

	UNIVERSIDAD SURCOLOMBIANA GESTIÓN SERVICIOS BIBLIOTECARIOS						 <small>SC 7384-1</small>	 <small>SA-CERE 597526</small>	 <small>OS-CER 597555</small>	
CARTA DE AUTORIZACIÓN										
CÓDIGO	AP-BIB-FO-06	VERSIÓN	1	VIGENCIA	2014	PÁGINA	1 de 2			

Neiva, 17 de enero 2024

Señores

CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN

UNIVERSIDAD SURCOLOMBIANA

Neiva, Huila.

El (Los) suscrito(s):

Andrés Felipe Palomá Collazos, con C.C. No. 1.003.814.141 y Sergio David Caquimbo Dussan, con C.C. No 1003801378. Autor(es) de la tesis y/o trabajo de grado titulado “DISEÑO Y PROTOTIPO DE PLANTA SELECCIONADORA Y CLASIFICADORA DE BOTELLAS DE PLÁSTICO CON VISIÓN ARTIFICIAL Y MACHINE LEARNING PARA LA EMPRESA ASOMUFAMEDIO” presentado y aprobado en el año 2024 como requisito para optar al título de Ingeniero Electrónico;

Autorizo (amos) al CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN de la Universidad Surcolombiana para que, con fines académicos, muestre al país y el exterior la producción intelectual de la Universidad Surcolombiana, a través de la visibilidad de su contenido de la siguiente manera:

- Los usuarios puedan consultar el contenido de este trabajo de grado en los sitios web que administra la Universidad, en bases de datos, repositorio digital, catálogos y en otros sitios web, redes y sistemas de información nacionales e internacionales “open access” y en las redes de información con las cuales tenga convenio la Institución.
- Permite la consulta, la reproducción y préstamo a los usuarios interesados en el contenido de este trabajo, para todos los usos que tengan finalidad académica, ya sea en formato Cd-Rom o digital desde internet, intranet, etc., y en general para cualquier formato conocido o por conocer, dentro de los términos establecidos en la Ley 23 de 1982, Ley 44 de 1993, Decisión Andina 351 de 1993, Decreto 460 de 1995 y demás normas generales sobre la materia.
- Continúo conservando los correspondientes derechos sin modificación o restricción alguna; puesto que, de acuerdo con la legislación colombiana aplicable, el presente es un acuerdo jurídico que en ningún caso conlleva la enajenación del derecho de autor y sus conexos.

De conformidad con lo establecido en el artículo 30 de la Ley 23 de 1982 y el artículo 11 de la Decisión Andina 351 de 1993, “Los derechos morales sobre el trabajo son propiedad de los autores”, los cuales son irrenunciables, imprescriptibles, inembargables e inalienables.

Vigilada Mineducación

La versión vigente y controlada de este documento, solo podrá ser consultada a través del sitio web Institucional www.usco.edu.co, link Sistema Gestión de Calidad. La copia o impresión diferente a la publicada, será considerada como documento no controlado y su uso indebido no es de responsabilidad de la Universidad Surcolombiana.



UNIVERSIDAD SURCOLOMBIANA
GESTIÓN SERVICIOS BIBLIOTECARIOS

CARTA DE AUTORIZACIÓN



SC 7384-1 SA-CERE 597526 OS-CER 597555

CÓDIGO	AP-BIB-FO-06	VERSIÓN	1	VIGENCIA	2014	PÁGINA	2 de 2
--------	--------------	---------	---	----------	------	--------	--------

EL AUTOR/ESTUDIANTE:

Firma: *Andrés F. Palomá*

EL AUTOR/ESTUDIANTE:

Firma:

Vigilada Mineducación

La versión vigente y controlada de este documento, solo podrá ser consultada a través del sitio web Institucional www.usco.edu.co, link Sistema Gestión de Calidad. La copia o impresión diferente a la publicada, será considerada como documento no controlado y su uso indebido no es de responsabilidad de la Universidad Surcolombiana.



DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO

CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2014	PÁGINA	1 de 4
--------	--------------	---------	---	----------	------	--------	--------

TÍTULO COMPLETO DEL TRABAJO: "DISEÑO Y PROTOTIPO DE PLANTA SELECCIONADORA Y CLASIFICADORA DE BOTELLAS DE PLÁSTICO CON VISIÓN ARTIFICIAL Y MACHINE LEARNING PARA LA EMPRESA ASOMUFAMEDIO"

AUTOR O AUTORES:

Primero y Segundo Apellido	Primero y Segundo Nombre
Palomá Collazos	Andrés Felipe
Caquimbo Dussan	Sergio David

DIRECTOR Y CODIRECTOR TESIS:

Primero y Segundo Apellido	Primero y Segundo Nombre
Sendoya Losada	Diego Fernando

ASESOR (ES):

Primero y Segundo Apellido	Primero y Segundo Nombre
N/A	N/A

PARA OPTAR AL TÍTULO DE: Ingeniero Electrónico

FACULTAD: Ingeniería

PROGRAMA O POSGRADO: Ingeniería Electrónica

CIUDAD: Neiva

AÑO DE PRESENTACIÓN: 2023

NÚMERO DE PÁGINAS: 81

TIPO DE ILUSTRACIONES (Marcar con una X):

Diagramas Fotografías Grabaciones en discos Ilustraciones en general Grabados Láminas
Litografías Mapas Música impresa Planos Retratos Sin ilustraciones Tablas o Cuadros

Vigilada Mineducación

La versión vigente y controlada de este documento, solo podrá ser consultada a través del sitio web Institucional www.usco.edu.co, link Sistema Gestión de Calidad. La copia o impresión diferente a la publicada, será considerada como documento no controlado y su uso indebido no es de responsabilidad de la Universidad Surcolombiana.



SOFTWARE: Python.

MATERIAL ANEXO:

1. Anexo 1: Tutorial de uso para YoloV5 y sus aplicaciones. [Enlace](#).
2. Documentación Técnica de Códigos Realizados. [Enlace](#).

PREMIO O DISTINCIÓN (En caso de ser LAUREADAS o Meritoria): N/A.

PALABRAS CLAVES EN ESPAÑOL E INGLÉS:

<u>Español</u>	<u>Inglés</u>	<u>Español</u>	<u>Inglés</u>
1. Aprendiza Automático	Machine Learning	6. Inteligencia Artificial	Artificial Intelligence
2. Botellas	Bottles	7. Plástico	Plastic
3. Clasificación	Classification	8. Plástico	Plastic
4. Color	Color	9. Redes Neuronales	Neural Networks
5. Detección	Detection	10. Visión por computador	Computer Vision

RESUMEN DEL CONTENIDO: (Máximo 250 palabras)

La inteligencia artificial (IA) es un campo tecnológico de gran interés debido a su naturaleza multidisciplinaria, en el cual se desarrollan sistemas que imitan la capacidad humana para llevar a cabo tareas y resolver problemas. Este proyecto se vale de dos vertientes de la IA: el Aprendizaje Automático (Machine Learning) y la Visión Artificial, que se encargan de interpretar y reconocer objetos e información a partir de imágenes. Específicamente, el ML instruye a la máquina mediante la importación, exploración, preprocesamiento y extracción de características de bases de datos, mientras que la Visión Artificial se dedica al procesamiento, análisis e interpretación de imágenes digitales. Estas herramientas se combinan para diseñar un algoritmo capaz de identificar botellas de plástico y clasificarlas según su color, incluso cuando existen múltiples tipos de materiales reciclables. Además, se ha desarrollado un prototipo a pequeña escala que incluye una banda transportadora, a lo largo de la cual pasan los objetos reciclables. El sistema captura y clasifica automáticamente si se trata de una botella de plástico, y los resultados se visualizan en tiempo real mediante la implementación de un circuito electrónico adicional.

Asimismo, se tiene la intención de compartir este diseño con ASOMUFAMEDIO para que puedan considerar la viabilidad de implementar una máquina a mayor escala en busca de



una solución sostenible. Esta asociación se dedica a la protección, el cuidado y la conservación del medio ambiente, lo que refuerza aún más el valor de esta iniciativa.

ABSTRACT: (Máximo 250 palabras)

Artificial intelligence (AI) is a highly intriguing technological field due to its multidisciplinary nature, where systems are developed to mimic human capacity in performing tasks and solving problems. This project leverages two branches of AI: Machine Learning (ML) and Computer Vision, which are responsible for interpreting and recognizing objects and information from images. Specifically, ML instructs the machine through data importation, exploration, preprocessing, and feature extraction from databases, while Computer Vision is dedicated to the processing, analysis, and interpretation of digital images. These tools are combined to design an algorithm capable of identifying plastic bottles and classifying them by color, even in the presence of various types of recyclable materials. Furthermore, a small-scale prototype has been developed, incorporating a conveyor belt where recyclable items pass through. The system automatically captures and classifies whether an object is a plastic bottle, and the results are displayed in real-time through the implementation of an additional electronic circuit.

It is crucial to emphasize that this project contributes to speeding up separating recyclable materials. Furthermore, it enhances resilience and the ability to adapt to the risks associated with climate change that impact waterways, pollute oceans, threaten wildlife, infiltrate the food chain, and increase the frequency of natural disasters worldwide. Additionally, there is an intention to share this design with ASOMUFAMEDIO for them to consider the feasibility of implementing a larger-scale machine in pursuit of a sustainable solution. This association is dedicated to environmental protection, care, and



conservation, further reinforcing the value of this initiative.

APROBACION DE LA TESIS

Nombre Presidente Jurado: **Diego Fernando Sendoya Losada**

Firma:

Nombre Jurado: **FAIBER IGNACIO ROBAYO BETANCOURT**

Firma:

Nombre Jurado: **JOHAN JULIÁN MOLINA MOSQUERA**

Firma:

**DISEÑO Y PROTOTIPO DE PLANTA SELECCIONADORA Y CLASIFICADORA DE
BOTELLAS DE PLÁSTICO CON VISIÓN ARTIFICIAL Y MACHINE LEARNING PARA
LA EMPRESA ASOMUFAMEDIO**

ANDRÉS FELIPE PALOMÁ COLAZOS

SERGIO DAVID CAQUIMBO DUSSÁN

**UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERIA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
NEIVA – HUILA
2023**

**DISEÑO Y PROTOTIPO DE PLANTA SELECCIONADORA Y CLASIFICADORA DE
BOTELLAS DE PLÁSTICO CON VISIÓN ARTIFICIAL Y MACHINE LEARNING PARA
LA EMPRESA ASOMUFAMEDIO**

**ANDRÉS FELIPE PALOMÁ COLLAZOS
CÓDIGO: 20181167824**

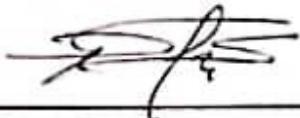
**SERGIO DAVID CAQUIMBO DUSSÁN
CÓDIGO: 20181166277**

**Trabajo de grado presentado como requisito para obtener el título de Ingeniero
Electrónico**

**Director:
Diego Fernando Sendoya Losada
Ingeniero Electrónico, MSc. en Ingeniería de Control Industrial.**

**UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERIA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
NEIVA – HUILA
2023**

Notas de Aceptación



Firma del presidente del Jurado
DIEGO FERNANDO SENDOYA LOSADA



Firma del Jurado
FAIBER IGNACIO ROBAYO BETANCOURT



Firma del Jurado
JOHAN JULIÁN MOLINA MOSQUERA

Agradezco y dedico en primer lugar a Dios por permitirme alcanzar este logro, a mis padres Sandra Milena Collazos y Víctor Palomá quienes son mi principal motivo, apoyo en cualquier situación y a quién les debo todo lo que soy. A mi hermano menor Juan José que con su ternura e inocencia le agrada ver mis proyectos y mis trabajos. A mi pareja Laura Valentina Anturi quien ha sido una fuente de ayuda, amor incondicional, acompañamiento y motivo para lograr mis metas. A mi compañero Sergio Caquimbo que persistiendo pudimos lograr el desarrollo de este trabajo de grado. A mis amigos y familiares que de alguna forma me brindaron su compañía y ayuda en este proceso. Y también agradecer a mis profesores de carrera quienes fueron un pilar importante en todo mi aprendizaje y desarrollo en mi formación profesional.

Andrés Felipe Palomá Collazos

Agradezco a mis padres Judith Andrea Dussán y Yomberly Caquimbo por permitirme lograr esta meta de convertirme en ingeniero, aportando su apoyo tanto emocional como financiero, y por, sobre todo, plantar en mí una idea de siempre llevar el conocimiento de la mano. A mis hermanos por estar orgullosos de quien es su hermano mayor y verme, así como un ejemplo a seguir. A mi pareja Karol Yelena Illera, quien, en los momentos más complicados donde no encontraba el camino para llegar a esta meta, iluminar ese sendero a seguir y recordarme quien soy y de lo que soy capaz, dándome las fuerzas para seguir adelante con este sueño. A mi compañero Felipe Palomá que nunca se rindió con este trabajo de grado y sacó fuerza para ambos en los momentos difíciles de desarrollo de este proyecto. A mis familiares y amigos que hicieron parte de este proceso, con su apoyo e ideas para superar los baches que se presentaban a lo largo de mi carrera. Y, por último, agradecer a los ingenieros que con su conocimiento me mostraron el camino a seguir a lo largo de este procedimiento académico.

Sergio David Caquimbo Dussán

AGRADECIMIENTOS

Un agradecimiento especial a nuestro asesor de Tesis, el Ingeniero Diego Fernando Sendoya por su apoyo y supervisión a lo largo de todo este trabajo proyecto de grado y especialmente, por su acompañamiento persistente. A la ingeniera Ana María Polo por el planteamiento de la problemática sucedida en ASUMUFAMEDIO y ser el primer puente para encontrar la metodología de este proyecto de grado y a su vez los integrantes de esta asociación por brindarnos información acerca de sus procedimientos en la etapa de reciclaje. Al ingeniero Faiber Robayo por ser nuestro primer asesor y ayudarnos a plantear las bases de viabilidad de este trabajo. Al ingeniero José Salgado por sus asesorías relacionadas a la Visión por Computador y su aporte de un instrumento clave para este proyecto (Cámara digital sin Filtro IR). Al ingeniero Neisar Salazar por los conocimientos otorgados en la aplicación de registros lógicos de desplazamiento. A nuestros compañeros por su acompañamiento y aportes en campos relacionados a las aplicaciones usadas en este proyecto. Y por último y no menos importante un agradecimiento especial a los miembros, ingenieros y administrativos del programa de ingeniería electrónica.

