad de la ubicación de la cámara. Esto facilita la adquisición de imágenes con condiciones estables de luz y fondo, disminuyendo el ruido visual y mejorando la actuación del modelo de clasificación fundamentado en redes neuronales. Esto establece una relación directa entre la etapa de diseño mecánico y los resultados previstos durante el entrenamiento y las pruebas del sistema de visión artificial.




Figura 56. Diseño final del prototipo

#### 4.5.1. Selección de componentes

##### 4.5.1.1. Selección de la mejor alternativa para la cámara

Para la selección de la cámara en el prototipo de clasificación de chochos mediante visión artificial, se aplicó una matriz de ponderaciones con criterios técnicos alineados a los requisitos del sistema y estándares de visión artificial, como se muestra en la siguiente Tabla 20.

Tabla 20. Criterios de ponderación de la cámara

Criterio	Peso	Logitech Brio 500	Puntaje ponderado	ArgomTech 1080p	Puntaje ponderado
Tipo de Sensor	4	4	16	3	12
Megapíxeles (MP)	5	5	25	3	15
Velocidad de captura (FPS)	5	5	25	3	15
Enfoque	4	5	20	2	8
Adaptabilidad lumínica	5	5	25	2	10
Interfaz de conexión	3	5	15	3	9
Compatibilidad de software	4	5	20	3	12
Costo	4	2	8	5	20
<b>Total</b>			154		101

Conforme a la matriz de decisiones presentada, la opción 1, correspondiente a la cámara Logitech Brio 500, se adapta de mejor manera al desarrollo del prototipo en comparación con la opción 2. Por consiguiente, se procede a utilizar la cámara Logitech Brio 500, la cual destaca por su alta resolución, mayor cantidad de megapíxeles, velocidad de captura de hasta 60 FPS, enfoque automático, adaptabilidad a condiciones lumínicas variables, interfaz USB 3.0 para transferencia eficiente de datos, compatibilidad con Jetson Nano mediante controladores oficiales y una construcción robusta adecuada para ambientes industriales. Estas características permiten obtener imágenes de alta calidad y confiabilidad, facilitando el procesamiento y tratamiento de los chochos en movimiento sobre la banda transportadora.

#### 4.5.1.2. Selección de la mejor alternativa para el Microcontrolador

Para la selección del microcontrolador en el prototipo de clasificación de chochos, se aplicó una matriz de ponderaciones con criterios técnicos alineados a los requisitos del sistema, como se muestra en la siguiente Tabla 21.

Tabla 21. Criterios de ponderación del Microcontrolador

<b>Criterio</b>	<b>Peso</b>	<b>Arduino Nano v3.0</b>	<b>Puntaje ponderado</b>	<b>Arduino UNO R3</b>	<b>Puntaje ponderado</b>
Tamaño físico	5	5	25	2	10
Número de pines I/O	4	5	20	4	16
Consumo energético	4	5	20	3	12
Facilidad de integración	4	5	20	3	12
Compatibilidad (librerías)	3	5	15	5	15
Disponibilidad en el mercado	3	5	15	5	15
Costo	2	5	10	3	6
<b>Total</b>			<b>125</b>		<b>86</b>

Conforme a la matriz de decisiones presentada en la Tabla 21, la opción 1, correspondiente al Arduino Nano v3.0, se adapta de mejor manera al desarrollo del prototipo en comparación con

la opción 2. Por consiguiente, se procede a utilizar el Arduino Nano v3.0, ya que su tamaño compacto facilita la integración en espacios reducidos del sistema de clasificación, ofrece un número suficiente de pines de entrada/salida para el control de servomotores, presenta un bajo consumo energético que contribuye a la eficiencia global del prototipo y mantiene una excelente compatibilidad con las librerías y herramientas del entorno Arduino. Además, su amplia disponibilidad en el mercado y su costo reducido lo convierten en la alternativa más adecuada para la automatización eficiente y económica del sistema de clasificación de chochos mediante visión artificial.

#### 4.5.1.3. Matriz de decisiones y justificación de la selección de la luminaria

Para la selección de las luminarias para el ambiente controlado del prototipo de clasificación de chochos, se aplicó una matriz de ponderaciones con criterios técnicos alineados a los requisitos del ambiente controlado, como se muestra en la siguiente Tabla 22.

Tabla 22. Criterios de ponderación para la iluminación

<b>Criterio</b>	<b>Peso</b>	<b>Módulo LED de 3 chips</b>	<b>Puntaje ponderado</b>	<b>Tiras de LEDs flexibles</b>	<b>Puntaje ponderado</b>
Tamaño	4	5	20	4	16
Facilidad de acople	4	5	20	4	16
Brillo adecuado	5	5	25	3	15
Uniformidad lumínica	4	5	20	3	12
Protección	3	5	15	4	12
Durabilidad	3	5	15	4	12
Costo	2	4	8	5	10
<b>Total</b>			<b>123</b>		<b>93</b>

Conforme a la matriz de decisiones, el Módulo LED de 3 chips se adapta de mejor manera al prototipo, superando a las otras alternativas en criterios clave como brillo adecuado,

uniformidad lumínica, protección y durabilidad. Su tamaño compacto y facilidad de acople permiten una integración eficiente, mientras que su iluminación homogénea mejora la calidad de las imágenes capturadas para la clasificación de chochos, evitando distorsiones y reflejos. Por estas razones, se selecciona el Módulo LED de 3 chips como la luminaria óptima para el sistema.

#### 4.5.1.4. Matriz de decisiones y justificación de la selección de la banda

Para la selección y justificación de la banda transportadora en el prototipo de clasificación de chochos, se aplicó una matriz de decisiones con criterios técnicos alineados a los requisitos del procesamiento de imágenes, como se muestra en la siguiente Tabla 23.

Tabla 23. Criterios de ponderación de la banda

<b>Criterio</b>	<b>Peso</b>	<b>Cuerina blanca</b>	<b>Puntaje ponderado</b>	<b>Eslabones plásticos</b>	<b>Puntaje ponderado</b>
Tamaño	4	5	20	5	20
Facilidad de acople	4	5	20	4	16
Comportamiento lumínico	5	5	25	2	10
Uniformidad superficial	4	5	20	3	12
Durabilidad	3	4	12	4	12
Costo	2	4	8	4	8
<b>Total</b>			<b>105</b>		<b>78</b>

Conforme a la matriz de decisiones, la banda de cuerina de color blanco se adapta de mejor manera al prototipo, superando a la banda de eslabones plásticos principalmente en el comportamiento lumínico y la uniformidad superficial. Su superficie mate evita los reflejos y distorsiones que dificultan la captura de imágenes, permitiendo una clasificación más precisa de los chochos mediante visión artificial. Por estas razones, se selecciona la banda de cuerina de color blanco como la opción óptima para el prototipo.

#### 4.5.1.5. Matriz de decisiones y justificación de la selección del servomotor

Para la selección y justificación del servomotor en el prototipo de clasificación de chochos, se aplicó una matriz de decisiones con criterios esenciales alineados a los requisitos del sistema, como se muestra en la siguiente Tabla 24.

Tabla 24. Criterios de ponderación del servomotor

Criterio	Peso	MG90S	Puntaje ponderado	SG90	Puntaje ponderado
Velocidad de actuación	4	5	20	4	16
Torque	5	5	25	3	15
Tamaño y peso	3	5	15	5	15
Durabilidad	4	5	20	3	12
Facilidad de acople	3	5	15	5	15
Costo	2	3	6	5	10
<b>Total</b>			<b>101</b>		<b>83</b>

Conforme a la matriz de decisiones, el servomotor MG90S se considera la mejor alternativa para el prototipo, destacando en torque, durabilidad y velocidad de actuación, lo que garantiza un funcionamiento fiable y preciso del mecanismo de clasificación. Aunque su costo es mayor que el del SG90, su construcción metálica y velocidad de actuación justifican la inversión para aplicaciones donde la fiabilidad y el rendimiento son prioritarios. Por estas razones, se selecciona el servomotor MG90S para el sistema de clasificación de chochos.

#### 4.5.1.6. Matriz de decisiones para selección de material para caja de Visión artificial

Para la selección del material para la caja de visión artificial en el prototipo de clasificación de chochos, se aplicó una matriz de decisiones con criterios esenciales alineados a los requisitos del sistema, como se muestra en la siguiente Tabla 25.

Tabla 25. Criterios de ponderación de material para el ambiente controlado

<b>Criterio</b>	<b>Peso</b>	<b>MDF</b>	<b>Puntaje ponderado</b>	<b>Impresión 3D</b>	<b>Puntaje ponderado</b>
Facilidad de construcción	4	5	20	3	12
Costo	5	5	25	2	10
Tiempo de fabricación	4	5	20	2	8
Resistencia mecánica	3	4	12	3	9
Facilidad de montaje	3	5	15	3	9
Bloqueo de luz externa	4	5	20	3	12
<b>Total</b>			<b>112</b>		<b>60</b>

Conforme a la matriz de decisiones, el ambiente controlado de madera MDF resulta ser la mejor alternativa para la caja de visión artificial, ya que supera a la opción de impresión 3D en facilidad de construcción, menor costo, rapidez de fabricación y capacidad para bloquear la luz externa. Estas ventajas permiten una integración eficiente y económica en el prototipo, garantizando condiciones óptimas para la captura de imágenes y facilitando el mantenimiento o modificaciones futuras. Por estas razones, se selecciona la caja de MDF como la opción más adecuada para el sistema de visión artificial.

#### **4.6. PROTOTIPAR**

##### **4.6.1. Resultados de fabricación e impresión 3D**

La impresión y fabricación en 3D revela que las piezas diseñadas en Fusion 360 se replican con exactitud en material PLA, conservando las dimensiones requeridas para su ensamblaje posterior en el prototipo. A través de la configuración de parámetros en Ultimaker Cura, se obtienen piezas con rigidez y estabilidad de dimensiones adecuadas, particularmente en elementos clave como los soportes de rodillos, las divisiones internas, las paletas de clasificación y los lados de la banda. Estos no muestran deformaciones importantes después del proceso de impresión. Adicionalmente, el acabado superficial logrado es apto para asegurar que los granos de chocho y la banda se deslicen adecuadamente, lo cual demuestra que el método de impresión elegido es adecuado para construir el sistema mecánico.

#### **4.6.1.1. Ensamblajes laterales**

En la Figura 57 se realizó pegando las piezas impresas De pelea color negro Mediante Una mezcla de pegamento con brujita y bicarbonato de sodio Uniendo las paredes laterales Que serán sus bases para la banda transportadora Estas piezas con diseño ergonómico y soporte integrados aseguran una conectividad efectiva de los chochos durante un movimiento de la banda evitando derrames hacia los lados



Figura 57.Laterales de la banda trasportadora

#### **4.6.1.2. Ensamble de separación y soporte de laterales**

En la Figura 58 se muestra el ensamblaje del costado y del soporte rectangular de madera, se fija para garantizar la estabilidad estructural usando pernos y tornillos asimismo se adapta a la pieza separadora que mantiene el ancho óptimo de la banda transportadora estableciendo los carriles para chochos buenos y malos. Este ensamblaje con pernos posibilita ajustes exactos y un fácil desarme para el mantenimiento, lo que asegura una alineación ideal y resistencia a las vibraciones de un funcionamiento continuo.



Figura 58. Soporte de los laterales

#### **4.6.1.3. Ensamble de Rodillos**

La Figura 59 se muestra el ensamblaje de rodillas con ejes metálicos que atraviesan los soportes fijados a la base de madera mediante pernos y tornillos. Las rodillas facilitan tracción uniforme de la banda soportando el peso de los granos de chocho sin deslizamientos ni desalineaciones durante el movimiento continuo, la configuración permite tensiones ajustables de la banda y la rotación impulsadas por el motor.




Figura 59. Montaje de rodillos

#### 4.6.1.4. acoplamiento de motor a los laterales

La Figura 60 se puede observar el acoplamiento del motor a los laterales, así fijando el motor DC al soporte impreso En PLA color negro mediante tornillos, posicionándolo y aliñándolo con los ejes del rodillo dentro de la estructura de sus extremos laterales. Esta unión transmite potencia directamente a la banda transportadora impulsando el movimiento continuo de granos de chochos a través de los carriles diseñados para una mejor tensión de la banda, así mismo se acopló uno de los engranes que asegura Su movimiento Correcto.




Figura 60. Acoplamiento del motor DC

#### 4.6.1.5. Acoplamiento de Banda transportadora

En la Figura 61 se muestra la instalación de la banda transportadora de cuero gris tensada entre los rodillos de los extremos del prototipo y fijada con cemento de contacto para mantener la tensión adecuada. Este ensamble asegura tracción uniforme cuando el motor acciona la banda, permitiendo recorrer sin problemas ni deslizamientos a la velocidad adecuada para la clasificación de chochos.




Figura 61. Cuerina blanca

#### 4.6.1.6. **Ensamble de Ambiente controlado**

La Figura 62 se muestra el ensamblaje del ambiente controlado Construido con paneles de madera y ranuras recortadas para formar una caja cerrada sobre la banda transportadora. Esta estructura proporciona iluminación uniforme, protección contra luz externa y se realizó agujeros ajustables para la altura de la cámara sobre la zona de detección de chonchos para la captura precisa de imágenes. Las piezas se unieron con pegamento fuerte asegurando su resistencia estructural durante la operación continua.



Figura 62. Pegado de ambiente controlado

#### 4.6.1.7. **Acoplamiento del circuito al prototipo**

El circuito electrónico fue acoplado al prototipo dentro de un ambiente controlado utilizando una caja Protectora que permitió resguardar y organizar adecuadamente los componentes electrónicos. Desde esta caja se realizaron las conexiones hacia el motor DC, los servomotores y el sistema de iluminación del ambiente controlado. La caja del circuito fue ubicada sobre el ambiente controlado con el objetivo de mejorar la organización y distribución del cableado. Los conductores eléctricos fueron asegurados mediante amarres plásticos y espirales, Lo que facilita

el orden Reduciendo la exposición de los cables y permitiendo un mantenimiento más sencillo del sistema.

