



**UNIVERSIDAD NACIONAL DE CHIMBORAZO
FACULTAD DE INGENIERÍA
CARRERA DE TELECOMUNICACIONES**

**IMPLEMENTACIÓN DE UN PROTOTIPO PARA LA CLASIFICACIÓN
AUTOMÁTICA DE TOMATES RIÑÓN BASADO EN LA NORMA INEN
1745, APLICANDO TÉCNICAS DE VISIÓN ARTIFICIAL**

Trabajo de Titulación para optar al título de Ingeniero en Telecomunicaciones.

Autor:

Cristian Christopher Manosalvas Ramos

Tutor:

PhD. Leonardo Fabián Rentería Bustamante.

Riobamba, Ecuador. 2023

DECLARATORIA DE AUTORÍA

Yo, **Cristian Christopher Manosalvas Ramos**, con cédula de ciudadanía **1500642713**, autor del trabajo de investigación titulado: **“IMPLEMENTACIÓN DE UN PROTOTIPO PARA LA CLASIFICACIÓN AUTOMÁTICA DE TOMATES RIÑÓN BASADO EN LA NORMA INEN 1745, APLICANDO TÉCNICAS DE VISIÓN ARTIFICIAL”**, certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mí exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor (a) de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 18 de diciembre del 2023.



Cristian Christopher Manosalvas Ramos

C.I: 1500642713

DICTAMEN FAVORABLE DEL PROFESOR TUTOR

Quien suscribe, **Leonardo Fabian Rentería Bustamante** catedrático adscrito a la Facultad de Ingeniería, por medio del presente documento certifico haber asesorado y revisado el desarrollo del trabajo de investigación titulado: **IMPLEMENTACIÓN DE UN PROTOTIPO PARA LA CLASIFICACIÓN AUTOMÁTICA DE TOMATES RIÑÓN BASADO EN LA NORMA INEN 1745, APLICANDO TÉCNICAS DE VISIÓN ARTIFICIAL**, bajo la autoría de **Cristian Christopher Manosalvas Ramos**; por lo que se autoriza ejecutar los trámites legales para su sustentación.

Es todo cuanto informar en honor a la verdad; en Riobamba, a los 21 días del mes de octubre de 2023



Firma digitalizada por:
**LEONARDO FABIAN
RENERIA BUSTAMANTE**

Leonardo Fabian Rentería Bustamante

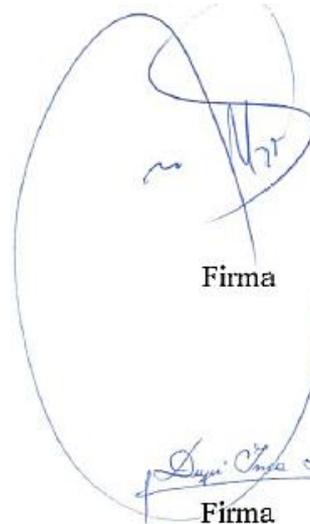
C.I: 1104064132

CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

Quienes suscribimos, catedráticos designados Miembros del Tribunal de Grado para la evaluación del trabajo de investigación “IMPLEMENTACIÓN DE UN PROTOTIPO PARA LA CLASIFICACIÓN AUTOMÁTICA DE TOMATES RIÑÓN BASADO EN LA NORMA INEN 1745, APLICANDO TÉCNICAS DE VISIÓN ARTIFICIAL”, por Cristian Christopher Manosalvas Ramos, con cédula de identidad número 1500642713, bajo la tutoría de PhD. Leonardo Fabián Rentería Bustamante; certificamos que recomendamos la APROBACIÓN de este con fines de titulación. Previamente se ha evaluado el trabajo de investigación y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

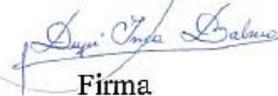
De conformidad a la normativa aplicable firmamos, en Riobamba a los 18 días de diciembre de 2023.

Presidente del Tribunal de Grado
PhD. Marlon Danilo Basantes Valverde



Firma

Miembro del Tribunal de Grado
Mgs. Deysi Vilma Inca Balseca



Firma

Miembro del Tribunal de Grado
Msc. José Luis Jinez Tapia



Firma



Dirección
Académica
VICERRECTORADO ACADÉMICO



UNACH-RGF-01-04-08.15
VERSIÓN 01: 06-09-2021

CERTIFICACIÓN

Que, **Manosalvas Ramos Cristian Christopher** con CC: **1500642713**, estudiante de la Carrera **Ingeniería en Telecomunicaciones**, Facultad de **Ingeniería**; ha trabajado bajo mi tutoría el trabajo de investigación titulado " **IMPLEMENTACIÓN DE UN PROTOTIPO PARA LA CLASIFICACIÓN AUTOMÁTICA DE TOMATES RIÑÓN BASADO EN LA NORMA INEN 1745, APLICANDO TÉCNICAS DE VISIÓN ARTIFICIAL**", cumple con el **4 %**, de acuerdo al reporte del sistema Anti plagio **URKUND**, porcentaje aceptado de acuerdo a la reglamentación institucional, por consiguiente autorizo continuar con el proceso.

Riobamba, 7 de noviembre de 2023



Verifique su autenticidad por:
**LEONARDO FABIAN
RENERIA BUSTAMANTE**

PhD. Leonardo Fabian Rentería Bustamante
TUTOR TRABAJO DE INVESTIGACIÓN

DEDICATORIA

Con todo mi amor y cariño, dedico este trabajo a mis padres, Hernán y María, pilares constantes en mi vida que siempre han estado presentes, apoyándome incondicionalmente en cada sueño y meta. A mis hermanas, Yanina y Angela, por su amor inquebrantable y por añadir alegría y ligereza a mis días. Es gracias a la fortaleza y apoyo de todos ellos que celebro este logro.

AGRADECIMIENTO

Agradezco a Dios por su amor incondicional y guía a lo largo de este proceso. A la Universidad, agradezco la oportunidad brindada para mi formación y crecimiento académico. A mis profesores por su dedicación, y por compartir sus vastos conocimientos y experiencias. Mi sincero agradecimiento a mi tutor de investigación Leonardo Rentería, por su invaluable orientación y por guiarme en cada etapa de este recorrido. A mis amigos y compañeros, gracias por su apoyo constante y por hacer que este proceso fuera más llevadero. Y a mi familia, mi eterno agradecimiento por su amor y apoyo inquebrantable en cada paso que he tomado. Este trabajo es una muestra de mi profundo aprecio hacia todos ustedes.

INDICE GENERAL

DECLARATORIA DE AUTORÍA	
DICTAMEN FAVORABLE DEL PROFESOR TUTOR	
CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL	
CERTIFICADO ANTIPLAGIO	
DEDICATORIA	
AGRADECIMIENTO	
INDICE GENERAL	
ÍNDICE DE FIGURAS	
ÍNDICE DE TABLAS	
RESUMEN	
ABSTRACT	
INTRODUCCIÓN.....	15
CAPÍTULO I.....	17
1.1 Planteamiento del problema.....	17
1.2 Justificación.....	17
1.3 Objetivos	18
1.3.1 General	18
1.3.2 Específicos	18
CAPÍTULO II.....	19
2.1 Estado del arte	19
2.2 Fundamentación Teórica	21
2.1.1. Clasificación de tomates riñón	21
2.1.1.1. Norma Técnica Ecuatoriana Voluntaria INEN 1 745.....	21
2.1.2. Visión Artificial	23
2.1.2.1. Importancia y Aplicaciones de la Visión artificial en la automatización...	23
2.1.2.2. Algoritmos de clasificación de objetos	24
2.1.2.3. Algoritmos de detección de objetos.....	25
2.1.2.4. Procesamiento digital de imágenes con visión artificial.....	26
2.1.3. Entorno de iluminación controlada	31
2.3 Plataforma de desarrollo Google Colab	31
CAPÍTULO III	33
3.1 Metodología	33

3.1.1.	Tipo de investigación	33
3.1.2.	Diseño de la investigación.....	33
3.1.3.	Métodos de la investigación.....	34
3.1.3.1.	Investigación experimental	34
3.1.3.2.	Investigación cuantitativa	34
3.1.4.	Técnicas de recolección de datos	34
3.1.4.1.	Fuentes de información.....	34
3.1.4.2.	Instrumentos de recolección de datos	35
3.1.5.	Población de estudio y tamaño de la muestra	35
3.1.5.1.	Población	35
3.1.5.2.	Muestra	35
3.1.6.	Operacionalización de las variables	36
3.2	Desarrollo y Funcionamiento del Dispositivo.....	37
3.2.1.	Selección de imágenes válidas y entrenamiento del modelo de detección	37
3.2.1.1.	Recolección y selección de Imágenes.....	38
3.2.1.2.	Proceso de etiquetado en las imágenes	39
3.2.1.3.	Entrenamiento del sistema de detección	39
3.2.1.4.	Validación del sistema de detección	42
3.3	Selección del hardware necesario para la implementación del prototipo	43
3.3.1.	Componentes de hardware para el procesamiento de imágenes y clasificación del prototipo43	
3.3.1.1.	Unidad Central de Procesamiento (CPU)	43
3.3.1.2.	Tarjeta de desarrollo.....	44
3.3.2.	Sistema de aislamiento de iluminación exterior y sistema de adquisición de imágenes	45
3.3.3.	Diseño de la placa de distribución del prototipo para los tomates riñón.....	47
3.3.4.	Estructura de soporte de la banda transportadora.....	48
3.3.5.	Tolva de distribución de tomates riñón	49
3.4	Desarrollo del software de detección, clasificación y control de hardware	50
3.4.1.	Ajuste del sistema de adquisición de imagen.....	50
3.4.2.	Procesamiento de Imágenes y desarrollo de los algoritmos para el prototipo clasificador.....	51
3.4.2.1.	Algoritmo para la clasificación de tamaños.....	52
3.4.2.2.	Algoritmo para la clasificación de colores.....	53

3.4.3.	Funcionamiento del sistema e interfaz gráfica.....	56
3.4.4.	Sistema para el control del hardware mediante el microcontrolador.....	59
3.5	Descripción de las pruebas de evaluación del prototipo para la clasificación automática de tamaños y colores de los tomates riñón.....	60
3.6	Descripción de las pruebas para la comparación entre los métodos de medición: calibrador, prototipo y operarios.....	61
CAPÍTULO IV		63
4.1	Resultados y discusión	63
4.1.1.	Resultados de las pruebas de evaluación del prototipo en la clasificación automática por tamaño y color.....	63
4.1.1.1.	Resultados de las clasificaciones en la categoría de tamaños para la comparación entre métodos de medición.....	64
4.1.1.2.	Resultados de la clasificación dado por el prototipo en la categoría de colores	66
4.1.2.	Análisis descriptivo	67
4.1.3.	Análisis de correlaciones.....	69
CAPÍTULO V.....		70
5.1	Conclusiones	70
5.2	Recomendaciones.....	71
BIBLIOGRAFÍA		72
ANEXOS.....		76

ÍNDICE DE FIGURAS

Figura 1: Planteamiento del Problema.	17
Figura 2: Instrumento de clasificación confeccionado en madera. Fuente: [4]	22
Figura 3: Calibrador vernier digital.....	22
Figura 4: Etapas de un sistema de visión artificial.....	27
Figura 5: Componentes de un sistema de procesamiento de imágenes. Fuente: [34].....	28
Figura 6: Estructura de Google Colab. Fuente: [39]	32
Figura 7: Diseño de la investigación.	33
Figura 8: Selección de imágenes y entrenamiento del modelo de detección.	37
Figura 9: Selección de imágenes válidas para el entrenamiento del modelo.	38
Figura 10: Etiquetado de imágenes en MakeSenseAI.....	39
Figura 11: Comando para clonar el modelo YOLOv5 en el cuaderno de Google Colab...	41
Figura 12: Comandos para el montaje de Google Drive en Colab.....	41
Figura 13: Carga de imágenes y etiquetas en la plataforma de Google Colab.....	41
Figura 14: Comando para inicializar el entrenamiento del modelo de detección.	42
Figura 15: Test del sistema para la detección de tomates.....	42
Figura 16: Infraestructura de hardware del prototipo.....	43
Figura 17: Adecuación del sistema de iluminación. a) Caja de aislamiento exterior, b) Sistema de adquisición de imágenes, c) Sistema de iluminación, d) Banda transportadora.	45
Figura 18: Aro de iluminación de intensidad regulable.	46
Figura 19: Dispositivo de adquisición de imágenes webcam Logitech C922Pro.....	46
Figura 20: Placa de distribución del prototipo. a) Vista superior, b) Vista inferior.....	48
Figura 21: Componentes del prototipo. a) Estructura, b) Compuertas, c) Servomotor DS3218mg, d) Interruptor final de carrera.	48
Figura 22: Tolva de distribución de tomates.	49
Figura 23: Componentes electrónicos de la tolva.	49
Figura 24: Ajuste de perfil de cámara Logitech C922Pro.....	50
Figura 25: Diagrama de flujo de adquisición y procesamiento de imágenes.....	51
Figura 26: Algoritmo de clasificación por tamaños.	52
Figura 27: Diagrama de flujo de clasificación por colores.	53
Figura 28: Rangos del canal Hue del espacio de color HSV para la clasificación de colores.	54
Figura 29: Grupos clasificados para la coloración de los tomates.	55
Figura 30: Determinación de color, a1-a2 histograma para tomates verdes, b1-b2 histograma para tomates pintones, c1-c2 histograma para tomates rasados y d1-d2 histograma para tomates rojos.....	55
Figura 31: Proceso de funcionamiento del sistema.....	57
Figura 32: Interfaz gráfica - Ventana principal.	58
Figura 33: Interfaz gráfica - Ventana de selección de clasificación.....	59
Figura 34: Dispositivos de entrada y salida del microcontrolador.	59
Figura 35: Distribución automática de tomates clasificados.....	60

ÍNDICE DE TABLAS

Tabla 1: Clasificación del tomate riñón por su tamaño según el diámetro ecuatorial. Fuente: [4]	21
Tabla 2: Categoría del tomate riñón según el porcentaje de coloración de su superficie. Fuente: [4]	23
Tabla 3: Comparación de características entre algoritmos de detección. Fuente: [31]–[33]	26
Tabla 4: Operacionalización de las variables.	36
Tabla 5: Aspectos considerados para el uso de la arquitectura YOLOv5	40
Tabla 6: Características técnicas Laptop HP Victus.	44
Tabla 7: Características técnicas tarjeta de desarrollo BluePill.	44
Tabla 8: Especificaciones técnicas webcam Logitech C922 Pro.	47
Tabla 9: Parámetros del perfil de la cámara establecidos para las pruebas.	50
Tabla 10: Valor pico de tonalidad para cada color de acuerdo con su histograma según la Figura 29.	56
Tabla 11: Clasificación por tamaño usando un calibrador digital.	61
Tabla 12: Clasificación por colores realizado por un experto.	61
Tabla 13: Estadísticas descriptivas e intervalo de confianza para el porcentaje de aciertos en diferentes tamaños del tomate riñón.	63
Tabla 14: Estadísticas descriptivas e intervalo de confianza para el porcentaje de aciertos en diferentes colores del tomate riñón.	64
Tabla 15: Resultado de la primera clasificación realizada por el prototipo.	64
Tabla 16: Resultado de la clasificación realizada por los operarios.	65
Tabla 17: Matriz de confusión - Resultado de la clasificación por color del prototipo.	66
Tabla 18: Análisis descriptivo de diámetros: Comparación entre métodos de medición (calibrador, prototipo y operarios)	67
Tabla 19: Análisis de varianza (ANOVA) para los diámetros medidos con métodos de medición.	68
Tabla 20: Comparación de medias entre grupos (operarios, prototipo, calibrador) mediante la Prueba de Tukey.	68
Tabla 21: Correlación entre las mediciones del prototipo y las del calibrador.	69
Tabla 22: Correlación entre las mediciones de los operarios y las del calibrador.	69
Tabla 23: Características técnicas Servomotor DS3218mg.	77
Tabla 24: Características técnicas Motor Reductor Gear AC.	78
Tabla 25: Presupuesto del prototipo.	84

RESUMEN

Ante la prevalencia de métodos manuales convencionales de clasificación por tamaño y color de tomates riñón que demandan experiencia prolongada y conllevan ineficiencias y costos adicionales, el presente estudio propone una solución al abordar el desarrollo de un prototipo destinado a la clasificación automática basado en la norma INEN 1745 utilizando técnicas de visión artificial. La implementación del prototipo se llevó a cabo en tres fases fundamentales; Inicialmente, se desarrolló un sistema de detección y clasificación empleando el algoritmo YOLOv5, el mismo que fue entrenado con imágenes adquiridas de los tomates provenientes de un invernadero del cantón Chambo provincia de Chimborazo. Luego, se integraron los componentes físicos como son la Unidad Central de Procesamiento, sistema de adquisición de imágenes, y diversos elementos electrónicos-mecánicos con un software desarrollado en Python y en C para la detección y reconocimiento y la gestión del hardware respectivamente.

El sistema fue sometido a pruebas de clasificación de tamaño y de color con 200 tomates seleccionados al azar y fue comparado con dos métodos tradicionales: observación sin uso de instrumento es decir basado en la experiencia y observación usando un instrumento de precisión. Para la prueba de tamaño se empleó un calibrador digital para determinar meticulosamente el diámetro transversal de los tomates, y se procedió con la clasificación manual de los mismos por parte de los operarios; mientras que, para la prueba de clasificación por color, el operario experto categorizó manualmente los tomates en verdes y rojos basándose en su criterio. Los resultados obtenidos fueron comparados con los resultados de la clasificación de tamaño y color del prototipo.

Como resultados más importantes se puede destacar que el sistema propuesto alcanzo 92.5% de efectividad en la clasificación de tamaños superando notablemente la efectividad obtenida por los operarios que alcanzo el 77%, mientras que en la clasificación de colores la efectividad del prototipo alcanzó el 93.5%, considerando que el experto tiene una efectividad del 100%. En conclusión, el uso del sistema implementado mejora considerablemente el proceso de clasificación de los tomates riñón en comparación con los métodos tradicionales, considerando que este puede tener intervalos de trabajo continuo mucho más largos con respecto a los de un operario.

Palabras claves: Visión Artificial, Procesamiento de Imágenes, Norma INEN 1745.

ABSTRACT

The process of manually classifying tomatoes by size and color is not only time-consuming but also inefficient and costly. The present study proposes a prototype that uses computer vision techniques to automatically classify tomatoes based on the INEN standard 1745 to address this issue. The implementation of the prototype was done in three main phases. Firstly, a detection and classification system was developed using the YOLOv5 algorithm. The system was trained using images acquired from tomatoes grown in a greenhouse located in the Chambo canton, province of Chimborazo. In the upcoming stages, physical components such as the Central Processing Unit, image acquisition system, and various electronic-mechanical elements were integrated with software developed in Python and C. The software was used for detection and recognition, while the hardware was managed by the software.

In order to evaluate the system, 200 tomatoes were randomly selected and subjected to tests for size and color classification. The system's performance was compared to two traditional methods: observation based on experience alone and the use of a precision instrument. For the size test, the tomatoes' transverse diameter was meticulously measured using a digital caliper and manually classified by the operators. For the color classification test, the expert operator manually categorized the tomatoes as green or red based on his criteria. Finally, the results obtained from the system were compared to the results obtained from the traditional methods for size and color classification of the prototype.

The proposed system achieved an effectiveness of 92.5% in size classification, which is notably higher than the 77% effectiveness achieved by operators. In color classification, the prototype achieved an effectiveness of 93.5%, while an expert is 100% effective. In conclusion, the implemented system significantly improves the classification process of tomatoes when compared to traditional methods. The system can also work for much longer continuous intervals, which is a significant advantage over an operator.

Keywords: Computer Vision, Image Processing, INEN 1745 Standard.



Reviewed by:
Lic. Jenny Freire Rivera
ENGLISH PROFESSOR
C.C. 0604235036

INTRODUCCIÓN

Hoy en día, el Ecuador posee alrededor de 1.800 hectáreas dedicadas a la producción de tomate riñón con una producción cercana a 52.000 toneladas métricas [1]. Esta hortaliza constituye un producto de la canasta básica familiar y es de gran valor para la agricultura del país. Es importante destacar que el tomate es muy apetecido por ser un alimento de fácil digestión y rico en vitaminas A, B y C, licopeno, fósforo, potasio, hierro y calcio [2].

En el Ecuador, la clasificación del tomate riñón se realiza de manera industrial y también por parte de pequeños productores de la región. Estos últimos, utilizan técnicas artesanales para la siembra, cosecha y clasificación del producto [3]. En este sentido, el tomate una vez recolectado, se clasifica de acuerdo con su tamaño definidos por el diámetro ecuatorial, la coloración de la superficie del fruto, respectivamente.