TABLA DE CONTENIDO

	Pág.
1. INTRODUCCIÓN	13
2. OBJETIVOS	14
2.1. OBJETIVO GENERAL	14
2.2. OBJETIVOS ESPECÍFICOS	14
3. MARCO DE TRABAJO	15
3.1. CLASIFICACIÓN DE BOTELLAS DE PLÁSTICO	15
3.1.1. Detección De Plástico En Las Botellas	16
3.1.1.1. Espectroscopia NIR	17
3.1.1.2. Sensibilidad Espectral	19
3.1.2. Clasificación De Botellas De Plástico Por Color	20
3.2. INTELIGENCIA ARTIFICIAL	21
3.2.1. Machine Learning	21
3.2.1.1. Redes Neuronales (Deep Learning)	22
3.2.1.2. Yolov5	24
3.2.2. Visión Artificial	24
3.2.2.1. Opencv	24
3.2.2.2. Python	25
4. METODOLOGÍA Y RESULTADOS	26
4.1. ETAPAS DE DESARROLLO DEL SISTEMA	27
4.1.1. Etapa De Selección De Botella	28
4.1.1.1. Materiales De Etapa	29
4.1.1.2. Construcción De Etapa	30
4.1.1.3. Resultados De Etapa	34
4.1.2. Etapa De Detección De Plástico	36
4.1.2.1. Materiales De Etapa	37
4.1.2.2. Construcción De Etapa	38
4.1.2.3. Resultados De Etapa	43
4.1.3. Etapa De Clasificación De Color	45
4.1.3.1. Materiales De Etapa	46
4.1.3.2. Construcción De Etapa	46
4.1.3.3. Resultados De Etapa	52
4.1.4. Etapa De Visualización	53
4.1.4.1. Materiales De Etapa	54
4.1.4.2. Construcción De Etapa	54
4.1.4.3. Resultados De Etapa	59
4.1.5. Etapa De Implementación De Planta A Baja Escala	62
4.1.5.1. Materiales De Etapa	62
4.1.5.2. Construcción De Etapa	62
4.1.5.3. Resultados De Etapa	65
5. ANALISIS DE RESULTADOS	68
5.1. LIMITACIONES DEL SISTEMA	68
5.2. VALIDACIÓN DE RESULTADOS	70
5.3. RECOMENDACIONES DE USO	72
6. CONCLUSIONES	74
7. TRABAJO A FUTURO	76

LISTA DE FIGURAS

	Pág.
Figura 1. Proceso de reciclaje de Botellas PET.	15
Figura 2. Clasificación manual de Botellas.	16
Figura 3. Tipos de plástico.	17
Figura 4. Espectro Reflectivo de diferentes Termoplásticos.	18
Figura 5. Interacción de la luz con la materia.	19
Figura 6. Espectro visible humano vs sensores CCD y CMOS.	19
Figura 7. Ramas de la Inteligencia Artificial.	21
Figura 8. Arquitectura de una Red Neuronal Artificial.	22
Figura 9. Estructura de una Red Neuronal Convolucional.	23
Figura 10. Diagrama de la Metodología.	26
Figura 11. Flujo principal del sistema.	28
Figura 12. Diagrama etapa de selección de Botella.	29
Figura 13. Imagenes tomadas con la extensión de Google.	30
Figura 14. Imagenes de "Bottles and Cans Images".	30
Figura 15. Dataset "Drinking Waste Classification".	31
Figura 16. Toma de Imágenes personalizadas de botellas.	31
Figura 17. Ejemplo de cambio de características de imagen para aumentar.	31
Figura 18. Organización de la base de datos por carpetas.	32
Figura 19. Etiquetado de imágenes en makesense.ai.	32
Figura 20. Contenido de etiquetas para YoloV5.	33
Figura 21. Comparación entre redes neuronales de YoloV5.	33
Figura 22. Gráfica de Épocas vs Precisión.	34
Figura 23. Gráficas de épocas vs Disminución de Error.	35
Figura 24. Gráfica de Confianza vs Precisión del modelo.	35
Figura 25. Pruebas de detección de modelo.	36
Figura 26. Diagrama etapa de detección de plástico.	37
Figura 27. Caja para el sistema de detección de plástico.	38
Figura 28. Pintado de caja para evitar luminosidad.	39
Figura 29. Medidas de ubicación de LEDs.	39
Figura 30. Circuito de LEDs IR.	41
Figura 31. Prueba de LEDs IR con caja de prueba.	41
Figura 32. Instalación de LEDs y Difusor en la caja del sistema.	42
Figura 33. Parámetros de espacios de color.	42
Figura 34. Elección de parámetros para clasificación de etapa IR.	43
Figura 35. Flujo de etapa de Clasificación de Color.	46
Figura 36. Tipos de modelos de YoloV5.	47
Figura 37. Base de datos para modelo YoloV5L.	47
Figura 38. Modelo de precisión Modelo YoloV5L.	48
Figura 39. Precisión de la confianza del modelo.	48
Figura 40. Métricas de Box_Loss en YoloV5L.	49
Figura 41. Ejemplo de obtención de rango de colores.	49
Figura 42. Muestra de etapa de detección de color.	51
Figura 43. Diagrama etapa de visualización.	54
Figura 44. Circuito Kicad.	56
Figura 45. Conexiones entre objetos.	57

Figura 46. Modelado 3D PCB.	58
Figura 47. Modelado 3D Arduino.	58
Figura 48. PCB Final.	59
Figura 49. Construcción de la banda Transportadora.	63
Figura 50. Pintado de Banda Transportadora.	63
Figura 51. Terminación de banda Transportadora con Tela Lino.	63
Figura 52. Agrupación Física de las etapas principales.	64
Figura 53. Funcionamiento de "main.py".	65
Figura 54. Pruebas de ejecución de main.py.	65
Figura 55. Respuesta del sistema a botella procesada.	66
Figura 56. Fotograma de etapa de detección de plástico con baja altura.	68
Figura 57. Detección de plástico con ruido por exceso de luz.	68
Figura 58. Botella de aguardiente (vidrio) con etiqueta.	71
Figura 59. Conceptos de ajuste a los modelos de ML.	73

LISTA DE ANEXOS

	Pág.
Anexo 1. Tutorial de uso para YoloV5	81
Anexo 2. Documentación Técnica de Códigos Realizados	81

LISTA DE CUADROS

	Pág.
Cuadro 1. Parámetros de colores en CIELAB.	43
Cuadro 2. Pruebas de la Etapa Detección de Plástico.	44
Cuadro 3. Rangos de colores en HSV.	50
Cuadro 4. Rango de color RGB para el blanco.	50
Cuadro 5. Resultados en imágenes de etapa de Clasificación por Color.	52
Cuadro 6. Resultados Etapa de Visualización.	60
Cuadro 7. Materiales y modelos de etapas.	64
Cuadro 8. Resultados de planta completa a baja escala.	66
Cuadro 9. Porcentajes de Acierto y Error de Sistemas.	70

RESUMEN

La inteligencia artificial (IA) es un campo tecnológico de gran interés debido a su naturaleza multidisciplinaria, en el cual se desarrollan sistemas que imitan la capacidad humana para llevar a cabo tareas y resolver problemas. Este proyecto se vale de dos vertientes de la IA: el Aprendizaje Automático (Machine Learning) y la Visión Artificial, que se encargan de interpretar y reconocer objetos e información a partir de imágenes. Específicamente, el ML instruye a la máquina mediante la importación, exploración, preprocesamiento y extracción de características de bases de datos, mientras que la Visión Artificial se dedica al procesamiento, análisis e interpretación de imágenes digitales. Estas herramientas se combinan para diseñar un algoritmo capaz de identificar botellas de plástico y clasificarlas según su color, incluso cuando existen múltiples tipos de materiales reciclables. Además, se ha desarrollado un prototipo a pequeña escala que incluye una banda transportadora, a lo largo de la cual pasan los objetos reciclables. El sistema captura y clasifica automáticamente si se trata de una botella de plástico, y los resultados se visualizan en tiempo real mediante la implementación de un circuito electrónico adicional.

Es fundamental destacar que este proyecto contribuye a agilizar el proceso de separación de materiales reciclables. Además, refuerza la resiliencia y la capacidad de adaptación a los riesgos asociados al cambio climático que impactan en vías fluviales, contaminan los océanos, amenazan la vida silvestre, se introducen en la cadena alimentaria y aumentan la frecuencia de desastres naturales en todo el mundo. Asimismo, se tiene la intención de compartir este diseño con ASOMUFAMEDIO para que puedan considerar la viabilidad de implementar una máquina a mayor escala en busca de una solución sostenible. Esta asociación se dedica a la protección, el cuidado y la conservación del medio ambiente, lo que refuerza aún más el valor de esta iniciativa.

Palabras claves: Aprendizaje automático, Botellas, Clasificación, Color, Detección, Imágenes, Inteligencia Artificial, Plástico, Redes Neuronales, Visión por computador.

ABSTRACT

Artificial intelligence (AI) is a highly intriguing technological field due to its multidisciplinary nature, where systems are developed to mimic human capacity in performing tasks and solving problems. This project leverages two branches of AI: Machine Learning (ML) and Computer Vision, which are responsible for interpreting and recognizing objects and information from images. Specifically, ML instructs the machine through data importation, exploration, preprocessing, and feature extraction from databases, while Computer Vision is dedicated to the processing, analysis, and interpretation of digital images. These tools are combined to design an algorithm capable of identifying plastic bottles and classifying them by color, even in the presence of various types of recyclable materials. Furthermore, a small-scale prototype has been developed, incorporating a conveyor belt where recyclable items pass through. The system automatically captures and classifies whether an object is a plastic bottle, and the results are displayed in real-time through the implementation of an additional electronic circuit.

It is crucial to emphasize that this project contributes to speeding up separating recyclable materials. Furthermore, it enhances resilience and the ability to adapt to the risks associated with climate change that impact waterways, pollute oceans, threaten wildlife, infiltrate the food chain, and increase the frequency of natural disasters worldwide. Additionally, there is an intention to share this design with ASOMUFAMEDIO for them to consider the feasibility of implementing a larger-scale machine in pursuit of a sustainable solution. This association is dedicated to environmental protection, care, and conservation, further reinforcing the value of this initiative.

Keywords: Artificial Intelligence, Bottles, Classification, Color, Computer Vision, Detection, Images, Machine Learning, Neural Networks, Plastic.

1. INTRODUCCIÓN

A nivel mundial el medio ambiente está afectado por la producción del plástico (en su mayoría botellas), la contaminación por plásticos tiene impactos negativos en los diferentes ecosistemas donde ha llegado y perdura por una cantidad de tiempo muy superior al tiempo de utilidad que brindaron dichos productos¹, se puede considerar que una solución para el beneficio al medio ambiente es deteniendo su demanda gracias al reciclaje, ya que contiene diversos procesos de reutilización y se debe realizar varios estudios para que se pueda aprovechar en su mayoría². En diferentes empresas relacionadas con los sanitarios de basura y de cuidado del medio ambiente impulsan el reciclaje a través de la conversión de residuos en nuevos productos; estas empresas buscan una mayor organización a los extensos procesos de clasificación, tratamiento y monitoreo de los materiales reciclados más demandados con la finalidad de seccionar por tipo de material y así comenzar su proceso con diferentes métodos mecánicos, químicos, energéticos y biológicos³. Lo más común en estas compañías es realizar las supervisiones y la clasificación de estos materiales reciclables que en su mayoría son botellas de plástico de manera manual, generando el riesgo para las personas al exponerse a materiales tóxicos y peligrosos como el contacto con sustancias cáusticas y generando un control no tan efectivo en la recolección de estos materiales⁴.

Uno de los objetivos principales de las nuevas tecnologías, la ingeniería y el desarrollo de software es realizar actividades que son ejecutadas por el ser humano. Lo que busca este proyecto es poder crear a baja escala un sistema capaz de seleccionar y clasificar botellas de plástico, simulando lo que realizan diversos trabajadores con diferentes herramientas de automatización en desarrollo de software, visión por computador y enseñándole a una máquina por medio de resultados, el método que realiza una persona (lo que se conoce hoy en día como Aprendizaje Automático). Esto puede generar diversas ideas para llevarse a un nivel más industrial, proponiendo una perspectiva de poder realizar una planta a alta escala en los sitios en donde se realiza esta clasificación de forma manual, garantizando así la integridad de algunos trabajadores y aprovechando sus habilidades en otras áreas de innovación, consentimiento del reciclaje y gestión humana.

¹ TÉLLEZ MALDONADO, Alejandra. La complejidad de la problemática ambiental de los residuos plásticos: una aproximación al análisis narrativo de política pública en Bogotá. [en línea]. Tesis de maestría. Universidad Nacional de Colombia, 2012 [Fecha de consulta: 27 de mayo 2023]. Disponible en: <https://repositorio.unal.edu.co/handle/unal/10015>.

² ARTHUZ-LÓPEZ, L.; PÉREZ-MORA, W. Alternativas de bajo impacto ambiental para el reciclaje del poliestireno expandido a nivel mundial. [en línea]. Artículo de revisión. Servicio Nacional de Aprendizaje SENA (Colombia), 2019 [Fecha de consulta: 27 de mayo 2023]. Disponible en: https://revistas.sena.edu.co/index.php/inf_tec/article/view/1638. ISSN: 2256-5035.