El acoplamiento final del circuito evidenció una correcta integración eléctrica como se muestra en la Figura 63, garantizando una conexión estable entre los actuadores y sistema de control, sin interferir con el funcionamiento del sistema de visión artificial.




Figura 63. Integración del sistema electrónico

#### **4.6.1.8. Ensamble de la tolva**

La tolva fue ensamblada físicamente utilizando las piezas impresas en 3D como se muestra en la Figura 64, que fueron incorporadas de manera adecuada sin necesidad de ajustes extra. Los componentes mostraron una precisión dimensional apropiada, lo que posibilitó un empalme adecuado entre la estructura principal y la pieza adaptada desde Thingiverse.

La tolva ensamblada demostró estabilidad mecánica a lo largo de las pruebas, manteniendo la carga media de granos de chocho sin sufrir deformaciones. Además, los orificios calibrados posibilitaron un flujo del producto hacia la cinta transportadora de manera continua y controlada. El ensamblaje resultó en una adecuada orientación de los granos hacia el área de inspección visual, lo que confirmó la capacidad funcional y constructiva del sistema para ser integrado con el sistema de visión artificial.




Figura 64. Ensamblaje de todos los componentes de la tolva

#### **4.6.1.9. Ensamble de servomotores y paletas**

En la Figura 65 se muestra el ensamblaje de dos servomotores MG90S fijados a un soporte impreso en el extremo de la banda transportadora donde caen los chochos clasificados. Cada servomotor se acopla a su paleta mediante tornillos permitiendo un giro preciso para dirigir los granos de mal estado hacia su recipiente.




Figura 65. Montaje de servomotores y paletas

### **4.7. DESARROLLO DEL MODELO DE VISIÓN ARTIFICIAL**

#### **4.7.1.1. Recolección de imágenes**

La recolección de imágenes se realizó mediante el uso de la computadora donde configuré todos los parámetros necesarios para la captura de imágenes, que se van guardando en la carpeta de "Train". Se tomaron un total de 150 imágenes, divididas en 75 imágenes de granos buenos y 75 imágenes de granos malos (incluyendo las categorías con puntos negros y dañados). Esta metodología garantiza una base de datos equilibrada y representativa para el entrenamiento del

modelo, facilitando una clasificación precisa y confiable como se muestra continuación, en la siguiente Figura 66 se puede observar la recolección de imágenes para el entrenamiento.



Figura 66. Captura de imágenes en el ambiente controlado

#### 4.7.1.2. Etiquetado de imágenes

MAKE SENCES: Es una herramienta gratuita y de código abierto diseñada para facilitar el etiquetado de imágenes en proyectos de visión artificial y aprendizaje automático como se muestra en la Figura 67, esta herramienta nos ayuda a crear un conjunto de datos mediante las imágenes de chochos buenos y malos para ser etiquetados y se pueda hacer el procesamiento de imágenes.




Figura 67. Plataforma MAKE SENSE

#### 4.7.1.3. Etiquetado de granos buenos y malos

Para etiquetar las imágenes se carga todas las fotos de la carpeta donde están los chochos buenos y se configuran los siguientes parámetros, verde serán buenos y rojos serán malos para posteriormente seleccionar primero los chochos buenos mediante una selección de cada grano con un perfil de color verde que indica que está en buen estado como se muestra en la Figura 68, luego hacemos el mismo procedimiento desde cargar todas las fotos de la carpeta para los granos en mal estado seleccionando con un perfil rojo como se muestra en la Figura 69.




Figura 68. Se muestra el etiquetado de los granos en buen estado




Figura 69. Se muestra el etiquetado de los granos en mal estado

#### 4.7.1.4. Exportaciones de anotaciones en Make Sense

Una vez que terminamos de etiquetar todos los granos de chocho buenos como los defectuosos, en las imágenes vamos al ícono de Actions en el software. A continuación se seleccionó Export Annotations, que abre un menú con varias opciones de exportación. Para este proyecto, elegimos el formato YOLO, y el programa genera un archivo comprimido en .zip estos pasos se puede observar en la siguiente Figura 70. Este archivo trae toda la información de las anotaciones: las coordenadas de los cuadros y las clases de cada grano. Todo esto lo usaremos después para entrenar el modelo de reconocimiento y clasificación automática.

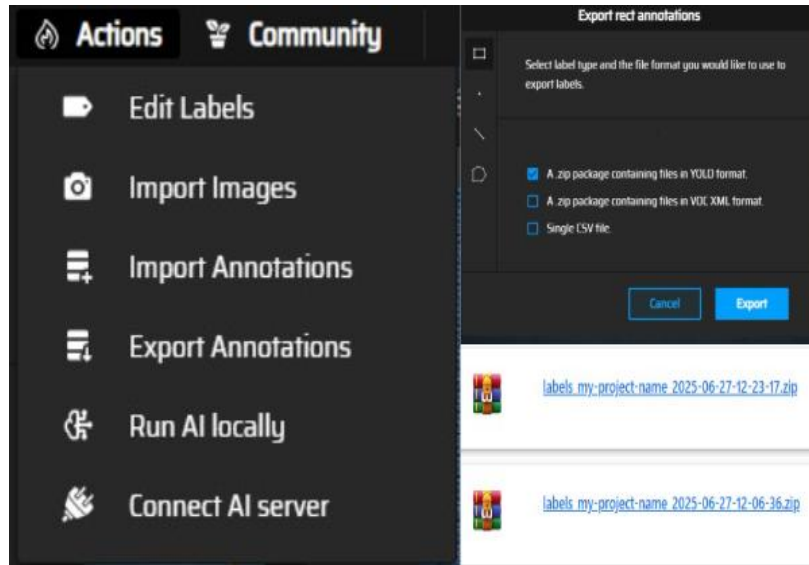


Figura 70. Proceso de exportación de etiquetas para el entrenamiento

#### 4.7.1.5. Entrenamiento del modelo

Para el entrenamiento de imágenes se abre (Windows PowerShell) y se ingresa el siguiente código. Este código hará que el programa se ejecute sin problemas al momento que cargue más de una vez la misma biblioteca (librería).

*Set KMP\_DUPLICATE\_LIB\_OK=TRUE*

A continuación, usamos este código para entrenar un modelo de detección de objetos con YOLO, basado en los datos que exportamos antes desde Make Sense. El entrenamiento corre por 100 épocas con las imágenes ya etiquetadas, y al final genera el archivo de configuración del dataset llamado `chochos_data.yaml`. Este archivo es clave para arrancar el proceso de visión artificial.

*yolo detect train data=chochos\_data.yaml model=yolov11n.pt epochs=100 imgsz=640 batch=4 name=entrenamiento\_chochos\_final*

La descripción de cada parámetro del comando es la siguiente:

- **yolo detect train:** El comando base que arranca el entrenamiento de un modelo de detección con YOLO.
- **data=chochos\_data.yaml:** Apunta al archivo YAML con toda la configuración del dataset, como las rutas de imágenes para entrenar.
- **model=yolov11n.pt:** El modelo preentrenado inicial; usamos la versión "nano" porque es liviana y perfecta para computadoras con recursos limitados.






Figura 72. Estructura del dataset al finalizar el entrenamiento

#### 4.7.1.7. Implementación del código y entrenamiento del modelo

En la Figura 73 se observa que después de terminar el entrenamiento y crear los archivos `yolo11n.pt` y la carpeta `runs`, se ejecutó el código de inferencia en Python. Se especificaron las rutas al modelo entrenado (`model='yolo11n.pt'`) y al archivo de configuración (`data='Chochos11_data.yaml'`), además de cargar los pesos optimizados. Este script emplea la biblioteca Ultralytics para analizar video en tiempo real desde la cámara web. Aplica el modelo entrenado para identificar y clasificar chochos en las categorías "bueno" (recuadro verde) y "malo" (recuadro rojo), con una certeza mayor al 70%.

El código que se ejecutó a través de `yolo detect predict model=yolo11n.pt source=0 show=True` abrió una ventana en tiempo real, en la que la cámara toma imágenes del transportador. El modelo lleva a cabo inferencias al instante (más o menos 30 FPS), dibuja cuadros delimitadores con colores que dependen de la clase detectada y presenta métricas de confianza. Esto hace posible verificar visualmente la exactitud de clasificación automática antes de incorporarla al prototipo industrial con Arduino y servomotores.

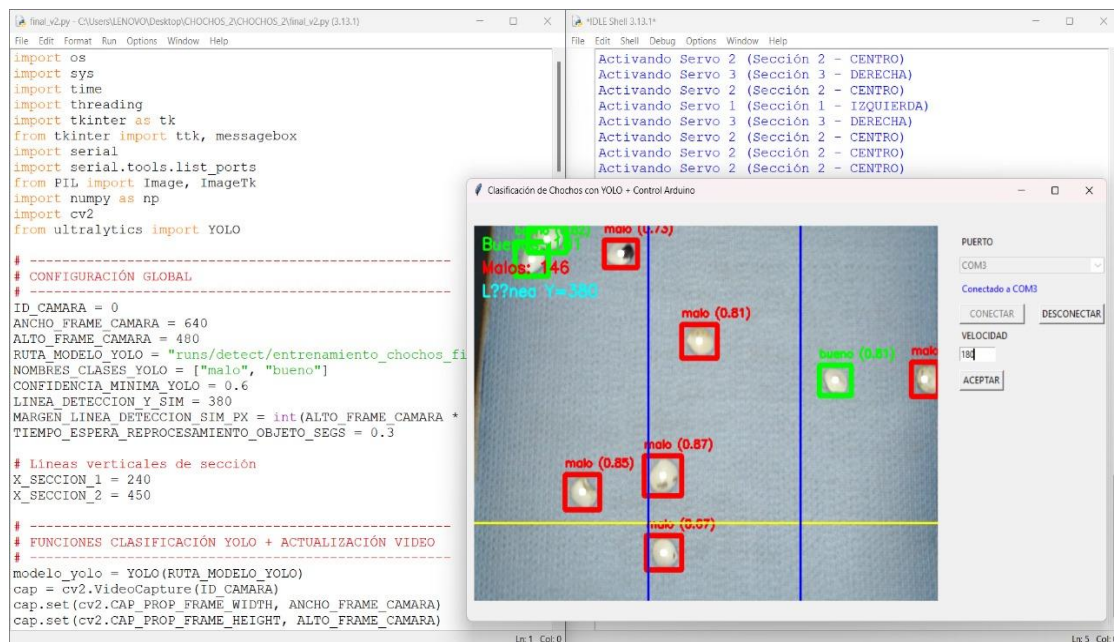


Figura 73. Ejecución del entrenamiento con el código

## 4.8. RESULTADOS DE LAS FASES TESTEAR Y TESTEO

### 4.8.1. Análisis de desempeño de los modelos

#### 4.8.1.1. Entrenamiento del modelo con variaciones de parámetros.

Para una mejor validación de este diseño del modelo de visión artificial se procedió a realizar tres entrenamientos durante el desarrollo de la investigación, los cuales permiten valorar la evolución del desempeño del modelo de detección de granos. Estos resultados fueron generados automáticamente al finalizar cada proceso de entrenamiento mediante la librería YOLOv11, herramienta especializada en detección de objetos que facilita el cálculo de métricas de precisión, a lo largo de las épocas de entrenamiento. A partir de esta información, se analizan y comparan las tres modelos entrenados, con el propósito de comprender su comportamiento para posteriormente, validar esos resultados en tiempo real.

En el primer modelo se utilizó un conjunto inicial de 116 imágenes, de las cuales 100 se destinaron al entrenamiento del modelo y se organizaron en la carpeta Train, que estaba formado por 50 imágenes de granos buenos y 50 de granos malos, garantizando un equilibrio entre ambas clases desde las primeras pruebas. Las 16 imágenes restantes se ubicaron en la carpeta Val que se emplearon para la validación, La elección de un conjunto relativamente reducido se consideró adecuada, ya que cada imagen contenía aproximadamente 10 granos previamente etiquetados, lo que incrementó de forma efectiva la cantidad de ejemplos

disponibles para el aprendizaje. El entrenamiento se ejecutó durante 100 épocas, lo que permitió obtener una primera referencia del comportamiento del modelo.

En el segundo entrenamiento se amplió el conjunto de datos con el fin de analizar cómo variaba el rendimiento del modelo al disponer de un mayor volumen de imágenes. En este caso se trabajó con 190 imágenes, de las cuales eran 75 de granos buenos y 75 de granos malos se colocaron en la carpeta Train para el proceso de aprendizaje. Las 40 imágenes restantes se asignaron a la carpeta Val que se utilizaron para la validación del entrenamiento, al igual que en el primer entrenamiento, se mantuvo el número de épocas en 100, de forma que las diferencias observadas en las métricas puedan atribuirse principalmente al incremento de datos y no a cambios en los parámetros de entrenamiento.

En el tercer entrenamiento se empleó un conjunto de datos aún más amplio, utilizando 300 imágenes en total. De ellas, 250 se destinaron al entrenamiento del modelo, distribuidas equitativamente en 125 imágenes de granos buenos y 125 de granos malos. Las 50 imágenes restantes se utilizaron en la carpeta Val para la fase de validación, a diferencia de los dos casos anteriores, en este entrenamiento se incrementó el número de épocas a 150, para estudiar el efecto de un mayor número de iteraciones sobre el proceso de aprendizaje del modelo.

Al realizar los tres entrenamientos permitió evaluar de manera progresiva la mejora del desempeño del modelo, especialmente en términos de precisión y estabilidad. A continuación, se analizarán los diagramas generados por los entrenamientos realizados, presentando únicamente aquellos correspondientes al entrenamiento que evidenció el mejor desempeño.