Para ello, de acuerdo con en la norma técnica ecuatoriana INEN 1 745 (Requisitos generales para la hortaliza fresca tomate riñón), se consideran las propiedades físicas para clasificar los tomates de acuerdo con el diámetro ecuatorial: pequeños, medianos y grandes. De igual manera se clasifican según el grado de coloración, al ser una norma voluntaria los productores optan por realizar una clasificación de dos etapas determinadas a continuación con la finalidad de agilizar y disminuir los tiempos de clasificación: verdes y rojos, esta categorización es fundamental en la venta, ya que según los grados de calidad en color y tamaño del fruto se fija su valor en el mercado [4].

En las industrias, el tomate se clasifica mecánicamente, mediante el uso de maquinarias automatizadas [5], a diferencia de los productores locales quienes lo realizan de forma manual con la ayuda de calibres fijos, herramientas usualmente confeccionadas en madera, para medir el tamaño y de manera visual para detectar su estado de madurez [6]. Por lo tanto, el procedimiento manual requiere de mayor tiempo y presencia de un operario, lo que recae en una baja eficiencia del proceso y aumento de gastos de producción.

Actualmente, las investigaciones muestran factibilidad en el uso de algoritmos de visión artificial que permitan medir e identificar formas y siluetas de los tomates riñón con un gran porcentaje de éxito. Existen diversos estudios que proponen el uso de redes neuronales convolucionales profundas, DCNNs (Deep Convolutional Neural Networks), para la detección de la masa de los tomates [7] - [8], de la misma manera también se plantea el uso de redes neuronales para la identificación de imágenes de los tipos de tomates [9].

Así, el diseño e implementación de un sistema de clasificación automática de tomates riñón, con técnicas y algoritmos de visión artificial, puede identificar la silueta y forma del tomate, medir el mayor diámetro transversal, establecer su estado de madurez de manera autónoma. Esto implica una mayor facilidad, ayudando a automatizar el proceso de producción.

El proyecto tuvo como base una investigación experimental donde se aplicaron métodos de recolección de datos mediante la consulta a los expertos y trabajos realizados anteriormente referentes al campo de aplicación, visión artificial. Para evaluar el prototipo se realizaron pruebas donde se evaluó el funcionamiento y eficiencia de la implementación.

A continuación, se presenta una estructura organizada en cinco capítulos. El capítulo I abarca el planteamiento del problema, la justificación y los objetivos general y específicos. El capítulo II se enfoca en el estudio de las técnicas, los algoritmos de visión artificial y el procesamiento de imágenes digitales. En el capítulo III se describe la metodología utilizada en la investigación y se detalla el desarrollo del prototipo, tanto en términos de hardware como de software. En el capítulo IV muestra los resultados obtenidos y su posterior discusión, destacando los hallazgos clave derivados del trabajo de investigación. Esta estructura clara y formal facilita la comprensión del lector acerca de los aspectos abordados y los logros alcanzados en el estudio. Finalmente, en el capítulo V se presenta las conclusiones y recomendaciones correspondientes al trabajo de investigación.

CAPÍTULO I

1.1 Planteamiento del problema

En la actualidad los pequeños y medianos productores de tomates riñón del país siguen utilizando técnicas convencionales de clasificación manual, como el uso de instrumentos de medición confeccionados en madera para clasificar los tamaños y la percepción visual para la identificación del grado de madurez, entonces para que esta clasificación sea adecuada requiere de mucho tiempo de práctica y experiencia por parte de los operarios, debido a esto la clasificación manual implica ciertas causas que son importantes considerar y que en lo posible se deben evitar para disminuir la deficiencia y gastos de producción, en la Figura 1 se presenta el planteamiento del problema acorde a las causas y efectos de una clasificación manual.

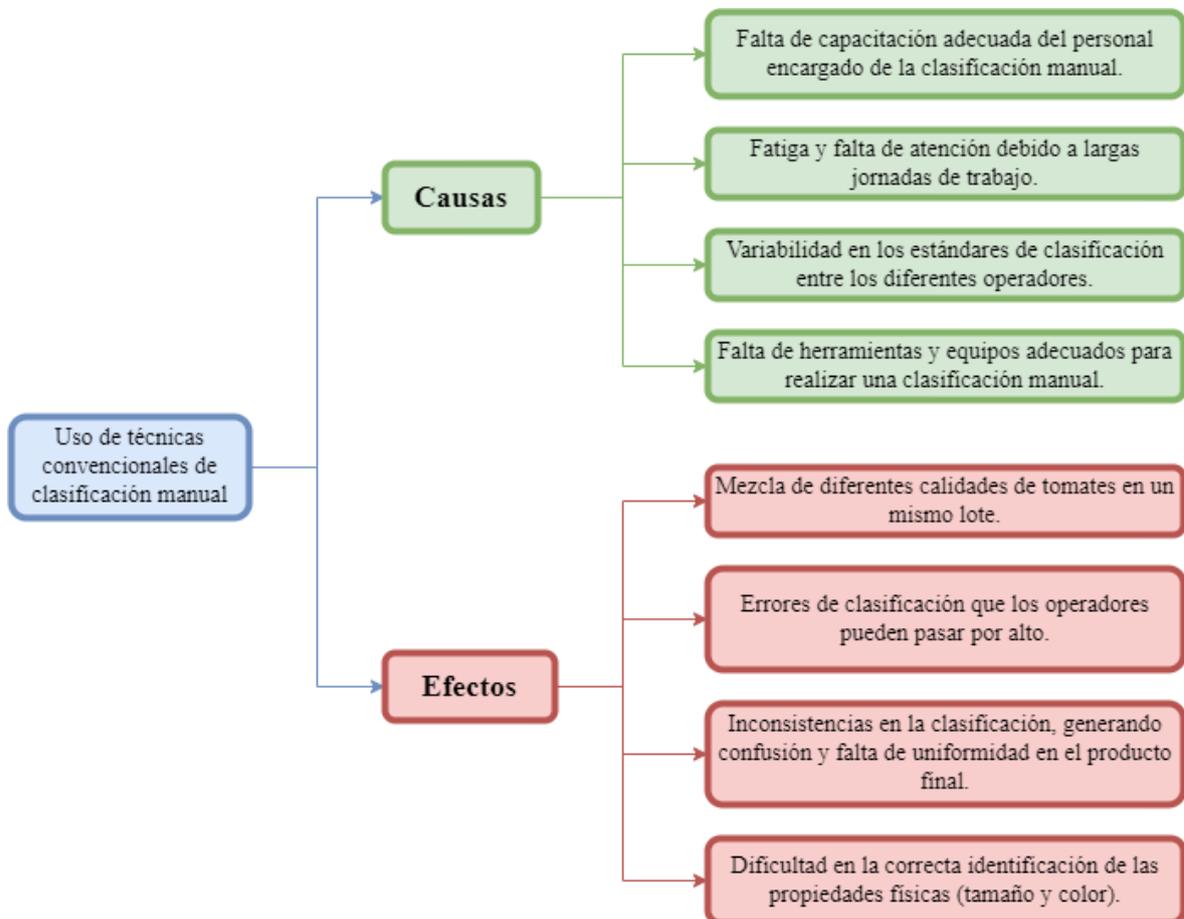


Figura 1: Planteamiento del Problema.

1.2 Justificación

En un esfuerzo por mejorar la eficiencia y reducir costos, los agricultores y productores están adoptando la tecnología para automatizar sus procesos. Actualmente, la clasificación de

tomates se realiza mediante maquinarias especializadas, pero estas no son accesibles para pequeños y medianos productores por su alto costo. Por esta razón, se ha propuesto el desarrollo de un sistema de clasificación automática de tomates riñón que permita clasificar los tomates en tres tipos o tamaños (pequeño, mediano y grande) basado en la norma técnica ecuatoriana INEN 1745 y en dos tipos de colores (verdes y rojos) basado en la experiencia de expertos, utilizando técnicas de visión artificial. Este sistema busca ayudar a los productores de pequeña y mediana escala, y disminuirá los costos de producción, ya que no requerirá de varios operarios para clasificar. La modernización de las técnicas de clasificación hacia métodos automáticos no solo sería beneficiosa para mejorar la calidad del producto final, sino que también contribuiría a la eficiencia operativa, brindando a los productores una ventaja competitiva en el mercado.

1.3 Objetivos

1.3.1 General

- Implementar un prototipo para la clasificación automática de tomates riñón basado en la norma INEN 1745, aplicando técnicas de visión artificial.

1.3.2 Específicos

- Recopilar mediante revisión bibliográfica técnicas, procesos, algoritmos de detección y clasificación de imágenes con visión artificial, seleccionando lo más adecuado para la implementación del sistema de clasificación del tomate riñón.
- Obtener muestras de imágenes válidas del tomate riñón, que permitan extraer características físicas de clasificación con técnicas de visión artificial, para ser procesadas mediante un sistema computacional.
- Construir un prototipo con el hardware y software necesario, integrado con un modelo de visión artificial para clasificar de forma automática el tomate riñón según características físicas de tamaño y color basado en la norma técnica INEN 1745.
- Evaluar el funcionamiento del prototipo a desarrollar, determinando la tasa de error de clasificación obtenida y los intervalos de confianza para validar el proceso de clasificación automática de tomates riñón, mismos que serán proporcionados por un productor local del Cantón Chambo en la Provincia de Chimborazo.

CAPÍTULO II

2.1 Estado del arte

El campo de la visión artificial es una tecnología con una amplia variedad de usos. En [10], se implementó un sistema de control de calidad en una máquina de selección de botellas que clasifica los materiales en aluminio, vidrio y plástico. Para lograr esto, se consideraron factores como la iluminación, la cámara y el software Matlab para procesar las imágenes. El resultado fue un proceso eficiente de control de calidad, que permite reconocer y clasificar las botellas en base a su material y características. Durante el proceso, se utiliza una iluminación difusa para evitar sombras y la clasificación se llevó a cabo con la ayuda de electroválvulas y pistones.

Asimismo, en [11] los autores mencionan que, esta tecnología también es útil en el sector agrícola, específicamente en la industria avícola, donde se requiere una mayor calidad en los productos. Para lograr esto, se creó un prototipo para el control de calidad de huevos de gallina con el fin de clasificarlos como aptos para la incubación. Este sistema se construyó con hardware y software libre y tiene capacidad para analizar 36 huevos a la vez. Se utiliza una cámara digital para escanear los huevos y detectar problemas como fisuras, porosidades excesivas y cáscaras finas. El proceso toma aproximadamente un minuto. Sin embargo, es importante tener en cuenta que, aunque los huevos sean clasificados como aptos, no necesariamente se garantiza que produzcan pollos, ya que otros factores como procesos biológicos, manipulación y equipos también influyen en el resultado final.

El campo de visión e inteligencia artificial han sido intensamente utilizados, y una de sus aplicaciones es la medición de la textura del suelo mediante reflectancia difusa y algoritmos. Esta técnica ha logrado una precisión del 89%, una sensibilidad del 92%, una especificidad del 71% y un error de 11% (identificaciones incorrectas). En la metodología utilizada para medir la textura del suelo, el algoritmo tiene un margen de error de 13.6%, lo que es menor que el margen de error del método tradicional, que es del 33.33%. Esto significa que la incertidumbre y el margen de error son menores con el uso de algoritmos [12].

En el campo de la agricultura, la tecnología de visión e inteligencia artificial tienen una gran influencia. Esto permite la identificación y clasificación de plagas en plantas de tomate riñón. Para ser parte de la Industria 4.0, se han aplicado diferentes procesos y métodos para lograr esta tarea. Para ello, se recolectaron muestras significativas que luego se guardaron en la nube de Google Cloud. Se entrenó el algoritmo de clasificación mediante la plataforma

Google Colab y las librerías TensorFlow, lo que permitió obtener un modelo con una mayor precisión y optimizado para ser ejecutado en tarjetas desarrolladoras. Finalmente, se logró una precisión del 98,438%, mientras que las pruebas realizadas por el personal de campo fueron del 92,54 % de eficacia [13].

De acuerdo con [14], los sistemas de visión artificial también pueden ser utilizados para la identificación por colores, como es el caso de un sistema de clasificación de manzanas en Fresh & Natural C.I. Este sistema utiliza una banda transportadora blanca de grado alimenticio y una cámara web para capturar imágenes, las cuales son procesadas con el software Matlab. Los algoritmos de reconocimiento RGB (Red, Green and Blue) clasifican las manzanas según su madurez (madura, pintón o verde) con una efectividad del 100%.

De igual manera, según [15], se puede usar la tecnología de visión artificial para clasificar objetos por su forma, como lo demuestra un sistema implementado en 2018 para clasificar limones según su forma regulada por la Organización de Comida y Agricultura de las Naciones Unidas. El proceso incluye la adquisición de imágenes, procesamiento, segmentación, descripción, reconocimiento e interpretación de datos, logrando una eficiencia del 83.9% con un tiempo de análisis promedio de 0.33 segundos por limón.

Finalmente, el uso de tecnología de visión artificial también es útil para determinar el estado de un producto, especialmente en el sector agrícola. La investigación demuestra que se pueden utilizar algoritmos de control de calidad para evaluar si los productos están en buen estado para su venta. Para lograr esto, se emplean técnicas de procesamiento de imágenes utilizando el software Matlab. La efectividad del sistema es del 90% con un tiempo promedio de 69.5 segundos por producto evaluado [16].

En conclusión, el campo de la visión artificial ha demostrado ser una herramienta valiosa en la clasificación y análisis de diversos objetos y productos en diferentes sectores. Los estudios realizados en áreas como la clasificación de frutas por madurez o la identificación de plagas proporcionan un marco esencial para desarrollar un prototipo de clasificación de tomates riñón de acuerdo con el tamaño o color. Utilizando las técnicas y conocimientos adquiridos en estos estudios previos, es viable diseñar un sistema para dicho propósito. La experiencia acumulada en la visión artificial se traduce en soluciones más robustas y eficientes para nuevos desafíos.

2.2 Fundamentación Teórica

2.1.1. Clasificación de tomates riñón

La clasificación manual de tomates riñón es un proceso mediante el cual los tomates se seleccionan y se dividen en diferentes categorías basadas en características físicas específicas. Estas características pueden ser: el tamaño, color y la presencia de defectos [4].

2.1.1.1. Norma Técnica Ecuatoriana Voluntaria INEN 1 745

Esta normativa hace referencia a los tomates riñón, los cuales pertenecen a la familia de las Solaceas, género Lycopersicon, especie Esculentum Mill. El propósito principal de este reglamento es establecer los requisitos generales que debe cumplir la hortaliza denominada tomate riñón, para ello se establecen términos variados útiles para clasificar según las propiedades físicas [4].

➤ Clasificación del tomate riñón por tamaños

La clasificación por tamaños del tomate riñón es crucial al momento de comercializar dicho producto en el mercado, para ello la Norma INEN 1745 sugiere una clasificación en tres rangos de medición según el mayor diámetro ecuatorial [4], estos rangos están dados por los siguientes parámetros indicados en la Tabla 1.

Tabla 1: Clasificación del tomate riñón por su tamaño según el diámetro ecuatorial.
Fuente: [4]

TIPO (Tamaño)	Diámetro en mm	
	Mínimo	Máximo
I (grande)	>70	-
II (mediano)	>55	70
III (pequeño)	40	55

La normativa recomienda el uso de herramientas y materiales que faciliten la categorización de los tomates. Uno de estos instrumentos son los calibradores fijos (ver Figura 2), en los cuales se realizan agujeros con los rangos de las medidas de acuerdo con la Tabla 1. Esta configuración establece los 3 tipos de tamaños del diámetro ecuatorial. Es crucial su uso para asegurar el cumplimiento de normas de calidad y comercialización. Además, la adecuada clasificación influirá en el valor de mercado y destino final del producto.

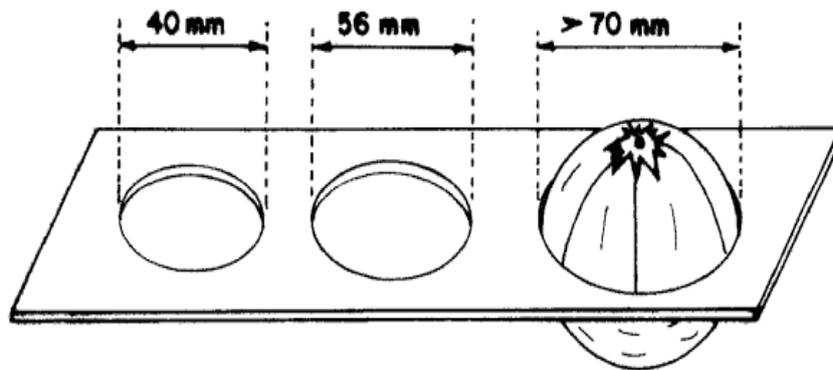


Figura 2: Instrumento de clasificación confeccionado en madera. **Fuente:** [4]

También, existen otras herramientas útiles y de mejor precisión como calibradores digitales (ver Figura 3), a diferencia de los calibradores fijos confeccionados en madera, estos se ajustan al contorno o forma de un objeto y arroja la medida en milímetros o pulgadas.



Figura 3: Calibrador vernier digital.

➤ Clasificación del tomate riñón por colores

La normativa sugiere cuatro etapas para la distinción de la madurez [4], para ello en la Tabla 2 se muestra los porcentajes de referencias de las coloraciones de la superficie del tomate riñón que se identifican mediante la percepción visual y criterio personal del operario ya que no existe una herramienta que defina el porcentaje de coloración ideal para cada tomate.

Tabla 2: Categoría del tomate riñón según el porcentaje de coloración de su superficie.
Fuente: [4]

Característica de Coloración	Coloración en la superficie	Porcentaje de coloración [%]
Tomate verde	Verde	90-100
Tomate pintón	Tonos rojos	40
Tomate rosado	Rosa y/o roja	40-90
Tomate rojo	Roja	90-100

2.1.2. Visión Artificial

Según [17], la visión artificial es un estudio derivado del campo de la Inteligencia Artificial (IA), permite que los ordenadores y sistemas puedan extraer información de imágenes digitales, videos y otras entradas visuales para tomar decisiones a partir de esa información. Por otro lado, el funcionamiento es similar a la visión de un ser humano con la diferencia de que utiliza cámaras, datos y algoritmos para entrenar máquinas para reconocer y comprender las imágenes [17].

2.1.2.1. Importancia y Aplicaciones de la Visión artificial en la automatización

La visión artificial resulta conveniente para automatizar tareas repetitivas y de precisión, lo que puede mejorar la eficiencia y reducir los costos de mano de obra [18]. Algunas aplicaciones comunes de la visión artificial en la automatización incluyen el control de calidad, el seguimiento, clasificación de objetos y el reconocimiento facial.

En los últimos años, esta rama de la Inteligencia Artificial ha ganado terreno en muchas aplicaciones de utilidad y en áreas importantes para el desarrollo, a continuación, se mencionan varias de ellas [19].

- **Seguridad:** Principalmente usado en la videovigilancia de espacios abiertos y cerrados. Los sistemas de videovigilancia inteligentes son capaces de detectar comportamientos anómalos en áreas de inspección seleccionadas por el usuario, como el acceso a zonas restringidas o el control de multitudes [20].
- **Industria:** Comúnmente usado para el montaje de maquinaria, equipos, placas electrónicas o pre-montajes con mucha complejidad. También se utiliza para optimizar y perfeccionar el funcionamiento de los procesos de producción, el control de los activos y el uso de datos de gran valor [21].

- **Medicina:** Con el propósito de mejorar el diagnóstico y el tratamiento de enfermedades. Algunas aplicaciones de la visión artificial en la medicina incluyen el procesamiento de imágenes médicas como radiografías, resonancias magnéticas y tomografías, la cirugía guiada por imagen, la identificación temprana de enfermedades y el análisis de datos médicos [22].

2.1.2.2. Algoritmos de clasificación de objetos

Los algoritmos de clasificación de objetos son técnicas de inteligencia artificial que consiste en analizar datos y organizarlos en categorías o grupos mediante el uso de algoritmos [23]. En este proceso, el sistema aprende de un conjunto de datos de entrenamiento etiquetados y puede identificar patrones y características comunes para clasificar nuevos datos.

➤ **Redes Neuronales Convolucionales (CNN)**

Las Redes Neuronales Convolucionales son una especialización de las redes neuronales multicapa, diseñadas para reconocer patrones directamente desde imágenes con mínimo preprocesamiento [24]. Aprovechan la arquitectura jerárquica de la imagen y emplean convoluciones en lugar de multiplicaciones de matrices en al menos una de sus capas. Su diseño único y su eficiencia las han convertido en una parte integral de numerosos sistemas de inteligencia artificial, permitiendo avances significativos en áreas como el reconocimiento facial, la conducción autónoma y la medicina [25]. Estas redes también se han adaptado para trabajar con datos estructurados y no estructurados, lo que amplía aún más su aplicabilidad.

➤ **Random Forest**

Se trata de un algoritmo de aprendizaje supervisado en el contexto de la inteligencia artificial, particularmente en el ámbito del aprendizaje automático (machine learning). [26]. En la etapa de entrenamiento, dicho algoritmo crea múltiples árboles de decisión y combina sus predicciones con el fin de mejorar tanto la precisión como la capacidad de generalización del modelo resultante. [27]. Cada uno de estos árboles se entrena utilizando un conjunto de datos y características elegidas al azar. Posteriormente, se realiza una votación para establecer la predicción final. La función principal de Random Forest es realizar tareas de clasificación y regresión en situaciones que involucran conjuntos de datos complejos.