³ Proceso de reciclaje [sitio web]. Guadalajara: Aseca. [Fecha de consulta: 28 de mayo 2023]. Disponible en: <https://aseca.com/proceso-de-reciclaje>.

⁴ Los riesgos de la gestión de residuos – Protección laboral [sitio web]. Interempresas. [Fecha de consulta: 28 de mayo 2023]. Disponible en: <https://www.interempresas.net/Proteccion-laboral/Articulos/213083-Los-riesgos-de-la-gestion-de-residuos.html>

2. OBJETIVOS

2.1. OBJETIVO GENERAL

Diseñar un sistema automatizado de detección y selección de botellas de plástico dentro de otros materiales reciclables y clasificarlas por colores para garantizar eficiencia en el proceso de separación de botellas y una mejor organización de gastos en la empresa ASOMUFAMEDIO.

2.2. OBJETIVOS ESPECÍFICOS

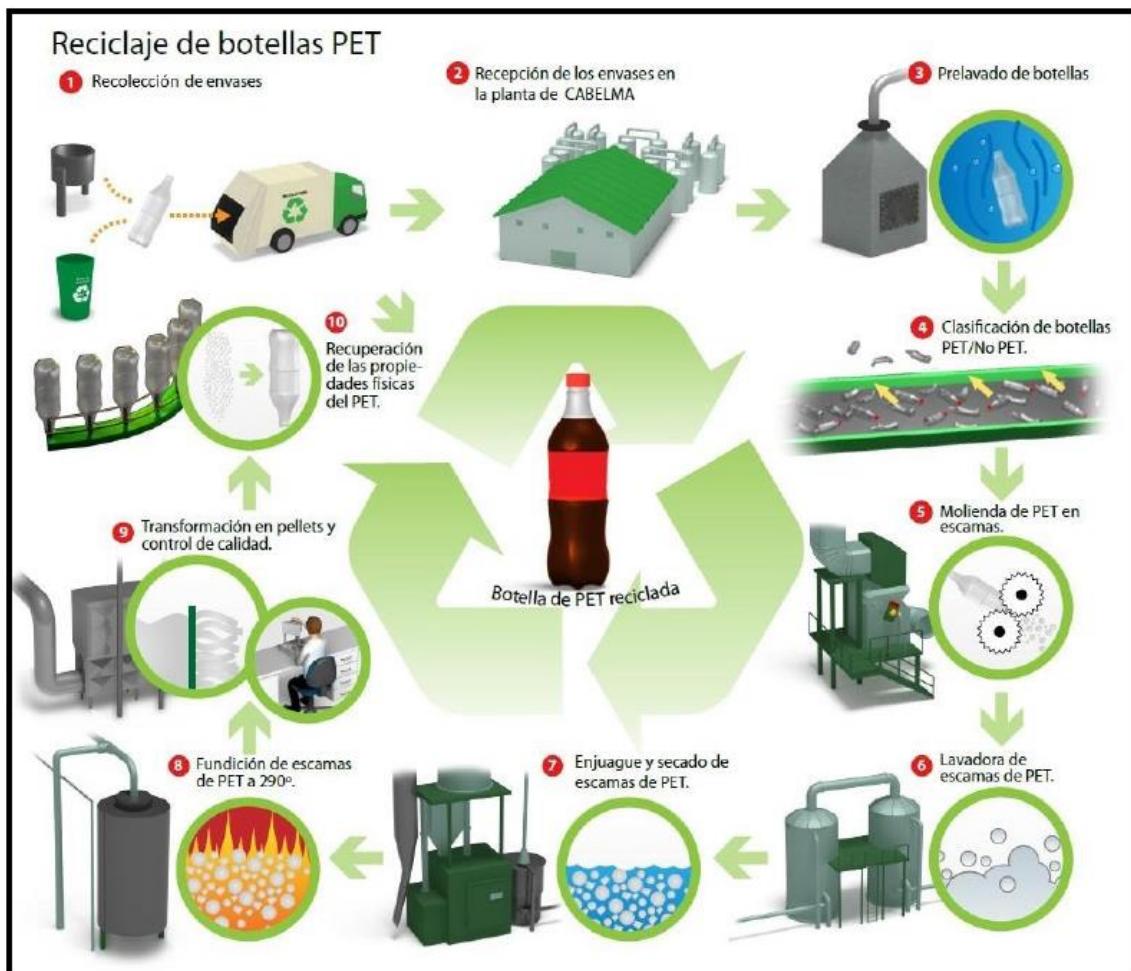
- Detección y separación de botellas de plástico dentro de diferentes materiales reciclables utilizando herramientas de reconocimiento inteligente, redes neuronales aplicando métodos de Machine Learning con bases de datos y técnicas de visión por computador.
- Clasificar las botellas de plástico detectadas por color aplicando funciones y técnicas de visión por computador.
- Implementar a pequeña escala el sistema automatizado de separación de botellas de plástico de otros materiales y su clasificación por color, asegurando el correcto funcionamiento de los algoritmos y del sistema.

3. MARCO DE TRABAJO

3.1. CLASIFICACIÓN DE BOTELLAS DE PLÁSTICO

La clasificación de botellas de plástico hace parte del reciclaje de materiales sólidos, dada su fabricación y composición química sus desechos pueden convertirse en importantes combustibles y en otras sustancias peligrosas que pueden afectar la atmósfera⁵. Una de sus características es su moldeabilidad y plasticidad durante su producción lo que permite diferentes maneras de ser reciclado⁶.

Figura 1. Proceso de reciclaje de Botellas PET.



FUENTE: García, Eliana Susana. Los residuos potencialmente reciclables y la elaboración de nuevos productos a través del reciclaje [En línea]. Trabajo de tesis, publicado el 09 de octubre de 2014. pp. 87-88.

⁵ CHAMÁN, Antonio Benjamín Say. Manejo de la basura y su clasificación. [En línea]. Artículo publicado en 2019, Gutamela. [Fecha de consulta: 26 de junio 2023]. Disponible en: biblioteca.usac.edu.gt.

⁶ García, Eliana Susana. Los residuos potencialmente reciclables y la elaboración de nuevos productos a través del reciclaje [En línea]. Trabajo de tesis, publicado el 09 de octubre de 2014. [Fecha de consulta: 27 de agosto 2023]. Disponible en: <https://ri.unlu.edu.ar/xmlui/handle/rediunlu/1218>.

En la Figura 2, se visualiza el subproceso 4 que es la clasificación de las botellas, este es el enfoque de este proyecto ya que en muchas industrias que realizan este proceso de reciclaje, la etapa de clasificación se ejecuta manualmente⁷.

Figura 2. Clasificación manual de Botellas.



FUENTE: García, Eliana Susana. Los residuos potencialmente reciclables y la elaboración de nuevos productos a través del reciclaje [En línea]. Trabajo de tesis, publicado el 09 de octubre de 2014. pp. 84.

Gracias al desarrollo de software y a las herramientas que nos brinda la ingeniería electrónica, se han hecho diseños de plantas con la capacidad de separar botellas de plástico de forma automática reduciendo costos y tiempos, a continuación, se presenta un ejemplo.

- **Diseños de redes neuronales para la clasificación de botellas por medio del procesamiento de imágenes digitales:** las redes neuronales crean modelos de detección y reconocimiento de objetos siendo un área muy popular en la actualidad en el que se está llevando diversos desarrollos a nivel mundial por diferentes organizaciones. Gracias al objetivo de lograr enseñarle a la maquina comprender datos, se ha podido realizar investigaciones y diseños de una red neuronal convolucional que detecta las botellas por su etiqueta, la cual reconoce para clasificar por su marca y color de cada una de ellas⁸.

Resulta atractivo este método de aplicar herramientas de la inteligencia artificial para simular y automatizar el clasificado de botellas de plástico enfocado en la detección de su forma, ya que en los lugares donde se reciclan estas botellas es común que no cuenten con su etiqueta y/o marca.

3.1.1. Detección De Plástico En Las Botellas

Es importante conocer los conceptos y la composición del plástico para dar una solución a ¿cómo se va a detectar solo botellas de plástico sin que se confundan con botellas de

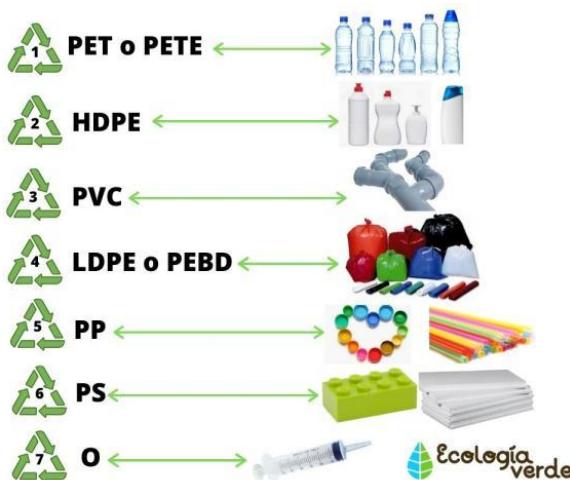
⁷ VEOLIA. [sitio Web]. España: Gestión de Residuos. [Fecha de consulta: 02 de mayo 2023]. Disponible en: <https://www.veolia.com/latamib/es/soluciones/gestion-residuos>

⁸ LUNA BUSTAMENTE, Genesis Janeth y VASCONEZ CAMINO, Kleyner Ariel. DESARROLLO DE UNA RED NEURONAL CONVOLUCIONAL PARA LA CLASIFICACIÓN DE BOTELLAS... [En línea]. Trabajo de grado. Universidad Estatal de Milagro, Febrero 2020. [Fecha de consulta: 26 de agosto 2023]. Disponible en: <https://repositorio.unemi.edu.ec/handle/123456789/5130>

vidrio? Y así, obtener el prototipo más robusto de seleccionar solo las botellas de plástico para su clasificación.

- **El plástico:** Es un polímero que se combina con diversos aditivos y productos químicos para constituir los distintos tipos de plástico presentes en todo el mundo. Su relevancia radica en su capacidad para facilitar el proceso de moldeo y prensado en comparación con otros materiales. Esta característica es la que posibilita la amplia diversidad de plásticos, dado que su versatilidad permite la fabricación de una extensa gama de productos⁹. En la siguiente figura se pueden observar los diferentes tipos de plásticos.

Figura 3. Tipos de plástico.



FUENTE: “Tipos de plásticos”. [En línea]. Página web. Disponible en: <https://www.ecologiaverde.com/tipos-de-plasticos-1732.html>

3.1.1.1. Espectroscopia NIR

Existen diferentes formas de detectar y clasificar el plástico debido a su densidad y composición química, pero en este caso, se estudian los métodos en que se pueda detectar por imagen¹⁰.

- **Near Infrared Spectroscopy**

La espectroscopia de infrarrojo cercano (NIR) es una de las tecnologías más desarrolladas para el reciclaje de plástico. Se basa en la recolección de espectros de la longitud de onda reflejada por los polímeros (plásticos), energizados por una fuente de luz, que, en este proceso, es luz infrarroja¹¹. La tecnología NIR comúnmente utiliza LEDs

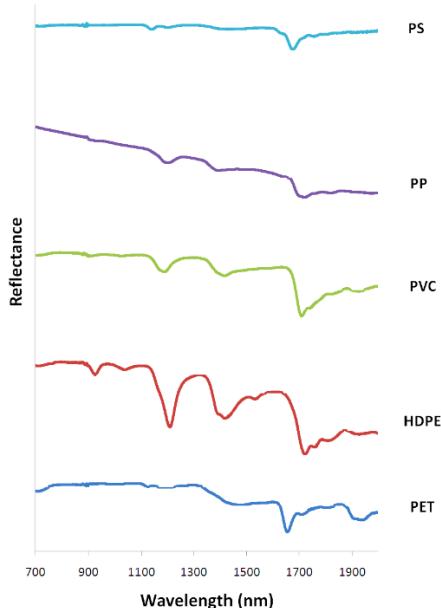
⁹ ELIAS, Xavier y JURADO, Lorena. LOS PLASTICOS RESIDUALES Y SUS POSIBILIDADES DE VALORIZACIÓN. Madrid: Ediciones Díaz de Santos, 2012. ISBN 978-84-9969-371-2.

¹⁰ SERRANTI, Silvia y BONIFAZI, Giusuppe. Techniques for separation of plastic wastes. [En línea]. Department of Chemical Engineering, Materials & Environment, Sapienza University of Rome, Rome, Italy. [Fecha de consulta: 7 de marzo 2023]. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/B9780081026762000025>

¹¹ ibid. pp. 23

receptores para medir la intensidad IR reflejada al exponerla a una fuente de luz IR con LEDs emisores. En otros casos, se pueden emplear espacios de color capaces de detectar la reflectancia característica de los plásticos y, a partir de esos resultados, identificarlos en las imágenes¹². En diferentes compañías se puede analizar que su mayoría de material reciclable son botellas de plástico con la referencia PET y HDPE¹³.

Figura 4. Espectro Reflectivo de diferentes Termoplásticos.



FUENTE: Masoumi, Hamed & Safavi, Seyed Mohsen & Khani, Z.. “Identification and classification of plastic resins using near infrared reflectance spectroscopy”. International Journal of Mechanical and Industrial Engineering. Vol. 6, 2012, p. 215.

Según la figura anterior, se pueden encontrar 2 puntos importantes para la apropiada clasificación de estos plásticos, los cuales son en 1656 nm y 1724 nm de longitud de onda, en estos puntos se logra identificar una inflexión en la reflectancia del plástico PET y en el plástico HDPE respectivamente. En base a esta información se puede diferenciar entre estos dos, mientras en 1656 nm de longitud de onda el valor de reflectancia de plástico PET es bajo, para el plástico HDPE es considerablemente alto¹⁴.