#### **4.8.1.2. Evolución de la curva F1 en relación con el umbral de confianza**

La curva F1 en función del umbral de confianza es fundamental para evaluar un modelo de visión artificial, ya que muestra el equilibrio entre precisión y recall según el nivel de confianza en las predicciones. Esta curva ayuda a hallar el punto óptimo de operación, donde el valor de confianza maximiza el rendimiento general del modelo. En este estudio, se usa para comparar los entrenamientos en la clasificación de chochos (*Lupinus Mutabilis*), . A continuación, se presentan sus resultados obtenidos en la Tabla 26. Comparación del valor F1 y umbral de confianza correspondiente a los tres modelos entrenados, para analizar su evolución y seleccionar el óptimo.

Tabla 26. Comparación del valor F1 y umbral de confianza

Entrenamiento	Número de imágenes	Mejor F1	Umbral óptimo
Entrenamiento 1	100 imágenes	0.99	0.52
Entrenamiento 2	150 imágenes	1.00	0.72
Entrenamiento 3	250 imágenes	0.99	0.72

A partir del análisis de la Tabla 26, se observa que el entrenamiento con 150 imágenes alcanza su máximo valor de  $F1 = 1$ , con un umbral de confianza del 0.72, lo que evidencia una mejor capacidad del modelo para mantener un equilibrio adecuado entre precisión y recall incluso al exigir predicciones de alta confianza. Por otro lado, el entrenamiento con 250 imágenes presenta casi un mismo resultado en comparación con el entrenamiento ganador. En contraste, el entrenamiento con 100 imágenes presenta su punto óptimo en un umbral significativamente menor, lo cual indica una menor robustez ante predicciones dudosas. A continuación, en la Figura 74, se presenta la curva F1 correspondiente al entrenamiento seleccionado.




Figura 74. F1-Confidence curve

#### 4.8.1.3. Análisis de la curva de precisión según el umbral de confianza

La curva Precisión–Confianza muestra cómo se comporta el modelo de clasificación al ajustar el umbral mínimo de confianza para validar una predicción. Este parámetro resulta clave en

sistemas automáticos, pues la precisión refleja la proporción de aciertos entre todas las detecciones hechas. Un valor elevado de precisión significa pocos falsos positivos, ideal para minimizar errores en clasificaciones críticas. Aquí, la curva analiza la respuesta de cada modelo ante mayor exigencia en sus decisiones, a continuación, se compara los parámetros de cada entrenamiento en la Tabla 27. Comparación de precisión según el umbral de confianza

Tabla 27. Comparación de precisión según el umbral de confianza

Entrenamiento	Número de imágenes	Precisión máxima	Umbral de confianza asociado
Entrenamiento 1	100 imágenes	1.00	0.83
Entrenamiento 2	150 imágenes	1.00	0.82
Entrenamiento 3	250 imágenes	1.00	0.88

De la curva Precisión–Confianza se identifica que el entrenamiento 2, con 150 imágenes, ofrece el mejor equilibrio entre estabilidad y fiabilidad, al lograr alta precisión desde umbrales bajos y sostenerla de forma constante en toda la gráfica. Esto refleja su habilidad para reducir falsos positivos sin necesidad de umbrales muy estrictos. Por ello, se elige este entrenamiento como el modelo superior según este indicador. A continuación, se presenta la Figura 75 del entrenamiento seleccionado.




Figura 75. Precision - confidence curve

#### 4.8.1.4. Análisis de la curva Precision–Recall Curve

La curva de precisión recall resulta fundamental para evaluar el rendimiento de modelos de clasificación en visión artificial, ya que examina al mismo tiempo la precisión del modelo su capacidad para acertar en las muestras detectadas y el recall su habilidad para identificar la mayor cantidad posible de instancias reales. El área bajo esta curva se resume en la métrica mean Average Precision (mAP), que ofrece una medida global y clara del desempeño general del modelo. A continuación, la Tabla 28 compara los parámetros de cada entrenamiento realizado.

Tabla 28. Comparación de las métricas de Precision–Recall Curve

<b>Entrenamiento</b>	<b>Nº de imágenes</b>	<b>Precisión clase “malo”</b>	<b>Precisión clase “bueno”</b>	<b>mAP@0.5</b>
Entrenamiento 1	100	0.995	0.995	0.995
Entrenamiento 2	150	0.995	0.995	0.995
Entrenamiento 3	250	0.995	0.993	0.994

De acuerdo con los resultados en la Tabla 28, el entrenamiento con 150 imágenes destaca por su mejor rendimiento global en la curva de precisión-recall. Logra un mAP@0.5 de 0.995, con precisión de 0.995 en ambas clases, lo que confirma una clasificación muy confiable y equilibrada. Comparado con las 100 imágenes, ofrece mayor robustez gracias al dataset más amplio que reduce el sobreajuste, mientras que el de 250 imágenes, aunque sólido, baja ligeramente a 0.994 en mAP@0.5 y 0.993 en precisión para la clase "bueno". Por eso, se elige el modelo de 150 imágenes como ganador, en la Figura 76 se muestra su curva de precisión-recall.




Figura 76. Precision- recall curve

#### 4.8.1.5. Análisis de la matriz de confusión

La matriz de confusión es una herramienta clave para medir el rendimiento de modelos de clasificación, ya que detalla los aciertos y errores del sistema de manera clara. No solo cuenta las clasificaciones correctas, sino que revela el tipo de confusiones entre clases incluyendo el fondo de la imagen (background), que en este trabajo se refiere a todos los elementos que no pertenecen a las clases de interés como "bueno" o "malo", lo cual es vital en aplicaciones reales donde ciertos errores impactan más. A continuación, en la siguiente Tabla 29 , se puede observar la comparación de esta evaluación en los tres entrenamientos.

Tabla 29. Comparación de las matrices de confusión

Entrenamiento	Nº de imágenes	Aciertos "malo"	Aciertos "bueno"	Confusión entre clases	Errores hacia background
Entrenamiento 1	100	80	79	2	5
Entrenamiento 2	150	164	124	0	4
Entrenamiento 3	250	244	204	2	6

A partir del análisis de la matriz de confusión presentada en la Tabla 29, queda claro que los tres entrenamientos logran varias clasificaciones correctas en "bueno" y "malo". Sin embargo, el de 100 imágenes tiene una muestra pequeña, y el de 250, aunque suma más aciertos totales,

genera confusiones entre clases y más errores hacia el background. En cambio, el de 150 imágenes resalta con 164 aciertos en "malo", 124 en "bueno", cero confusiones entre ellas y solo cuatro fallos al background, mostrando una separación clara y alta fiabilidad. Por lo tanto, este entrenamiento se escoge como el modelo con el mejor rendimiento de acuerdo a la matriz de confusión, que se muestra gráficamente en la siguiente Figura 77.




Figura 77. Matriz de confusión

**4.8.1.6. Evaluación global del rendimiento de los modelos entrenados**

En la Tabla 30, que se presenta a continuación se realiza el análisis global que permiten evaluar de manera integral cómo se comportan los modelos entrenados a lo largo de las épocas en la fase de entrenamiento. En estas figuras se observó las curvas de pérdida junto con las principales métricas de desempeño lo que ofrece una visión completa del proceso de aprendizaje del modelo.

Este análisis resulta esencial para comprobar la estabilidad del entrenamiento, la capacidad de generalización y la ausencia de sobreajuste, evitando modelos que funcionen bien solo con los

datos de entrenamiento, pero fallen con datos nuevos. A partir de estas métricas, se realiza una comparación objetiva entre los tres entrenamientos ejecutados, lo que permite seleccionar con criterio técnico el modelo con mejor desempeño.

Tabla 30. Comparación del rendimiento global de los modelos

<b>Parámetro evaluado</b>	<b>Entrenamiento 1</b>	<b>Entrenamiento 2</b>	<b>Entrenamiento 3</b>
Estabilidad de train/box_loss	Media	Alta	Media
Estabilidad de val/box_loss	Baja (alta dispersión)	Alta	Media
Estabilidad de train/cls_loss	Alta	Alta	Alta
Estabilidad de val/cls_loss	Media	Alta	Media
train/df1_loss	Media	Alta	Media
val/df1_loss	Inestable	Estable	Tendencia creciente
Precisión final	0.99	0.99	0.99
Recall final	0.99	1.00	0.99
mAP@0.5	0.99	1.00	0.99
mAP@0.5–0.95	0.62	0.65	0.64
<b>Comportamiento general</b>	<b>Aceptable</b>	<b>Óptimo</b>	<b>Bueno</b>

Tras revisar a fondo las métricas globales y las curvas de entrenamiento y validación, se concluye que el Entrenamiento 2 ofrece el mejor rendimiento. Este modelo exhibe curvas de pérdida más estables y suaves en el entrenamiento como en validación, señal de un proceso de aprendizaje consistente y una sólida capacidad de generalización. Logra además valores finales muy altos en precisión y recall, próximos a 1.00, con fluctuaciones mínimas entre épocas. Sobresale particularmente en la métrica mAP@0.5–0.95, alcanzando alrededor de 0.65, por encima del resto de entrenamientos, por tales razones el modelo 2 es el mejor entrenado.

Por su parte, el Entrenamiento 1 se descartó porque usó menos datos, lo que causa mayor dispersión en las curvas de validación y menor estabilidad en las métricas, afectando su generalización. El entrenamiento 3, pese a métricas altas, muestra señales de sobreentrenamiento, las pérdidas de entrenamiento siguen bajando, pero las de validación se

estabilizan o suben. La Figura 78 muestra el comportamiento del modelo ganador, lo que justifica su elección como el modelo adecuado para clasificación de chochos.




Figura 78. Resultados del entrenamiento

#### 4.8.2. Validación del entrenamiento a través de pruebas experimentales

Para verificar experimentalmente el modelo sugerido, se realizaron ensayos en tiempo real en dos plataformas de procesamiento. En primer lugar, se realizaron diez pruebas independientes en una computadora para analizar cómo funciona la clasificación. Después, se realizaron las mismas diez pruebas en una Raspberry Pi 5, utilizando la misma cantidad de granos de chocho por iteración, haciendo una comparación del rendimiento en un sistema embebido. Cabe destacar que todo se centró en el Entrenamiento 2, elegido anteriormente por el análisis previo de métricas y curvas de aprendizaje.

##### 4.8.2.1. Pruebas en tiempo real utilizando computadora

En la Figura 79 se muestran las pruebas realizadas en tiempo real del sistema de clasificación utilizando la computadora como unidad de procesamiento. En la pantalla se observa la interfaz del modelo de visión artificial, identificando las muestras mediante recuadros de colores que indican la categoría asignada por el modelo de visión artificial.




Figura 79. Sistema de procesamiento computadora

Los resultados de la validación experimental de la modelo realizada en una computadora como primer sistema de procesamiento que se muestran en la Tabla 31, donde se observa los resultados de las pruebas realizadas en la categorización de chochos que han sido catalogados con anterioridad como buenos y malos. En las diez pruebas realizadas, se introdujeron 20 granos por clase y se registró en tiempo real cuántos fueron detectados correctamente y cuántos fueron mal clasificados por el sistema.

Tabla 31. Pruebas del modelo con computadora

Nº de pruebas	Buenos reales	Verdaderos positivos (TP)	Falsos negativos (FN)	Malos reales	Verdaderos negativos (TN)	Falsos positivos (FP)
1	20	20	0	20	19	1
2	20	20	0	20	18	2
3	20	19	1	20	18	2
4	20	20	0	20	18	2
1	20	19	1	20	17	3
6	20	19	1	20	19	1
7	20	19	1	20	19	1
8	20	20	0	20	17	3
9	20	19	1	20	20	1
10	20	19	1	20	19	1
<b>Total</b>	<b>200</b>	<b>194</b>	<b>6</b>	<b>200</b>	<b>184</b>	<b>17</b>

De la Tabla 31 se visualiza que el sistema se comporta de forma estable al detectar chochos buenos, acertando con 19 o 20 granos en la mayoría de pruebas, y solo con pocos falsos positivos. Lo mismo pasa con los granos malos, identifica bien la mayoría de los defectuosos, aunque en algunas pruebas hay falsos positivos aislados. Esto demuestra que funciona adecuadamente en condiciones reales, con errores moderados y bien controlados.

Para evaluar cuantitativamente su rendimiento, ahora usamos tres métricas clave en clasificación precisión, recall y F1-score. Estos parámetros permiten medir objetivamente qué tan bien reconoce chochos buenos y malos, y cómo equilibra aciertos con errores en tiempo real. A continuación, se describen las fórmulas matemáticas de cada métrica que estamos usando.

- **Recall:** El Recall se calcula con la siguiente ecuación ( 1):

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

Donde:

TP (Verdaderos Positivos) = Chochos buenos correctamente detectados como buenos.

FN (Falsos negativos) = Chochos buenos reales que fueron clasificados erróneamente como malos

- **Precisión:** La Precisión se calcula con la siguiente ecuación ( 2):

$$Precisión = \frac{TP}{TP + FP} \quad (2)$$

Donde:

TP (Verdaderos Positivos) = Chochos buenos correctamente detectados como buenos.

FP (Falsos Positivos) = Chochos malos que fueron clasificados erróneamente como buenos.

- **F1-score:** El F-score se calcula con la siguiente ecuación ( 3):

$$F1\_score = 2 \cdot \frac{Precisión \cdot Recall}{Precisión + Recall} \quad (3)$$

A partir de las fórmulas matemáticas presentadas para las métricas de evaluación, se calculó la precisión, el recall y el F1-score para cada una de las diez pruebas realizadas en la validación en tiempo real. Estas métricas nos permiten medir de forma concreta el desempeño del modelo:

qué tan bien detecta correctamente, su capacidad para recuperar todos los casos positivos y cómo equilibra ambos aspectos. En la Tabla 32 se muestran los valores obtenidos para cada entrenamiento.