➤ **Máquinas de vectores de soporte (SVM)**

Es un algoritmo de aprendizaje automático que se construye extendiendo el concepto de perceptrón. El propósito de una SVM es encontrar un hiperplano, también conocido como límite de decisión, que distinga de la mejor manera posible las clases de datos [28]. La SVM se centra en maximizar el "margen", que es la distancia entre el límite de decisión y los puntos de entrenamiento más cercanos a este, llamados "vectores de soporte" [29]. Al maximizar el margen, la SVM ayuda a prevenir el sobreajuste. En una clasificación binaria, se utilizan dos hiperplanos paralelos al límite de decisión para representar las "clases positivas" y "negativas" [30].

2.1.2.3. Algoritmos de detección de objetos

Los algoritmos de detección de objetos han evolucionado significativamente en los últimos años, con un cambio notable hacia los enfoques basados en el aprendizaje profundo. Los algoritmos modernos como Faster R-CNN (Region based Convolutional Neural Network), YOLO (You Only Look Once) y SSD (Single Shot Multibox Detector) y han demostrado ser altamente efectivos para la detección de objetos en tiempo real en diversas aplicaciones [24].

➤ **Algoritmo Faster R-CNN**

El algoritmo Faster R-CNN, es una mejora de sus predecesores R-CNN y Fast R-CNN, es una innovación significativa en la detección de objetos por su eficiencia y precisión. Utiliza una red convolucional profunda para extraer características de la imagen, una "Region Proposal Network" (RPN) para identificar posibles ubicaciones de objetos, y otra red convolucional para clasificar y ubicar con precisión dichos objetos [31].

➤ **Algoritmo YOLO**

You Only Look Once o Solo mira una vez, es un algoritmo de aprendizaje profundo que se usa para detectar objetos en imágenes en tiempo real y con alta precisión [32]. A diferencia de otros algoritmos que usan regiones propuestas o deslizan ventanas para localizar objetos, YOLO divide la imagen en una cuadrícula y predice las coordenadas y las clases de los objetos en cada celda usando una sola red neuronal convolucional.

➤ **Algoritmo SSD**

El algoritmo detector de disparo único o SSD (Single Shot Multibox Detector) es una metodología revolucionaria que utiliza una única red neuronal convolucional para identificar y localizar objetos en una imagen, sin importar su escala o proporciones [33]. A diferencia de los algoritmos tradicionales de dos etapas, SSD realiza la detección en un solo paso, lo

que lo hace increíblemente rápido y eficiente. Aplica una serie de filtros de diferentes tamaños en la última capa de la red para detectar objetos de diversas dimensiones en la imagen.

➤ **Comparaciones entre algoritmos de detección**

En la Tabla 3 se presenta una comparación de los tres modelos de detección de objetos en tiempo real más utilizados en aplicaciones de visión artificial.

Tabla 3: Comparación de características entre algoritmos de detección. **Fuente:** [31]–[33]

Características	Faster R-CNN	YOLO	SSD
Método de detección	Basado en dos pasadas	Basado en una única pasada	Basado en una única pasada
Velocidad de detección	Moderada, requiere más tiempo de cálculo	Muy rápida, adecuada para tiempo real	Rápida, similar a YOLO
Precisión de detección	Alta precisión, especialmente en objetos pequeños	Menos precisa en objetos pequeños	Buena precisión en objetos de diferentes tamaños
Número de regiones propuestas	Utiliza regiones propuestas (RPN)	No utiliza regiones propuestas	No utiliza regiones propuestas
Tamaño de red neuronal	Grande	Moderado	Pequeño
Uso de recursos de hardware	Requiere más recursos de hardware	Requiere menos recursos de hardware	Requiere menos recursos de hardware
Facilidad de implementación	Requiere más conocimiento técnico	Fácil de implementar y utilizar	Fácil de implementar y utilizar
Rendimiento en tareas generales	Buen rendimiento en tareas generales	Buen rendimiento en tareas generales	Buen rendimiento en tareas generales

2.1.2.4. Procesamiento digital de imágenes con visión artificial

Se refiere al conjunto de técnicas y algoritmos utilizados para manipular y transformar imágenes digitales mediante el uso de una computadora. Estas técnicas se aplican a las

imágenes para mejorar su calidad, extraer información útil, realizar análisis y reconocimiento de patrones, y en general, obtener información visual significativa. Un componente básico de una imagen digital es el píxel. Cada imagen digital tiene un número finito de píxeles, cada uno con una ubicación y un valor específico [27]. Las etapas básicas para el procesamiento digital de imágenes con visión artificial se pueden apreciar en la Figura 4.

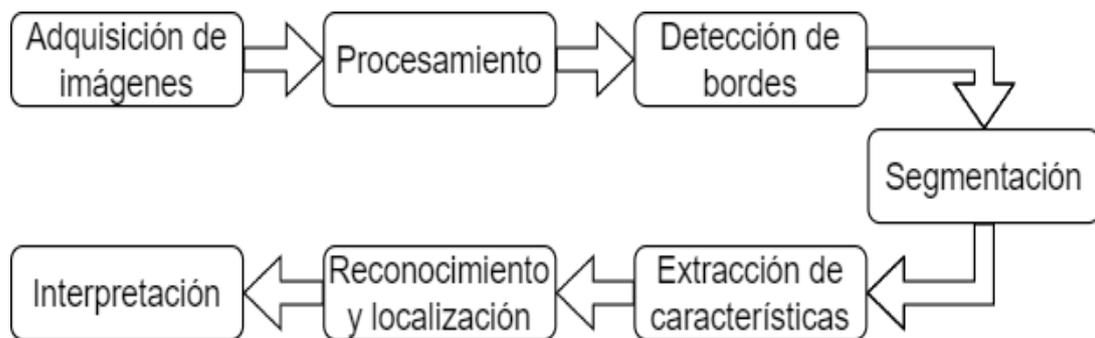


Figura 4: Etapas de un sistema de visión artificial.

- **Adquisición de imágenes:** Esta etapa implica la captura de imágenes mediante cámaras o sensores.
- **Procesamiento:** Las imágenes se procesan mediante técnicas de procesamiento de imágenes y visión por computadora.
- **Detección de bordes:** Se refiere a un conjunto de técnicas matemáticas que se utilizan para encontrar los límites o curvas en una imagen digital cuando hay cambios bruscos en el brillo de la imagen o discontinuidades.
- **Segmentación:** La segmentación de objetos implica la identificación y separación de objetos individuales en la imagen.
- **Extracción de características:** En esta etapa se extraen características de los objetos segmentados, como su forma, tamaño y textura.
- **Reconocimiento y localización:** Esta etapa se encarga de identificar y localizar objetos en una imagen o video. El proceso se realiza mediante la extracción de características de la imagen y la comparación con un modelo previamente entrenado.
- **Interpretación:** La interpretación implica la identificación de objetos y patrones en una imagen, así como la comprensión del contexto en el que se encuentra la imagen.

➤ Componentes de un sistema de procesamiento de imágenes

Para el procesamiento de imágenes se tiene varios componentes. En la Figura 5, se muestra los componentes básicos que comprenden un sistema de propósito general típico utilizado para el procesamiento de imágenes digitales [34].

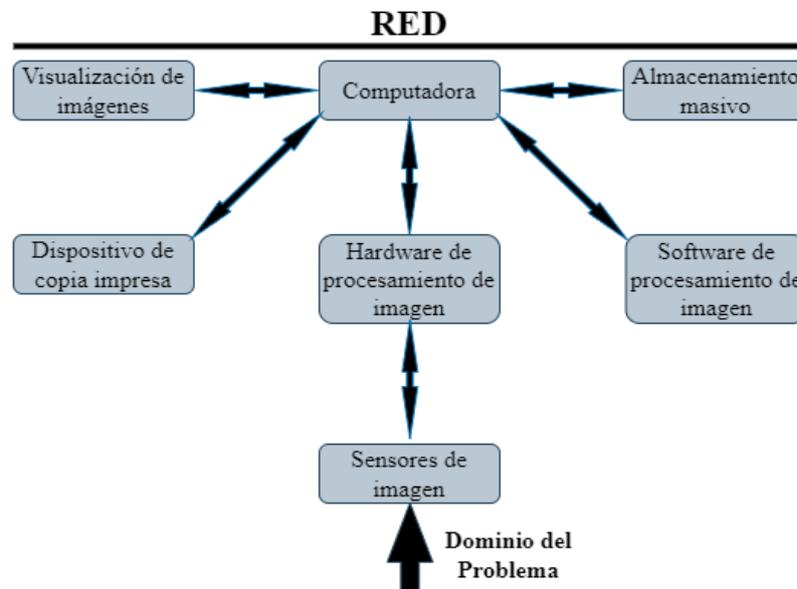


Figura 5: Componentes de un sistema de procesamiento de imágenes. **Fuente:** [34]

- **Sensores de imagen:** Se encargan de convertir la luz en señales eléctricas para crear imágenes digitales. Son esenciales en cámaras, escáneres y dispositivos de captura de imágenes. Capturan la luz a través del lente y luego procesan la imagen para mejorarla, corregir distorsiones o eliminar elementos no deseados.
- **Visualización de imágenes:** Es la representación gráfica de una imagen digital para mejorar la comprensión. Utiliza matrices numéricas que contienen información de los píxeles. La visualización incluye mejoras en claridad, contraste y color. Hay herramientas desde visualizadores 2D hasta avanzadas técnicas 3D interactivas.
- **Computadora:** Es un sistema informático que utiliza software y hardware especializados para editar, analizar y mejorar imágenes digitales. Es esencial en campos como la medicina, la investigación, la fotografía y la industria del entretenimiento. Su uso permite tomar decisiones precisas y crear contenido digital de calidad.
- **Hardware de procesamiento de imagen:** El procesamiento digital de imágenes requiere tecnología especializada y dispositivos de alto rendimiento para realizar tareas complejas en tiempo real. Esto incluye hardware como DSP, GPU, SoC,

FPGAs y ASICs, que son ideales para aplicaciones de alta velocidad y capacidad de cálculo en campos como inteligencia artificial, robótica y medicina.

- **Software de procesamiento de imagen:** Permite editar, mejorar, analizar y reconocer patrones en imágenes digitales. Programas como Adobe Photoshop, GIMP, ImageJ y MATLAB son utilizados en diversos campos para realizar tareas complejas de manera eficiente, facilitando decisiones precisas y creación de contenido de calidad.
- **Dispositivos de copia impresa:** Son esenciales para generar copias físicas de imágenes digitales. Estos incluyen impresoras, fotocopadoras y plotters que utilizan tecnologías como inyección de tinta, láser y térmica. Se utilizan en campos como fotografía, publicidad y educación.
- **Almacenamiento masivo:** Esta etapa se realiza mediante dispositivos externos como discos duros, unidades flash y almacenamiento en la nube. Para obtener copias físicas, se utilizan impresoras, fotocopadoras y plotters. Se requiere hardware y software especializados para capturar, procesar y analizar imágenes digitales en diversos campos como fotografía, medicina y ciencia.

➤ **Espacios de colores**

Un modelo de color es un enfoque matemático que representa colores como números en grupos de tres o cuatro valores. Cada modelo se asocia con un "espacio de color" que describe cómo se mostrarán los colores [35]. Los espacios de color comunes usados en el procesamiento de imágenes son: GRAY, RGB y HSV. La conversión entre estos espacios se realiza mediante funciones de transformación. A continuación, se describen brevemente los espacios de color más utilizados en aplicaciones actuales.

- **GRAY:** El espacio de color GRAY, utilizado en imágenes digitales, representa cada píxel mediante una única intensidad de luz, variando desde el negro absoluto (valor 0) hasta el blanco absoluto (valor 255). Con 256 niveles de intensidad, esta escala de grises permite representar una amplia gama de tonos de gris. Es comúnmente utilizado en el procesamiento de imágenes cuando la información del color no es relevante, enfocándose en la luminosidad y la representación tonal de la imagen.
- **RGB:** Es ampliamente utilizado en imágenes digitales. Cada píxel se describe mediante una mezcla de intensidades de luz para los colores rojo, verde y azul. Con valores de intensidad de 0 a 255, se pueden representar más de 16 millones de colores. Este modelo es común en el procesamiento de imágenes digitales.

- **HSV:** El espacio de color HSV (Hue, Saturation, Value) describe los colores en términos de tono, saturación y valor. Se utiliza en el procesamiento de imágenes para manipular y seleccionar colores, lo que facilita la detección y segmentación de objetos en aplicaciones de imagen.

➤ **Histograma de color**

Según [36], en el ámbito de la visión artificial, un histograma de color es un gráfico que mide la frecuencia de las diferentes tonalidades en una imagen digital. Cada color tiene una barra en el histograma, y la altura de esa barra refleja la cantidad de píxeles que tienen dicho color. Esta herramienta es clave para analizar y trabajar con imágenes, permitiendo acciones como la modificación del color, la segmentación de la imagen y la categorización de imágenes basadas en la distribución del color.

➤ **Operaciones entre imágenes con OpenCV**

Las operaciones realizadas entre imágenes utilizando la biblioteca OpenCV, conocida como Open Source Computer Vision Library, engloban una amplia gama de manipulaciones y transformaciones que se pueden aplicar a las imágenes. OpenCV es una biblioteca de código abierto muy reconocida y ampliamente empleada en el campo del procesamiento de imágenes y la visión por computadora [37]. Algunas de las operaciones comunes que se pueden realizar con OpenCV en imágenes incluyen:

- **Suma y resta de imágenes:** Se pueden combinar dos imágenes mediante la suma o resta de los valores de píxeles correspondientes en cada imagen. Esto puede ser útil para realizar operaciones de mezcla, fusión o corrección de imágenes.
- **Multiplicación y división de imágenes:** Se pueden multiplicar o dividir los valores de píxeles de dos imágenes para obtener una nueva imagen resultante. Esto se puede utilizar para aplicar máscaras, ajustar el contraste o realizar operaciones de realce en imágenes.
- **Operaciones lógicas:** Son las diferentes operaciones lógicas como AND, OR, XOR y NOT que se pueden aplicar a los valores de píxeles de dos imágenes. Estas operaciones son útiles para combinar y comparar imágenes en función de ciertos criterios.
- **Transformaciones geométricas:** Se refiere a las transformaciones geométricas, como rotación, escala, traslación, deformación y perspectiva. Estas transformaciones

permiten modificar la geometría de las imágenes para corregir la perspectiva, ajustar el tamaño o la orientación, y realizar otras manipulaciones espaciales.

- **Filtros y operaciones de convolución:** Consiste en los métodos para aplicar diversos filtros y operaciones de convolución a las imágenes. Estos incluyen suavizado (blur), realce de bordes (edge detection), detección de características (feature detection), entre otros. Estas técnicas se utilizan para mejorar la calidad de la imagen, resaltar características importantes o extraer información específica.

2.1.3. Entorno de iluminación controlada

Este aspecto es muy importante para el procesamiento de imágenes ya que se refiere a un ambiente donde se pueden manipular y ajustar ciertos parámetros para facilitar la adquisición y el procesamiento de imágenes [23]. Al controlar factores como la iluminación, la posición de la cámara, el sujeto, el fondo, entre otros, se puede mejorar la precisión y la eficiencia de los algoritmos de visión artificial.

- **Iluminación:** Este es un aspecto crucial en un escenario controlado. Al manipular la intensidad, la dirección y la calidad de la luz, se puede resaltar ciertas características del objeto y suprimir las no deseadas. Además, la iluminación constante ayuda a obtener resultados consistentes.
- **Posicionamiento de la Cámara:** La posición y orientación de la cámara respecto al objeto también son factores importantes. El ángulo de la cámara puede afectar la apariencia del objeto en la imagen, por lo que debe ser ajustado adecuadamente.
- **Fondo:** Un fondo uniforme y contrastante puede facilitar la detección y segmentación del objeto de interés.
- **Preparación del Objeto:** En algunos casos, el objeto puede necesitar ser preparado, por ejemplo, al aplicar una capa de pintura para aumentar el contraste o al colocar marcadores para facilitar el seguimiento.

2.3 Plataforma de desarrollo Google Colab

Colaboratory, comúnmente conocido como Google Colab, es una herramienta desarrollada por Google Research [38]. Proporciona un entorno en el que cualquier individuo puede desarrollar y ejecutar código de Python directamente en su navegador web. Es muy eficaz para tareas relacionadas con el aprendizaje automático, la evaluación de datos y la enseñanza [39]. Desde un punto de vista técnico, Colab es una plataforma basada en la nube para cuadernos Jupyter [40], que se puede utilizar sin necesidad de configuración previa.

En la Figura 6 se presenta la estructura de Google Colab. Dado que está hospedado en la infraestructura de Google, Colab ofrece una integración fluida con repositorios prominentes como GitHub y Google Drive. Esta interconexión facilita tanto el almacenamiento como la importación de datos directamente en el entorno del cuaderno de Jupyter proporcionado por Colab. Gracias a su amplio soporte para las bibliotecas de Python, los usuarios pueden acceder a Colab a través de un navegador web y aprovechar al máximo los recursos y herramientas avanzadas que la plataforma proporciona, consolidando su posición como una herramienta esencial para la investigación y el aprendizaje en ciencia de datos.

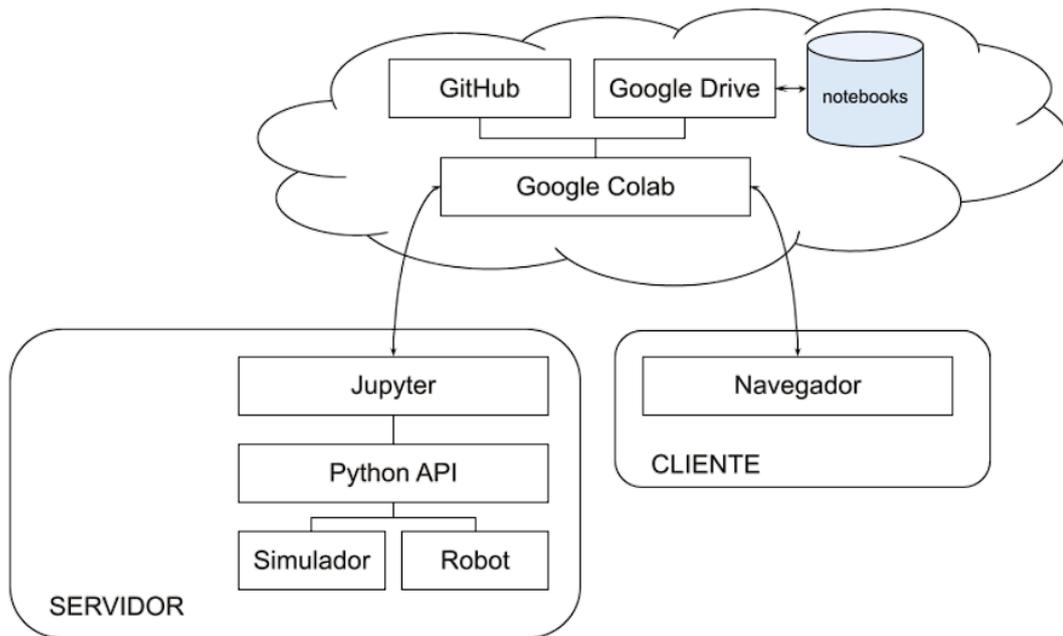


Figura 6: Estructura de Google Colab. **Fuente:** [39]

CAPÍTULO III

3.1 Metodología

3.1.1. Tipo de investigación

El presente estudio se trata de una investigación experimental y cuantitativa enfocada en la implementación de un prototipo que utiliza técnicas de visión artificial y procesamiento de imágenes para clasificar tomates riñón automáticamente. El propósito principal es categorizar estos tomates según su tamaño y color. Esta iniciativa surge de la necesidad de brindar a los pequeños y medianos productores una herramienta que les permita clasificar sus productos con mayor exactitud, alineándose con los estándares establecidos por la normativa INEN 1745. A través de este proyecto, se busca recolectar y analizar datos pertinentes que evalúen de manera efectiva el rendimiento y fiabilidad del prototipo propuesto.

3.1.2. Diseño de la investigación

Este proyecto de investigación se desarrolló en 4 etapas, a continuación, se presenta un esquema (ver Figura 7).

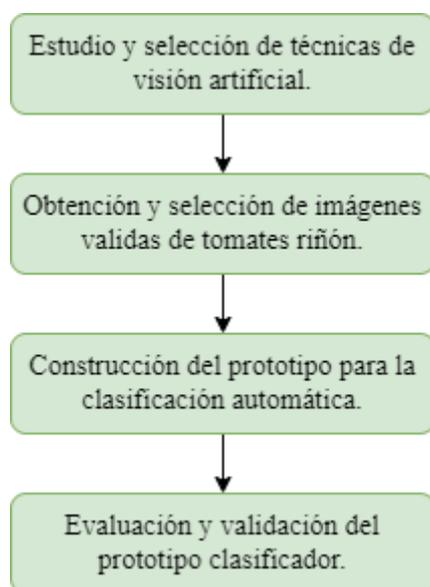


Figura 7: Diseño de la investigación.