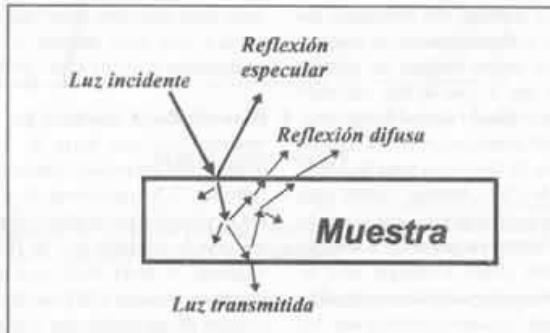
En el caso del proyecto, se planea utilizar el NIR para separar el Plástico del vidrio teniendo en cuenta las características de absorción y reflectancia de estos materiales, así se capturan parámetros específicos que pueden ayudar a clasificarlos. Para brindar un mejor detalle de este proceso, se puede visualizar la Figura 5.

¹² BURBANO YULE, Hernán Camilo. Fusión de imágenes hiperespectrales y visibles para la clasificación de residuos plásticos. [En línea]. Tesis de grado. Publicado en PONTIFICIA UNIVERSIDAD JAVERIANA, 2013. [Fecha de consulta: 4 de noviembre 2022]. Disponible en: <https://repository.javeriana.edu.co/handle/10554/13600>

¹³ Garcia, Eliana Susana. 09 de octubre de 2014.

¹⁴ MASOUMI, HAMED & SAFAVI, SEYED MOHSEN & KHANI, Z.. Identification and classification of plastic resins using near infrared reflectance spectroscopy. [en línea]. Artículo. International Journal of Mechanical and Industrial Engineering. 6. p. 213-220, 2012 [Fecha de consulta: 23 de agosto 2023]. Disponible en: https://www.researchgate.net/publication/285330830_Identification_and_classification_of_plastic_resins_using_near_infrared_reflectance_spectroscopy

Figura 5. Interacción de la luz con la materia.



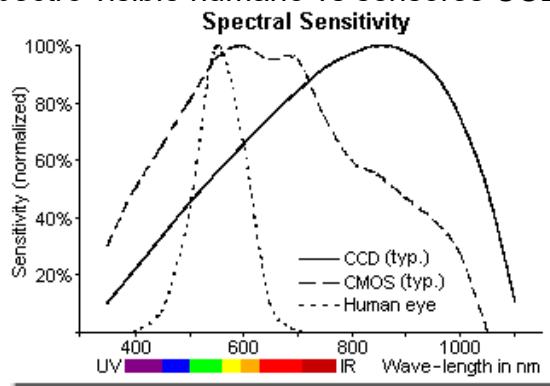
FUENTE: ALOMAR, Daniel, y FUCHSLOCHER, Rita. FUNDAMENTOS DE LA ESPECTROSCOPIA DE REFLECTANCIA... [En línea]. Publicado en Universidad Austral de Chile, 1998, 2023. Disponible en: <http://146.83.217.169/index.php/agrosur/article/view/3840>.

La luz incidente se refiere a la fuente de luz infrarroja proporcionada a la muestra. Esta luz es absorbida en diferentes proporciones por la muestra, dependiendo de su composición, generando una parte de energía transmitida (llamada refracción) y otra parte reflejada (tanto reflexión specular como reflexión difusa), que se conoce como reflexión. La detección y captura de esta energía reflejada permite determinar si el objeto está fabricado con plástico¹⁵.

3.1.1.2. Sensibilidad Espectral

Para capturar estos fenómenos de absorción y reflexión de luz IR, se puede quitar el filtro contra la luz infrarroja que las cámaras contienen en su lente¹⁶. Para elegir la cámara adecuada se debe analizar el tipo de sensor que poseen y ver cómo se comportan con las ondas electromagnéticas que emite la luz IR. En la Figura 6, se puede ver el comparativo de sensores CCD, CMOS y el ojo humano con respecto a la longitud de onda de la luz.

Figura 6. Espectro visible humano vs sensores CCD y CMOS.



FUENTE: WP. [Sitio Web]. CCD and CMOS Sensor Info. 2010. Disponible en: <http://www.fen-net.de/walter.preiss/e/slomoinf.html>.

¹⁵ ALOMAR, Daniel, y FUCHSLOCHER, Rita. FUNDAMENTOS DE LA ESPECTROSCOPIA DE REFLECTANCIA EN EL INFRAROJO CERCANO (NIRS) COMO MÉTODO DE ANÁLISIS DE FORRAJES. [En línea]. Publicado en Universidad Austral de Chile. [Fecha de consulta: 31 de agosto 2023]. Disponible en: <http://146.83.217.169/index.php/agrosur/article/view/3840>.

¹⁶ BURBANO YULE, Hernán Camilo (2013).

Para capturar adecuadamente el fenómeno de refracción y reflexión de luz infrarroja en las muestras, es necesario utilizar una cámara CCD y eliminar el filtro de infrarrojos para que la luz capturada sea visible en la imagen generada por la cámara.

3.2.2. Clasificación De Botellas De Plástico Por Color

La clasificación de botellas de plástico por color es fundamental en el proceso de reciclaje, ya que determina cómo se reutilizarán. Se clasifican en categorías como transparente (PET), blancas (HDPE), marrones (color malta), verdes y otros colores. Esta diferenciación se basa en las oportunidades de reutilización, siendo las botellas transparentes las más versátiles para la fabricación de diversos productos, en contraste con las botellas de colores.¹⁷ Se pueden visualizar los beneficios de la reutilización dependiendo del color:

- **Transparente:** Estas botellas a menudo se utilizan para envases de agua, bebidas carbonatadas, jugos y otros líquidos gracias al procesamiento de lavado y recuperación de forma. El plástico transparente es altamente valorado en el reciclaje debido a su pureza y versatilidad¹⁸.
- **Blancas:** Estas botellas también pasan por un proceso de reciclaje similar al de las transparentes, que incluye lavado y soplado para recuperar su forma. Un aspecto importante es que, debido a su densidad molecular, estas botellas tienden a tener una composición rígida, resistente y mayor tolerancia a temperaturas altas¹⁹.
- **Malta (Marrón):** Estas botellas a la hora de ser recicladas tienen funciones específicas de descomposición mecánica y química logrando que su materia sea reutilizada en la construcción y en el agro²⁰. A diferencia de las botellas transparentes estas no tienden a ser reutilizadas como recuperación de botellas.
- **Verde:** La gran mayoría de botellas verdes, en sí son botellas transparentes teñidas a un color verdoso, lo cual hace complicada su reutilización; además, algunas empresas han optado estos últimos años por dejar de producir este tipo de botellas ya que no genera ningún valor su reutilización por su color²¹. Debido a esto, es necesario que estas botellas se distingan de las transparentes para que

¹⁷ TXS. [sitio web]. ¿Por qué las botellas transparentes son más amigables con el medio ambiente que las de color? Publicado el 20 septiembre de 2021. [Fecha de consulta: 26 de agosto 2023] Disponible en: <https://txsplus.com/2021/09/por-que-las-botellas-transparentes-son-mas-amigables-con-el-medio-ambiente-que-las-de-color/>

¹⁸ Ibid.

¹⁹ Rosaenvases. [Sitio Web]. Envases HDPE: material, utilidades y ventajas de su uso. España: Subido 13 agosto 2020. [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://rosaenvases.com/blog/envases-plastico>.

²⁰ Bluradio. [sitio web]. Envase de la Pony Malta es reciclado para usarse en la construcción y en el agro. Colombia: 29 abril 2016. [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://www.bluradio.com/medio-ambiente/envase-de-la-pony-malta-es-reciclado-para-usarse-en-la-construcion-y-en-el-agro>

²¹ Elempaque. [sitio web]. Coca Cola anuncia que eliminará el PET verde de sus productos en América del Norte. 29 julio 2022. [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://www.elempaque.com/es/noticias/coca-cola-anuncia-que-eliminara-el-pet-verde-de-sus-productos-en-america-del-norte>

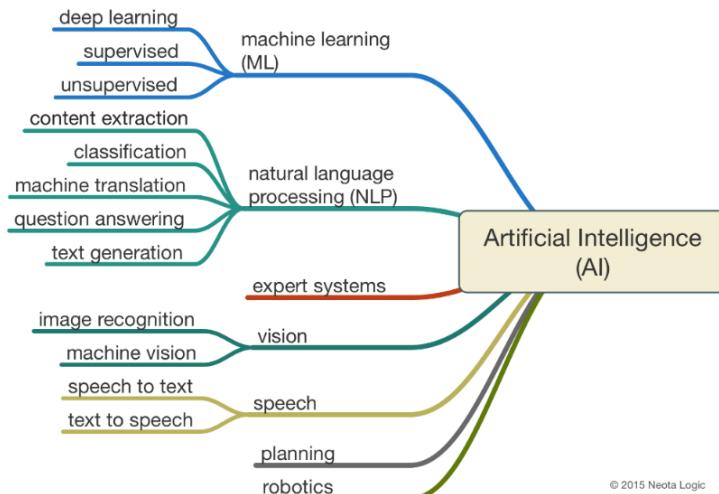
sean procesadas en otros campos como la descomposición química y aprovechar su material.

- **Otros colores:** las botellas fabricadas tanto en PET como en HDPE que han sido teñidas con colores tienden a experimentar una disminución en su valor cuando se considera su reutilización. En consecuencia, la mayoría de estas botellas de colores se agrupan en grandes cantidades para someterlas a métodos de trituración mecánica y descomposición química, con el fin de aprovechar sus materiales en otras aplicaciones.

3.2. INTELIGENCIA ARTIFICIAL

El campo de la inteligencia artificial (IA) está en constante evolución, teniendo la habilidad de aprender conceptos y reconocer parámetros específicos, con el fin de solucionar problemas²². Dos de los enfoques principales de la IA es el reconocimiento de objetos y la clasificación de datos, en donde se involucran diversos algoritmos que simulen lo que una persona puede hacer a la hora de enfrentarse a diversos problemas de estos enfoques²³.

Figura 7. Ramas de la Inteligencia Artificial.



FUENTE: PlanetaChatBot. [Sitio Web]. Historia de la Inteligencia artificial relacionada con los Chatbots. 1 septiembre 2017. Disponible en: <https://planetachatbot.com/historia-inteligencia-artificial-relacionada-con-chatbots/>

3.2.1. Machine Learning

El Aprendizaje Automático o también conocido como Machine Learning (ML) es una herramienta para entrenar modelos que puedan clasificar y entender basándose en información y/o ejemplos previamente establecida. ML puede resolver situaciones a partir de datos, indicando que entre más datos se tengan mejores resultados obtendremos²⁴.

²² Heaton, Jeff. Artificial Intelligence for Humans, Volume 1: Fundamental Algorithms. [En línea]. Artículo publicado por Heaton Research, Inc. St. Louis, MO, USA, fecha: noviembre 26, 2013. [Fecha de consulta: 26 de junio 2023]. Disponible en: www.heatonresearch.com

²³ ibid.

²⁴ ROJAS, Esperanza Manrique. Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. [En línea]. Artículo de investigación. Publicado en Revista Ibérica de Sistemas y

El ML tiene diferentes categorías, la más indicada para este trabajo de grado, es el Aprendizaje Supervisado.

- **Aprendizaje Supervisado:**

Es el uso de conjunto de datos etiquetados (información válida) para entrenar algoritmos de clasificación y/o predicción en el que se identifican parámetros y características de estos datos²⁵. Se puede decir que es el método que más define al ML y el más utilizado para la detección de objetos. Los algoritmos más representativos del aprendizaje supervisado son: Redes Neuronales y K vecino más cercano (KNN)²⁶.

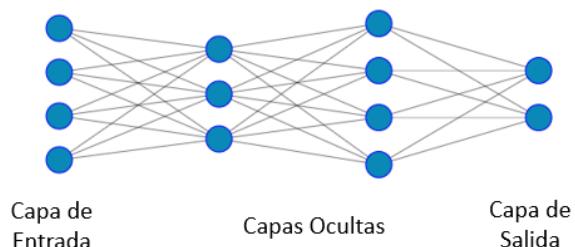
3.2.1.1. Redes Neuronales (Deep Learning)

El aprendizaje profundo o Deep Learning (DL) es una categoría del ML muy popular en la actualidad por el gran desarrollo de estos últimos años. El Deep Learning se basa en trabajar en Redes Neuronales Artificiales, ANN (Artificial Neuronal Network) las cuales simulan el funcionamiento de aquellas conexiones y manejo de impulsos neuronales biológicos del cerebro y esto genera otra categoría llamada Redes Neuronales Artificiales para el procesamiento y clasificación de imágenes^{27 28}.

- **Redes Neuronales Artificiales (ANN):**

El funcionamiento de las ANN es hallar la sumatoria de los pesos que tiene cada entrada de la neurona de datos para umbralizar y obtener el dato de salida (puntaje de similitud)²⁹. En la Figura 8, se puede visualizar la arquitectura de una red neuronal artificial.

Figura 8. Arquitectura de una Red Neuronal Artificial.



FUENTE: GENESIS, Luna y KLEYNER, Vasconez. DESARROLLO DE UNA RED NEURONAL CONVOLUCIONAL PARA LA CLASIFICACIÓN DE BOTELLAS... Proyecto de grado. Publicado en

Tecnologías de la información, 06 febrero 2020 [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://www.proquest.com/openview/c7e24c997199215aa26a39107dd2fe98/1?pq-origsite=gscholar&cbl=1006393>.

²⁵ IBM. [sitio web]. ¿Qué es el aprendizaje supervisado? [Fecha de consulta: 16 de julio 2023]. Disponible en: <https://www.ibm.com/mx-es/topics/supervised-learning>.

²⁶ Ibid.

²⁷ OLABE, Xabier Basogain. Redes neuronales artificiales y sus aplicaciones. Publicaciones de la Escuela de Ingenieros de Bilbao, 1998. [Fecha de consulta: 29 de agosto 2023].

²⁸ Ibid. pp. 6.