Tabla 32. Métricas calculadas de las pruebas realizadas

<b>Nº de pruebas</b>	<b>Precisión</b>	<b>Recall</b>	<b>F1-score</b>
1	0.95	1.00	0.98
2	0.91	1.00	0.95
3	0.90	0.95	0.93
4	0.91	1.00	0.95
1	0.86	0.95	0.90
6	0.95	0.95	0.95
7	0.95	0.95	0.95
8	0.87	1.00	0.93
9	0.95	0.95	0.95
10	0.95	0.95	0.95

Para una mejor comprensión los resultados numéricos presentados en la Tabla 32 que muestra cómo se comportan la precisión, Recall y F1\_score durante las diez pruebas realizadas en la computadora como sistema de procesamiento. La Figura 80 deja claro que el modelo es muy estable en tiempo real, la precisión se mantiene entre 0.86 y 0.95, lo que significa pocos falsos positivos. El recall está entre 0.95 y 1.00 en casi todas las pruebas, demostrando que detecta muy bien los chochos buenos. Y el F1-score, que balancea todo, supera el 0.93 en la mayoría, llegando cerca de 0.98, confirmando un rendimiento sólido, consistente y confiable en la validación experimental.




Figura 80. Métricas de evaluación en tiempo real

Sumando todos los valores de las diez pruebas de validación en tiempo real en la computadora, calculamos las métricas globales usando las mismas fórmulas de antes. El modelo logra una precisión global de 0.92, lo que muestra una baja tasa de falsos positivos en la clasificación. El recall global de 0.97 demuestra una gran capacidad para detectar correctamente los chochos buenos. Y el F1-score global de 0.94 confirma un rendimiento equilibrado entre precisión y recuperación, probando que el modelo es confiable y consistente en condiciones, dichos resultados se muestran en la Tabla 33.

Tabla 33. Resultados globales de la ejecución del modelo

Parámetros	Total	Métricas Globales	Valor
TP	194	Precisión	0.92
FN	6		
TN	184	Recall	0.97
FP	17	F1-score	0.94

#### 4.8.2.2. Pruebas en tiempo real a través de la Raspberry Pi 5

En la Figura 81 se muestran las pruebas realizadas en tiempo real del sistema de clasificación utilizando la Raspberry Pi 5 como unidad de procesamiento. En la pantalla se observa la interfaz del modelo de visión artificial, identificando las muestras mediante recuadros de colores que indican la categoría asignada por el modelo de visión artificial.




Figura 81. Sistema de procesamiento Raspberry Pi 5

Los resultados de la validación experimental del modelo en la Raspberry Pi 5, como segundo sistema de procesamiento se muestran en la Tabla 34. Estas pruebas se hicieron con la banda transportadora en movimiento para ver cómo se comporta en condiciones reales. Al igual que con la computadora, corrimos diez pruebas, poniendo 20 granos por clase. Registramos los verdaderos positivos, falsos negativos, verdaderos negativos y falsos positivos de cada prueba, evaluando así el rendimiento del modelo en tiempo real.

Tabla 34. Pruebas del modelo con Raspberry

Nº de pruebas	Buenos reales	Verdaderos positivos (TP)	Falso negativos (FN)	Malos reales	Verdaderos negativos (TN)	Falsos positivos (FP)
1	20	15	5	20	15	5
2	20	13	7	20	12	8
3	20	17	3	20	10	10
4	20	16	4	20	14	6
1	20	17	3	20	15	5
6	20	14	6	20	15	5
7	20	15	5	20	16	4
8	20	13	7	20	17	3
9	20	14	6	20	16	4
10	20	15	5	20	14	6
<b>Total</b>	<b>200</b>	<b>149</b>	<b>51</b>	<b>200</b>	<b>144</b>	<b>56</b>

A partir de los resultados presentados en la Tabla 34, se ve cómo se comporta el modelo en las pruebas en tiempo real ejecutado desde la Raspberry Pi 5, clasificando chochos buenos y malos en condiciones reales donde se aprecia un desempeño ligeramente inferior en comparación con las pruebas realizadas en la computadora, evidenciado por una mayor presencia de errores de clasificación. Con el fin de evaluar cuantitativamente calculamos precisión, recall y F1-score con las fórmulas ya descritas, dichos análisis se presentan en la Tabla 35, por cada prueba realizada

Tabla 35. Métricas calculadas de las pruebas realizadas

<b>Nº de pruebas</b>	<b>Precisión</b>	<b>Recall</b>	<b>F1-score</b>
1	0.75	0.75	0.75
2	0.62	0.65	0.63
3	0.63	0.85	0.72
4	0.73	0.80	0.76
1	0.77	0.85	0.81
6	0.74	0.70	0.72
7	0.79	0.75	0.77
8	0.81	0.65	0.72
9	0.78	0.70	0.74
10	0.71	0.75	0.73

De la Tabla 35, se puede observar que las pruebas en tiempo real con la Raspberry Pi 5, la precisión del modelo varía entre 0.62 y 0.81 aproximadamente, lo que muestra algunos falsos positivos en ciertas pruebas. El recall está entre 0.65 y 0.85, indicando que detecta bien la mayoría de chochos buenos, aunque hay pérdidas moderadas por falsos negativos. Por otro lado, el F1-score se mantiene entre 0.63 y 0.81, un rendimiento aceptable pero menor que en la computadora. Para verlo más claro, la Figura 82 se muestra el diagrama de barras con la variabilidad de precisión, recall y F1-score en las diez pruebas, confirmando que el modelo presenta variaciones bajas en comparación con el procesamiento en una computadora.




Figura 82. Métricas de evaluación en tiempo real

Como se muestra en la Figura 82, las métricas de precisión, recall y F1-score de las pruebas en la Raspberry Pi 5 salen más bajas y con mayor variabilidad que en la computadora. Esto muestra un rendimiento menos estable en el entorno embebido, algo lógico por las limitaciones del hardware. Para tener una conclusión más clara, calculamos las métricas globales sumando los valores totales de las diez pruebas presentadas en la Tabla 34 y aplicando las fórmulas ya vistas. Esos resultados globales se pueden observar en la siguiente Tabla 36, mostrando una visión completa del desempeño del modelo en la Raspberry Pi 5.

Tabla 36. Resultados globales de la ejecución del modelo

Parámetros	Total	Métricas Globales	Valor
TP	149	Métricas Globales	Valor
FN	51		
TN	144		
FP	56		
		Precisión	0.73
		Recall	0.75
		F1-score	0.74

Del cálculo global de las métricas, salieron una precisión de 0.73, recall de 0.75 y F1-score de 0.74, valores que muestran un rendimiento bajo del modelo en la Raspberry Pi 5. Esto confirma que presenta una clasificación deficiente en comparación de la computadora, por las limitaciones de procesamiento del sistema embebido que afectan su desempeño en tiempo real.

### 4.8.3. Selección final del mejor sistema de procesamiento

A partir del análisis de las métricas globales que se presenta en la Tabla 37, se selecciona la computadora como el sistema de procesamiento más adecuado para el modelo propuesto. La precisión (0.92) indica que el sistema comete una baja cantidad de errores al clasificar chochos malos como buenos, lo que es fundamental para evitar clasificaciones incorrectas. El recall (0.97) evidencia una alta capacidad del modelo para detectar correctamente la mayoría de los chochos buenos, reduciendo la pérdida de granos válidos.

Tabla 37. Puntuación del mejor sistema de procesamiento

<b>Métricas Globales</b>	<b>Computadora</b>	<b>Raspberry</b>
Presicion	0.92	0.73
Recall	0.97	0.75
F1-score	0.94	0.74

El F1-score (0.94) confirma un equilibrio favorable entre precisión y recall, reflejando un comportamiento más estable del modelo frente a la Raspberry Pi 5. Si bien el sistema aún presenta ciertos errores propios de una fase experimental, estos resultados demuestran que la computadora ofrece mejores condiciones de procesamiento y confiabilidad. En la Figura 42 se muestra el esquema del sistema basado en computadora, correspondiente al modelo desarrollado y evaluado en esta investigación.

### 4.8.4. Impactos y limitaciones del modelo de visión artificial

Permite cambiar un proceso de clasificación que se hace a mano, el cual puede variar dependiendo de la persona, por uno automatizado que se basa en cosas que se pueden medir y ver, como el color, la forma y los defectos en los granos de chocho. Esto ayuda a que la evaluación de la calidad sea más consistente.

Se puede demostrar que los modelos de visión artificial son técnicamente viables para clasificar productos agroindustriales andinos. Esto muestra que esta tecnología puede funcionar bien en diferentes granos cuando se usa en entornos controlados.

Evidencia que el uso de un entorno controlado de iluminación, combinado con una cámara de alta resolución, influye de manera directa en la calidad de las imágenes capturadas y, en consecuencia, en el desempeño del modelo de visión artificial durante las etapas de procesamiento y clasificación.

El modelo de visión artificial fue validado únicamente en un entorno controlado de iluminación y captura de imágenes, por lo que su desempeño podría variar al ser expuesto a condiciones reales de campo, donde factores como cambios de iluminación y variaciones en el fondo de los granos pueden afectar la precisión de la clasificación.

La Raspberry Pi 5 tiene limitaciones en cuanto a su capacidad de procesamiento. Esto significa que el tamaño del modelo y la velocidad de procesamiento deben ser cuidadosamente optimizados en el código y los parámetros del modelo ajustando configuraciones para lograr un desempeño poco estable en tiempo real. Esto es importante debido a las limitaciones del hardware de la Raspberry Pi 5.

La velocidad de la banda transportadora es importante. Debe ajustarse con cuidado. Si la velocidad es muy alta, las capturas pueden ser incompletas o desenfocadas. Por otro lado, si la velocidad es muy baja, el sistema no es eficiente y el proceso de clasificación se ve afectado.

El prototipo presenta una capacidad limitada en términos del volumen de granos clasificados por unidad de tiempo, debido a su carácter experimental y a las restricciones computacionales del sistema, lo que impide su aplicación directa en el proceso de producciones industriales sin modificaciones adicionales.

## **5. CONCLUSIONES**

El modelo de visión artificial desarrollado y evaluado en un entorno controlado demostró ser una base funcional que busca ser escalable para futuros sistemas de clasificación automática logrando un Recall máximo de 0.97 en el sistema de procesamiento computacional, validando la hipótesis planteada sobre la viabilidad del uso de visión artificial en la clasificación del chocho (*Lupinus mutabilis*).

El análisis del proceso manual de clasificación del chocho permitió identificar limitaciones operativas significativas, tales como la fatiga visual del operario y errores de clasificación, lo que evidencia la necesidad de implementar soluciones tecnológicas orientadas en la visión artificial para la automatización agroindustrial.

El modelo de visión artificial basado en el algoritmo YOLOv11 permitió clasificar la calidad del chocho (*Lupinus Mutabilis*) a partir de imágenes recolectadas en un entorno controlado, las cuales fueron etiquetadas mediante la herramienta Make Sence para su posterior entrenamiento del modelo, logrando identificar automáticamente los granos en buen estado y defectuosos de

esta manera evidenciando la factibilidad del modelo de visión artificial como una opción de apoyo para el proceso.

A partir de la comparación entre dos alternativas de sistemas de procesamiento, se determinó que la opción A es más factible para el procesamiento de datos en tiempo real, al alcanzar un F1-score máximo de 0.94, lo que refleja un mejor desempeño en la detección y clasificación del chocho, en diferencia con la Raspberry Pi 5, que obtuvo un F1-score máximo de 0.74, considerado insuficiente para los objetivos de esta investigación.

Se concluyó que el uso de un conjunto reducido de 250 imágenes, combinado con un elevado número de 150 épocas de entrenamiento puede provocar sobre entrenamiento del modelo, lo que evidencia una insuficiente recopilación de datos. Esta situación resulta no factible para un sistema de clasificación basado en visión artificial, ya que limita su capacidad de reconocimiento.

## **6. RECOMENDACIONES**

Se recomienda ampliar el dataset de entrenamiento incorporando una mayor cantidad de imágenes, superando las 250 capturas utilizadas, considerando entre 10 y 15 etiquetas de granos por imagen. Además, se podría incluir una mayor variabilidad en condiciones reales de producción, como cambios de iluminación, fondo, humedad, suciedad y características del grano de *Lupinus mutabilis*, con el fin de mejorar la robustez y capacidad de generalización del modelo permitiendo ajustar adecuadamente el número de épocas de entrenamiento para evitar problemas de sobreentrenamiento.

Se recomienda implementar una cámara de aislamiento lumínico que permita mantener condiciones de iluminación controladas mediante una fuente de luz LED uniforme, con el objetivo de reducir la variabilidad de la luz ambiental y mejorar la estabilidad del sistema en distintos entornos de aplicación, como en el ambiente natural al tener diferentes tipos de iluminación y plantas de procesamiento.

Se recomienda realizar pruebas de validación del sistema de clasificación en entornos reales de operación, fuera de las condiciones controladas para identificar posibles limitaciones relacionadas con la acumulación de polvo en el lente de la cámara o fallas en los mecanismos de actuación. Permitiendo explorar la integración del modelo de visión artificial con hardware industrial, como bandas transportadoras, sistemas de expulsión automática, cámaras y sensores

complementarios, que permitan avanzar hacia el desarrollo de un sistema de clasificación automático.

Se sugiere emplear una tolva de alimentación que facilite una mejor organización y control de los granos al entrar en la banda transportadora ayudando a minimizar la acumulación y el desorden de los granos, promoviendo una distribución equilibrada durante el movimiento y mejorando las condiciones para la captura de imágenes. De este modo, se podría aumentar la estabilidad del flujo de producto, optimizar el rendimiento del sistema de visión artificial y reducir los posibles errores de clasificación relacionados con una alimentación irregular del grano.