La primera etapa de desarrollo involucró el estudio y la selección de trabajos de investigación relacionados. A través de este proceso, se recopiló técnicas, procedimientos y algoritmos para la detección y clasificación de imágenes en tiempo real utilizando visión artificial. Este

conocimiento fue crucial para entender los conceptos básicos necesarios para el desarrollo de este proyecto.

En la segunda fase, se procedió a la recolección de imágenes pertinentes destinadas al entrenamiento del sistema detector de tomates riñón. Estas imágenes se obtuvieron directamente de un invernadero ubicado en el Cantón Chambo, Provincia de Chimborazo.

La tercera etapa del proyecto se enfocó en el diseño y construcción del prototipo de clasificación. La selección del hardware involucra el diseño de la estructura de la cinta clasificadora, que incorpora componentes necesarios para clasificar cada tomate según su tamaño y color. Mientras que, el desarrollo del software está comprendido por el sistema de detección en conjunto con el algoritmo de clasificación desarrollado en los lenguajes de programación Python y C.

En la fase final, se llevaron a cabo pruebas rigurosas para validar la eficiencia del prototipo conforme a los criterios preestablecidos. Se garantizó que el sistema presentara un margen de error mínimo, el cual resultó ser tolerable, especialmente al contrastarlo con las imprecisiones del método de clasificación manual.

3.1.3. Métodos de la investigación

3.1.3.1. Investigación experimental

Este proyecto de investigación se clasifica como experimental, dado que facilitó el control riguroso de escenarios y parámetros de las variables involucradas. Esta estructura permitió obtener resultados más precisos y alineados con los objetivos planteados.

3.1.3.2. Investigación cuantitativa

Con la puesta en marcha del prototipo implementado, se recolectó datos cuantitativos relacionados con las medidas de los diámetros transversales de los tomates riñón, permitiendo identificar el rendimiento del prototipo, basándose en los estándares de la normativa ecuatoriana INEN 1745.

3.1.4. Técnicas de recolección de datos

3.1.4.1. Fuentes de información

Se hizo una revisión bibliográfica para recopilar información pertinente sobre técnicas, procesos y algoritmos empleados en la detección y clasificación de objetos. Esta búsqueda se fundamentó en diversas fuentes académicas, artículos científicos, tesis y otros trabajos de

investigación. También para la parte de experimentación se consultó a expertos en la clasificación de tomates riñón.

3.1.4.2. Instrumentos de recolección de datos

Para registrar las mediciones, se empleó una hoja de registro en la que se consignaron los datos proporcionados por el calibrador digital, el prototipo y el operario (ver Anexo 5). Estos datos, esenciales para el estudio, consolidaron todas las mediciones derivadas de las pruebas de evaluación. Posteriormente, se transcribieron a un formato digital para facilitar el análisis estadístico.

3.1.5. Población de estudio y tamaño de la muestra

3.1.5.1. Población

La población de estudio se conformó por un conjunto finito de datos de mediciones de tamaño y color de tomates riñón que se obtuvieron en el interior del invernadero situado en el cantón Chambo, provincia de Chimborazo. En este invernadero se cosechan cada 2 días un aproximado de 6 cajas, conteniendo 150 tomates riñón cada una. La población se conformó de 3600 datos obtenidos al medir las propiedades físicas de los tomates en un periodo de pruebas de 8 días.

3.1.5.2. Muestra

La muestra se conformó por un subconjunto de la población de estudio, la misma que se obtuvo seleccionando tomates de manera aleatoria de las cajas recolectadas. Esta selección permitió determinar la tasa de error al clasificar automáticamente los tomates riñón en función de sus propiedades físicas, como el tamaño y el color.

$$n = \frac{Z^2 * N * p * q}{Z^2 * p * q + (N - 1) * \varepsilon^2} \quad (3.1)$$

n = Muestra

N = Población (3600)

Z = Valor estandarizado con un nivel de confianza (1.96)

p = La posibilidad de que un individuo de la población sea incluido en la muestra (0.5)

q = La posibilidad de que un individuo de la población no sea incluido en la muestra (0.5)

ε = Error (0.07)

$$n = \frac{1.96^2 * 3600 * 0.5 * 0.5}{1.96^2 * 0.5 * 0.5 + (3600 - 1) * 0.07^2} \quad (3.2)$$

$$n = 185.9 \quad (3.3)$$

$$\text{tamaño de muestra utilizada } n = 200 \quad (3.4)$$

3.1.6. Operacionalización de las variables

En la Tabla 4, se detalla la operacionalización de las variables a utilizar en este proyecto de investigación, mismas que serán de utilidad para la comprobación de los datos y resultados que se obtengan para el apartado del capítulo 4.

Tabla 4: Operacionalización de las variables.

VARIABLE	CONCEPTO	INDICADORES	TÉCNICAS E INSTRUMENTOS
INDEPENDIENTE			
Método utilizado de clasificación	La forma y los instrumentos que se utilizan para medir las propiedades de los tomates.	Tipo: Automático con el sistema implementado y manual con el método de observación basado en experiencia.	Por observación.
DEPENDIENTE			
Tasa de Error en la clasificación	Es la comparación porcentual entre los tomates clasificados por el dispositivo respecto a los tomates clasificados con el calibrador y el experto.	Esta comprendida por el porcentaje de error [%Error].	Observación usando un calibrador, observación directa y a través del sistema con el software.

3.2 Desarrollo y Funcionamiento del Dispositivo

El prototipo de clasificación automática de tomates riñón está dividido en 4 etapas: la primera etapa correspondió a la selección de imágenes válidas y el entrenamiento del modelo de detección, la segunda etapa consistió en el procesamiento de imágenes y desarrollo de los algoritmos de clasificación de colores y tamaños, el algoritmo de control de dispositivos del prototipo clasificados para el prototipo de clasificación, también se elaboró una interfaz gráfica para el usuario; finalmente, la tercera etapa fue la selección de hardware necesario, el diseño e implementación del prototipo el cual se conformó por una banda de transporte, la recámara de aislamiento de luz externa y la tolva de distribución automática. Se utilizó los lenguajes de programación Python y C, se desarrolló un software con una interfaz de usuario personalizada.

3.2.1. Selección de imágenes válidas y entrenamiento del modelo de detección

Esta etapa de selección de imágenes válidas fue fundamental para el entrenamiento del modelo, para ello se dividió en 5 fases de acuerdo con la Figura 8.

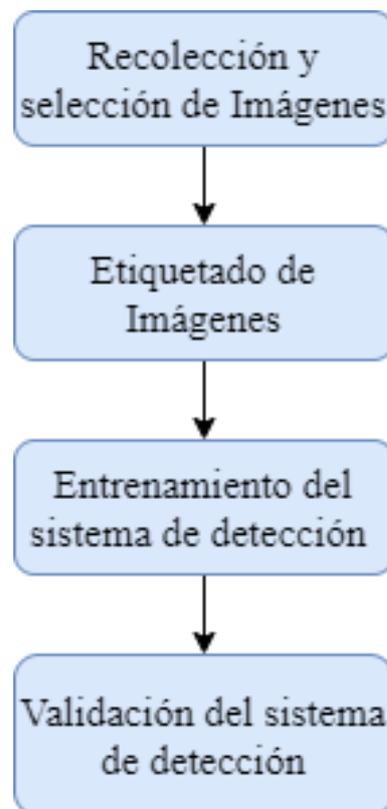


Figura 8: Selección de imágenes y entrenamiento del modelo de detección.

3.2.1.1. Recolección y selección de Imágenes

Esta etapa correspondió a la recolección de imágenes, para ello se acudió al invernadero de cultivos de tomate riñón ubicado en el cantón Chambo, provincia de Chimborazo en las coordenadas -1.737676 , -78.607577 . Allí, se recolectaron de forma aleatoria una amplia cantidad de imágenes de los tomates en diferentes etapas de crecimiento y condiciones. Con este esfuerzo, se capturaron 600 imágenes, de las cuales 420 fueron empleadas para entrenar el sistema de detección y 180 para las pruebas de validación. Para la recolección de imágenes se consideraron las características físicas como el tamaño, color y formas de los tomates, no se consideraron tomates en mal estado para este estudio debido a que, los operarios no seleccionan este tipo para su venta. La amplia variedad de datos recolectados sirvió para desarrollar un modelo de detección de tomates riñón en tiempo real. En la Figura 9 se observa una pequeña parte del conjunto total de imágenes utilizadas para el entrenamiento del modelo de detección.



Figura 9: Selección de imágenes válidas para el entrenamiento del modelo.

3.2.1.2. Proceso de etiquetado en las imágenes

El siguiente paso consistió en etiquetar cada región de interés (ver Figura 10) presente en las imágenes recolectadas. Para esto, se utilizó la herramienta en línea llamada MakeSenseAI. Esta herramienta permite etiquetar mediante la asignación de un nombre a las clases en las imágenes de manera eficiente. Una vez etiquetados los tomates en las imágenes, la herramienta proporciona archivos *nombre_de_imagen.txt* el cual contiene las ubicaciones exactas de los objetos en dicha imagen.



Figura 10: Etiquetado de imágenes en MakeSenseAI.

3.2.1.3. Entrenamiento del sistema de detección

Para el entrenamiento del sistema de detección se usó la arquitectura de YOLOv5 debido a su velocidad y eficiencia en la detección de objetos en tiempo real, también porque es fácil de implementar y entrenar. Esta arquitectura utiliza pocos recursos en ordenadores menos

potentes, su eficacia para detectar objetos en imágenes da resultados precisos en la identificación en las imágenes en tiempo real (ver Tabla 5).

Tabla 5: Aspectos considerados para el uso de la arquitectura YOLOv5

Aspectos	Detalles
Velocidad de procesamiento	YOLOv5, al ser rápido, permite un mejor análisis en tiempo real.
Precisión elevada	Asegura una detección con exactitud, minimizando falsos positivos y negativos.
Flexibilidad	Puede detectar objetos de diferentes tamaños.
Soporte para entrenamiento	Permite entrenar el sistema con un conjunto de datos específicos.
Eficiencia en el uso de recursos	Adecuado para sistemas con recursos limitados.
Escalabilidad	Puede ser utilizado en sistemas más grandes.
Adaptabilidad	Es capaz de detectar objetos bajo diferentes condiciones de iluminación y perspectivas.

➤ **Proceso para el entrenamiento del sistema de detección**

Para obtener un sistema de detección de tomates riñón, se utilizó el algoritmo antes mencionado, el cual mediante una base de datos de imágenes y etiquetas guardadas en Google drive para ser exportados a la plataforma de Google Colab, de esta manera se detalla a continuación el procedimiento.

- El primer paso consistió en preparar el entorno Jupyter para trabajar con el modelo YOLOv5. Se clonó el repositorio, luego se instaló las dependencias necesarias, e inicializó el cuaderno para trabajar con YOLOv5.

```

!git clone https://github.com/ultralytics/yolov5 # clone
%cd yolov5
!pip install -qr requirements.txt # install

import torch
import utils
display = utils.notebook_init() # checks

YOLOv5 v7.0-225-gbb9706e Python-3.10.12 torch-2.0.1+cu118 CUDA:0 (Tesla T4, 15102MiB)
Setup complete (2 CPUs, 12.7 GB RAM, 26.3/78.2 GB disk)

```

Figura 11: Comando para clonar el modelo YOLOv5 en el cuaderno de Google Colab.

- El segundo paso consistió en el montaje de Google Drive en el entorno de Google Colab para acceder a los archivos almacenados directamente de las imágenes y archivos de etiquetas desde el entorno.

```

from google.colab import drive
drive.mount('/content/drive')

Mounted at /content/drive

!unzip "/content/drive/MyDrive/Entrenamiento_modelo_deteccion/train_data.zip" -d "/content/"

```

Figura 12: Comandos para el montaje de Google Drive en Colab.



Figura 13: Carga de imágenes y etiquetas en la plataforma de Google Colab.

- Finalmente, el último proceso de entrenamiento consistió en ejecutar el modelo de YOLOv5 en donde se ejecuta la línea de código de la Figura 14. Aquí se establecieron los parámetros necesarios como el número de épocas que fueron 50 y tamaño del lote 32, estos parámetros permitieron un ajuste correcto del modelo.

```
# Train YOLOv5s for # epochs
!python train.py --img 640 --batch 32 --epochs 50 --data customdata.yaml --weights yolov5s.pt --cache
```

Figura 14: Comando para inicializar el entrenamiento del modelo de detección.

Al finalizar el entrenamiento de este sistema, se obtuvieron dos archivos *last.pt* y *best.pt*, del cual se seleccionó el *best.pt* denominado como el mejor u óptimo para su aplicación.

3.2.1.4. Validación del sistema de detección

Finalmente, se procedió a la etapa final correspondiente a la validación del sistema entrenado. En esta etapa, se probó el funcionamiento utilizando un conjunto de imágenes que no se habían utilizado durante la fase de entrenamiento. El propósito de esta prueba fue evaluar la fiabilidad y precisión del modelo en la identificación de tomates en nuevas imágenes, proporcionando una efectividad adecuada del modelo para este proyecto.



Figura 15: Test del sistema para la detección de tomates.

En la validación de detección (ver Figura 15), el sistema ha identificado como tomates en cada una de las imágenes, la mayoría de los tomates detectados muestran un nivel de confiabilidad mayor al 80%, salvo en algunas circunstancias en las que el sistema no logró diferenciar los tomates correctamente debido a que no están bien posicionados en las imágenes.

3.3 Selección del hardware necesario para la implementación del prototipo

El diseño e implementación del prototipo está formado de una infraestructura que consta de varios sistemas para lo cual se ha seleccionado varios componentes para el funcionamiento (ver Figura 16), para ello se han seleccionado el hardware necesario que se describe en las secciones a continuación.

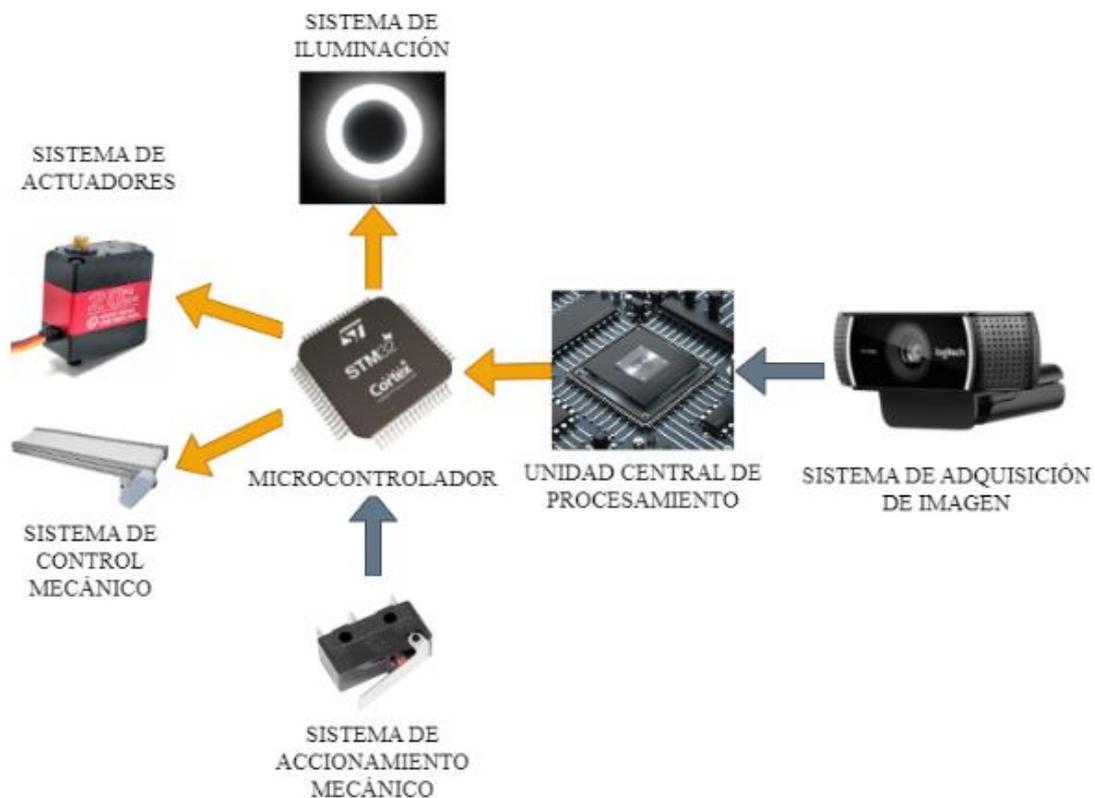


Figura 16: Infraestructura de hardware del prototipo.

3.3.1. Componentes de hardware para el procesamiento de imágenes y clasificación del prototipo

3.3.1.1. Unidad Central de Procesamiento (CPU)

La Unidad Central de Procesamiento utilizado en este proyecto es el portátil HP Victus con procesador Ryzen 7 el cual ofrece un excelente rendimiento. Este modelo fue elegido debido

a su potencia en procesamiento y gráficos, además de su capacidad de memoria para manejar grandes conjuntos de datos, sus especificaciones técnicas se aprecian en la Tabla 6.

Especificaciones Técnicas:

Tabla 6: Características técnicas Laptop HP Victus.

Características	Detalles
Procesador	AMD Ryzen 7 5800H de ocho núcleos
Velocidad del procesador	3.2 GHz - 4.4 GHz
RAM	16 GB DDR4 SDRAM a 3200 MHz
Almacenamiento	SSD PCIe NVMe de 512 GB
Pantalla	Pantalla FHD 144Hz IPS de 16.1 pulgadas (1920 x 1080)
Tarjeta Gráfica	NVIDIA GeForce RTX 3050 Ti con 4 GB de VRAM
Conectividad	Wi-Fi 6 (802.11ax), Bluetooth 5.2
Puertos	1 x HDMI, 1 x USB 3.2 Gen 2 Type-C, 3 x USB 3.2 Gen 1 Type-A, 1 x RJ-45
Sistema operativo	Windows 11 Home

3.3.1.2. Tarjeta de desarrollo

El uso del microcontrolador STM32F103C8T6 o BluePill fue ideal para este proyecto debido a su capacidad para controlar los diferentes mecanismos del prototipo, gracias a su procesamiento en tiempo real, su eficiencia energética y su gran número de pines de entrada/salida. Su amplio soporte de software facilitó la programación y configuración. Sus especificaciones importantes se aprecian en la Tabla 7.

Especificaciones técnicas:

Tabla 7: Características técnicas tarjeta de desarrollo BluePill.

Características	Detalles
Arquitectura	ARM Cortex-M3 de 32 bits
Velocidad de reloj	Hasta 72 MHz
Memoria Flash	64 KB
Memoria RAM	20 KB
Interfaces de comunicación	UART, SPI, I2C

ADC	12 bits, 16 canales
PWM	Hasta 16 canales
Timers	Hasta 7 timers de 16 bits
GPIO	37 pines
Alimentación	2.0 - 3.6 V

3.3.2. Sistema de aislamiento de iluminación exterior y sistema de adquisición de imágenes

El desarrollo de un sistema para adecuar la detección de los tomates resulta necesario debido a que evita la iluminación exterior, para lo cual se realizó una recámara en donde se pueda controlar la iluminación (ver Figura 17) de forma que ayude en el procesamiento de imágenes, de esta manera se aísla el entorno exterior con el entorno interior.

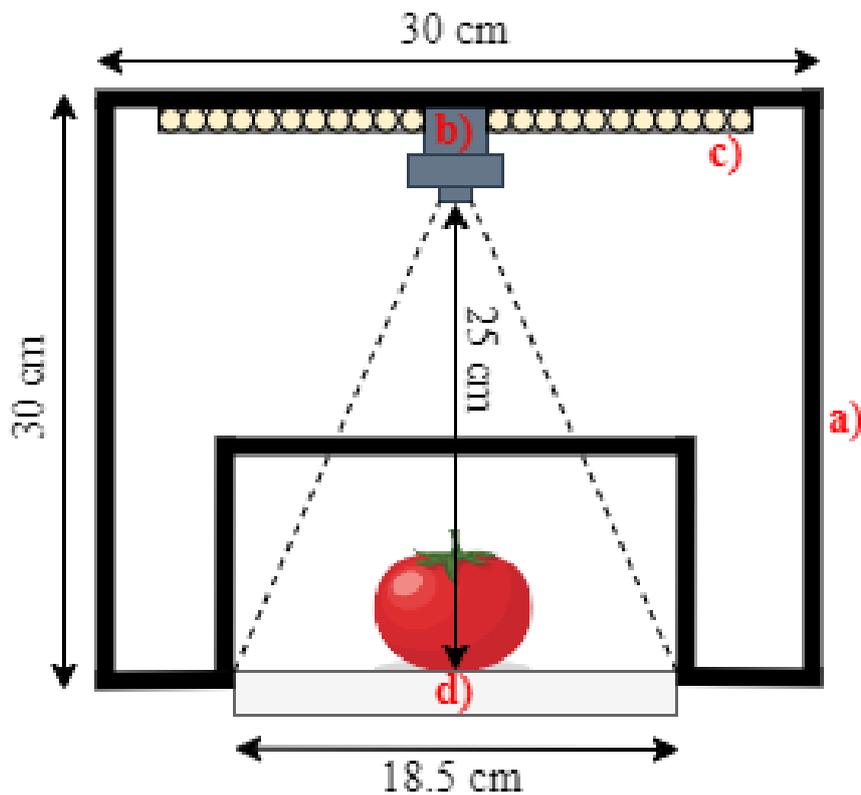


Figura 17: Adecuación del sistema de iluminación. a) Caja de aislamiento exterior, b) Sistema de adquisición de imágenes, c) Sistema de iluminación, d) Banda transportadora.