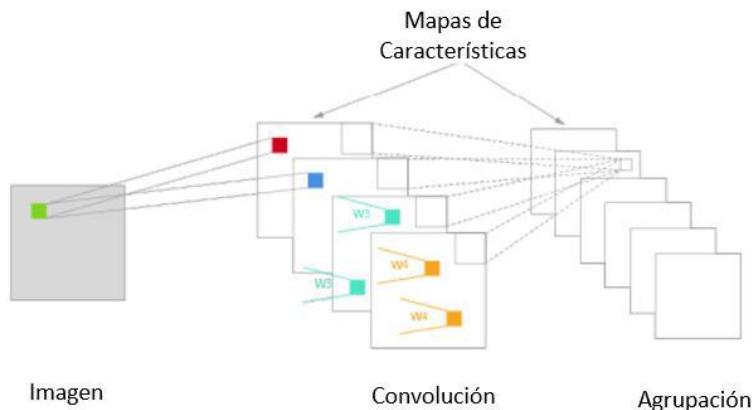
²⁹ Ibid. pp. 6.

La Capa de Entrada alberga la información que se busca validar o entrenar. Mientras tanto, las Capas Ocultas consisten en conjuntos de neuronas interconectadas que operan mediante una función de activación. Su función principal es ajustar los pesos y bias para proporcionar la información correcta a la Capa de Salida. Esta última representa la respuesta deseada una vez que se han procesado los datos de la Capa de Entrada, habiendo ajustado la información en las Capas Ocultas para dar la respuesta requerida³⁰³¹.

- **Redes Neuronales Convolucionales (CNN)**

Anteriormente se realizaban procesos manuales para la extracción de características en imágenes y así capturar el contenido en ellas, de este modo, las CNN se desarrollaron para brindar un enfoque más escalable a las tareas de clasificación de imágenes y detección de objetos al aprovechar principios del álgebra lineal, enfocado en el análisis de las matrices³² ³³ ³⁴ ³⁵ ³⁶.

Figura 9. Estructura de una Red Neuronal Convolucional.



FUENTE: GENESIS, Luna y KLEYNER, Vasconez. desarrollo de una red neuronal convolucional para la clasificación de botellas... Proyecto de grado. Publicado en UNIVERSIDAD ESTATAL DE MILAGRO, Ecuador, febrero 2020. Disponible en: <https://repositorio.unemi.edu.ec/handle/123456789/5130>. pp. 24.

³⁰ GENESIS, Luna y KLEYNER, Vasconez. febrero 2020.

³¹ MicrosoftLearn. [sitio Web]. ¿Cómo aprenden las redes neuronales?. [Fecha de consulta: 31 de agosto 2023]. Disponible en: <https://learn.microsoft.com/es-es/archive/msdn-magazine/2019/april/artificially-intelligent-how-do-neural-networks-learn>

³² IBM. [sitio web]. ¿Qué son las redes neuronales convolucionales?. [Fecha de consulta: 31 de agosto 2023]. Disponible en: <https://www.ibm.com/es-es/topics/convolutional-neural-networks>

³³ GENESIS, Luna y KLEYNER, Vasconez. 2020.

³⁴ IBM. [sitio web]. Fecha de consulta: 31 de agosto 2023].

³⁵ Ibid.

³⁶ Ibid.

3.2.1.2. Yolov5

YOLO (You Only Look Once) es una red neuronal convolucional pre-entrenada de detección de objetos que puede ser aplicada tanto a imágenes como a video en tiempo real en donde se destaca su velocidad de procesamiento. Esta CNN divide la imagen en una rejilla dónde cada celda de esta es responsable de detectar un objeto³⁷.

La versión 5 de YOLO (YOLOV5) contiene mejoras en el procesamiento de la CNN el cual se ha convertido en uno de los frameworks más utilizado en el desarrollo de aplicaciones de ML para detección de objeto junto con las librerías de Tensorflow y Keras^{38 39 40}. Debido a su versatilidad y eficiencia, es elige esta red neuronal para entrenarla a la detección de botellas.

3.2.2. Visión Artificial

Durante muchos años, la clasificación de residuos se ha llevado a cabo de manera manual, lo que implica que un usuario separa los materiales en función de ciertas características físicas para garantizar su correcto procesamiento, ya sea para su reciclaje o su eliminación. En los últimos años, la visión artificial ha provocado un avance significativo en los procesos sanitarios e industriales, ya que las características que se utilizan para clasificar los residuos pueden ser identificadas mediante imágenes capturadas por cámaras⁴¹.

3.2.2.1. Opencv

OpenCV (Open Source Computer Vision Library)⁴² es una plataforma de software de código abierto diseñada para aplicaciones de visión por computadora y aprendizaje automático. Su propósito fundamental es establecer una base unificada para el desarrollo de soluciones en estos campos y promover la integración de la percepción artificial en productos comerciales. Esta biblioteca engloba más de 2.500 algoritmos altamente optimizados, abarcando desde técnicas fundamentales de visión por computadora hasta avanzados métodos de aprendizaje automático. Proporciona herramientas esenciales para la detección facial, reconocimiento de objetos, seguimiento de movimientos de cámaras, generación de modelos 3D, entre otros aspectos cruciales.

³⁷ PEINADO GARCÍA, Raúl, et al. Estudio de la calidad en las detecciones de la red YOLOv5 con transformación de imágenes. Proyecto de grado. Publicado en universidad de Málaga, 2022. [Fecha de consulta: 01 de septiembre 2023]. Disponible en: <https://riuma.uma.es/xmlui/handle/10630/26026>.

³⁸ Ibíd. pp. 34

³⁹ COCODataSet. [sitio web]. COCO common objects in Context. [Fecha de consulta: 01 de septiembre 2023]. Disponible en: <https://cocodataset.org/#home>

⁴⁰ Makesense. [Sitio Web]. Disponible en: makesense.ai

⁴¹ How Computer Vision Has Evolved and Its Role in Waste Sorting [sitio web]. Recycleye. [Fecha de consulta: 26 de agosto 2023]. Disponible en: <https://recycleye.com/how-computer-vision-has-evolved-and-its-role-in-waste-sorting/>

⁴² OpenCV [sitio web]. [Fecha de consulta: 28 de agosto 2023]. Disponible en: <https://opencv.org/>

3.2.2.2. Python

Python⁴³ se presenta como un lenguaje de programación interpretado de naturaleza multiparadigma y orientado a objetos. Este lenguaje respalda tanto la programación imperativa como, hasta cierto punto, la programación funcional.

Entre los destacados beneficios de Python se encuentra su sintaxis robusta, escalable y altamente legible. Esta característica posibilita la elaboración de algoritmos sumamente complejos en un reducido número de líneas de código. Tal particularidad ha elevado la popularidad de este lenguaje, convirtiéndolo en una elección de preferencia en diversos ámbitos, incluyendo la Inteligencia Artificial. Ejemplos de su aplicación abarcan la visión por computadora, el análisis de grandes volúmenes de datos y la ciencia de datos.

En el desarrollo de código, se utilizarán diversas bibliotecas como^{44 45} y conceptos importantes fundamentales de Python, por ejemplo^{46 47}. Estos con el objetivo de lograr resultados altamente productivos y estables del sistema realizado.

⁴³ Python [sitio web]. [Fecha de consulta: 28 de agosto 2023]. Disponible en: <https://python.org/>

⁴⁴ NumPy [sitio web]. [Fecha de consulta: 28 de agosto 2023]. Disponible en: <https://numpy.org/>

⁴⁵ PySerial [sitio web]. [Fecha de consulta: 1 de septiembre 2023]. Disponible en: <https://pythonhosted.org/pyserial/pyserial.html>

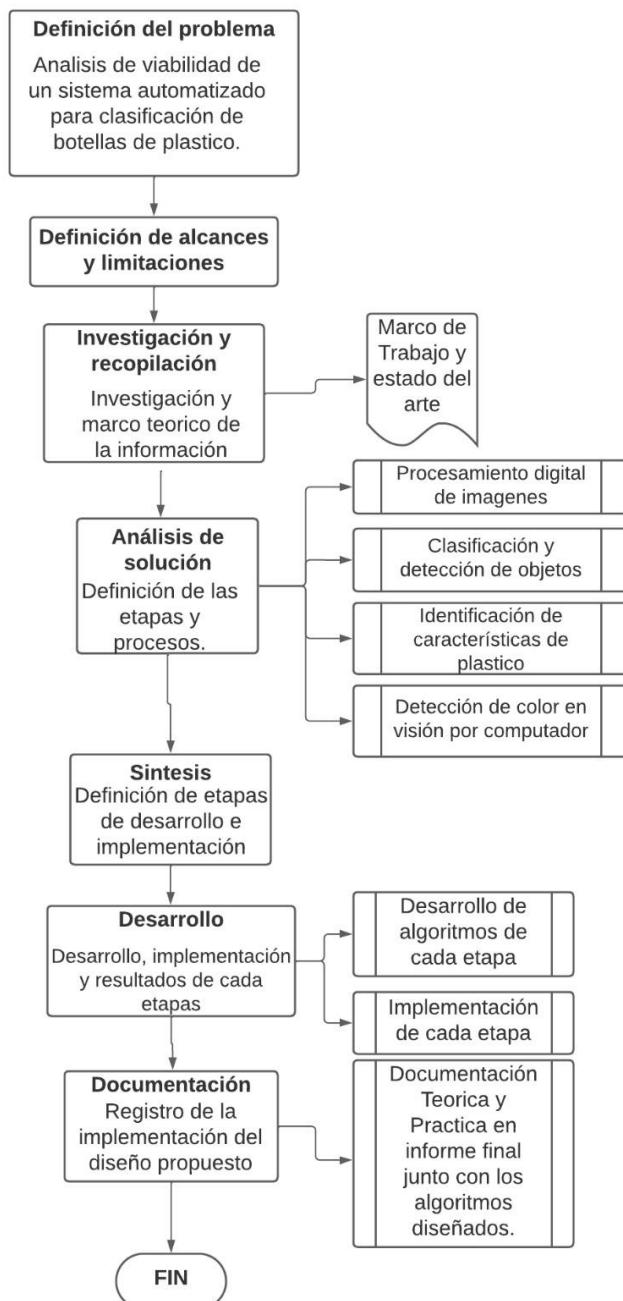
⁴⁶ An Intro to Threading in Python [sitio web]. Real Python. [Fecha de Consulta: 30 de agosto 2023]. Disponible en: <https://realpython.com/intro-to-python-threading/#what-is-a-thread>

⁴⁷ What Is the Python Global Interpreter Lock (GIL)? [sitio web]. Real Python. [Fecha de consulta: 30 de agosto 2023]. Disponible en: <https://realpython.com/python-gil/>

4. METODOLOGÍA Y RESULTADOS

La metodología empleada en este trabajo de grado se fundamenta en la siguiente secuencia de pasos: primero, se realiza un análisis exhaustivo del problema en cuestión. Posteriormente, se procede a evaluar diversas alternativas de solución con el objetivo de seleccionar el diseño más adecuado. Una vez definido el diseño, se estructuran las etapas correspondientes al desarrollo y la implementación del sistema. A continuación, se presenta una visión general del flujo de actividades de alto nivel que se llevan a cabo para alcanzar la implementación exitosa de este sistema.

Figura 10. Diagrama de la Metodología.



FUENTE: Elaboración propia.

El proyecto se basa en un diagrama de metodología que previamente definió las etapas de definición del problema, de solución y de investigación, junto con el marco de trabajo y el estado del arte. Estas etapas dieron forma a las actividades que delinearon los métodos más adecuados para el desarrollo del sistema automatizado.

La etapa de Análisis y Síntesis de la solución propone la estructura de las técnicas, conceptos y funciones del sistema necesario para establecer un "Happy-Path" (proceso lineal ideal) viable en relación con las muestras y la información de entrada. Esto fue fundamental para optimizar el proyecto, buscando robustez y precisión mediante el aprovechamiento de herramientas de desarrollo de software, procesamiento digital y electrónica.

La etapa de desarrollo aplicó conocimientos adquiridos y conceptos autodidactas para diseñar algoritmos capaces de detectar y clasificar botellas de plástico por color. La respuesta se visualiza en la etapa de visualización, donde se verifica la clasificación a baja escala esperada.

Finalmente, la etapa de documentación plasmó las bases teóricas, investigaciones de técnicas viables, y el registro de la construcción y estructura de todo el proyecto, aportando una referencia sólida para su implementación.

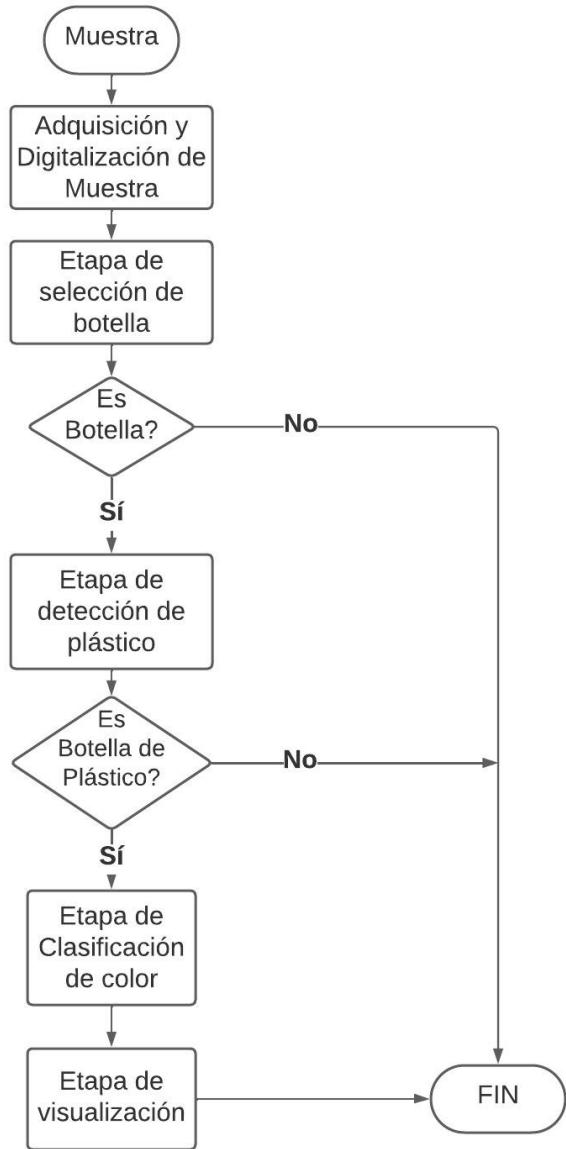
4.1. ETAPAS DE DESARROLLO DEL SISTEMA

Las etapas de desarrollo e implementación implican el diseño de algoritmos y la construcción de una planta a baja escala, simulando lo que podría implementarse a nivel industrial. Esto presenta una idea prometedora para las empresas de clasificación de materiales reciclables. Cada etapa abarca la adquisición y digitalización de muestras individuales con respuestas específicas relacionadas con su fase correspondiente. La implementación incluye una banda transportadora para llevar los objetos reciclables a través de diversas etapas de selección y clasificación.