## 7. REFERENCIAS

- [1] D. Rodríguez-Ortega, J. L. Zambrano, S. Pereira-Lorenzo, A. Torres, and Á. Murillo, “Lupinus mutabilis Breeding in the Andes of Ecuador, Peru, and Bolivia: A Review,” *Agronomy*, vol. 14, no. 1, p. 94, Dec. 2023, doi: 10.3390/agronomy14010094.
- [2] J. Díaz-Álvarez, F. A. Galea-Gragera, F. C. de la O, P. A. Salguero-López, and F. L. Cid, “A comparative ML approach to classify Lupinus species using VIS-NIR spectral data from entire seeds and various data transformation techniques and resampling methods,” Jul. 30, 2025. doi: 10.21203/rs.3.rs-7240896/v1.
- [3] A. A. M. S. Ibrahim and J. R. Tapamo, “Transfer learning-based approach using new convolutional neural network classifier for steel surface defects classification,” *Sci. Afr.*, vol. 23, p. e02066, Mar. 2024, doi: 10.1016/j.sciaf.2024.e02066.
- [4] J. Díaz-Álvarez, F. A. Galea-Gragera, F. C. de la O, P. A. Salguero-López, and F. L. Cid, “A comparative ML approach to classify Lupinus species using VIS-NIR spectral data from entire seeds and various data transformation techniques and resampling methods,” Jul. 30, 2025. doi: 10.21203/rs.3.rs-7240896/v1.
- [5] J. Chen, H. Fu, C. Lin, X. Liu, L. Wang, and Y. Lin, “YOLOPears: a novel benchmark of YOLO object detectors for multi-class pear surface defect detection in quality grading systems,” *Front. Plant Sci.*, vol. 16, Feb. 2025, doi: 10.3389/fpls.2025.1483824.
- [6] P. Freire Diaz, X. López-Mendoza, B. Casignia, A. S. Cisneros Barahona, and M. I. Uvidia Fassler, “Classification of Andean Chocho (*Lupinus Mutabilis* Sweet) by Shape and Color Using Artificial Vision,” 2021, pp. 64–78. doi: 10.1007/978-3-030-68080-0\_5.

- [7] W. Wang and Q. Li, “Smart farming revolution: Leveraging machine learning for sustainable agriculture,” *J. Clean. Prod.*, vol. 527, p. 146434, Oct. 2025, doi: 10.1016/j.jclepro.2025.146434.
- [8] A. Kaur, “Smart Farming: CNN-Based Rice Variety Classification for Global Impact,” in *2025 3rd International Conference on Advancement in Computation & Computer Technologies (InCACCT)*, IEEE, Apr. 2025, pp. 231–236. doi: 10.1109/InCACCT65424.2025.11011395.
- [9] L. Lei, Q. Yang, L. Yang, T. Shen, R. Wang, and C. Fu, “Deep learning implementation of image segmentation in agricultural applications: a comprehensive review,” *Artif. Intell. Rev.*, vol. 57, no. 6, p. 149, May 2024, doi: 10.1007/s10462-024-10775-6.
- [10] Y. Zhu, S. Zhang, S. Tang, and Q. Gao, “Research Progress and Applications of Artificial Intelligence in Agricultural Equipment,” *Agriculture*, vol. 15, no. 15, p. 1703, Aug. 2025, doi: 10.3390/agriculture15151703.
- [11] X. Chen, “The role of modern agricultural technologies in improving agricultural productivity and land use efficiency,” *Front. Plant Sci.*, vol. 16, Sep. 2025, doi: 10.3389/fpls.2025.1675657.
- [12] H. C. A. D. C. Miguel Botto-Tobar, *Artificial Intelligence, Computer and Software Engineering Advances*, vol. 1326. Cham: Springer International Publishing, 2021. doi: 10.1007/978-3-030-68080-0.
- [13] A. Gulisano *et al.*, “Diversity and Agronomic Performance of *Lupinus mutabilis* Germplasm in European and Andean Environments,” *Front. Plant Sci.*, vol. 13, Jun. 2022, doi: 10.3389/fpls.2022.903661.
- [14] M. Hidalgo, C. Ramos, and G. Zolla, “Analysis of lncRNAs in *Lupinus mutabilis* (Tarwi) and Their Potential Role in Drought Response,” *Noncoding RNA*, vol. 9, no. 5, p. 48, Aug. 2023, doi: 10.3390/ncrna9050048.
- [15] S. Promboonruang and T. Boonrod, “Deep transfer learning CNN based for classification quality of organic vegetables,” *International Journal of ADVANCED AND APPLIED SCIENCES*, vol. 10, no. 12, pp. 203–210, Dec. 2023, doi: 10.21833/ijaas.2023.12.022.
- [16] M. Revilla Bueloth, M. A. Morante Dávila, W. Chavez Espinoza, and A. M. Quijano Quilo, “Alfarería como expresión cultural en el distrito de Huancas, región Amazonas,”

*ACADEMO Revista de Investigación en Ciencias Sociales y Humanidades*, vol. 11, no. 2, pp. 125–135, May 2024, doi: 10.30545/academo.2024.may-ago.3.

- [17] P. Freire Diaz, X. López-Mendoza, B. Casignia, A. S. Cisneros Barahona, and M. I. Uvidia Fassler, “Classification of Andean Chocho (*Lupinus Mutabilis* Sweet) by Shape and Color Using Artificial Vision,” 2021, pp. 64–78. doi: 10.1007/978-3-030-68080-0\_5.
- [18] P. Freire Diaz, X. López-Mendoza, B. Casignia, A. S. Cisneros Barahona, and M. I. Uvidia Fassler, “Classification of Andean Chocho (*Lupinus Mutabilis* Sweet) by Shape and Color Using Artificial Vision,” 2021, pp. 64–78. doi: 10.1007/978-3-030-68080-0\_5.
- [19] Ana Maribel Manotoa Bombón, “Efecto del uso de harinas de cultivos andinos de papa china (*Colocasia esculenta*) y chocho (*Lupinus mutabilis*) en la producción de yogur entero ,” UNIVERSIDAD TÉCNICA DE AMBATO, Ambato, 2023.
- [20] Katherine Mishell Torres Romero, “Caracterización fisicoquímica de variedades de chochos *lupinus mutabilis* en sweet por los métodos tradicionales y visión artificial,” UDLA, 2021.
- [21] F. J. Guerrero de la Torre, “Caracterización de germinado de chocho (*Lupinus mutabilis*) ,” UNIVERSIDAD NACIONAL DE CHIMBORAZO , Riobamba, 2024.
- [22] B. C. Chiza Maldonado, “ Estudio de la producción y comercialización del chocho (*lupinus mutabilis* sweet) en la provincia de Imbabura,” UTN, 2017.
- [23] L. A. Luisa Jerés, “Efecto del uso de harinas de cultivos andinos papa china (*Colocasia esculenta*) y chocho (*Lupinus mutabilis*) en la producción de yogur desnatado,” Universidad Técnica de Ambato, Ambato, 2023.
- [24] Z. Khan, S. Rawat, S. Kumar, and A. Sharma, “Using computer vision for automated grading and sorting of fruits and vegetables,” *International Journal of Agriculture and Food Science*, vol. 7, no. 8, pp. 1056–1065, Aug. 2025, doi: 10.33545/2664844X.2025.v7.i8j.674.
- [25] Y. He *et al.*, “Rapid appearance quality of rice based on machine vision and convolutional neural network research on automatic detection system,” *Front. Plant Sci.*, vol. 14, Aug. 2023, doi: 10.3389/fpls.2023.1190591.

- [26] J. Ávila, S. Camacho, S. G. Galeas Hurtado, L. Huilca, P. Proaño, and W. Monar, “Recuperación del Aluminio de los Empaques Tipo Blíster por Medios Termomecánicos,” *Revista Politécnica*, vol. 51, no. 1, pp. 67–76, Feb. 2023, doi: 10.33333/rp.vol51n1.06.
- [27] J. E. Soto Sogamoso, J. E. Pinto Lopera, and E. E. Millán Rojas, “Micorrizas arbusculares y las técnicas de visión artificial para su identificación,” *TecnoLógicas*, vol. 25, no. 54, p. e2348, Aug. 2022, doi: 10.22430/22565337.2348.
- [28] O. Shobayo and R. Saatchi, “Developments in Deep Learning Artificial Neural Network Techniques for Medical Image Analysis and Interpretation,” *Diagnostics*, vol. 15, no. 9, p. 1072, Apr. 2025, doi: 10.3390/diagnostics15091072.
- [29] L. Alzubaidi *et al.*, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,” *J. Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [30] A. Marin, V. C. Chiaradia, M. Dobre, A. Brateanu, O. C. Baltatu, and L. A. Campos, “High-frequency chest wall oscillation devices: An umbrella review and bibliometric analysis,” *Comput. Biol. Med.*, vol. 182, p. 109135, Nov. 2024, doi: 10.1016/j.combiomed.2024.109135.
- [31] J. K. S. dos Santos, L. S. Siqueira, E. M. B. Faria, K. A. Bispo, G. J. F. da Silva, and M. S. Soares, “Methodological Advances in Expert Systems with Artificial Intelligence,” in *Anais do XXI Simpósio Brasileiro de Sistemas de Informação (SBSI 2025)*, Sociedade Brasileira de Computação, May 2025, pp. 703–712. doi: 10.5753/sbsi.2025.246618.
- [32] H. Zhao *et al.*, “Intelligent indoor metasurface robotics,” *Natl. Sci. Rev.*, vol. 10, no. 8, Jun. 2023, doi: 10.1093/nsr/nwac266.
- [33] R. Sh. Othman and I. M. Ibrahim, “Deep Learning for Natural Language Processing: A Review of Models and Applications,” *International Journal of Scientific World*, vol. 11, no. 2, pp. 71–78, Aug. 2025, doi: 10.14419/t1xnaq87.
- [34] X. Wang and W. Zhu, “Advances in neural architecture search,” *Natl. Sci. Rev.*, vol. 11, no. 8, Jul. 2024, doi: 10.1093/nsr/nwae282.
- [35] A. K. , R.-M. G. F. , Y.-G. D. A. , & S.-L. M. N. Guerrero-Solís, “El impacto de la inteligencia artificial en la producción científica: The impact of artificial intelligence on scientific production,” p. 22, Apr. 2025.

- [36] J. L. Uc Castillo, A. E. Marín Celestino, D. A. Martínez Cruz, J. Tuxpan Vargas, J. A. Ramos Leal, and J. Morán Ramírez, “A systematic review of Machine Learning and Deep Learning approaches in Mexico: challenges and opportunities,” *Front. Artif. Intell.*, vol. 7, Jan. 2025, doi: 10.3389/frai.2024.1479855.
- [37] C. Gajiwala, “The Rise of Deep Learning and Neural Networks: Revolutionizing Artificial Intelligence,” *European Journal of Computer Science and Information Technology*, vol. 13, no. 17, pp. 88–98, Apr. 2025, doi: 10.37745/ejcsit.2013/vol13n178898.
- [38] A. Khan, A. Laghari, and S. Awan, “Machine Learning in Computer Vision: A Review,” *ICST Transactions on Scalable Information Systems*, p. 169418, Jul. 2018, doi: 10.4108/eai.21-4-2021.169418.
- [39] C. Collins, D. Dennehy, K. Conboy, and P. Mikalef, “Artificial intelligence in information systems research: A systematic literature review and research agenda,” *Int. J. Inf. Manage.*, vol. 60, p. 102383, Oct. 2021, doi: 10.1016/j.ijinfomgt.2021.102383.
- [40] S. , L. C. M. , G. G. E. , D. P. G. , M.-P. F. and D. B. Samoili, “AI WATCH. Defining Artificial Intelligence,” vol. 1, Feb. 2020.
- [41] Y. Xu *et al.*, “Artificial intelligence: A powerful paradigm for scientific research,” *The Innovation*, vol. 2, no. 4, p. 100179, Nov. 2021, doi: 10.1016/j.xinn.2021.100179.
- [42] J. C. Lopes and R. P. Lopes, “Computer Vision in Augmented, Virtual, Mixed and Extended Reality environments—A bibliometric review,” *Visual Informatics*, vol. 8, no. 4, pp. 13–22, Dec. 2024, doi: 10.1016/j.visinf.2024.11.002.
- [43] Y. Xu, T. M. Khan, Y. Song, and E. Meijering, “Edge deep learning in computer vision and medical diagnostics: a comprehensive survey,” *Artif. Intell. Rev.*, vol. 58, no. 3, p. 93, Jan. 2025, doi: 10.1007/s10462-024-11033-5.
- [44] X. Zhang, “Current Research and Applications of Combining Computer Vision (CV) and Machine Learning (ML) at Home and Abroad CiteSpace-based Integration of CNKI and Google Scholar’s Public Research Results for 2019-2024,” 2024, pp. 57–63. doi: 10.2991/978-94-6463-504-1\_7.
- [45] R. Nosrati, N. Emaminejad, S. Ganapathi, S. Kamineni, Y. Sun, and S. Sarraf, “Advancing industrial inspection with an automated computer vision solution for

- orthopedic surgical tray inspection,” *Sci. Rep.*, vol. 15, no. 1, p. 7867, Mar. 2025, doi: 10.1038/s41598-025-88974-6.
- [46] C. Angulo Mendoza and L. Morales Escobar, “Eficiencia de la visión artificial con IA en clasificación de plásticos y otros frente a métodos tradicionales,” *Revista Social Fronteriza*, vol. 5, no. 3, May 2025, doi: 10.59814/resofro.2025.5(3)713.
- [47] M. A. De la Cruz-Rocca, W. Muñoz-Robles, and M. A. Trinidad-Malpartida, “Análisis de la aplicación de redes neuronales convolucionales en el área de la visión artificial,” *Investigación Valdizana*, vol. 18, no. 1, p. e2105, Mar. 2024, doi: 10.33554/riv.18.1.2105.
- [48] S. Ghazal, A. Munir, and W. S. Qureshi, “Computer vision in smart agriculture and precision farming: Techniques and applications,” *Artificial Intelligence in Agriculture*, vol. 13, pp. 64–83, Sep. 2024, doi: 10.1016/j.aiia.2024.06.004.
- [49] N. Lee, “Development of AI ethics guidelines model based on AI life cycle,” *AI and Ethics*, vol. 6, no. 1, p. 9, Feb. 2026, doi: 10.1007/s43681-025-00851-0.
- [50] L. W. O. C. Italo Paul Yaranga Vite, “Integración de la inteligencia artificial con big data para la toma de decisiones en las empresas: un estudio bibliométrico,” p. 10, Jan. 2025.
- [51] F. Pittaluga, S. J. Koppal, S. B. Kang, and S. N. Sinha, “Revealing Scenes by Inverting Structure From Motion Reconstructions,” in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2019, pp. 145–154. doi: 10.1109/CVPR.2019.00023.
- [52] B. Arad, P. Kurtser, E. Barnea, B. Harel, Y. Edan, and O. Ben-Shahar, “Controlled Lighting and Illumination-Independent Target Detection for Real-Time Cost-Efficient Applications. The Case Study of Sweet Pepper Robotic Harvesting,” *Sensors*, vol. 19, no. 6, p. 1390, Mar. 2019, doi: 10.3390/s19061390.
- [53] R. Ruiz-Gonzalez, T. S. Stombaugh, V. Martínez-Martínez, and J. Gomez-Gil, “An acoustic method for flow rate estimation in agricultural sprayer nozzles,” *Comput. Electron. Agric.*, vol. 141, pp. 255–266, Sep. 2017, doi: 10.1016/j.compag.2017.08.003.
- [54] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollar, “Focal Loss for Dense Object Detection,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 42, no. 2, pp. 318–327, Feb. 2020, doi: 10.1109/TPAMI.2018.2858826.