El sistema de aislamiento se construyó en tol galvanizado con una entrada y salida para que los tomates pasen por esta sobre la cinta transportadora, cuyas dimensiones son 30 cm de alto, 30 cm de largo y 30 cm de profundidad.

El aro de luz utilizado tiene un diámetro de 26 cm, cuenta con tres tonos de iluminación: blanco frío, blanco neutro y cálido, acompañado de diez niveles de intensidad (ver Figura 18), fue ubicada en la parte superior interna a 30 cm de la superficie de la banda en la recamara de reconocimiento. Su uso resulta adecuado para la aplicación del proyecto, pues proporciona iluminación uniforme aceptable y ajustable dentro de la recamara.



Figura 18: Aro de iluminación de intensidad regulable.

Para la adquisición de imágenes se ha seleccionado la webcam Logitech C922 Pro por sus especificaciones (ver Tabla 8), la calidad de imagen que proporciona es excelente, tiene enfoque manual/automático y corrección de luz que pueden ser ajustados con el software Logitech G Hub, ideal para este proyecto. Ofrece imágenes claras y precisas. La ubicación de esta es fundamental, fue colocada a 25 cm de altura desde la superficie de la banda de manera que quede centrada dentro de la recamara de iluminación controlada.



Figura 19: Dispositivo de adquisición de imágenes webcam Logitech C922Pro.

Especificaciones técnicas:

Tabla 8: Especificaciones técnicas webcam Logitech C922 Pro.

Características	Detalles
Resolución máxima	1080p a 30 fps / 720p a 60 fps
Tecnología de enfoque	Enfoque automático/manual
Campo de visión	78 grados
Compresión de video	H.264
Conectividad	USB 2.0
Compatibilidad	Windows 7, 8, 10 / macOS X 10.9 o posterior
Software compatible	Logitech Capture, OBS, XSplit, entre otros.
Dimensiones	44 mm x 95 mm x 71 mm

3.3.3. Diseño de la placa de distribución del prototipo para los tomates riñón

Para la clasificación física de los tomates, se elaboró el diseño de una placa en el software Kicad para el control de los diversos dispositivos de entrada y salida del microcontrolador. En la Figura 20 se muestra el diseño, el cual consta de los siguientes componentes: el microcontrolador STM32, el reductor de voltaje LM2596S, un módulo de relé de 2 canales y bornes de conexión destinados al control de iluminación, motor de la banda de transporte, actuadores o servomotores y a los interruptores finales de carrera. Su implementación se observa en el Anexo 1.

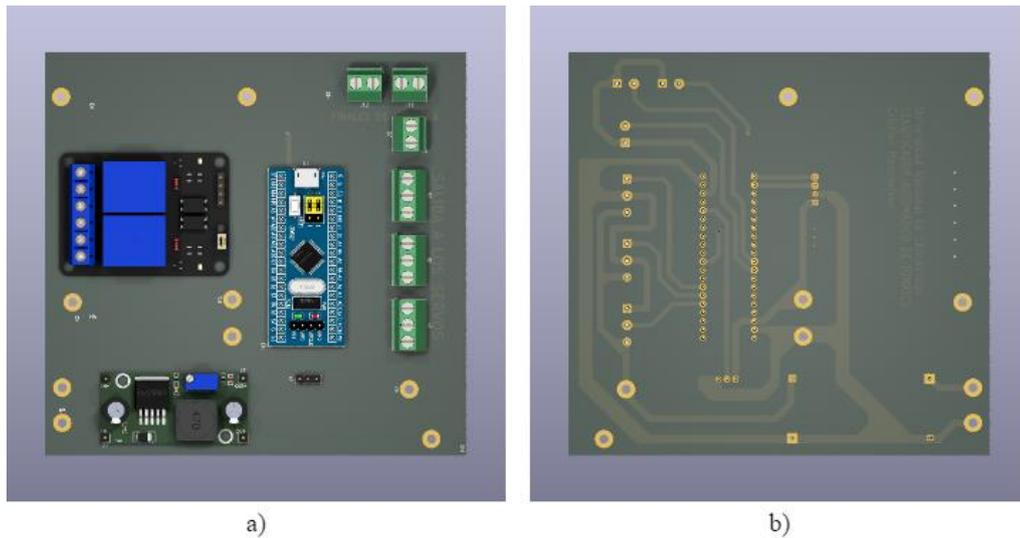


Figura 20: Placa de distribución del prototipo. a) Vista superior, b) Vista inferior.

3.3.4. Estructura de soporte de la banda transportadora

La banda transportadora está conformada de una estructura de soporte sólida con vigas longitudinales, columnas y dispositivos de tensión para sostener la banda de lona recubierta con PVC (ver Anexo 4). Incorpora un sistema de clasificación físico mediante tres compuertas en impresión 3D controladas por servomotores DS3218mg (ver Anexo 2), que se abren de acuerdo con las características tomadas por la cámara y con finales de carrera al detectar los tomates para el cierre las mismas (ver Figura 21). El accionamiento de la banda se logra con un motor AC Gear con reductor (ver Anexo 3), proporcionando alta potencia y control ajustable de velocidad. Esta solución garantiza eficiencia y suavidad en el movimiento, facilitando la clasificación precisa del material transportado.

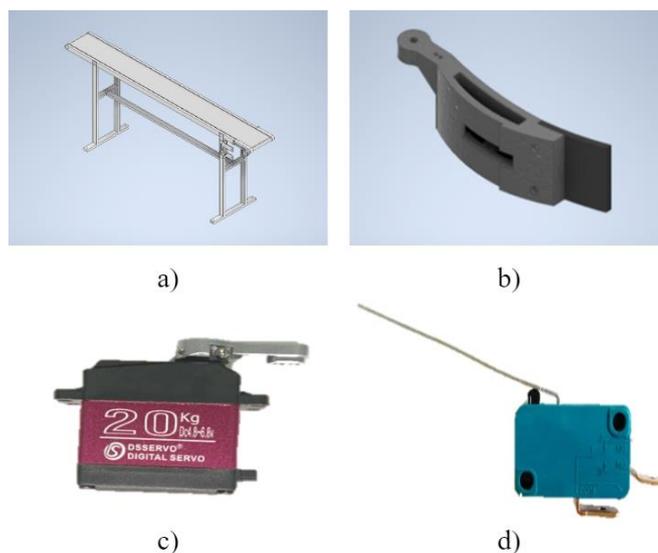


Figura 21: Componentes del prototipo. a) Estructura, b) Compuertas, c) Servomotor DS3218mg, d) Interruptor final de carrera.

3.3.5. Tolva de distribución de tomates riñón

Para una distribución eficiente y automática de los tomates en la banda de transporte, se construyó un mecanismo que permite al operario colocar los tomates en la tolva y estos se posicionen automáticamente para pasar por la recámara de detección. En la construcción de este dispositivo se emplearon elementos como una estructura de metal con soportes verticales y una tolva hecha de material de tol para el almacenamiento de los tomates. También, se incorporó varios componentes: una fuente DC de 12 V, un eje con paletas que gira gracias a un motor DC de hasta 10 RPM y un controlador modulador PWM (ver Figura 22 y 23).



Figura 22: Tolva de distribución de tomates.



Figura 23: Componentes electrónicos de la tolva.

3.4 Desarrollo del software de detección, clasificación y control de hardware

3.4.1. Ajuste del sistema de adquisición de imagen

Se ajustaron meticulosamente los parámetros de la cámara Logitech C922 Pro en un entorno de iluminación controlado antes de proceder con el procesamiento de imágenes. Esta medida fue crucial ya que la calidad y precisión de las imágenes capturadas pueden verse comprometidas por variaciones en la iluminación. Gracias a un ajuste adecuado (ver Tabla 9), se aseguró que las imágenes obtenidas fueran consistentes y claras para el procesamiento de imágenes. Para este propósito, se utilizó el software Logitech G HUB de acuerdo con la Figura 24, proporcionado por el fabricante, que permitió una configuración detallada y precisa de los parámetros de la cámara, garantizando que las condiciones óptimas de captura se mantuvieran durante toda la investigación.

Tabla 9: Parámetros del perfil de la cámara establecidos para las pruebas.

Parámetro	Valor
Brillo	13%
Contraste	47%
Nitidez	65%
Equilibrio de blancos	Manual
Saturación	65%
Frecuencia de parpadeo	60Hz

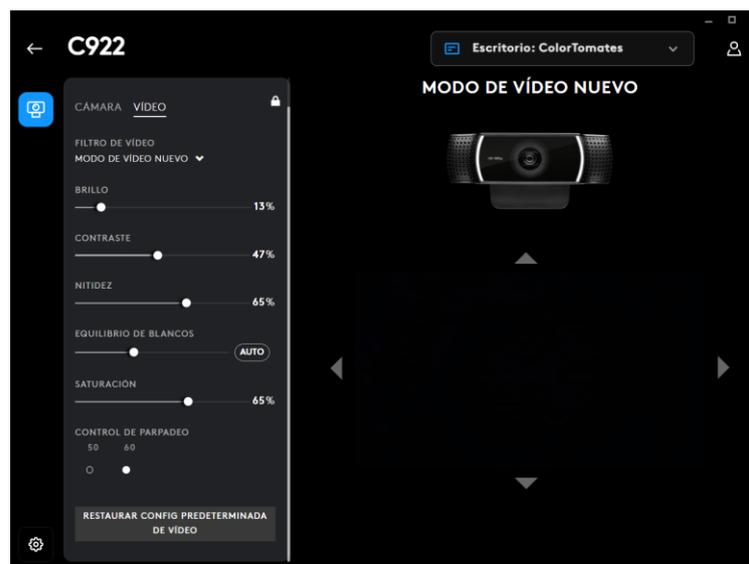


Figura 24: Ajuste de perfil de cámara Logitech C922Pro.

3.4.2. Procesamiento de Imágenes y desarrollo de los algoritmos para el prototipo clasificador

Para el tratamiento de las imágenes en tiempo real, se utilizó el lenguaje de programación de Python, este cuenta con una biblioteca de software de código abierto denominado OpenCV el cual proporciona una amplia gama de funciones y algoritmos para procesamiento de imágenes y visión por computadora. El procedimiento para el tratamiento respectivo se muestra en el esquema de la Figura 25.

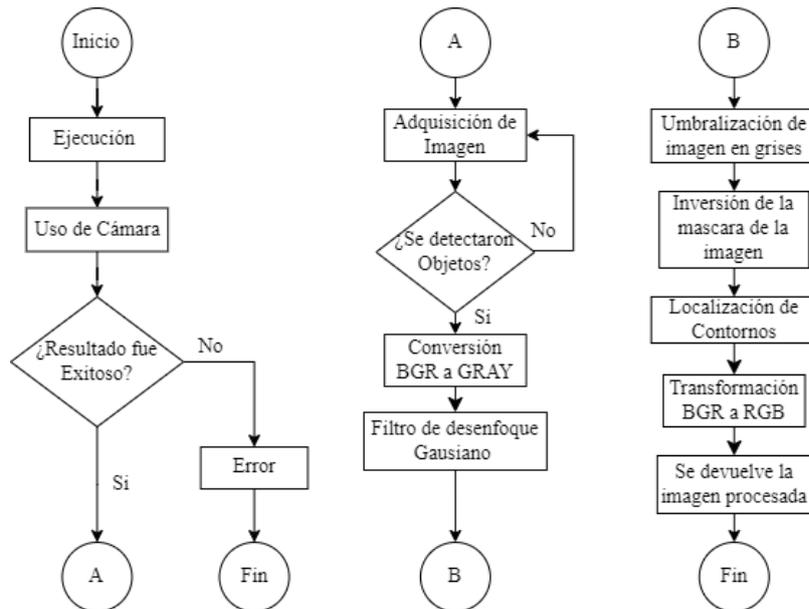


Figura 25: Diagrama de flujo de adquisición y procesamiento de imágenes.

El sistema inicia ejecutando el proceso y habilitando la cámara, seguido se verifica si el uso de esta fue exitoso, de ser así se adquiere la imagen en tiempo real, caso contrario se muestra un error y finaliza el proceso, luego se verifica si se han detectado objetos en la imagen, de no ser así se vuelve a adquirir una imagen nuevamente; cuando se haya detectado un objeto, se inicia el tratamiento respectivo y hace una conversión del espacio de color BGR (Azul, Verde, Rojo) al espacio de color GRAY (escala de grises) al frame capturado, a continuación se aplica un filtro de desenfoque Gaussiano para suavizar la imagen. Luego se aplica un umbral a la imagen resultante para obtener una imagen binaria. Posterior a esto, se encuentran los contornos en la imagen binaria. Luego, se crea una máscara del mismo tamaño que el frame original y se invierte. Después, se encuentran los contornos en esta imagen y se utiliza una máscara para resaltar las áreas de interés. Se extraen las dimensiones y esquinas de los rectángulos encontrados en los contornos. En el siguiente paso se recorren todos los contornos, y se convierte el frame al espacio de color RGB (Rojo, Verde, Azul).

Luego, se aplica la máscara a la imagen original para obtener la imagen procesada. Finalmente, se devuelve la imagen procesada, características de las dimensiones del rectángulo contenedor, esquinas y el frame original.

3.4.2.1. Algoritmo para la clasificación de tamaños

Al igual que en el algoritmo de colores, para realizar la clasificación por tamaños: pequeño, mediano o grande, se realizó un algoritmo cuyo proceso permite discernir los tamaños correspondientes basados en la normativa ecuatoriana INEN 1745, para lo cual se sigue el procedimiento del diagrama a continuación.

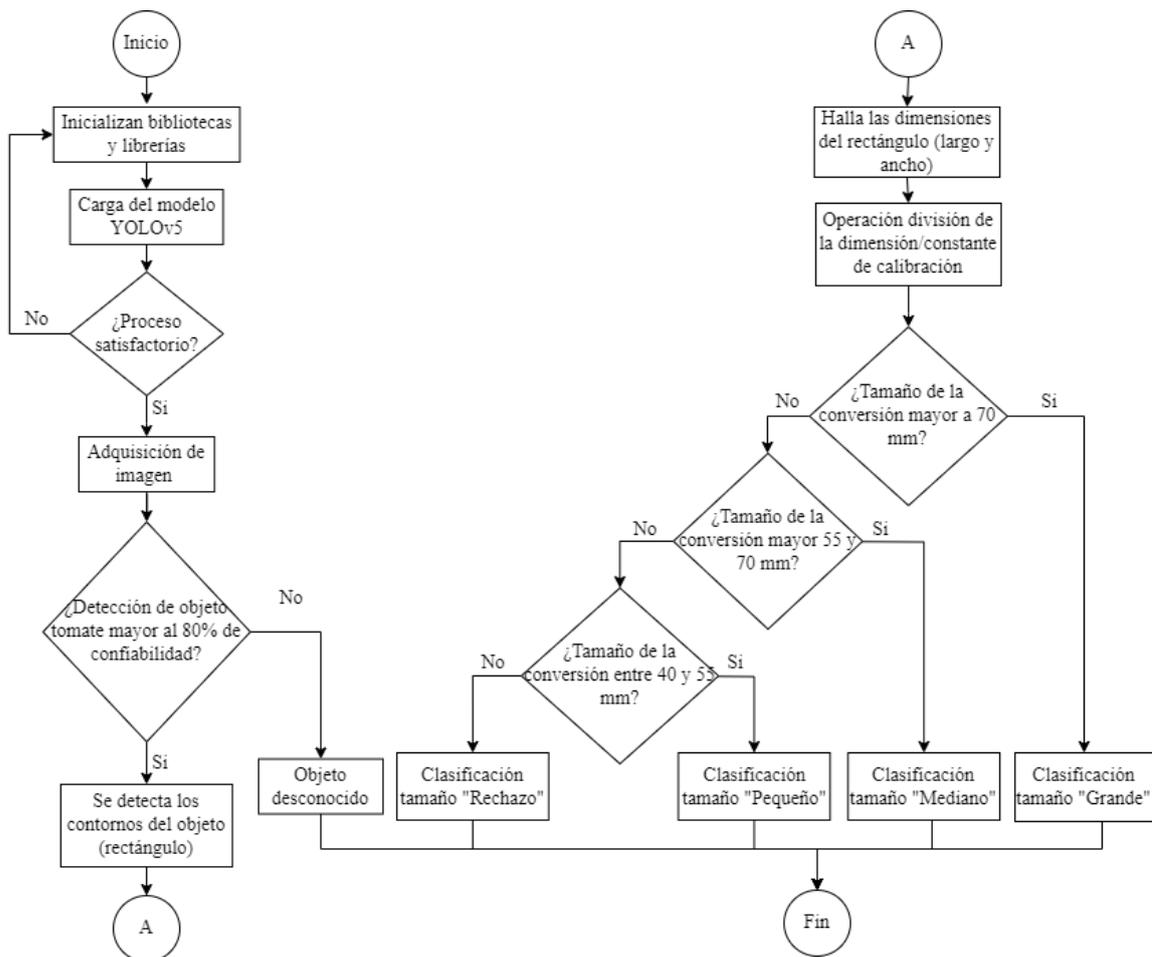


Figura 26: Algoritmo de clasificación por tamaños.

Siguiendo el esquema planteado en la Figura 26, se inicializan las librerías *numpy* y *torch* de la biblioteca de OpenCV, luego se carga el modelo de detección de objetos denominado *best.pt* de YOLOv5 previamente entrenado en la plataforma de Google Colab, se verifica si los procesos anteriores fueron satisfactorios, si no hubo problemas empieza la adquisición de imágenes con la cámara, caso contrario se vuelve a verificar la biblioteca y librerías. Se verifica si el objeto detectado frente a la cámara corresponde a un tomate riñón con una

confiabilidad mayor al 80%, caso contrario se detecta como objeto desconocido y se descarta, si es tomate se detecta contornos y se traza una caja contenedora en el objeto en forma de rectángulo, este proporciona dimensiones del total de pixeles detectados en el objeto de largo y ancho, luego se obtienen las dimensiones del mayor diámetro a partir de una conversión usando una constante de posicionamiento que es 32.59, finalmente se compara las medidas obtenidas y se clasifica en pequeños, medianos y grandes.

3.4.2.2. Algoritmo para la clasificación de colores

El algoritmo implementado tiene la función de realizar la clasificación de los tomates en dos categorías basadas en su etapa de coloración: rojos (maduros) y verdes (inmaduros). Para lograr resultados óptimos, se utilizó el canal de tonalidad (Hue) del espacio de colores HSV (Hue, Saturation, Value) proporcionado por la biblioteca de OpenCV en conjunto con Python.

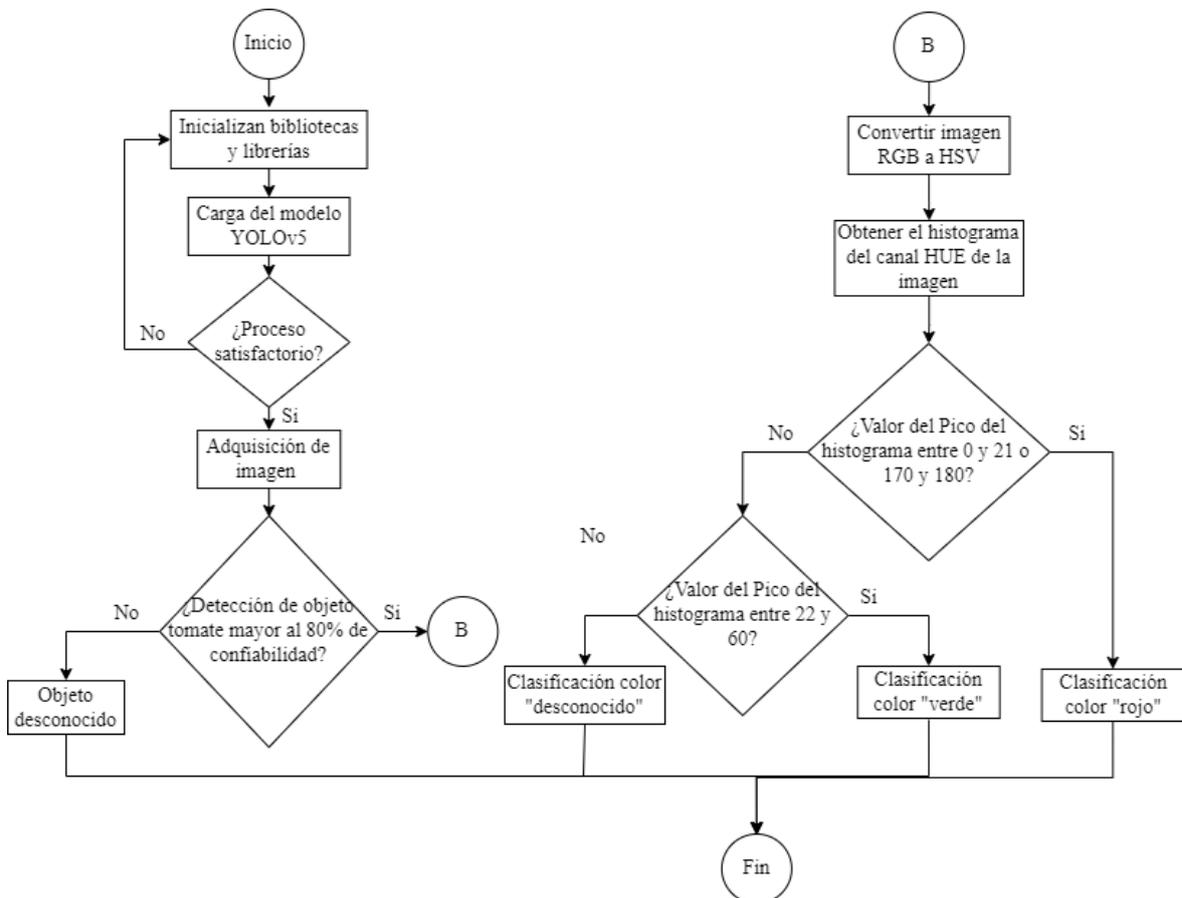


Figura 27: Diagrama de flujo de clasificación por colores.