La primera etapa se centra en la selección y clasificación de botellas mediante un modelo de Machine Learning. Luego, se aborda la detección de plástico, con el objetivo de separar posibles botellas de vidrio. Finalmente, la detección de color determina en qué grupo se debe ubicar la botella de plástico.

Se presenta a continuación el flujo del proceso ideal que describe el funcionamiento del sistema, junto con una explicación detallada de las etapas de desarrollo en algoritmos y construcción de la implementación, incluyendo los materiales necesarios.

Figura 11. Flujo principal del sistema.

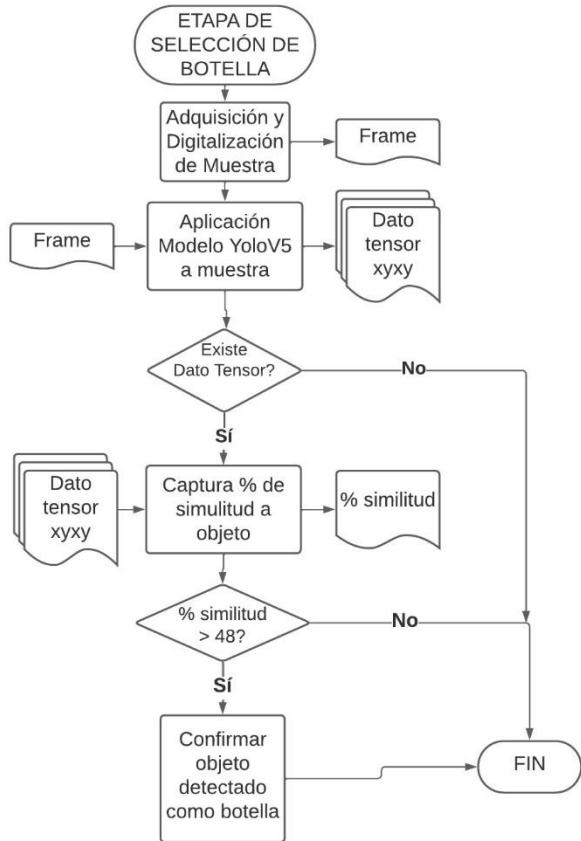


FUENTE: Elaboración propia.

4.1.1. Etapa De Selección De Botella

La primera etapa se enfoca en garantizar que el sistema seleccione exclusivamente botellas entre otros materiales reciclables. Esto se logra mediante el reentrenamiento de una red neuronal convolucional conocida como YoloV5. Este proceso permite la creación de un modelo de Machine Learning personalizado a través del aprendizaje supervisado, cuyo objetivo es detectar específicamente la clase u objeto deseado, en este caso, botellas. Para llevar a cabo este proceso, es esencial contar con una base de datos que proporcione los ejemplos necesarios para que el sistema pueda identificar con precisión lo que constituye una botella y lo que no lo es.

Figura 12. Diagrama etapa de selección de Botella.



Cuando el sistema recibe la muestra proveniente de la videocámara, procede a digitalizarla, siendo cada fotograma (frame) tratado individualmente. Cada uno de estos fotogramas se introduce en el modelo YoloV5 para que este realice una revisión en busca de objetos. En caso de que se detecte un objeto, el modelo proporciona datos en forma de un Tensor que contiene información sobre las coordenadas xyxy del objeto detectado, así como el porcentaje de similitud de ese objeto con respecto a una botella, según lo determinado por el mismo modelo.

Si el Tensor no genera datos xyxy, esto indica que el modelo no ha detectado ningún objeto en el fotograma. En este punto, se procede a establecer un rango de similitud en función del porcentaje obtenido. Este rango permite al modelo determinar si el objeto detectado debe ser considerado como una botella válida o no. Es importante destacar que estos factores de rango de similitud son sensibles a las imágenes utilizadas en la base de datos, tanto en términos de calidad como de cantidad, durante la fase de creación del modelo.

FUENTE: Elaboración propia

4.1.1.1. Materiales De Etapa

- Cámara Web: Genius FaceCam 1000x
Tipo de sensor: CMOS
Interfaces: USB
Resolución máxima de video: 1280 px x 720 px
- Computador:
Procesador: Intel Core i5
Ram: 8GB
Sistema Operativo: Windows 11 Pro 64 bits

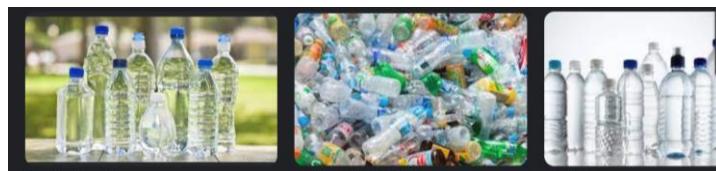
4.1.1.2. Construcción De Etapa

- **Base de Datos: Obtención de imágenes de botellas.**

La creación del almacén de datos para el modelo de Machine Learning fue un paso crucial en busca de robustez y precisión en el proceso de aprendizaje. Se afrontó el desafío de recopilar una cantidad considerable de imágenes de diversas fuentes. Esto incluyó la extracción de bases de datos desde sitios web, la captura manual de fotografías de botellas y la generación de nuevas imágenes a partir de las existentes.

En primer lugar, se descargaron fotos utilizando una extensión llamada "Download All Images" desde un motor de búsqueda eficiente, en este caso, Google Images. Esto se realizó al buscar "Botellas de plástico".

Figura 13. Imágenes tomadas con la extensión de Google.



FUENTE: Elaboración propia

Esto proporcionó imágenes de botellas comunes en cualquier espacio y otras no relevantes que se tuvieron que filtrar para capturar las imágenes más útiles. Luego se dirige a páginas webs mayormente reconocidas por el tratamiento de datasets completos que suben y descargan los mismos usuarios como Kaggle y OpenML, encontrando en la primera, una base de datos llamada "Bottles and Cans Images" con botellas en buen estado y también aplastadas, siendo una buena fuente de información ya que en la industria o en el ambiente a alta escala la mayoría de las botellas llegan aplastadas, así que el modelo debe también detectarlas en dichas condiciones.

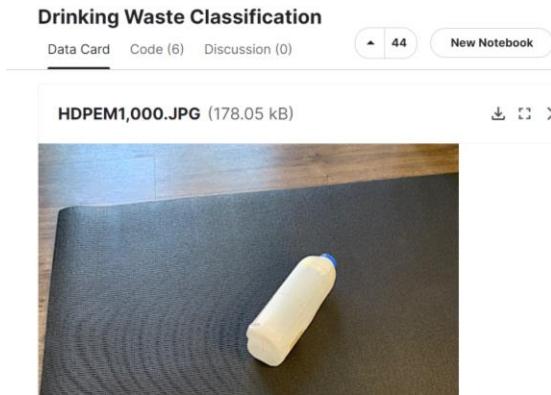
Figura 14. Imágenes de "Bottles and Cans Images".



FUENTE: Kaggle [sitio web]. Bottles and Cans Images. Disponible en: https://www.kaggle.com/datasets/moezabid/bottles-andcans?select=Bottle_150cl

Otro base de datos encontrada en Kaggle fue "Drinking Waste Classification" el cual contenía imágenes de latas y botellas de vidrio de soda, pero también imágenes de botellas de plástico de tipo HDPE.

Figura 15. Dataset "Drinking Waste Classification".



FUENTE: Kaggle [Sitio web]. Drinking Waste Classification. Disponible en: <https://www.kaggle.com/datasets/arkadiyhacks/drinking-waste-classification>

Se fue a diferentes lugares en donde se podrían encontrar botellas de plástico para poder tomar las imágenes y poder darle más ejemplos al modelo de realizar bien la selección y clasificación de botellas.

Figura 16. Toma de Imágenes personalizadas de botellas.



FUENTE: Elaboración propia.

Para aumentar la cantidad de muestras, se realiza con un código en Python con la librería “keras.preprocessing.image” se ejecuó la función “ImageDataGenerator()” la cual ofrece una gran cantidad de opciones para modificar la imagen que le es ingresada, así es posible variar orientación, iluminación, contraste y la cercanía de la imagen. Este script se encontrará con el nombre de data_augmentation.py en el anexo 2.

Figura 17. Ejemplo de cambio de características de imagen para aumentar.



FUENTE: Elaboración propia.

- **Bases de datos: Organización y etiquetado de imágenes.**

Al momento de ya tener una cantidad considerable de imágenes, se procede a elegir un 70% de botellas para entrenar el modelo y un 30% de validación que el mismo modelo realiza a la hora de entrenarlo, estos porcentajes son los recomendables a la hora de trabajar con Machine Learning.

La carpeta principal de la base de datos se llamará “data” y se crearán dos subcarpetas llamadas “images” y otra “labels” para almacenar las imágenes y las etiquetas respectivamente.

Figura 18. Organización de la base de datos por carpetas.

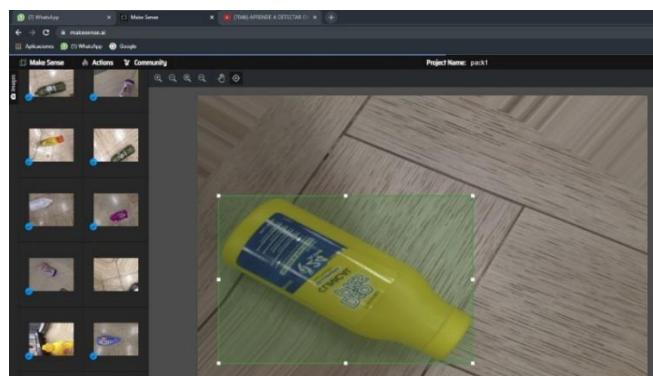
Organización de la base de datos		
Nuevo vol (D:) > Universidad > Proyecto de grado > YoloDetec > data > images		
Nombre	Fecha de modificación	Tipo
train	5/12/2022 12:56 a. m.	Carpetas de archivos
val	5/12/2022 12:57 a. m.	Carpetas de archivos

Nuevo vol (D:) > Universidad > Proyecto de grado > YoloDetec > data > labels		
Nombre	Fecha de modificación	Tipo
train	5/12/2022 12:59 a. m.	Carpetas de archivos
val	6/12/2022 12:36 a. m.	Carpetas de archivos

FUENTE: Elaboración propia

Luego de ya tener organizada las imágenes de validación y entrenamiento, se dirige a la página web Kaggle⁴⁸ la cual ofrece un servicio gratuito de generar las etiquetas según el formato requerido por YoloV5, en donde solo se selecciona el recuadro en donde se aprecia la botella en la imagen (puede verse en la Figura 19) y es ahí donde se etiquetan las imágenes tanto de entrenamiento como de validación.

Figura 19. Etiquetado de imágenes en makesense.ai.



FUENTE: Elaboración propia

Al terminar de etiquetar todas las imágenes, se puede descargar en conjunto todas las etiquetas realizadas y tener el paquete de etiquetas para cada imagen de entrenamiento

⁴⁸ Kaggle. [Sitio web]. [Fecha de consulta: 01 de diciembre 2022]. Disponible en: <https://www.makesense.ai/>

y de validación. Estas etiquetas son en formato txt y su contenido indica el número de etiqueta (en este caso etiqueta “0”) y la región (coordenadas) en donde se encuentra la botella dentro de la imagen.

Figura 20. Contenido de etiquetas para YoloV5.

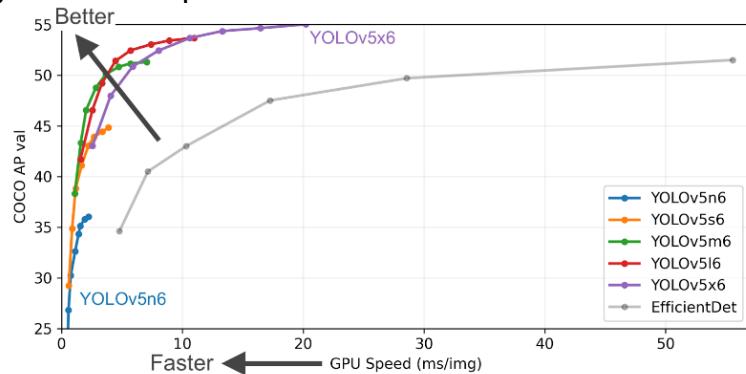
Nombre	Fecha de modificación	Tipo	Tamaño
800px-Botella_de_pony_maltaJPG	9/06/2023 11:31 p. m.	Documento de texto	1 KB
1087771	9/06/2023 11:31 p. m.		
20221201_191433	9/06/2023 11:31 p. m.		
20221201_191449	9/06/2023 11:31 p. m.		
20221201_192043	9/06/2023 11:31 p. m.		
20221201_192048	9/06/2023 11:31 p. m.		
20221201_192052	9/06/2023 11:31 p. m.		
20221201_192126	9/06/2023 11:31 p. m.		
20221201_192131	9/06/2023 11:31 p. m.		
20221201_192134	9/06/2023 11:31 p. m.		
20221201_192238	9/06/2023 11:31 p. m.		
20221201_192341	9/06/2023 11:31 p. m.		