- [55] A. East *et al.*, “Optimizing image capture for computer vision-powered taxonomic identification and trait recognition of biodiversity specimens,” *Methods Ecol. Evol.*, vol. 16, no. 10, pp. 2260–2275, Oct. 2025, doi: 10.1111/2041-210X.70140.
- [56] S. Dai *et al.*, “Electrically programmable organic in-display neuromorphic computing,” *Natl. Sci. Rev.*, vol. 12, no. 8, Jul. 2025, doi: 10.1093/nsr/nwaf224.
- [57] E. M. Nowara, D. McDuff, and A. Veeraraghavan, “The Benefit of Distraction: Denoising Camera-Based Physiological Measurements using Inverse Attention,” in *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, IEEE, Oct. 2021, pp. 4935–4944. doi: 10.1109/ICCV48922.2021.00491.
- [58] N. Ahmad, S. Singh, M. F. AlAjmi, A. Hussain, and K. Raza, “CropGCNN: color space-based crop disease classification using group convolutional neural network,” *PeerJ Comput. Sci.*, vol. 10, p. e2136, Jul. 2024, doi: 10.7717/peerj-cs.2136.
- [59] S. Wang, J. Cui, F. Li, and L. Wang, “Image Sampling Based on Dominant Color Component for Computer Vision,” *Electronics (Basel)*, vol. 12, no. 15, p. 3360, Aug. 2023, doi: 10.3390/electronics12153360.
- [60] Z. Zhang *et al.*, “Hybrid-gate MoS<sub>2</sub> 2T0C DRAM for low-power multi-bit storage with high linearity,” *Natl. Sci. Rev.*, Dec. 2025, doi: 10.1093/nsr/nwaf555.
- [61] Z. Wu, H. Zhang, and C. Fang, “Research on machine vision online monitoring system for egg production and quality in cage environment,” *Poult. Sci.*, vol. 104, no. 1, p. 104552, Jan. 2025, doi: 10.1016/j.psj.2024.104552.
- [62] Y. Gong, G. Liu, Y. Xue, R. Li, and L. Meng, “A survey on dataset quality in machine learning,” *Inf. Softw. Technol.*, vol. 162, p. 107268, Oct. 2023, doi: 10.1016/j.infsof.2023.107268.
- [63] B. Sistaninejhad, H. Rasi, and P. Nayeri, “A Review Paper about Deep Learning for Medical Image Analysis,” *Comput. Math. Methods Med.*, vol. 2023, no. 1, Jan. 2023, doi: 10.1155/2023/7091301.
- [64] M. Salvi, U. R. Acharya, F. Molinari, and K. M. Meiburger, “The impact of pre- and post-image processing techniques on deep learning frameworks: A comprehensive review for digital pathology image analysis,” *Comput. Biol. Med.*, vol. 128, p. 104129, Jan. 2021, doi: 10.1016/j.combiomed.2020.104129.

- [65] B. Sistaninejhad, H. Rasi, and P. Nayeri, "A Review Paper about Deep Learning for Medical Image Analysis," *Comput. Math. Methods Med.*, vol. 2023, no. 1, Jan. 2023, doi: 10.1155/2023/7091301.
- [66] J. Kaur and W. Singh, "Tools, techniques, datasets and application areas for object detection in an image: a review," *Multimed. Tools Appl.*, vol. 81, no. 27, pp. 38297–38351, Nov. 2022, doi: 10.1007/s11042-022-13153-y.
- [67] C. Sager, C. Janiesch, and P. Zschech, "A survey of image labelling for computer vision applications," *Journal of Business Analytics*, vol. 4, no. 2, pp. 91–110, Jul. 2021, doi: 10.1080/2573234X.2021.1908861.
- [68] Y. Cui, W. Ren, X. Cao, and A. Knoll, "Focal Network for Image Restoration," in *2023 IEEE/CVF International Conference on Computer Vision (ICCV)*, IEEE, Oct. 2023, pp. 12955–12965. doi: 10.1109/ICCV51070.2023.01195.
- [69] Q. Yu, H. H. Cheng, W. W. Cheng, and X. Zhou, "Ch OpenCV for interactive open architecture computer vision," *Advances in Engineering Software*, vol. 35, no. 8–9, pp. 527–536, Aug. 2004, doi: 10.1016/j.advengsoft.2004.05.003.
- [70] S. Sivkov *et al.*, "The algorithm development for operation of a computer vision system via the OpenCV library," *Procedia Comput. Sci.*, vol. 169, pp. 662–667, 2020, doi: 10.1016/j.procs.2020.02.193.
- [71] S. Sivkov *et al.*, "The algorithm development for operation of a computer vision system via the OpenCV library," *Procedia Comput. Sci.*, vol. 169, pp. 662–667, 2020, doi: 10.1016/j.procs.2020.02.193.
- [72] H. Kimm, I. Paik, and H. Kimm, "Performance Comparision of TPU, GPU, CPU on Google Colaboratory Over Distributed Deep Learning," in *2021 IEEE 14th International Symposium on Embedded Multicore/Many-core Systems-on-Chip (MCSoc)*, IEEE, Dec. 2021, pp. 312–319. doi: 10.1109/MCSoc51149.2021.00053.
- [73] A. Ahmad, D. Saraswat, and A. El Gamal, "A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools," *Smart Agricultural Technology*, vol. 3, p. 100083, Feb. 2023, doi: 10.1016/j.atech.2022.100083.
- [74] A. Ahmad, D. Saraswat, and A. El Gamal, "A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools,"

- Smart Agricultural Technology*, vol. 3, p. 100083, Feb. 2023, doi: 10.1016/j.atech.2022.100083.
- [75] Z. Cai, K. Zhou, and Z. Liao, “A Systematic Review of YOLO-Based Object Detection in Medical Imaging: Advances, Challenges, and Future Directions,” *Computers, Materials & Continua*, vol. 85, no. 2, pp. 2255–2303, 2025, doi: 10.32604/cmc.2025.067994.
- [76] A. A. Murat and M. S. Kiran, “A comprehensive review on YOLO versions for object detection,” *Engineering Science and Technology, an International Journal*, vol. 70, p. 102161, Oct. 2025, doi: 10.1016/j.jestch.2025.102161.
- [77] Y. Miao, W. Meng, and X. Zhou, “SerpensGate-YOLOv8: an enhanced YOLOv8 model for accurate plant disease detection,” *Front. Plant Sci.*, vol. 15, Jan. 2025, doi: 10.3389/fpls.2024.1514832.
- [78] M. Dalal and P. Mittal, “A Systematic Review of Deep Learning-Based Object Detection in Agriculture: Methods, Challenges, and Future Directions,” *Computers, Materials & Continua*, vol. 84, no. 1, pp. 57–91, 2025, doi: 10.32604/cmc.2025.066056.
- [79] Z. F. Elsharkawy, “Enhanced YOLOv11 framework for high precision defect detection in printed circuit boards,” *Sci. Rep.*, vol. 15, no. 1, p. 42550, Nov. 2025, doi: 10.1038/s41598-025-27415-w.
- [80] K. Kanna S, K. Ramalingam, P. P, J. R, and P. P.C., “YOLO deep learning algorithm for object detection in agriculture: a review,” *Journal of Agricultural Engineering*, vol. 55, no. 4, Dec. 2024, doi: 10.4081/jae.2024.1641.
- [81] T. Zhou and L. Wei, “YOLO-DP: A detection model of fifteen common rice diseases and pests,” *Sci. Rep.*, vol. 15, no. 1, p. 35968, Oct. 2025, doi: 10.1038/s41598-025-19310-1.
- [82] S. Asutkar and S. Tallur, “Deep transfer learning strategy for efficient domain generalisation in machine fault diagnosis,” *Sci. Rep.*, vol. 13, no. 1, p. 6607, Apr. 2023, doi: 10.1038/s41598-023-33887-5.
- [83] Z. Al Sahili and M. Awad, “The power of transfer learning in agricultural applications: AgriNet,” *Front. Plant Sci.*, vol. 13, Dec. 2022, doi: 10.3389/fpls.2022.992700.

- [84] S. Ahmed Medjahed, “A Comparative Study of Feature Extraction Methods in Images Classification,” *International Journal of Image, Graphics and Signal Processing*, vol. 7, no. 3, pp. 16–23, Feb. 2015, doi: 10.5815/ijigsp.2015.03.03.
- [85] X. Zhao, F. He, and K. Li, “Introducing an efficient method for feature extraction in image retrieval systems,” *Sci. Rep.*, vol. 15, no. 1, p. 43664, Dec. 2025, doi: 10.1038/s41598-025-24118-0.
- [86] H. Suresh and J. Guttag, “A Framework for Understanding Sources of Harm throughout the Machine Learning Life Cycle,” in *Equity and Access in Algorithms, Mechanisms, and Optimization*, New York, NY, USA: ACM, Oct. 2021, pp. 1–9. doi: 10.1145/3465416.3483305.
- [87] Y. G. F. T. S. L. W. Y. Z. W. J. W. H. S. H. P. S. L. Changjian Chen, “A Unified Interactive Model Evaluation for Classification, Object Detection, and Instance Segmentation in Computer Vision,” vol. 1, Aug. 2023.
- [88] C. Miller, T. Portlock, D. M. Nyaga, and J. M. O’Sullivan, “A review of model evaluation metrics for machine learning in genetics and genomics,” *Frontiers in Bioinformatics*, vol. 4, Sep. 2024, doi: 10.3389/fbinf.2024.1457619.
- [89] J. H. Cabot and E. G. Ross, “Evaluating prediction model performance,” *Surgery*, vol. 174, no. 3, pp. 723–726, Sep. 2023, doi: 10.1016/j.surg.2023.05.023.
- [90] B. S. X. Z. Z. C. J. Y. Penghao Liang, “Automating the Training and Deployment of Models in MLOps by Integrating Systems with Machine Learning,” May 2024.
- [91] D. G. Lema, R. Usamentiaga, and D. F. García, “Quantitative comparison and performance evaluation of deep learning-based object detection models on edge computing devices,” *Integration*, vol. 95, p. 102127, Mar. 2024, doi: 10.1016/j.vlsi.2023.102127.
- [92] C. Wang, V. Mariani, F. Poitevin, M. Avaylon, and J. Thayer, “End-to-end deep learning pipeline for real-time Bragg peak segmentation: from training to large-scale deployment,” *Frontiers in High Performance Computing*, vol. 3, Mar. 2025, doi: 10.3389/fhpcp.2025.1536471.
- [93] H. Naveed, S. Barnett, C. Arora, J. Grundy, H. Khalajzadeh, and O. Haggag, “Monitoring Machine Learning Systems: A Multivocal Literature Review,” *ACM Transactions on Software Engineering and Methodology*, vol. XX, Sep. 2025,

- [94] Manish Tripathi and Dr. Rajneesh Kumar Singh, “MLOps for AI: Tracking, Synthesizing, and Monitoring Models,” *International Journal for Research Publication and Seminar*, vol. 16, no. 2, pp. 149–162, May 2025, doi: 10.36676/jrps.v16.i2.261.
- [95] A. Balasubramanian, “End-to-end model lifecycle management: An MLOPS framework for drift detection, root cause analysis, and continuous retraining,” *International Journal of Multidisciplinary Research and Growth Evaluation*, vol. 1, no. 1, pp. 92–102, 2020, doi: 10.54660/IJMRGE.2020.1.1-92-102.
- [96] N. Farah *et al.*, “EVALUATION METRICS OF MACHINE LEARNING OPERATIONS (MLOPS),” *J. Theor. Appl. Inf. Technol.*, vol. 15, no. 23, 2025, [Online]. Available: [www.jatit.org](http://www.jatit.org)
- [97] L. M. M. Parraga and C. A. S. Villafuerte, “Reconocimiento de enfermedades en hojas de maíz utilizando modelos de aprendizaje profundo: Corn leaf disease recognition using deep learning models,” *Investigación, Tecnología e Innovación*, vol. 17, no. 24, pp. 81–93, Nov. 2025, doi: 10.53591/ITI.V17I24.2642.
- [98] C. De Electrónica and Y. Automatización, “Diseño e implementación de un sistema de identificación de componentes eléctricos en módulos didácticos mediante visión artificial,” 2024.
- [99] R. A. León León, H. Y. Aguirre Vasquez, and I. Cruz Galdos, “Development of an Artificial Vision System using Yolov8 for the Detection of the Fungus *Sphaceloma Perseae* in Avocado,” in *Memorias de la Conferencia Iberoamericana de Complejidad, Informatica y Cibernetica, CICIC*, International Institute of Informatics and Systemics, IIIS, 2025, pp. 357–363. doi: 10.54808/CICIC2025.01.357.
- [100] M. Zribi Università degli Studi Roma La Sapienza, V. Gian Domenico Romagnosi, and A. Rome Francesca Pitolli Università degli Studi Roma La Sapienza, “A Computer Vision-Based Quality Assessment Technique for the automatic control of consumables for analytical laboratories,” Apr. 2024, Accessed: Jan. 19, 2026. [Online]. Available: <https://arxiv.org/pdf/2404.10454v1>
- [101] C. De *et al.*, “UNIVERSIDAD TÉCNICA DE COTOPAXI FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS AUTORES: TUTOR: “DESARROLLO DE UN PROTOTIPO PARA LA IDENTIFICACIÓN AUTOMÁTICA DE PLAGAS Y,” Latacunga, Mar. 2024.