El proceso de clasificación de colores se ejecuta siguiendo el esquema representado en la Figura 27. Inicialmente, el programa empieza con la inicialización de la biblioteca de OpenCV y la carga de las librerías *torch* y *numpy*. A continuación, se carga el modelo de

detección de objetos *best.pt* de YOLOv5, que ha sido obtenido previamente en el entrenamiento en Google Colab. Si este proceso se ejecuta satisfactoriamente, se procede a adquirir imágenes utilizando la cámara. En caso contrario, se vuelve a realizar la inicialización de la biblioteca y las librerías. Posteriormente, se detecta el objeto presente frente a la cámara. Si el objeto detectado tiene una confiabilidad mayor al 80% según el modelo, se identifica como un tomate riñón. En caso contrario, se considera un objeto desconocido y se descarta. Una vez detectado como tomate riñón, se realiza la conversión de cada imagen del espacio de colores RGB al espacio de colores HSV.

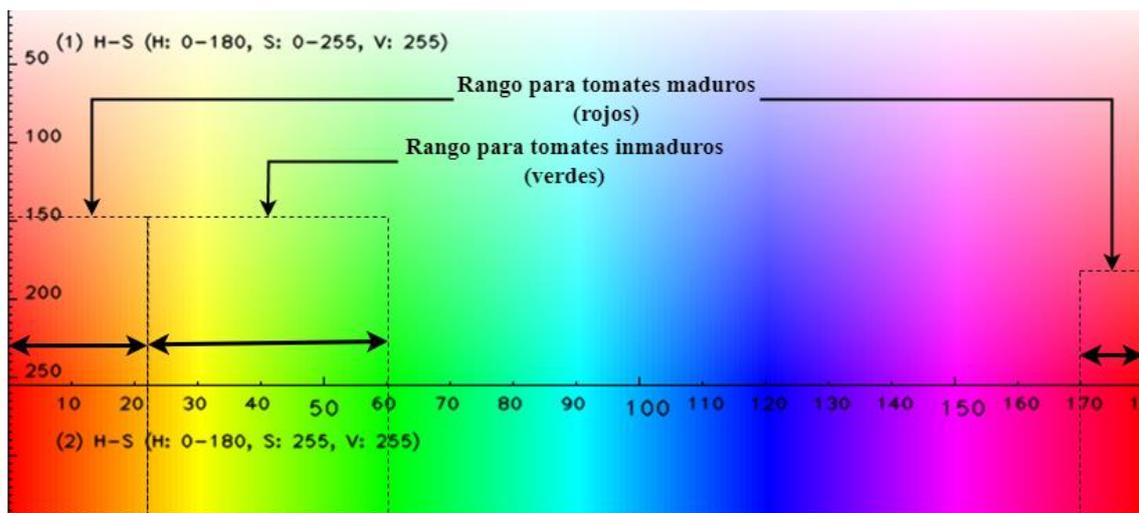


Figura 28: Rangos del canal Hue del espacio de color HSV para la clasificación de colores.

Esta conversión permite separar la información del canal de tonalidad o matiz (Hue) de cada píxel de la imagen. A continuación, se utiliza un umbral o valor pico específico en el canal de tonalidad (Hue) en donde se seleccionaron los rangos de 0° a 21° o 170° a 179° para la selección de tonos rojos y de 22° a 60° para los tonos de color verde (ver Figura 28), este rango de colores fue seleccionado por un experto en la clasificación manual de tomates riñón. Una vez obtenido el valor pico del canal de tonalidad para cada tomate, se realiza un promedio de los picos de tonalidad de los fotogramas obtenidos por el sistema de adquisición de imágenes y se procede a clasificarlos como tomates rojos o verdes según el esquema de la Figura 29.

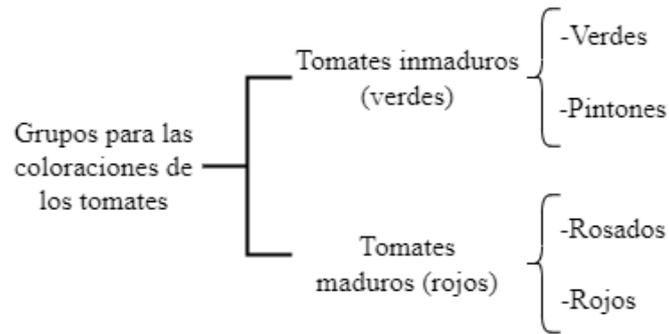


Figura 29: Grupos clasificados para la coloración de los tomates.

➤ **Histogramas del canal de tonalidad (Hue)**

Al aplicar el algoritmo de colores a varios tomates, se pudo observar el resultado final en la Figura 30. En dicha figura se muestra la imagen ya procesada, la cual representa el objeto tomate. Además, se muestran las gráficas de los histogramas correspondientes a cada tonalidad de color obtenido.

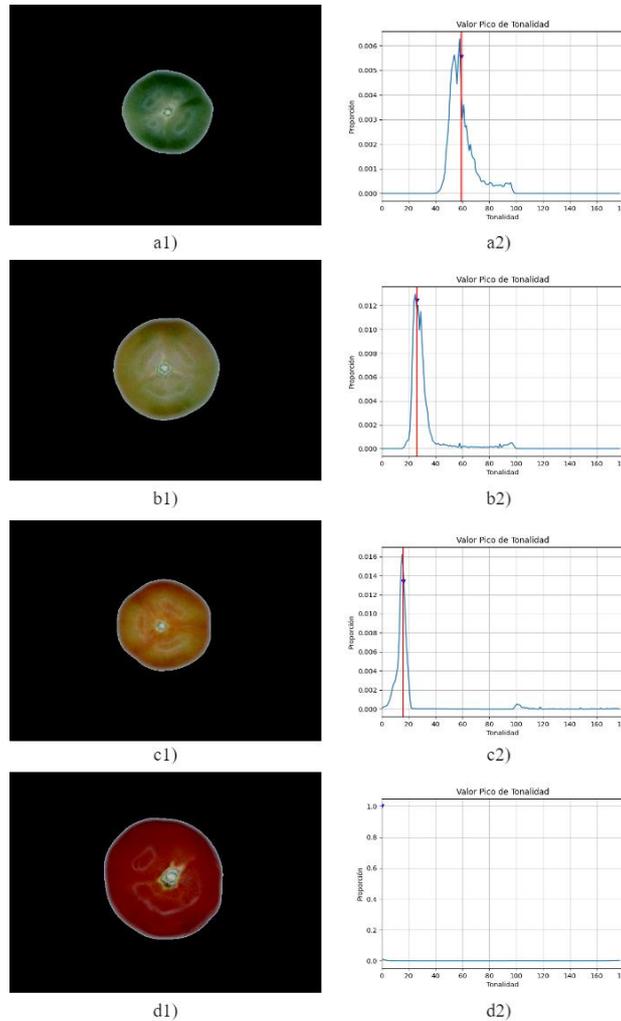


Figura 30: Determinación de color, a1-a2 histograma para tomates verdes, b1-b2 histograma para tomates pintones, c1-c2 histograma para tomates rasados y d1-d2 histograma para tomates rojos.

De acuerdo con la Tabla 10, para el gráfico etiquetado como "a1", se observa el tomate de color verde y su respectivo histograma denominado "a2", en dicho histograma se identifica un pico en el canal de tonalidad (Hue) con un valor de 59°. Para el gráfico "b1" se observa un tomate de color pintón y su histograma asociado al gráfico "b2" en donde se muestra en la gráfica un pico de 26°. En el caso de "c1" se observa un tomate con una tonalidad de color más rojiza y su gráfico correspondiente "c2" exhibe un pico de 16°. Por último, en el gráfico "d1", se aprecia un tomate de color rojo y su histograma asociado "d2" indica un pico con un valor de 0°. Obtenido el valor máximo en cada tomate, se clasifica en dos grupos. Aquellos tomates que presentan colores verde y pintón se catalogan como "verdes" e indican que están en una etapa de no madurez. Por otro lado, los tomates que exhiben tonalidades rosadas y rojas se consideran "rojos", por lo tanto, se encuentran en una etapa madura.

Tabla 10: Valor pico de tonalidad para cada color de acuerdo con su histograma según la Figura 29.

Etiqueta	Color real	Histograma	Tonalidad (Hue)	Color prototipo
a1	Verde	a2	59	Verde
b1	Pintón	b2	26	Verde
c1	Rosado	c2	16	Rojo
d1	Rojo	d2	0	Rojo

3.4.3. Funcionamiento del sistema e interfaz gráfica

La interfaz gráfica se desarrolló mediante el uso del lenguaje de programación Python. Para lograr una apariencia personalizada en la ventana de la interfaz visual, se empleó la librería *CustomTkinter*. Esta interfaz consta de dos secciones de ventanas: la ventana principal y la ventana de selección de clasificación. Está diseñada para facilitar su uso por parte del operario o persona encargada.

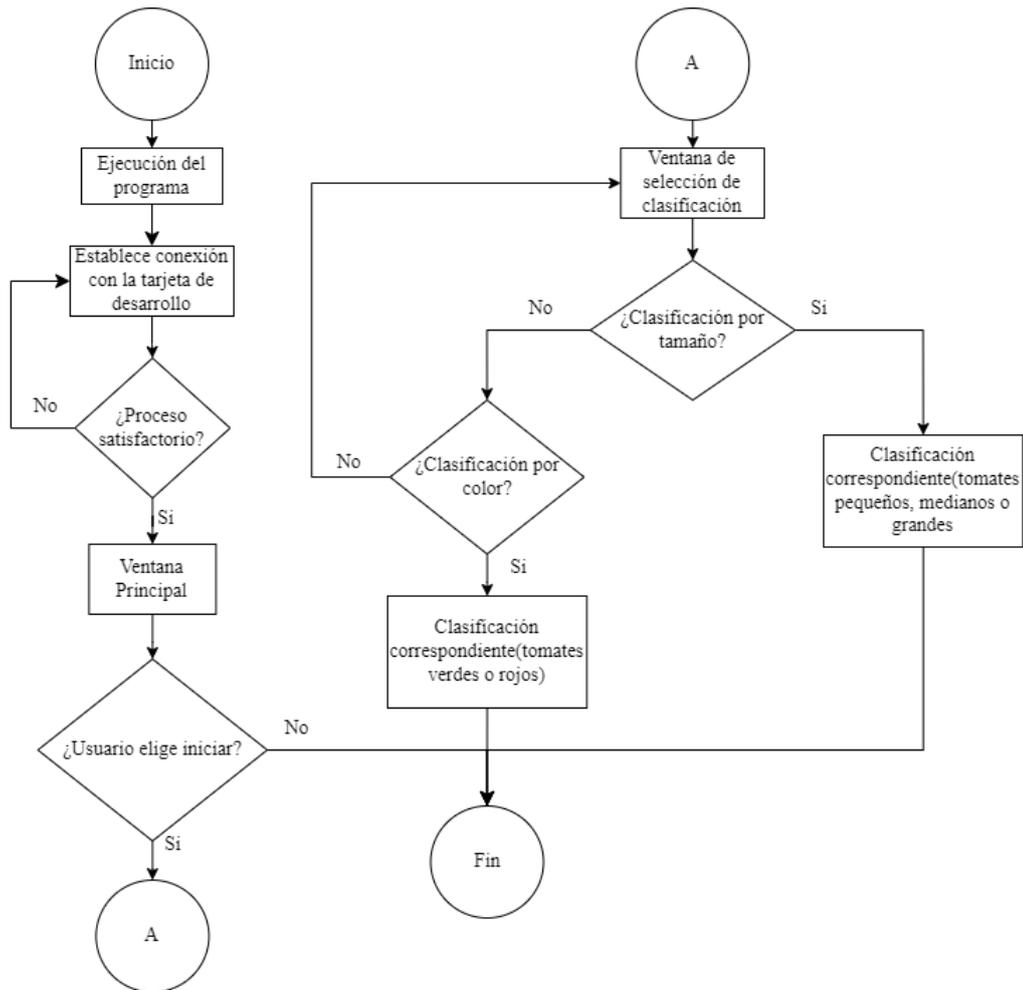


Figura 31: Proceso de funcionamiento del sistema.

De acuerdo con el diagrama presentado en la Figura 31, el funcionamiento comienza cuando el usuario ejecuta el programa. Luego, es necesario establecer una conexión con el microcontrolador. Si la conexión se realiza satisfactoriamente, se abre la ventana principal; caso contrario, se intenta volver a establecer la conexión con el microcontrolador. Una vez dentro de la ventana principal (ver Figura 32), el usuario tiene la opción de iniciar el programa o salir del mismo. En caso de seleccionar la opción de iniciar, se desplegará la ventana de clasificación. Si se opta por salir, el programa se cerrará.



Figura 32: Interfaz gráfica - Ventana principal.

En la ventana de selección (ver Figura 33), el usuario elige que tipo de clasificación desea realizar, para ello la ventana consta de ciertos indicadores que permiten al usuario verificar el proceso de clasificación con el prototipo en tiempo real, también consta de tres botones y un menú desplegable, el menú desplegable consta de tres modos que son: Tamaño, Color y Reiniciar; El botón Configurar permite seleccionar el modo requerido del menú desplegable, el botón Iniciar arranca el sistema de clasificación.



Figura 33: Interfaz gráfica - Ventana de selección de clasificación.

3.4.4. Sistema para el control del hardware mediante el microcontrolador

Para el control de los componentes físicos, se desarrolló un algoritmo el cual fue programado en el lenguaje C, este se ejecuta en el microcontrolador de acuerdo con la petición realizada por el usuario en la interfaz gráfica. El algoritmo permite recibir etiquetas enviadas por el ordenador a través del puerto de comunicación serial “COM3”. Con esto se puede controlar los dispositivos de entrada y salida del microcontrolador (ver Figura 34).

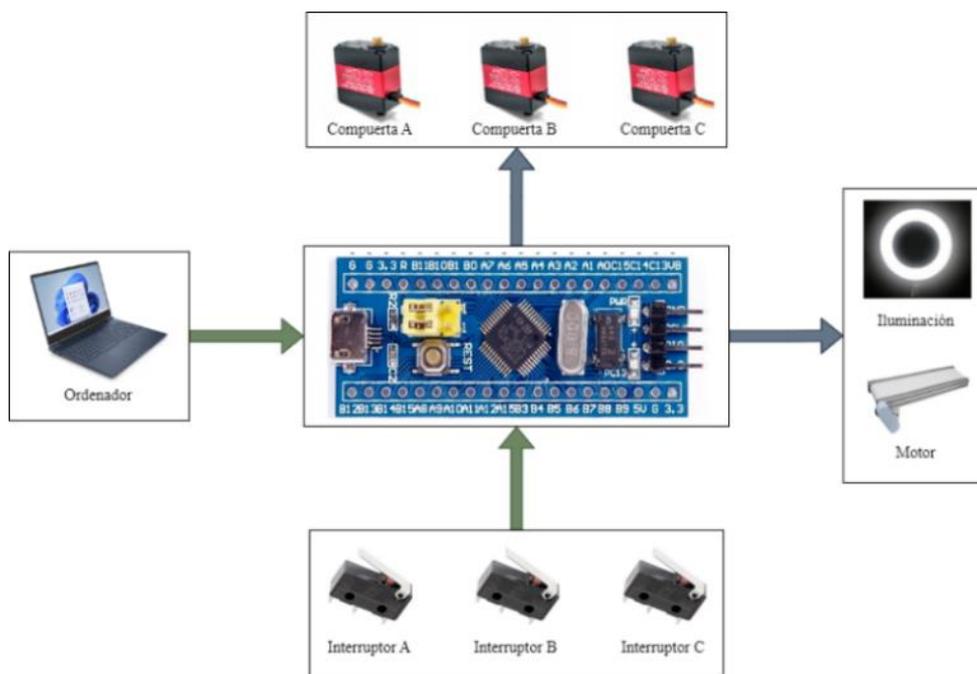


Figura 34: Dispositivos de entrada y salida del microcontrolador.

Este proceso permite el control del hardware del prototipo, ya que actúa junto con el algoritmo de clasificación implementado. Su funcionamiento se basa en recibir comando establecidos que son enviados por el ordenador, estas se almacenan en una lista en la memoria del microcontrolador y se ejecutan en una cola FIFO (*First In, First Out*) para determinar las acciones que debe llevar a cabo en relación con los diversos sistemas físicos incorporados.

En la Figura 35, se distribuyen los datos de comandos que recibe el microcontrolador para clasificar, si se realiza una clasificación por tamaños, el ordenador envía comandos específicos hacia el microcontrolador como “p, m, g, y” que pertenecen a “Pequeño, Mediano, Grande, Rechazo” respectivamente. De lo contrario es una clasificación por colores y las etiquetas que recibe el microcontrolador son “r, v, x” que pertenecen a “Verde, Rojo, Rechazo” respectivamente.

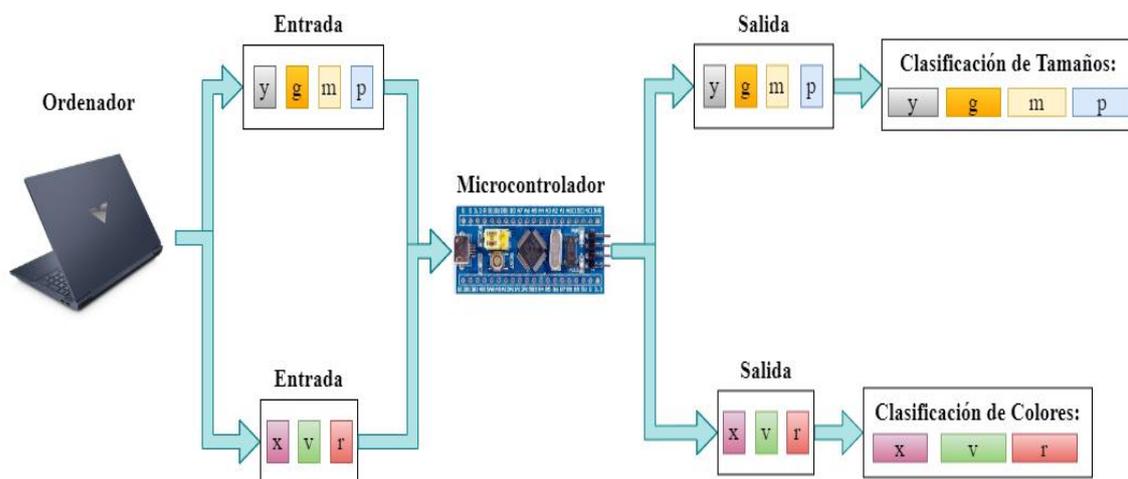


Figura 35: Distribución automática de tomates clasificados.

3.5 Descripción de las pruebas de evaluación del prototipo para la clasificación automática de tamaños y colores de los tomates riñón.

Con el objetivo de conocer el porcentaje de aciertos de manera general obtenido por el prototipo implementado en la clasificación automática de los tomates riñón por tamaños, se realizó 50 pruebas que consistieron en medir el diámetro ecuatorial con un calibrador digital y etiquetarlos para conocer la clasificación luego de pasar aleatoriamente 45 unidades de tomates (15 pequeños, 15 medianos y 15 grandes) previamente etiquetadas con las medidas de los diámetros ecuatoriales analizados por el experto a través del sistema, esto permitió verificar cuantos errores obtuvo el prototipo al final de cada prueba.