FUENTE: Elaboración propia.

- **Entrenamiento de Red Neuronal con YoloV5**

Para realizar nuestra Red Neuronal usamos Yolo V5x, el cuál es la red neuronal de Yolo V5 más efectiva, esto podemos observar en la siguiente figura:

Figura 21. Comparación entre redes neuronales de YoloV5.



FUENTE: Github [Sitio Web]. Ultralytics – YoloV5. Disponible en: <https://github.com/ultralytics/yolov5>.

Por tanto, se procedió a entrar al GitHub oficial de Yolo V5, en donde se puede encontrar la información referente y paso a paso de cómo entrenar la red neuronal personalizada⁴⁹ y generar el modelo, para esto se ingresa Google Colab que proporciona el repositorio de Git, es de vital importancia mencionar que la red fue desarrollada en Google Colab, para no tener problemas con la paquetería que es necesaria para este procedimiento y se podrá visualizar en el Anexo 1, por lo tanto se siguieron los pasos que indica el Colab,

⁴⁹ Github [sitio web]. Ultralytics – YoloV5. Fecha de consulta: 20 noviembre 2022. Disponible en: <https://github.com/ultralytics/yolov5>.

el primero corresponde a la instalación de los requerimientos necesarios para llevar a cabo el proceso de entrenamiento de la red.

Finalmente, se ejecuta el código de entrenamiento de la red utilizando "train.py" de YOLOv5. Se especifica el tamaño de las imágenes de entrada, que en este caso es de 460 para esta base de datos, así como el batch size, que se configuró en 4 para un aprendizaje más rápido. Se establecen 50 épocas para el entrenamiento de la red, se define el archivo.yaml en el que se basará el aprendizaje, así como el tipo de red neuronal YOLO V5, en este caso, "yoloV5x". Al finalizar, se incluye un comando para exportar el archivo que contiene el modelo "best.pt" una vez finalizado el entrenamiento, que será el modelo personalizado para la clasificación de botellas. Así como se en el siguiente comando:

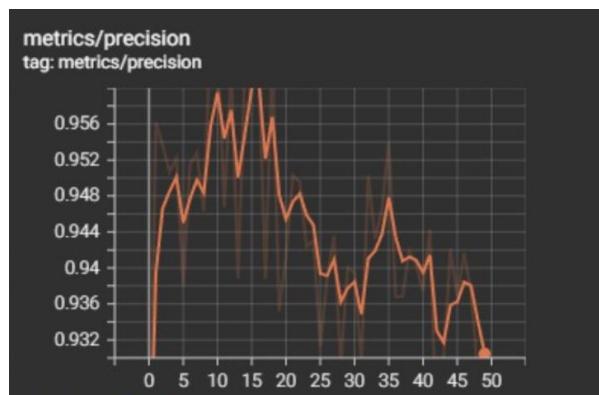
```
# Train YOLOv5s on COCO128 for project
!python train.py --img 460 --batch 4 --epochs 50 --data
/content/yolov5/data/custom.yaml --weights yolov5s.pt -cach
```

4.1.1.3. Resultados De Etapa

- **Resultados de entrenamiento:**

Los resultados se basan en las gráficas más relevantes como la de precisión, de pérdidas y de confianza. En la Figura 22 se observa la respuesta de precisión del modelo según la evaluación hecha por el tensorboard con los datos de entrenamiento.

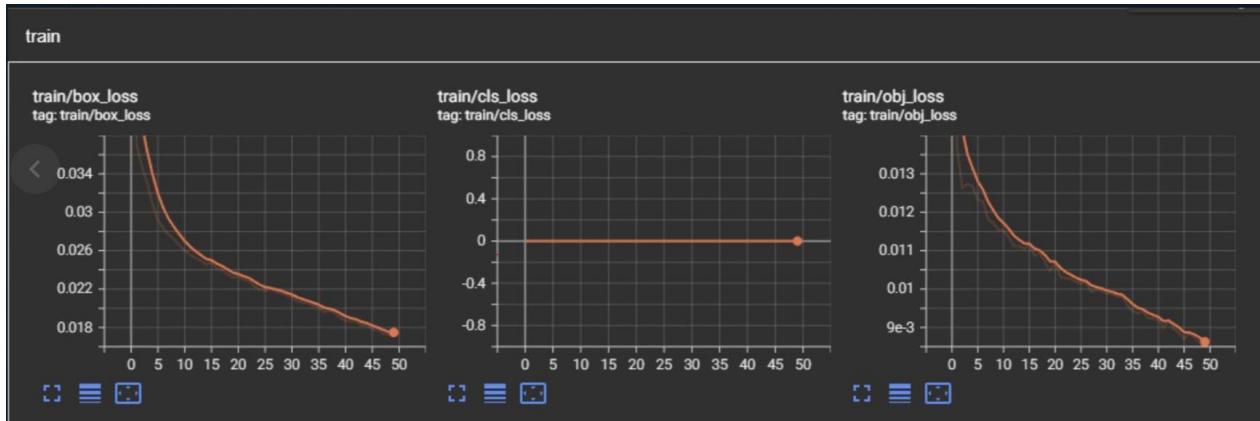
Figura 22. Gráfica de Épocas vs Precisión.



FUENTE: Elaboración propia.

En la Figura 22 se puede apreciar que se alcanzó aproximadamente en la última época una presión de 93.2% aproximadamente, siendo este un valor considerablemente bueno. Ahora en la Figura 23 se observa cómo va disminuyendo el error a medida que pasan las épocas.

Figura 23. Gráficas de épocas vs Disminución de Error.

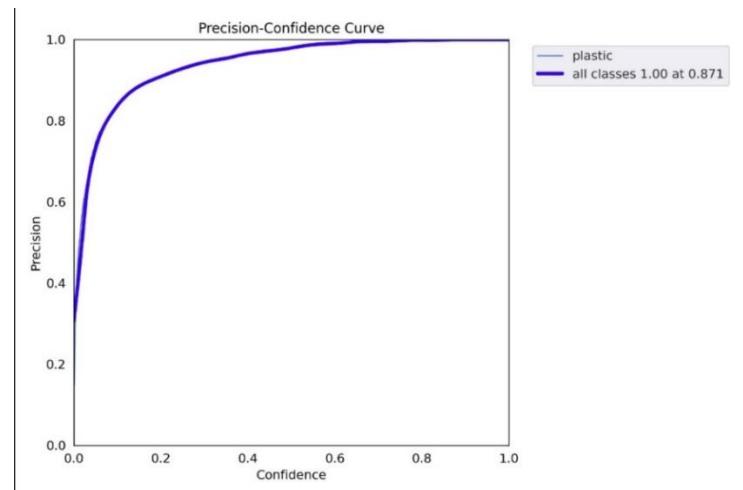


FUENTE: Elaboración propia.

La primera gráfica, "train/box_loss," muestra cómo disminuye el error a medida que aumentan las épocas de entrenamiento para la detección de objetos por YOLOv5 en una imagen. Esta detección es el primer paso, donde se verifica la presencia de un objeto antes de evaluar qué tan parecido es a una botella. La siguiente gráfica, "train/cls_loss," refleja la disminución del error entre las clases trabajadas durante el entrenamiento por épocas. Sin embargo, al tratarse de una única clase en este caso, el error permanece en 0, ya que no hay datos para comparar con otras clases. Finalmente, la gráfica "train/obj_loss" muestra la disminución del error en la detección del objeto en relación con su similitud con una botella.

El Tensorboard también muestra una gráfica de la confianza Vs la Precisión, en donde la confianza hace referencia al valor que da el modelo al objeto detectado de qué tanto se parece a la botella de 0 a 1, en donde los valores cercanos a 0 indican que se parece muy poco y los valores cercanos a 1 nos dan como respuesta una similitud a botella confirmada, como se puede ver en la Figura 24.

Figura 24. Gráfica de Confianza vs Precisión del modelo.



FUENTE: Elaboración propia.

La gráfica demuestra que existe una precisión exacta cuando el modelo arroja un valor de confianza ("confidence") mayor a 0.871, el cual sería el dato teórico para clasificar

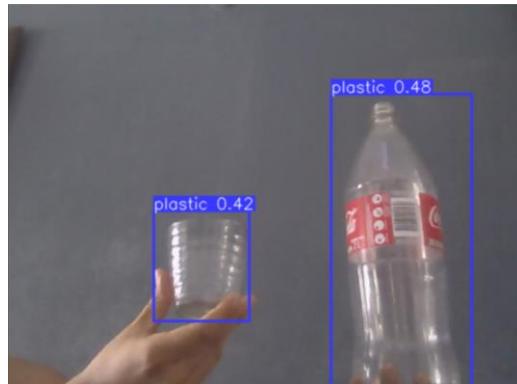
botellas de otros materiales reciclables, pero considerando la forma física en que puede ir la botella se realizan pruebas para considerar qué valor de confianza es el indicado cuando detecte cualquier tipo de botella de otro material diferente.

- **Resultados de práctica y validación**

Para realizar pruebas y encontrar el valor de confianza óptimo que clasificará las botellas con otros materiales, se realizó un pequeño script de Python trabajado en Visual Studio. El script de pruebas está nombrado como "CoordinatesAndConfidenceDetection.py" encontrará en los Anexos 2 de este libro.

En este Script, se realizaron pruebas con múltiples botellas, estableciendo que un porcentaje de confianza del 43% permite una clasificación precisa de objetos como botellas, definiendo el umbral efectivo para la detección en el flujo de video. Estas pruebas coinciden consistentemente con las métricas y el rendimiento del modelo durante el entrenamiento.

Figura 25. Pruebas de detección de modelo.



FUENTE: Elaboración propia.

En esta prueba, el modelo detectó dos objetos y los enmarcó en cajas delimitadoras. Los nombres "plastic 0.42" y "plastic 0.48" representan el porcentaje de confianza en su similitud con una botella. En este caso, el primer objeto (el vaso) tiene un 42% de confianza en su similitud con una botella, mientras que la botella de gaseosa tiene un 48% de similitud.

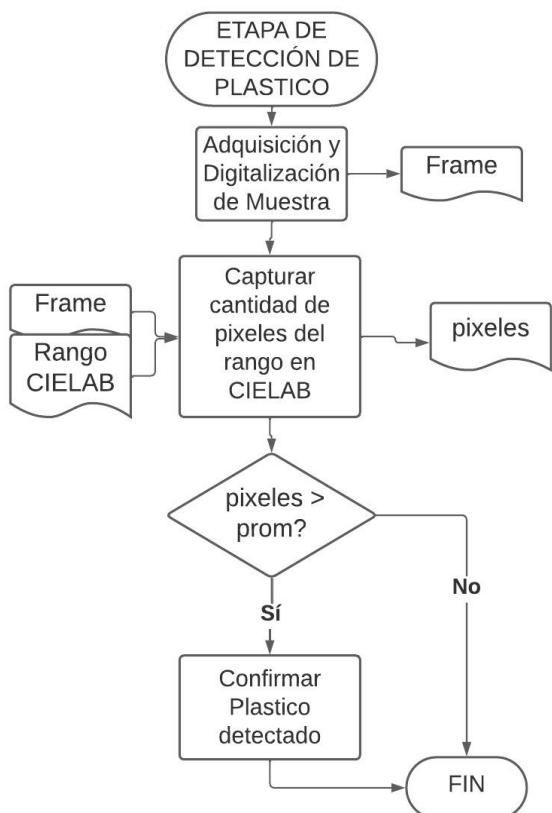
Se concluye que los valores de confianza pueden variar debido a la calidad de la imagen y las condiciones de iluminación. Por lo tanto, es crucial asegurarse de contar con un entorno adecuado y una cámara de buena resolución para obtener resultados precisos en la detección y clasificación de objetos.

4.1.2. Etapa De Detección De Plástico

En la segunda etapa, se separan botellas de plástico y vidrio previamente detectadas. El modelo de aprendizaje automático está diseñado para detectar ambas debido a su forma similar. Aunque las botellas de vidrio son raras debido a su reutilización, se incluye esta etapa para mejorar la precisión.

Para la separación, se emplea la reflexión infrarroja (NIR) que diferencia plástico de vidrio. Esto se basa en la mayor reflexión infrarroja del plástico debido a su composición química, mejorando la precisión en la clasificación.

Figura 26. Diagrama etapa de detección de plástico.



En esta etapa, se toma cada cuadro de la cámara que ha sido iluminado con luz infrarroja y se realiza una conversión del espacio de color RGB al espacio CIELAB. Esto se hace para aprovechar la dimensión de este espacio específicamente diseñada para capturar la información de iluminación presente en la imagen.

Antes de llevar a cabo esta conversión, el código establece un promedio de la cantidad de píxeles que deben superar un umbral de iluminación predefinido. Este umbral se utiliza para determinar la presencia de reflexiones en la imagen capturada por la cámara. La cantidad de píxeles que supera este umbral en el frame permite distinguir entre objetos de plástico y vidrio, ya que estos materiales responden de manera diferente a la luz infrarroja.

FUENTE: Elaboración propia.

4.1.2.1. Materiales De Etapa

- Sistema Computador:
 - Procesador: Intel Core i5
 - Ram: 8GB
 - Operativo: Windows 11 Pro 64 bits
- Cámara Web: **Logitech C920** sin filtro IR
 - Interfaces: USB 2.0
 - Resolución máxima de video: 1920 px x 1080 px
 - Full HD 30FPS
- 12 LEDs infrarrojo emisor convencional
 - Corriente de funcionamiento: 100 mA
 - Ángulo de transmisión: 15 a 30 grados
- Cables de cargador USB
- Cargador de celular genérico
 - Vin: 110 a 220 VAC
 - Vo: 5 VDC – Io = 1.5A

- Caja de cartón totalmente cerrada
Ancho: 75 cm – Alto: 66 cm – Profundo: 32 cm
- Banda transportadora
Ancho 1.2 m – Alto: 20 cm – Profundo: 32 cm
- Resistencia 1.5 Ohm a 10 watts
- Pintura negra mate
- 2 difusores
Largo: 75 cm – Ancho: 32 cm

4.1.2.2. Construcción De Etapa

En esta etapa, se presenta la creación de una caja donde las botellas seleccionadas en la fase anterior pasaran por esta. Este ambiente permitirá la detección y clasificación de las botellas si son de plástico o vidrio, utilizando técnicas de visión por computadora y los conocimientos previamente establecidos.