- [102] S. P. L. Á. Asqui Vaca Xavier Alejandro, “Diseño y construcción de un sistema automatizado de clasificación de chochos mediante visión artificial que permita reducir el tiempo en la obtención del producto selecto para la empresa CORL.,” UNIVERSIDAD DE LAS FUERZAS ARMADAS, Latacunga, 2023.
- [103] A. Minet, D. Wentzel, S. Raff, and J. Garbas, “Design thinking in physical and virtual environments: Conceptual foundations, qualitative analysis, and practical implications,” *Technol. Forecast. Soc. Change*, vol. 207, p. 123596, Oct. 2024, doi: 10.1016/j.techfore.2024.123596.
- [104] M. Hennink and B. N. Kaiser, “Sample sizes for saturation in qualitative research: A systematic review of empirical tests,” *Soc. Sci. Med.*, vol. 292, p. 114523, Jan. 2022, doi: 10.1016/j.socscimed.2021.114523.
- [105] L. R. Murphy, S. R. Daly, and C. M. Seifert, “Idea characteristics arising from individual brainstorming and design heuristics ideation methods,” *Int. J. Technol. Des. Educ.*, vol. 33, no. 2, pp. 337–378, Apr. 2023, doi: 10.1007/s10798-021-09723-0.
- [106] L. M. Casper, M. Helminen, and E. S. Veinott, “Design Thinking: Experimental Evidence of Ideation Strategies That Support Team Innovation,” *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 68, no. 1, pp. 693–698, Sep. 2024, doi: 10.1177/10711813241260298.
- [107] S. González-Muñoz, Ma. L. Sánchez-Padilla, and R. Hernández-Benítez, “Árbol de problemas como base en la investigación,” *Educación y Salud Boletín Científico Instituto de Ciencias de la Salud Universidad Autónoma del Estado de Hidalgo*, vol. 12, no. 23, pp. 125–129, Dec. 2023, doi: 10.29057/icsa.v12i23.11153.

## **8. ANEXOS**

### **8.1. ENTREVISTAS**

#### **8.1.1.1. Agricultor**

1. ¿Cómo realiza actualmente la trilla del chocho?
2. ¿Cómo se lleva a cabo el proceso de clasificación del chocho?
3. ¿Cuánto tiempo toma clasificar el chocho manualmente?
4. ¿Qué hacen con el chocho que no cumple con los estándares de calidad?

5. ¿Cómo compara el tiempo de clasificación del chocho con otros cultivos?
6. ¿Cuál es el precio aproximado del quintal de chocho clasificado?
7. ¿Cuánta experiencia tiene realizando este proceso de clasificación?
8. ¿Cómo se realiza el proceso de desamargado del chocho?
9. ¿Qué efectos físicos tiene este proceso en quienes lo realizan?
10. ¿Qué criterios específicos utiliza para determinar si un grano es de buena calidad?
11. ¿Utiliza alguna herramienta para facilitar la clasificación (mallas, mesas, luz, etc.)?
12. ¿Quiénes participan normalmente en esta actividad de clasificación?
13. ¿Cuántos quintales suele clasificar por temporada o por semana?

#### **8.1.1.2. Comerciante**

1. ¿Cómo describiría el proceso que sigue para comprar y vender chocho?
2. ¿Qué entiende usted por chocho de buena calidad cuando va a comprarlo a los agricultores?
3. ¿Qué problemas ha tenido por recibir chocho mal clasificado?
4. ¿Cómo le afectan los problemas de mala clasificación en sus ventas?
5. ¿Qué información le gustaría recibir de los agricultores sobre cómo clasifican el chocho?
6. ¿Qué mejoras cree que se necesitan en la clasificación para que el producto sea más fácil de vender?
7. ¿Cómo reaccionarían sus clientes si pudieran saber que el chocho fue seleccionado con ayuda de una tecnología?
8. ¿Qué opina usted de una posible solución tecnológica para que le resulte útil en su negocio?

#### **8.1.1.3. Consumidor**

1. ¿Qué es lo primero que observa en el chocho antes de decidir si lo va a comprar o consumir?

2. ¿Cómo describiría un chocho que para usted tenga buenas condiciones en sabor, aspecto y textura?
3. ¿Qué experiencias negativas ha tenido al consumir chocho en cuanto a presentación?
4. ¿Cómo reacciona cuando encuentra granos dañados, manchados o muy pequeños en lo que compra?
5. ¿Qué piensa sobre el uso de tecnología para mejorar la selección del chocho que llega al mercado?
6. ¿Qué recomendación daría a agricultores y comerciantes para que el chocho que usted consume tenga mejores condiciones?
7. ¿Qué es lo que más le gustaría que mejorara en el chocho que compra normalmente?
8. ¿Qué tan importante es para usted la manera en que se selecciona el chocho antes de que usted lo compre?

## 8.2. EVIDENCIA DE LAS ENTREVISTAS REALIZADAS



Figura 83.



Figura 84. Entrevista 2



Figura 85. Entrevista 3



Figura 86. Entrevista 4

### 8.3. PCB (PLACA DE CIRCUITO IMPRESO DEL MODELO)

La placa PCB diseñada para este prototipo cumple el rol de distribuir adecuadamente las señales y la energía entre los diferentes componentes del sistema de clasificación. El circuito está organizado para que el Arduino Nano actúe como el controlador principal, permitiendo la conexión directa de los servomotores, el motor DC, el puente H, el regulador de voltaje y la fuente de alimentación como se muestra en la Figura 87. Mediante esta distribución el funcionamiento es más seguro y funcional debido a que las conexiones permanecen estables y ordenadas, facilitando el montaje, pruebas y posibles cambios a futuro.




Figura 87. Placa PCB

Para una mejor comprensión de cómo se vincula cada elemento del sistema con la placa, la siguiente Tabla 38 muestra de forma clara y resumida la función y el punto de conexión de cada componente. Esto permite identificar con rapidez la relación entre las partes y agilizar labores de ensamble y verificación durante la implementación del modelo.

Tabla 38. Componentes y funciones del circuito

Componente	Función	Conector
Arduino Nano	Control central	USB
Puente H	Control del motor de banda	J1
Servomotor 1	Paleta de clasificación	J2
Servomotor 2	Paleta de clasificación	J3
Servomotor 3	Paleta de clasificación	J4
LM2596 (DC1)	Fuente regulador de voltaje	–
Computadora	Programación	USB
Alimentación	Suministro de energía	–

#### 8.4. DIAGRAMA DE FLUJO DEL MODELO

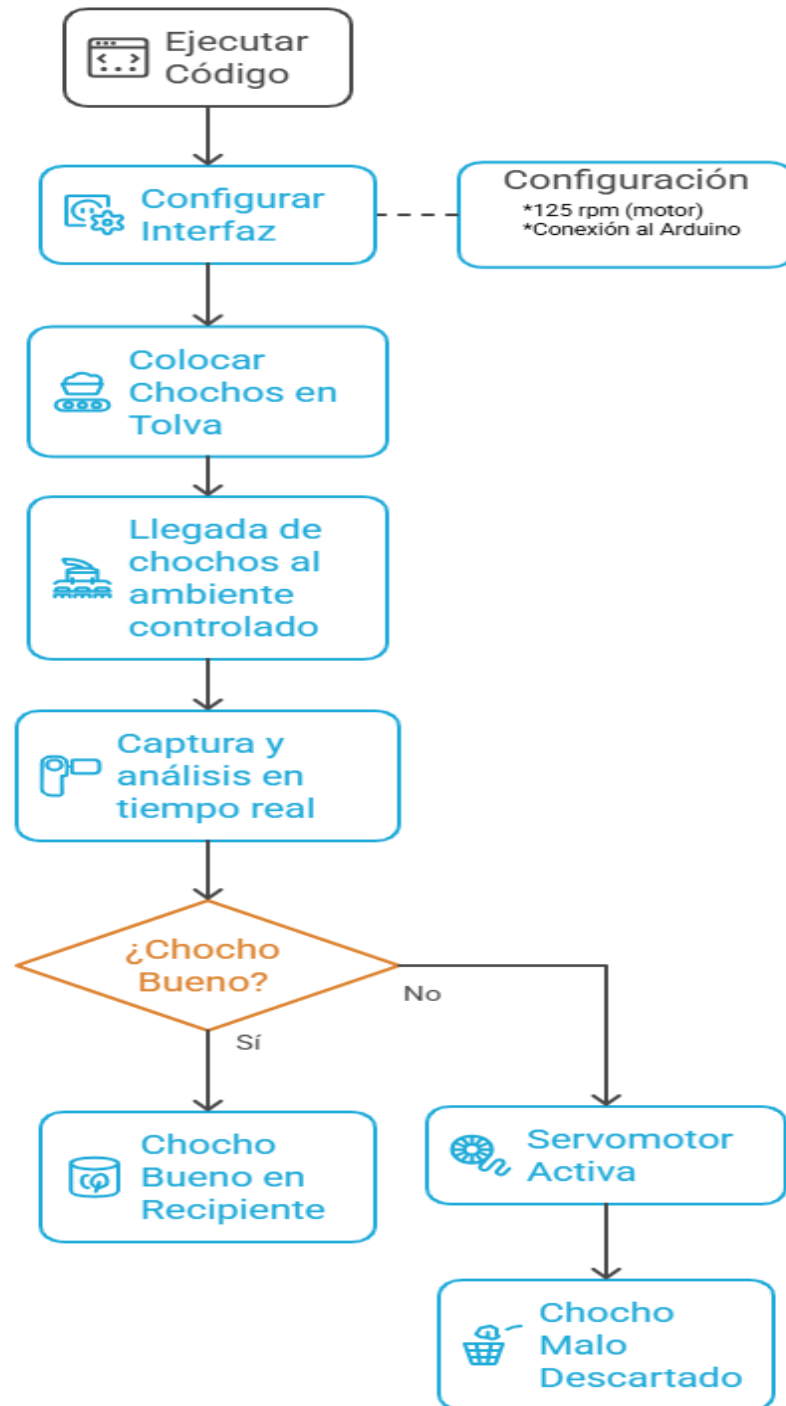


Figura 88. Diagrama del funcionamiento del prototipo

## 8.5. COSTOS DE LA INVETIGACIÓN

### 8.5.1.1. Sistema de procesamiento Raspberry pi 5

Tabla 39.Presupuesto utilizado con Raspberry pi 5

<b>Categoría</b>	<b>Descripción del recurso</b>	<b>Cantidad</b>	<b>Costo unitario (USD)</b>	<b>Costo total (USD)</b>
<b>Hardware de procesamiento</b>	Raspberry Pi 5	1	\$ 140,00	\$ 140,00
<b>Sistema de visión</b>	Cámara Logitech Brio 500	1	\$ 140,00	\$ 140,00
<b>Componentes electrónicos</b>	Arduino Nano	1	\$ 5,00	\$ 5,00
	Servomotores MG90S	3	\$ 3,75	\$ 11,25
	Servomotores MG996R	1	\$ 10,00	\$ 10,00
	Puente H	1	\$ 1,30	\$ 1,30
	Regulador de voltaje	1	\$ 5,25	\$ 5,25
	Adptador AC/DC	1	\$ 7,85	\$ 7,85
	Motor DC para banda transportadora	1	\$ 11,50	\$ 11,50
	Cables, resistencias y conectores		\$ 5,00	\$ 5,00
<b>Sistema de iluminación</b>	Leds de tres chips	2	\$ 2,00	\$ 4,00
<b>Materiales estructurales</b>	Impresión 3D		\$ 75,00	\$ 75,00
	Madera MDF para estructura	1	\$ 7,50	\$ 7,50
	Banda transportadora (cuerina blanca)	1/2 m	\$ 5,00	\$ 5,00
<b>Software y herramientas</b>	Software Python, librerías IA (uso académico)		\$ -	\$ -
	Software CAD (Fusion 360 versión educativa)		\$ -	\$ -
	Software online (Make Sense)		\$ -	\$ -
	Software (Arduino IDE)		\$ -	\$ -
			<b>TOTAL</b>	<b>428,65</b>