De la misma manera se realizó las pruebas para obtener el porcentaje de aciertos y errores al clasificar los tomates por colores, para lo cual se realizó 50 pruebas, cada prueba consistió en pasar aleatoriamente 30 unidades (15 verdes y 15 rojos) los cuales fueron identificados por el experto y etiquetados al color que corresponde según su criterio.

3.6 Descripción de las pruebas para la comparación entre los métodos de medición: calibrador, prototipo y operarios.

Para efectuar este proceso se realizó la clasificación previa de 200 tomates manualmente usando un calibrador digital para referencia del tamaño real (ver Anexo 7) para determinar el total de cada tipo de acuerdo con el rango del diámetro ecuatorial especificado en la norma INEN 1745 (ver Tabla 1). Se utilizó 48 tomates pequeños, 86 medianos y 66 grandes (ver Tabla 11).

Tabla 11: Clasificación por tamaño usando un calibrador digital.

Fuente: Autor.

Tipo (Tamaño)	Rango de Medida (mm)	Total
III (pequeño)	40-55	48
II (mediano)	>55-70	86
I (grande)	>70	66
	Total	200

De la misma manera, se llevó a cabo una clasificación según el color: verdes y rojos (ver Anexo 6), esto se hizo con la ayuda de un experto en la que mediante su percepción visual se clasificó manualmente la muestra de 200 tomates riñón con el objetivo de verificar que cantidad clasificó el prototipo correctamente de acuerdo con el criterio del experto. Como se detalla en la Tabla 12, se sometiendo a prueba un total de 100 tomates de color verde y 100 tomates de color rojo.

Tabla 12: Clasificación por colores realizado por un experto.

Fuente: Autor.

Coloración	Cantidad
Inmaduros (Verdes)	100
Maduros (Rojos)	100
Total	200

Luego de registrar la cantidad de tomates para cada experimento, se realizó las pruebas correspondientes del método de clasificación usando el prototipo y la estimación de los operarios, para ello se evaluó el total de los tomates de forma aleatoria, lo que permitió obtener resultados óptimos del rendimiento del sistema. A continuación, se presenta un análisis de los resultados obtenidos.

CAPÍTULO IV

4.1 Resultados y discusión

En este capítulo, se presentan los resultados obtenidos de la clasificación de tomates riñón por tamaño y color realizadas por el prototipo implementado y además la clasificación realizada por los operarios para comparar la efectividad del sistema implementado. Se analizaron aspectos físicos relacionados con el tamaño del mayor diámetro transversal (pequeño, mediano y grande) y los colores (verdes y rojos). Los hallazgos obtenidos fueron fundamentales para evaluar la eficacia del prototipo y su potencial aplicación en el proceso de clasificación, lo que podría representar un avance significativo en la eficiencia y exactitud de esta labor.

4.1.1. Resultados de las pruebas de evaluación del prototipo en la clasificación automática por tamaño y color

En esta sección se realiza el estudio general de los resultados de las pruebas realizadas al prototipo implementado para conocer el porcentaje de aciertos logrados y la tasa de error obtenida en la clasificación por tamaños y colores.

Tabla 13: Estadísticas descriptivas e intervalo de confianza para el porcentaje de aciertos en diferentes tamaños del tomate riñón.

		Estadístico	Error estándar	
Porcentaje_ aciertos_ ta maños	Media	90,6222	,39798	
	95% de intervalo de confianza para la media	Límite inferior	89,8225	
		Límite superior	91,4220	
	Mediana	91,1111		
	Varianza	7,919		
	Des. estándar	2,81414		
	Mínimo	84,44		
Máximo	95,56			

De acuerdo con la Tabla 13, la media de los porcentajes de aciertos de las pruebas realizadas para la clasificación automática de tomate riñón por tamaños fue de 90.62%. El intervalo de confianza para la media al 95% es de $x = \pm 0.7997$.

Tabla 14: Estadísticas descriptivas e intervalo de confianza para el porcentaje de aciertos en diferentes colores del tomate riñón.

		Estadístico	Error estándar	
Porcentaje_ aciertos_ c lores	Media	91,0667	,58275	
	95% de intervalo de confianza para la media	Límite inferior	89,8956	
		Límite superior	92,2377	
	Mediana	90,0000		
	Varianza	16,980		
	Desv. estándar	4,12063		

De acuerdo con la Tabla 14, la media de los porcentajes de aciertos de las pruebas realizadas para la clasificación automática de tomate riñón por colores fue de 91.06%. El intervalo de confianza para la media al 95% es de $x = \pm 1.1711$.

4.1.1.1. Resultados de las clasificaciones en la categoría de tamaños para la comparación entre métodos de medición.

Para evaluar el rendimiento del prototipo y de los operarios al clasificar los tamaños de los diámetros transversales de los tomates riñón, se elaboraron matrices de confusión con los resultados de los promedios de las clasificaciones realizadas por el prototipo y de los promedios de las clasificaciones manuales realizadas por los operarios. Estas matrices de confusión proporcionaron un análisis en la evaluación de las clasificaciones por tamaños.

➤ Resultado de la clasificación obtenida por el prototipo

De la evaluación, se obtuvo los resultados de la clasificación del realizada por el prototipo, estos están detallados en la Tabla 15. En esta prueba, el sistema implementado logró clasificar correctamente 45 tomates pequeños, 79 tomates medianos y 61 tomates grandes.

Tabla 15: Resultado de la primera clasificación realizada por el prototipo.

Fuente: Autor.

Estimación del prototipo				
Tamaño	Pequeño	Mediano	Grande	Rechazo
Pequeño	45	2	0	1
Mediano	4	79	3	0
Grande	0	5	61	0
Rechazo	0	0	0	0

$$Exactitud = \frac{45 + 79 + 61}{200} * 100 \quad (4.1)$$

$$Exactitud = 92.5\% \quad (4.2)$$

Resultados:

De acuerdo con los resultados obtenidos, el prototipo estimó correctamente el tamaño del 92.5% de los tomates evaluados. Esto implica que el sistema tuvo un excelente desempeño en la clasificación de tamaños. Demostrando una tasa de error inferior al 10%, lo que indica que un porcentaje pequeño de los tomates fue clasificado incorrectamente.

➤ **Resultado de la clasificación obtenida por los operarios**

En la evaluación del rendimiento de los operarios en la clasificación manual, se obtuvieron los siguientes resultados detallados en la Tabla 16. En las pruebas, los operarios lograron correctamente un promedio de 37 tomates pequeños, 73 tomates medianos y 44 tomates grandes.

Tabla 16: Resultado de la clasificación realizada por los operarios.

Fuente: Autor.

Estimación de los operarios				
Tamaño	Pequeño	Mediano	Grande	Rechazo
Pequeño	37	3	0	8
Mediano	11	73	2	0
Grande	0	22	44	0
Rechazo	0	0	0	0

$$Exactitud = \frac{37 + 73 + 44}{200} * 100 \quad (4.3)$$

$$Exactitud = 77.0\% \quad (4.4)$$

Resultados:

De acuerdo con los resultados obtenidos, los operarios estimaron correctamente el tamaño de los diámetros transversales del 77.0% de los tomates evaluados. Esto implica que el desempeño de los operarios es aceptable en la clasificación de tamaños. Demostrando que

la tasa de error es superior al 10%, lo que indica que un porcentaje considerable de los tomates fue clasificado incorrectamente por los operarios.

Discusión de los resultados:

Los resultados obtenidos revelan una notable disparidad en la exactitud entre el prototipo y los operarios en lo que respecta a la clasificación de los tamaños de tomates riñón. El prototipo desarrollado logró una excelente tasa de acierto del 92.5%, con una tasa de error inferior al 10%, indicando una alta confiabilidad en sus estimaciones y un bajo porcentaje de tomates clasificados de manera incorrecta. Por otro lado, los operarios demostraron una exactitud del 77.0%, lo que, si bien es aceptable, se vio acompañado por una tasa de error superior al 10%, evidenciando que un porcentaje significativo de los tomates fue erróneamente catalogado. Esta discrepancia enfatiza la ventaja de la automatización en términos de consistencia y exactitud, lo que podría traducirse en una mayor eficiencia en la producción.

4.1.1.2. Resultados de la clasificación dado por el prototipo en la categoría de colores

El rendimiento del prototipo en la clasificación de colores según los requerimientos de clasificación efectuados por el experto. En la Tabla 17 se presentan los resultados de la clasificación puestos a prueba aleatoriamente, donde el sistema obtuvo una clasificación de 94 tomates correctamente clasificados como verdes y 93 tomates correctamente clasificados como rojos.

Tabla 17: Matriz de confusión - Resultado de la clasificación por color del prototipo.

Fuente: Autor

Prototipo		
Coloración	Verde	Rojo
Verde	94	6
Rojo	7	93

$$Exactitud = \frac{94 + 93}{94 + 93 + 7 + 6} * 100 \tag{4.5}$$

$$Exactitud = 93.5 \tag{4.6}$$

Resultados:

El prototipo estimó correctamente el color del 93.5 % de los tomates evaluados. Esto implica que el sistema tuvo un excelente resultado en la clasificación de colores. Demostrando que tiene una tasa de error inferior al 10% lo que indica que solo un pequeño porcentaje de los tomates fue clasificado incorrectamente por el prototipo.

4.1.2. Análisis descriptivo

En este análisis, se tomaron en cuenta los datos obtenidos del estudio experimental para evaluar el rendimiento del prototipo en la clasificación de tomates según los criterios establecidos.

Tabla 18: Análisis descriptivo de diámetros: Comparación entre métodos de medición (calibrador, prototipo y operarios)

MÉTODO		Estadístico	Error estándar	
DIAMETR OS_METO DOS_MED ICION	Calibrador	Media	64,87300	,790881
	95% de intervalo de confianza para la media	Límite inferior	63,31342	
		Límite superior	66,43258	
		Mediana	65,90000	
		Varianza	125,098	
		Desv. Estándar	11,184742	
	Prototipo	Media	64,26348	,817387
95% de intervalo de confianza para la media	Límite inferior	62,65163		
	Límite superior	65,87533		
	Mediana	65,63350		
	Varianza	133,624		
	Desv. Estándar	11,559602		
Operarios		Media	61,43220	,800933
	95% de intervalo de confianza para la media	Límite inferior	59,85279	
		Límite superior	63,01160	
		Mediana	62,16650	
		Varianza	128,299	
		Desv. Estándar	11,326901	

La media de los diámetros de los tomates riñón medidos con el calibrador se encuentra en un valor de 64.873 mm, la media del prototipo estimó 64.263 mm y la media de los operarios en un valor de 61.432 mm.

Prueba de Hipótesis:

Hipótesis nula

- $H_0: \mu_1 = \mu_2 = \mu_3$

Los promedios de las mediciones del diámetro del tomate riñón respecto del calibrador, prototipo y operarios son significativamente iguales.

Hipótesis alternativa

- $H_1: \mu_j \neq \mu_k$

Los promedios de las mediciones del diámetro del tomate riñón respecto del calibrador, prototipo y operarios no son significativamente iguales.

Tabla 19: Análisis de varianza (ANOVA) para los diámetros medidos con métodos de medición.

DIAMETROS_METODOS_MEDICION					
	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Entre grupos	1348,455	2	674,228	5,226	,006
Dentro de grupos	77017,288	597	129,007		
Total	78365,743	599			

Conclusión:

Como p-valor <0.05 entonces se rechaza H_0 y se acepta H_1 , es decir que los promedios de la variable diámetro son significativamente distintos.

Tabla 20: Comparación de medias entre grupos (operarios, prototipo, calibrador) mediante la Prueba de Tukey.

MED	N	Subconjunto para alfa = 0.05	
		1	2
Operarios	200	61,43220	
Prototipo	200		64,26348
Calibrador	200		64,87300
Sig.		1,000	,853

De acuerdo con la Tabla 20, los promedios de las mediciones realizadas con el prototipo son estadísticamente iguales a las mediciones realizadas por el calibrador, mientras que las mediciones realizadas por los operarios son diferentes a las mediciones del calibrador.

4.1.3. Análisis de correlaciones

Tabla 21: Correlación entre las mediciones del prototipo y las del calibrador.

Variable dependiente: MEDICIÓN PROTOTIPO

Resumen del modelo						Estimaciones de parámetro	
Ecuación	R cuadrado	F	gl 1	gl2	Sig.	Constante	b1
Lineal	,979	9364,861	1	198	<,001	-2,086	1,023

La variable independiente es MEDICIÓN CALIBRADOR.

Como $R^2=0.979$ existe una alta correlación es decir que las medidas realizadas por el prototipo son estadísticamente iguales a las medidas realizadas por el calibrador.

Tabla 22: Correlación entre las mediciones de los operarios y las del calibrador.

Variable dependiente: MEDICIÓN OPERARIOS

Resumen del modelo						Estimaciones de parámetro	
Ecuación	R cuadrado	F	gl 1	gl2	Sig.	Constante	b1
Lineal	,889	1579,404	1	198	<,001	-,498	,955

La variable independiente es MEDICIÓN CALIBRADOR.

Como $R^2=0.889$ las medidas realizadas por los operarios estadísticamente tienen menor correlación con las medidas realizadas por el calibrador.

CAPÍTULO V

5.1 Conclusiones

- El estudio de diversas fuentes bibliográficas relacionadas con las técnicas de procesamiento de imágenes y algoritmos de visión artificial fueron de gran ayuda, esto permitió desarrollar el sistema de detección e interfaz de usuario para el sistema del clasificador automático.
- La recopilación y selección de las imágenes de los tomates riñón permitieron el entrenamiento y validación del sistema. Estas imágenes fueron etiquetadas minuciosamente para facilitar el entrenamiento de este sistema con el algoritmo YOLOv5 mismo que garantizó que el sistema identificara de manera eficiente, obteniendo resultados confiables en el proceso de detección.
- Se desarrolló el prototipo encargado de realizar la clasificación automática de los tomates riñón. De modo que, se seleccionó el software y hardware necesario para su implementación y de esta manera lograr una clasificación física de los tomates. Además, se construyó una tolva especialmente diseñada para permitir la colocación automática de los tomates en la banda transportadora, lo que proporciona a los productores una automatización completa del sistema.
- En las pruebas generales, el prototipo obtuvo un porcentaje de aciertos en promedio del 90.62% en la clasificación por tamaños y un 91.06% en la clasificación por colores. Además, en la comparación entre métodos de medición, el prototipo obtuvo en promedio el 92.5% en la clasificación por tamaños de los diámetros, exhibiendo una tasa de error inferior al 10%. En contraste, los operarios alcanzaron una efectividad del 77% con una tasa de error que supera el 10%. Adicionalmente, el prototipo mostró una efectividad promedio del 93.5% en la clasificación de colores, manteniendo una tasa de error por debajo del 10%, considerando que los expertos tuvieron una efectividad del 100%.

5.2 Recomendaciones

- Se recomienda llevar a cabo este estudio en un ambiente de iluminación controlado, evitando la luz ambiental exterior ya que afecta en el procesamiento óptimo de las imágenes. Al controlar los parámetros de la cámara e iluminación, se obtendrán resultados adecuados y precisos para el análisis de imágenes.
- Para mejorar el rendimiento del prototipo, es recomendable el uso de varias cámaras ubicadas en diferentes posiciones dentro de la recámara para capturar más imágenes del tomate en tiempo real. Esto permitirá obtener múltiples vistas del tomate, lo que resultará en un promedio más preciso de las mediciones de tamaños y colores. La utilización de múltiples cámaras ofrecerá una mayor cobertura y permitirá compensar posibles variaciones de iluminación y ángulos de visión, mejorando así la calidad y confiabilidad de las clasificaciones realizadas.
- Utilizar mecanismos que permitan retirar objetos de una banda mucho más rápido de esta manera se optimizará la eficiencia del proceso de clasificación, lo que permitirá una extracción más precisa y efectiva. Esta mejora contribuirá significativamente a la calidad y rendimiento de este prototipo clasificador.
- Si se realiza una implementación de tipo industrial de este tipo de sistemas, se recomienda utilizar materiales resistentes, como el acero inoxidable. Este tipo de material ofrece una mayor durabilidad y resistencia, lo que es crucial para soportar las demandas y condiciones rigurosas del entorno industrial.

BIBLIOGRAFÍA

- [1] ESPAC, “Tabulados de la Encuesta de Superficie y Producción Agropecuaria Continua”, Quito, 2022. Disponible en: <https://www.ecuadorencifras.gob.ec/estadisticas-agropecuarias-2/>
- [2] R. Rios, “PLAN DE DESARROLLO Y ORDENAMIENTO TERRITORIAL DE LA PROVINCIA DE CHIMBORAZO”, BS Thesis, Riobamba, may 2020. Disponible en: <https://chimborazo.gob.ec/principal/wp-content/uploads/2022/06/PDOT.pdf>
- [3] F. León y A. Moreta, “Diseño e Implementación de un Sistema Clasificador de Tomate de Riñón (*Lycopersicum Esculentum*) Aplicable a la Fundación ‘AYLLU APU FFA’ de la Provincia de Cotopaxi-Ecuador para Impulsar el Sector Microempresarial y Emprendimientos”, BS Thesis, Universidad de las Fuerzas Armadas, Latacunga, 2021. Disponible en: <http://repositorio.espe.edu.ec/handle/21000/27371>
- [4] Servicio Ecuatoriano de Normalización INEN, “Norma Técnica Ecuatoriana Voluntaria. Hortalizas Frescas. Tomate de riñón. Requisitos”. [En línea]. Disponible en: <https://www.normalizacion.gob.ec/buzon/normas/1745.pdf>
- [5] Cámara de Agricultura Zona I, “El Robot Que Cosecha Tomates Maduros”, <http://www.agroecuador.org/index.php/blog-noticias/item/390-el-robot-que-cosecha-tomates-maduros>. Disponible en: <http://www.agroecuador.org/index.php/blog-noticias/item/390-el-robot-que-cosecha-tomates-maduros>
- [6] D. Tene y J. Villagrán, “Diseño y construcción de una máquina clasificadora de tomate riñón – variedad daniela de 80 cartones de 23 [kg/h] de capacidad.”, BS Thesis, Escuela Superior Politécnica de Chimborazo, Riobamba, 2017. Disponible en: <http://dspace.esPOCH.edu.ec/handle/123456789/8071>
- [7] A. A. Tulbure, A. A. Tulbure, y E. H. Dulf, “A review on modern defect detection models using DCNNs – Deep convolutional neural networks”, *Journal of Advanced Research*, vol. 35. Elsevier B.V., pp. 33–48, el 1 de enero de 2022. doi: 10.1016/j.jare.2021.03.015.
- [8] J. Lee, H. Nazki, J. Baek, Y. Hong, y M. Lee, “Artificial Intelligence Approach for Tomato Detection and Mass Estimation in Precision Agriculture”, *Sustainability*, vol. 12, núm. 21, pp. 1–15, nov. 2020, doi: 10.3390/su12219138.
- [9] M. A. Alajrami y S. S. Abu-Naser, “Type of Tomato Classification Using Deep Learning”, *International Journal of Academic Pedagogical Research*, vol. 3, núm. 12, pp. 21–25, dic. 2019, [En línea]. Disponible en: www.ijeais.org/ijapr
- [10] J. Tierra y M. Galarza, “Implementación de un sistema de control y monitoreo en base al procedimiento de imágenes digitales en los sistemas de visión artificial aplicado al reconocimiento de la máquina selectora de botellas en el laboratorio de la Escuela de Ingeniería Industrial de la ESPOCH”, BS Thesis, Escuela Superior Politécnica de Chimborazo, Riobamba, 2017. Disponible en: <http://dspace.esPOCH.edu.ec/handle/123456789/9346>