### 8.5.1.2. Sistema de procesamiento Computadora

Tabla 40. Presupuesto utilizado con computadora

<b>Categoría</b>	<b>Descripción del recurso</b>	<b>Cantidad</b>	<b>Costo unitario (USD)</b>	<b>Costo total (USD)</b>
<b>Sistema de procesamiento</b>	Computadora	1	\$ 600,00	\$ 600,00
<b>Sistema de visión</b>	Cámara Logitech Brio 500	1	\$ 140,00	\$ 140,00
<b>Componentes electrónicos</b>	Arduino Nano	1	\$ 5,00	\$ 5,00
	Servomotores MG90S	3	\$ 3,75	\$ 11,25
	Servomotores MG996R	1	\$ 10,00	\$ 10,00
	Puente H	1	\$ 1,30	\$ 1,30
	Regulador de voltaje	1	\$ 5,25	\$ 5,25
	Adptador AC/DC	1	\$ 7,85	\$ 7,85
	Motor DC para banda transportadora	1	\$ 11,50	\$ 11,50
	Cables, resistencias y conectores		\$ 5,00	\$ 5,00
<b>Sistema de iluminación</b>	Leds de tres chips	2	\$ 2,00	\$ 4,00
<b>Materiales estructurales</b>	Impresión 3D		\$ 75,00	\$ 75,00
	Madera MDF para estructura	1	\$ 7,50	\$ 7,50
	Banda transportadora (cuerina blanca)	1/2 m	\$ 5,00	\$ 5,00
<b>Software y herramientas</b>	Software Python, librerías IA (uso académico)		\$ -	\$ -
	Software CAD (Fusion 360 versión educativa)		\$ -	\$ -
	Software online (Make Sense)		\$ -	\$ -
	Software (Arduino IDE)		\$ -	\$ -
			<b>TOTAL</b>	<b>888,65</b>

## **8.6. PROMPT PARA LA PROGRAMACIÓN DEL PYTHON DE VISIÓN ARTIFICIAL**

Actúa como un ingeniero experto en visión artificial, Python, OpenCV, Ultralytics YOLO, Tkinter y comunicación serial con Arduino, y genera un único archivo Python completamente funcional que implemente un sistema de clasificación automática de chochos en tiempo real usando cámara USB, detección YOLO y una interfaz gráfica en Tkinter; el código debe incluir captura de video con resolución configurable (ANCHO\_FRAME\_CAMARA, ALTO\_FRAME\_CAMARA), carga de un modelo YOLO desde RUTA\_MODELO\_YOLO con clases NOMBRES\_CLASES\_YOLO y umbral CONFIDENCIA\_MINIMA\_YOLO, detección del cruce de una línea horizontal LINEA\_DETECCION\_Y\_SIM con un margen vertical MARGEN\_LINEA\_DETECCION\_SIM\_PX y protección contra doble conteo mediante TIEMPO\_ESPERA\_REPROCESAMIENTO\_OBJETO\_SEGS, división vertical de la imagen usando X\_SECCION para decidir el accionamiento, comunicación serial con Arduino (listar puertos, conectar a 9600 baudios, enviar comandos simples y control de velocidad  $V\{\text{valor}\}$ ), activación de un servo izquierdo o derecho cuando se detecte un objeto “malo” según la posición horizontal del centro del bounding box, visualización en tiempo real del video con bounding boxes, etiquetas de clase y confianza, líneas de referencia, contadores de objetos buenos y malos, uso de hilos para retardos no bloqueantes y actualización periódica de la imagen con `ventana.after`, manteniendo una estructura procedural clara, nombres de variables descriptivos y un código listo para ejecutar, permitiendo que los valores de los parámetros definidos puedan ser modificados manualmente posteriormente según las necesidades del sistema sin alterar la lógica principal.

## **8.7. PROMPT PARA LA PROGRAMACIÓN DEL ARDUINO**

Actúa como un ingeniero experto en programación de Arduino y sistemas mecatrónicos, y genera un sketch completo en Arduino (C/C++) diseñado para comunicarse por puerto serial a 9600 baudios con un programa en Python; el Arduino debe leer comandos enviados como texto terminados en salto de línea y reaccionar de la siguiente manera: cuando reciba el carácter "4" debe activar un servo o actuador conectado a un pin configurado como salida correspondiente al lado izquierdo, cuando reciba el carácter "5" debe activar un segundo servo o actuador correspondiente al lado derecho, y cuando

reciba un comando en el formato "V{valor}" (donde {valor} es un número entre 0 y 255) debe ajustar la velocidad de un motor mediante PWM usando analogWrite; el código debe incluir inicialización clara de pines, uso de la librería Servo si es necesario, lectura robusta del buffer serial usando Serial.readStringUntil('\n') o lógica equivalente, validación básica de los comandos recibidos, y una estructura simple y estable pensada para funcionar continuamente con un sistema de visión artificial en tiempo real, permitiendo que los pines, tiempos de activación y valores de PWM puedan ser modificados manualmente más adelante sin alterar la lógica principal del programa.

## **8.8. PROGRAMACIÓN DEL MODELO DE VISIÓN ARTIFICIAL**

```
import os

import sys

import time

import threading

import tkinter as tk

from tkinter import ttk, messagebox

import serial

import serial.tools.list_ports

from PIL import Image, ImageTk

import numpy as np

import cv2

from ultralytics import YOLO

# -----

# CONFIGURACIÓN GLOBAL

# -----

ID_CAMARA = 1

ANCHO_FRAME_CAMARA = 640
```

```

ALTO_FRAME_CAMARA = 480

RUTA_MODELO_YOLO = "runs/detect/entrenamiento_chochos_final/weights/best.pt"

NOMBRES_CLASES_YOLO = ["malo", "bueno"]

CONFIDENCIA_MINIMA_YOLO = 0.6

LINEA_DETECCION_Y_SIM = 300

MARGEN_LINEA_DETECCION_SIM_PX = int(ALTO_FRAME_CAMARA * 0.1)

TIEMPO_ESPERA_REPROCESAMIENTO_OBJETO_SEGS = 0.3

# Líneas verticales de sección

X_SECCION_1 = 223

X_SECCION_2 = 410

# -----

# FUNCIONES CLASIFICACIÓN YOLO + ACTUALIZACIÓN VIDEO

# -----

modelo_yolo = YOLO(RUTA_MODELO_YOLO)

cap = cv2.VideoCapture(ID_CAMARA)

cap.set(cv2.CAP_PROP_FRAME_WIDTH, ANCHO_FRAME_CAMARA)

cap.set(cv2.CAP_PROP_FRAME_HEIGHT, ALTO_FRAME_CAMARA)

stats = {"buenos": 0, "malos": 0, "linea_cruzada": 0}

obj_procesados_recientemente = {}

def enviar_comando_con_retraso(comando, delay):

    def tarea():

        time.sleep(delay)

        enviar_comando(comando)

    threading.Thread(target=tarea, daemon=True).start()

def actualizar_video():

    ret, frame = cap.read()

```

```

if not ret:

    ventana.after(30, actualizar_video)

    return

current_time = time.time()

results = modelo_yolo.predict(frame, conf=CONFIDENCIA_MINIMA_YOLO,
verbose=False)

frame_display = frame.copy()

global obj_procesados_recientemente

obj_procesados_recientemente = {

    k: v for k, v in obj_procesados_recientemente.items()

    if current_time - v < TIEMPO_ESPERA_REPROCESAMIENTO_OBJETO_SEGS

}

if results and results[0].boxes:

    for box in results[0].boxes:

        x1, y1, x2, y2 = map(int, box.xyxy[0].tolist())

        confianza = float(box.conf[0])

        clase_id = int(box.cls[0])

        nombre_clase = NOMBRES_CLASES_YOLO[clase_id] if clase_id <
len(NOMBRES_CLASES_YOLO) else "Desconocido"

        cx = (x1 + x2) // 2

        cy = (y1 + y2) // 2

        id_obj = (x1, y1, x2, y2)

        es_bueno = nombre_clase == "bueno"

        color = (0, 255, 0) if es_bueno else (0, 0, 255)

        cv2.circle(frame_display, (cx, cy), 5, (255, 255, 255), -1)

```

```

    if abs(cy - LINEA_DETECCION_Y_SIM) <
MARGEN_LINEA_DETECCION_SIM_PX:

    if id_obj not in obj_procesados_recientemente:

        obj_procesados_recientemente[id_obj] = current_time

        stats["linea_cruzada"] += 1

        if es_bueno:

            stats["buenos"] += 1

        else:

            stats["malos"] += 1

        if cx < X_SECCION_1:

            print("Activando Servo 1 (Sección 1 - IZQUIERDA)")

            enviar_comando_con_retraso("4", 0.05)

        elif cx < X_SECCION_2:

            print("Activando Servo 2 (Sección 2 - CENTRO)")

            enviar_comando_con_retraso("5", 0.05)

        else:

            print("Activando Servo 3 (Sección 3 - DERECHA)")

            enviar_comando_con_retraso("6", 0.05)

cv2.rectangle(frame_display, (x1, y1), (x2, y2), color, 5)

cv2.putText(frame_display, f"{nombre_clase} ({confianza:.2f})", (x1, y1 - 10),

            cv2.FONT_HERSHEY_SIMPLEX, 0.5, color, 2)

cv2.line(frame_display, (0, LINEA_DETECCION_Y_SIM),

(ANCHO_FRAME_CAMARA, LINEA_DETECCION_Y_SIM), (0, 255, 255), 2)

cv2.line(frame_display, (X_SECCION_1, 0), (X_SECCION_1,

ALTO_FRAME_CAMARA), (255, 0, 0), 2)

```

```

    cv2.line(frame_display, (X_SECCION_2, 0), (X_SECCION_2,
ALTO_FRAME_CAMARA), (255, 0, 0), 2)

    cv2.putText(frame_display, f"Buenos: {stats['buenos']}", (10, 30),
cv2.FONT_HERSHEY_SIMPLEX, 0.7, (0, 255, 0), 2)

    cv2.putText(frame_display, f"Malos: {stats['malos']}", (10, 60),
cv2.FONT_HERSHEY_SIMPLEX, 0.7, (0, 0, 255), 2)

    ## cv2.putText(frame_display, f"Línea Y={LINEA_DETECCION_Y_SIM}", (10, 90),
cv2.FONT_HERSHEY_SIMPLEX, 0.7, (255, 255, 0), 2)

    frame_rgb = cv2.cvtColor(frame_display, cv2.COLOR_BGR2RGB)

    imagen_pil = Image.fromarray(frame_rgb)

    imagen_tk = ImageTk.PhotoImage(image=imagen_pil)

    video_label.imgtk = imagen_tk

    video_label.configure(image=imagen_tk)

    ventana.after(30, actualizar_video)

# -----
# FUNCIONES SERIAL Y GUI
# -----

arduino = None

def listar_puertos():

    return [port.device for port in serial.tools.list_ports.comports()]

def conectar():

    global arduino

    puerto = puerto_var.get()

    try:

        arduino = serial.Serial(puerto, 9600, timeout=1)

        time.sleep(2)

        estado_var.set("Conectado a " + puerto)

```

```

        boton_conectar.config(state='disabled')
        boton_desconectar.config(state='normal')
        menu_puertos.config(state='disabled')
    except:
        messagebox.showerror("Error", f"No se pudo conectar al puerto {puerto}")

def desconectar():
    global arduino
    if arduino:
        arduino.close()
        arduino = None
        estado_var.set("Desconectado")
        boton_conectar.config(state='normal')
        boton_desconectar.config(state='disabled')
        menu_puertos.config(state='readonly')

def enviar_comando(cmd):
    global arduino
    if arduino and arduino.is_open:
        arduino.write((cmd + '\n').encode())
    else:
        messagebox.showwarning("Desconectado", "Conecta el Arduino primero.")

def enviar_velocidad():
    velocidad = entrada_velocidad.get()
    if velocidad.isdigit():
        vel = int(velocidad)
        if 0 <= vel <= 255:
            enviar_comando(f"V{vel}")

```

```

else:
    messagebox.showwarning("Valor inválido", "Ingresa un valor entre 0 y 255.")

else:
    messagebox.showwarning("Entrada inválida", "Ingresa solo números.")

# -----
# INTERFAZ GRÁFICA
# -----

ventana = tk.Tk()

ventana.title("Clasificación de Chochos con YOLO + Control Arduino")

ventana.geometry("1000x600")

video_label = tk.Label(ventana)

video_label.place(x=10, y=30, width=640, height=480)

tk.Label(ventana, text="PUERTO").place(x=680, y=40)

menu_puertos = ttk.Combobox(ventana, textvariable=(puerto_var := tk.StringVar()),
                             values=(puertos_disponibles := listar_puertos()),
                             state="readonly")

puerto_var.set(puertos_disponibles[0] if puertos_disponibles else "")

menu_puertos.place(x=680, y=70, width=200)

estado_var = tk.StringVar(value="DESCONECTADO")

tk.Label(ventana, textvariable=estado_var, fg="blue").place(x=680, y=100)

boton_conectar = tk.Button(ventana, text="CONECTAR", command=conectar)

boton_conectar.place(x=680, y=130, width=90)

boton_desconectar = tk.Button(ventana, text="DESCONECTAR",
                               command=desconectar,
                               state='disabled')

```

```

boton_desconectar.place(x=790, y=130, width=90)

tk.Label(ventana, text="VELOCIDAD").place(x=680, y=160)

entrada_velocidad = tk.Entry(ventana)

entrada_velocidad.place(x=680, y=185, width=50)

tk.Button(ventana, text="ACEPTAR", command=enviar_velocidad).place(x=680,
y=215)

frame_servos = tk.Frame(ventana)

frame_servos.place(x=680, y=270)

for i in range(1, 7):

    texto = f"Servo  $\{(i-1)\%3+1\}$  → {'90°' if i <= 3 else '0°'}"

    tk.Button(frame_servos, text=texto, command=lambda c=str(i):
enviar_comando(c))\

        .grid(row=0, column=i-1, padx=5)

ventana.after(100, actualizar_video)

ventana.mainloop()

```