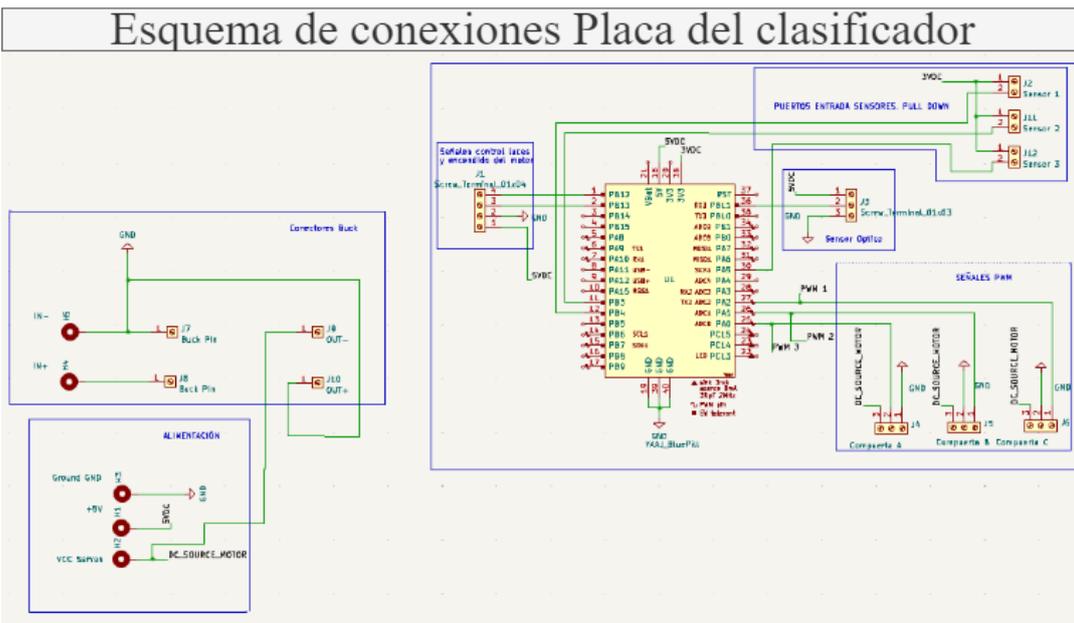
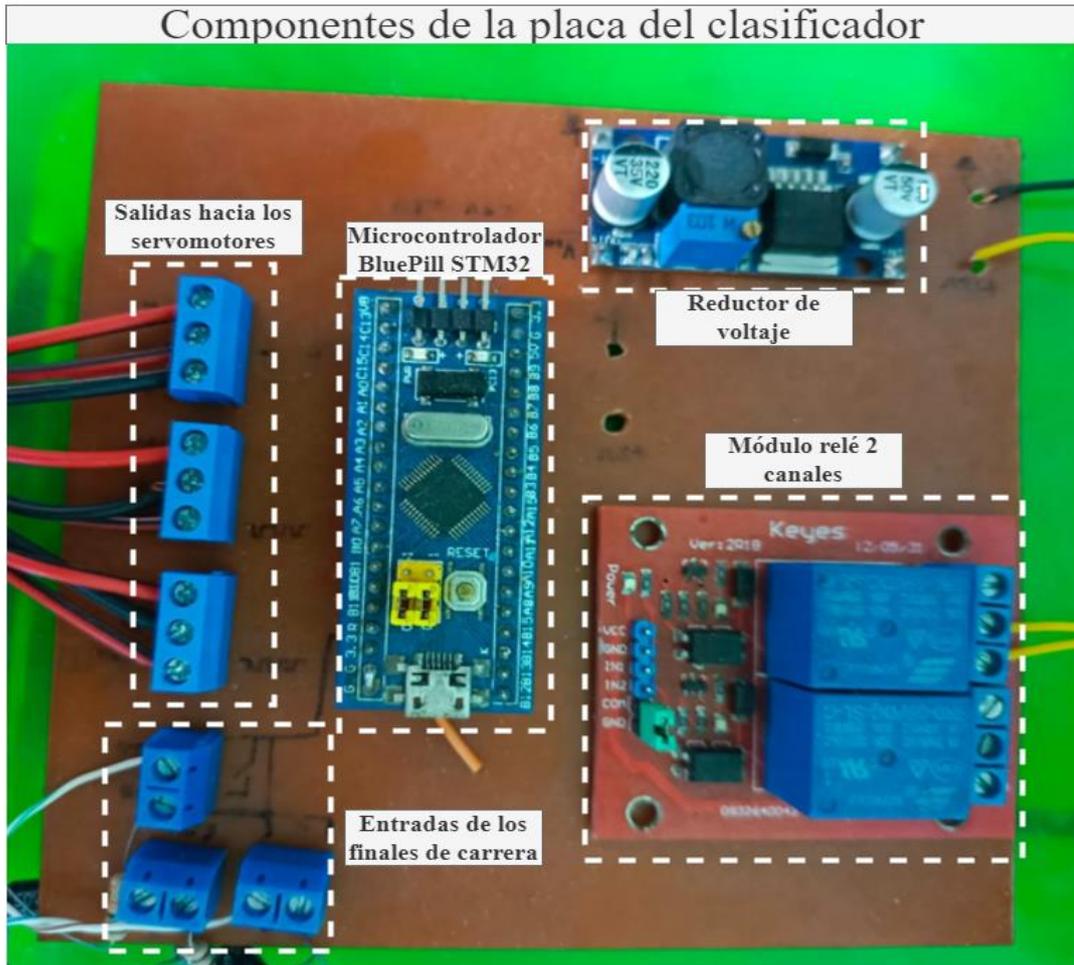
- [11] M. Jurado y Á. Fernández, “Sistema electrónico para el control de calidad de huevos de gallina mediante procesamiento de imágenes”, BS Thesis, Universidad Técnica de Ambato , Ambato, 2018.
- [12] V. García y E. Erazo, “Uso de Algoritmo de Inteligencia Artificial para Desarrollar una Metodología para Medir la Textura de los Suelos”, BS Thesis, Universidad Nacional de Chimborazo, Riobamba, 2019.
- [13] J. Jácome, “Detección temprana de minador, mosca blanca y fusarium en el tomate riñón, aplicando técnicas de visión artificial y machine learning”, BS Thesis, Universidad Nacional de Chimborazo, Riobamba, 2022.
- [14] A. Aguilar, “Diseño de un sistema clasificador de manzanas por color mediante visión artificial para la empresa Fresh & Natural C.I.”, BS Thesis, Universidad Técnica Equinoccial, Quito, 2017.
- [15] E. del Castillo, “Desarrollo de un sistema de visión artificial para realizar una clasificación uniforme de limones”, BS Thesis, Universidad Privada del Norte, Trujillo, 2018.
- [16] L. la Madrid, “Implementación de un algoritmo de control de calidad para la selección de productos agrícolas utilizando visión artificial”, BS Thesis, Universidad Nacional Pedro Ruiz Gallo, Lambayeque, 2019.
- [17] L. Sucari, Y. Aroquipa, E. Quispe, A. Sucari, L. Quina, y F. Huanca, “Visión artificial en reconocimiento de patrones para clasificación de frutas en agronegocios”, *PURIQ*, vol. 2, pp. 1–16, abr. 2020, doi: 10.37073/puriq.2.2.76.
- [18] H. Tian, T. Wang, Y. Liu, X. Qiao, y Y. Li, “Computer vision technology in agricultural automation —A review”, *Information Processing in Agriculture*, vol. 7, núm. 1, pp. 1–19, mar. 2020, doi: 10.1016/j.inpa.2019.09.006.
- [19] T. Domínguez, *Visión artificial: Aplicaciones prácticas con OpenCV - Python*, Primera. 2021.
- [20] J. Hurtado, “Desarrollo de un sistema de monitoreo para el ingreso de personas en establecimientos por medio de visión artificial.”, Grado, Institución Universitaria Pascual Bravo, Medellín, 2023.
- [21] S. S. Yamberla De La Torre, “Algoritmo para la clasificación de aguacates tipo fuerte según el estado de madurez mediante visión artificial”, Grado, Universidad Técnica del Norte, Ibarra, 2023.
- [22] R. Hinojosa, “Aplicación de técnicas de ensemble para segmentación de radiografías COVID-19”, Grado, E.T.S.I. de Sistemas Informáticos (UPM), Madrid, 2021. Consultado: el 12 de abril de 2023. [En línea]. Disponible en: <https://oa.upm.es/67444/>
- [23] L. Liu, Z. Li, Y. Lan, Y. Shi, y Y. Cui, “Design of a tomato classifier based on machine vision”, *PLoS One*, vol. 14, 2019.

- [24] S. Srivastava, A. Vishvas, C. Anilkumar, I. Naik, V. Kulkarni, y V. Pattabiraman, “Comparative analysis of deep learning image detection algorithms”, *Big Data*, pp. 1–27, 2021.
- [25] N. Casado, “Redes neuronales convolucionales y aplicaciones”, UNIVERSIDAD COMPLUTENSE DE MADRID, 2022.
- [26] M. Sheykhmousa, M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi, y S. Homayouni, “Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review”, *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 13, pp. 6308–6325, 2020, doi: 10.1109/JSTARS.2020.3026724.
- [27] J. L. Speiser, M. E. Miller, J. Tooze, y E. Ip, “A comparison of random forest variable selection methods for classification prediction modeling”, *Expert Syst Appl*, vol. 134, pp. 93–101, nov. 2019, doi: 10.1016/j.eswa.2019.05.028.
- [28] D. P. Penumuru, S. Muthuswamy, y P. Karumbu, “Identification and classification of materials using machine vision and machine learning in the context of industry 4.0”, *J Intell Manuf*, vol. 31, pp. 1229–1241, 2019.
- [29] J. Prieto y R. Trelles, “Clasificación de hojas de tomate con plagas o enfermedades usando una máquina de soporte vectorial (SVM)”, BS Thesis, Univerddidad de Piura, Piura, 2021.
- [30] R. Joaquin, “Máquinas de Vector Soporte (Support Vector Machines, SVMs)”. Disponible en: <https://cienciadedatos.net/>
- [31] S. Abbas y S. Singh, “Region-based object detection and classification using faster R-CNN”, *IEEE*, pp. 1–6, 2018.
- [32] K. Amino y T. Matsuo, “Automated Behavior Analysis Using a YOLO-Based Object Detection System”, 2022, pp. 257–275. doi: 10.1007/978-1-0716-2321-3_14.
- [33] M. Campos y Sánchez Jacqueline, “Red neuronal artificial para detección de armas de fuego y armas blanca en video vigilancia.”, *Revista de Iniciación Científica*, vol. 7, núm. 2, pp. 83–88, dic. 2021, doi: <https://doi.org/10.33412/rev-ric.v7.2.3343>.
- [34] R. Gonzalez y R. Woods, *Digital image processing*, 4ta ed. Pearson, 2018.
- [35] D. Hema y S. Kannan, “Interactive color image segmentation using HSV color space”, *Science and Technology*, vol. 7, núm. 1, pp. 37–41, 2019.
- [36] H. Hamdani, A. Septiarini, A. Sunyoto, S. Suyanto, y F. Utaminingrum, “Detection of oil palm leaf disease based on color histogram and supervised classifier”, *Optik (Stuttg)*, vol. 245, pp. 2–13, 2021.
- [37] G. Solano, “Operadores BITWISE (AND-OR-NOT-XOR) con OpenCV y Python”. Consultado: el 10 de julio de 2023. [En línea]. Disponible en: <https://omesva.com/operadores-bitwise/>
- [38] GeekFlare, “Google Colab: Todo lo que necesita saber”. Consultado: el 14 de noviembre de 2021. [En línea]. Disponible en: <https://geekflare.com/es/google-colab/>

- [39] E. Cervera, R. Marín, y J. Marín, “Más allá de Jupyter: usando Google Colab para la programación de robots”, en *XLIII Jornadas de Automática: libro de actas: 7, 8 y 9 de septiembre de 2022, Logroño (La Rioja)*, Servizo de Publicacións da UDC, 2022, pp. 662–669. doi: 10.17979/spudc.9788497498418.0662.
- [40] S. Nachtergaele y J. De Grave, “AI-Track-tive: open-source software for automated recognition and counting of surface semi-tracks using computer vision (artificial intelligence)”, *GEOCHRONOLOGY (GOTTINGEN)*, vol. 3, pp. 383–394, 2021.

ANEXOS

Anexo 1 – Implementación de placa de control de clasificación de tomates.



Anexo 2 – Especificaciones técnicas de los servomotores

Especificaciones Técnicas:

Tabla 23: Características técnicas Servomotor DS3218mg.

Característica	Detalles
Tipo	Servomotor
Modelo	DS3218mg
Voltaje de operación	4.8 - 6.8V
Corriente máxima	1.5A
Par de torsión máximo	18 kg/cm – 21.5 kg/cm
Velocidad sin carga	0.16 segundos/60 grados
Ángulo de rotación máximo	270 grados
Índice de protección	IP66
Dimensiones	40.2 x 20.1 x 43.2 mm

Anexo 3 – Motor Reductor Monofásico Gear 110V, 90W, 135RPM y sus especificaciones técnicas

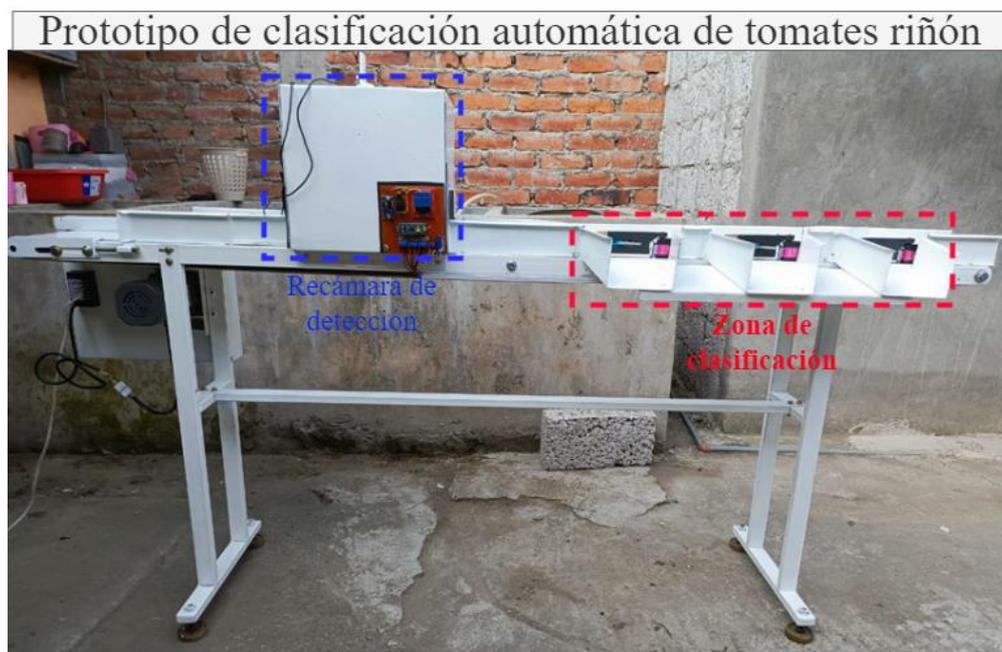


Características técnicas:

Tabla 24: Características técnicas Motor Reductor Gear AC.

Características	Detalles
Tipo de motor	Motor AC con reductor de engranajes
Es reversible	Sí
Fuente de alimentación	Monofásica
Potencia	90 vatios
Tensión de alimentación	110 V
Frecuencia de alimentación	de 50-60Hz
Velocidad Nominal	0-135 RPM
Relación de reducción	1-10 (10k)
Velocidad de rotación	Variable (ajustable con el controlador de velocidad)
Torque máximo	5.7 Nm
Peso	5 kg
Dimensiones	164*90*74 mm
Diámetro del eje	12 mm
Tamaño del reductor	41*90*74 mm

Anexo 4 – Implementación del prototipo



Anexo 5 – Tabla de registro por tamaños de tomates riñón

Evaluación del rendimiento del sistema y operarios

Nombre del
operario:

Fecha:

N^o	Medición Calibrador (mm)	Tipo o Tamaño	Estimación Prototipo (mm)	Tipo o Tamaño	Estimación Operario (mm)	Tipo o Tamaño
1						
2						
3						
4						
5						
6						
7						
8						
9						
10						
11						
12						
13						
14						
15						
16						
17						
18						
19						
20						
21						
22						
23						
24						
25						
26						
27						
28						
29						
30						
31						
32						
33						
34						
35						

Anexo 6 – Clasificación manual por colores de tomates riñón por un experto (verdes y rojos)



Anexo 7 – Clasificación manual por tamaños de tomates riñón usando un calibrador digital



- 3.10 Tomate verde.** Fruto cuya superficie presenta coloración verde en un 90% o más.
- 3.11 Tomate pintón.** Fruto cuya superficie presenta varios tonos de rojo, hasta en un 40%.
- 3.12 Tomate rosado.** Fruto cuya superficie presenta un color rosa y/o rojo entre un 40 y un 90%.
- 3.13 Tomate rojo.** Fruto cuya superficie presenta coloración roja en más del 90%.
- 3.14 Defectos tolerables** (que no afecten la aptitud de consumo). Pequeñas manchas, rajaduras o magulladuras que afecten superficialmente la presentación de los tomates.
- 3.15 Defectos no tolerables** (que afecten la aptitud de consumo). Lesiones causadas por microorganismos o insectos, rajaduras o magulladuras profundas que afecten a la pulpa de los tomates.

4. CLASIFICACION

4.1 El tomate, de acuerdo con el valor del diámetro ecuatorial, se clasifica como se indica en la Tabla 1.

TABLA 1. Clasificación del tomate de acuerdo con el diámetro ecuatorial

TIPO (Tamaño)	DIAMETRO EN mm	
	Mínimo	Máximo
I (grande)	mayor que	70
II (mediano)	56	70
III (pequeño)	40 y	55

4.2 **Tolerancias máximas para el tamaño.** Para los tipos señalados en el numeral 4.1 se admitirá un número máximo de 5% del tipo inmediato superior o inferior o la suma de ambos.

4.3 El tomate que no se encuadra en ninguno de los tipos establecidos se considerará no tipificado.

4.4 Para cada tipo se establece los grados de calidad, de acuerdo a lo establecido en la Tabla 2 de esta norma.

5. DISPOSICIONES GENERALES

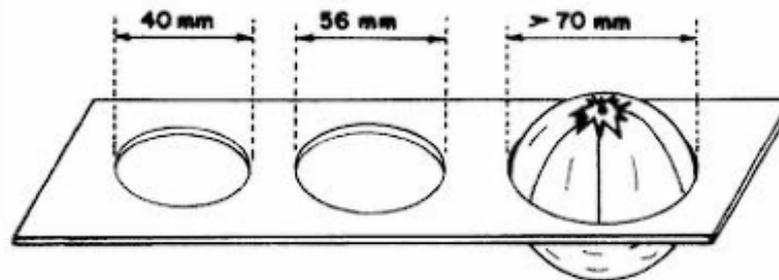
5.1 El tomate destinado a la alimentación humana, en cualquiera de sus tres tipos de selección, debe presentar características similares en forma, tamaño y color de la epidermis (cáscara).

(Continua)

ANEXO A**A.1 Determinación de las características****A.1.1 Determinación del tipo o tamaño**

A.1.1.1 El tomate puede ser clasificado mecánicamente, mediante el uso de máquinas adecuadas.

A.1.1.2 El tomate puede ser clasificado manualmente mediante el uso de calibres fijos que pueden ser confeccionados en madera, como se indica en la siguiente figura:



Los tomates deben separarse según sus tamaños y registrarse el número de tomates de cada tipo.

A.2 Grado de madurez

A.2.1 El grado de madurez se fijará por convenio entre el comprador y el proveedor.

A.3 Defectos tolerables y no tolerables

A.3.1 Los tomates deben separarse según sus defectos y registrarse el número de tomates de cada clase.

(Continúa)

Anexo 9 – Documento de validación por parte del Señor Jorge Reino, propietario del invernadero.

Chambo, 17 de junio de 2023

Señores
Carrera de Ingeniería en Telecomunicaciones
UNIVERSIDAD NACIONAL DE CHIMBORAZO
Presente. -

De mi consideración:

En el periodo del 6 al 13 de junio, en el cantón Chambo, provincia de Chimborazo, se llevó a cabo dentro de un invernadero de mi propiedad, la selección y pruebas correspondientes por parte de nuestro equipo, involucrando la clasificación manual de tomates riñón. Esta selección abarcó tanto los tamaños (pequeños, medianos y grandes) como los colores (verdes y rojos), esta selección sirvió para realizar las pruebas de funcionamiento del proyecto **"IMPLEMENTACIÓN DE UN PROTOTIPO PARA LA CLASIFICACIÓN AUTOMÁTICA DE TOMATES RIÑÓN, BASADO EN LA NORMA INEN 1745, APLICANDO TÉCNICAS DE VISIÓN ARTIFICIAL"** desarrollado por el señor estudiante Cristian Manosalvas Ramos.

Asimismo, se llevaron a cabo las pruebas de clasificación realizadas por el prototipo y por tres operarios de nuestro equipo, considerando la Norma Técnica Ecuatoriana INEN 1745 para la clasificación por tipos (tamaños). De esta manera se informa que el proyecto cumple con todos los requerimientos establecidos.

Es todo cuanto puedo decir en honor a la verdad.

Atentamente,



.....
Jorge Reino
Gerente Propietario

Anexo 10 – Repositorio con las codificaciones de los algoritmos en Python y C.

➤ **Enlace:** <https://gitlab.com/cristianomg6995/implementacion-de-un-prototipo-para-la-clasificacion-automatica-de-tomates-rinon-basado-en-la-norma-inen-1745-aplicando-tecnicas-de-vision-artificial.git>

Anexo 11 – Presupuesto del prototipo

Tabla 25: Presupuesto del prototipo.

N°	Ítem	Costos
1	1 tarjeta de desarrollo BluePill STM32	15.00\$
2	3 servomotores DS3218mg	25.00\$
3	Estructura, tolva dosificadora y cinta transportadora	715.00\$
4	Motor Reductor Monofásico Gear 110V, 90W, 135RPM	215.00\$
5	1 cámara Logitech C922Pro	95.00\$
6	3 interruptores finales de carrera	10.00\$
7	3 compuertas en impresión 3D material PLA	30.00\$
8	Componentes adicionales (aro de luz, componentes electrónicos)	125.00\$
9	Software	0.00\$
	Total	1230.00\$