- **Caja para detección de plástico**

Lo primero que se realizó en esta etapa es el espacio de trabajo en donde se podrá detectar la reflexión de iluminación IR en las botellas ya clasificadas. Las especificaciones necesarias es que el espacio sea totalmente negro ya que, según lo investigado, este es el color que absorbe todos los otros colores y por tal motivo se logra el objetivo que solo se reflejen los materiales que entrarán en esta caja.

Debido a las especificaciones, se encontró una caja con una altura significativa siendo un parámetro importante para el enfoque de la cámara que se utilizará y con un espacio permisible a entrar a cualquier tipo de botella sea de plástico o de vidrio.

Figura 27. Caja para el sistema de detección de plástico.



FUENTE: Elaboración propia.

Lo primero es que el interior de la caja sea totalmente negro, no luminoso, ni reflectivo para que no haya ruido y/o reflejos externos a la iluminación IR que será instalada a la misma caja. El interior de la caja fue pintado de un color negro mate para evitar luminosidad.

Figura 28. Pintado de caja para evitar luminosidad.

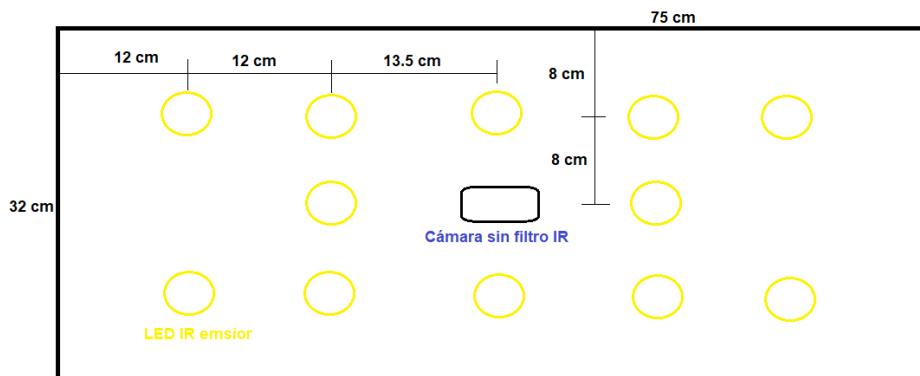


FUENTE: Elaboración propia.

Se procede al reacondicionamiento de la caja para incorporar LEDs y la cámara. Dado que se trata de un prototipo a baja escala, se ha diseñado una geometría específica para acomodar los LEDs convencionales, que varían en sus características, incluida la intensidad lumínica. Además, se han añadido dos difusores para asegurar una distribución uniforme de la luz infrarroja (IR) en todo el interior de la caja.

La cámara se ha ubicado cuidadosamente en el centro de la caja para ampliar su campo de visión. Los LEDs infrarrojos rodean la cámara e iluminan la parte inferior con un ángulo de 90 grados. La Figura 29 detalla la disposición de los LEDs en la parte superior de la caja, adaptada para la zona de trabajo de la cámara sin filtro IR. Además, se propone el uso de una tela negra en la parte inferior donde se colocarán las botellas para reducir reflejos no deseados y evitar confusiones en el sistema.

Figura 29. Medidas de ubicación de LEDs.



FUENTE: Elaboración propia.

Ahora, el proceso avanza desde el diseño del circuito destinado a activar todos los LEDs. En esta etapa, se emplea una fuente de alimentación de 5 voltios, en particular, un cargador genérico de teléfonos móviles. De acuerdo con las especificaciones de los

LEDs, se establece que requieren una corriente de encendido de 100 mA y pueden ser alimentados con una tensión que oscila entre 1.2 y 5 voltios. Basándonos en estos datos, procedemos a calcular la resistencia necesaria para regular la corriente total que abastecerá a los 12 LEDs que serán utilizados en nuestro proyecto. Esto se realiza mediante la siguiente fórmula:

$$V = I \times R; \text{ Ley de Ohm 1).}$$

V = Voltaje de entrada - I = Corriente del circuito - R= Resistencia

Se realizó un circuito en paralelo que se puede observar en la Figura 30. En este caso ya que son 12 LEDs se debe multiplicar esa cantidad con la corriente de trabajo de estos, para así conocer la corriente que debe entrar al circuito.

$$R = V / I$$

$$R = 5V / (12 * 100mA)$$

$$R = 4.16 \text{ Ohm} \rightarrow \text{Resultado teórico.}$$

Este es el valor máximo que debe tener de resistividad nuestro circuito para poder encender todos los LEDS. Así que, al momento de buscar el valor de resistencia comercial, se debe optar por uno de menor valor y así garantizar que nuestro sistema tenga una buena alimentación de energía y luminosidad.

Ahora se debe buscar el valor comercial más cercano pero menor.

$$R \approx 1.5 \text{ Ohm} \rightarrow \text{Valor comercial}$$

Ya que se eligió una resistencia de un pequeño valor, tenemos que conocer la potencia que estará consumiendo nuestro circuito para conseguir una resistencia de dicho valor pero que soporte la potencia que estará consumiendo. Para esto solo sacamos el valor multiplicando el Voltaje de entrada con la corriente total.

$$P = V * I \quad 2)$$

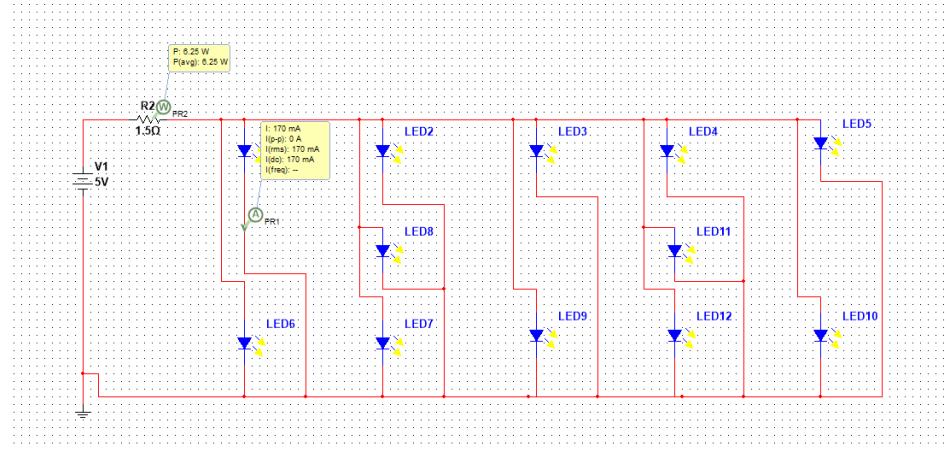
$$P = 5V * (12 * 100mA) = 6 \text{ Watts} \rightarrow \text{Valor teórico}$$

Este es el valor de la potencia que estará consumiendo el circuito, así que la resistencia debe soportar como mínimo 6 watts, en este caso cuando se busque su valor comercial, se eligió un valor mayor para que pueda soportar este valor sin ningún problema.

$$R = 1.5 \text{ Ohm a 10 Watts} \rightarrow \text{Valor comercial.}$$

Estos dos valores indican que la resistencia va a dejar pasar más corriente del valor mínimo para que enciendan los LEDs, garantizando un buen funcionamiento de estos y además soportando dicha cantidad de potencia consumida por el circuito total.

Figura 30. Circuito de LEDs IR.



FUENTE: Elaboración propia.

Una vez que se ha diseñado el circuito, se procede a su instalación en la caja correspondiente. La figura siguiente muestra la instalación de LEDs en una caja de menor tamaño que se preparó previamente antes de utilizar la caja definitiva. Esta medida se tomó con el propósito de evaluar la eficacia de los LEDs y de la cámara, lo que contribuyó a la decisión de optar por una caja de mayor altura para lograr una iluminación y enfoque óptimos en el espacio con la cámara.

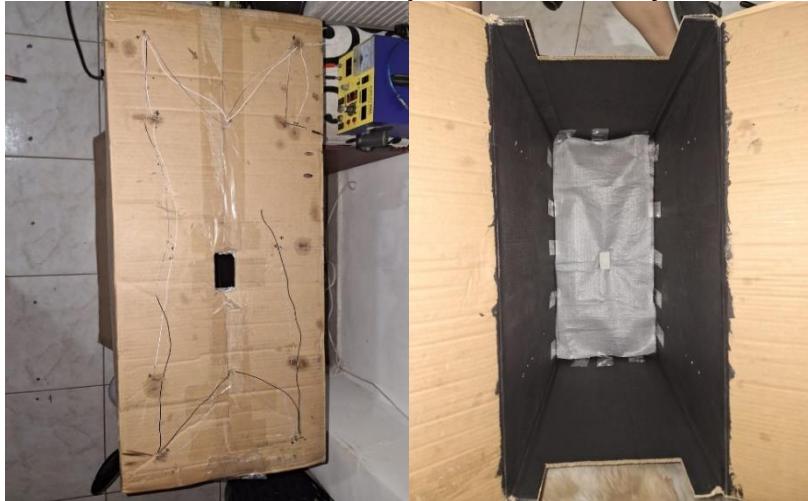
Figura 31. Prueba de LEDs IR con caja de prueba.



FUENTE: Elaboración propia.

Estas pruebas presentaban mucha confusión para diferenciar el plástico del vidrio, debido a que la altura era muy pequeña y la iluminación reflejaba además de las botellas también la parte inferior. En la Figura 32, se puede ver el reacondicionamiento y la instalación de los LEDs de la parte exterior superior y también la zona interior superior de la caja.

Figura 32. Instalación de LEDs y Difusor en la caja del sistema.



FUENTE: Elaboración propia.

Desarrollo de script para encontrar el rango de clasificación.

En Anexos 2, Se podrá visualizar el script “ColorClass” realizado en Python con técnicas de visión por computador para encontrar el rango de espacio de color⁵⁰ que indica el plástico, detectando este color se analiza un promedio el cual clasifique que la botella si sea de plástico.

Figura 33. Parámetros de espacios de color.



FUENTE: Elaboración propia.

Como se puede apreciar en la Figura 33, se establecen los rangos según los parámetros del espacio de color que se esté trabajando. Para este caso se trabaja con el espacio de color CIELAB⁵¹, así que se regula con los mínimos y máximos de cada parámetro. Cabe mencionar que este código está diseñado para que sea versátil con otros espacios de colores, en el cuadro 1 se explica los parámetros que se pueden ver en la figura anterior.

⁵⁰ Image Processing 101 Chapter 1.2: Color Models [sitio web]. Dynamosoft. [Fecha de Consulta: 1 de septiembre 2023]. Disponible en: <https://www.dynamsoft.com/blog/insights/image-processing/image-processing-101-color-models/>

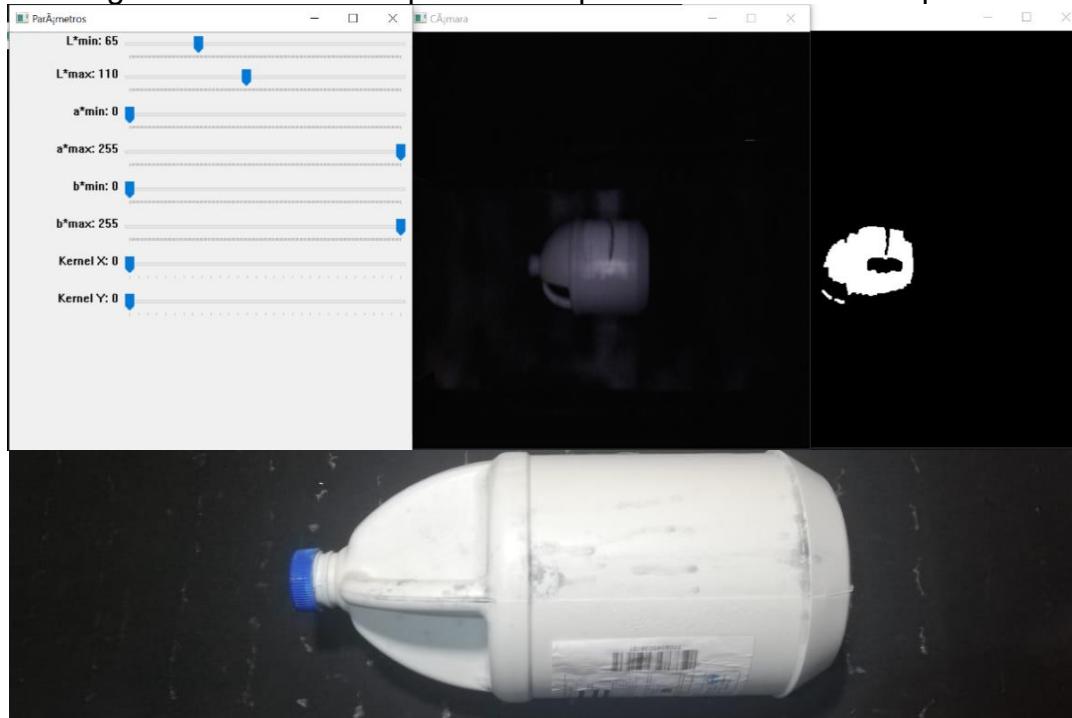
⁵¹ ¿Conoce el Espacio de Color CIE L*A*B*? [sitio web]. AQ Instruments. [Fecha de consulta: 1 de septiembre 2023]. Disponible en: <https://www.aquateknica.com/conoce-el-espacio-de-color-cie-lab/>

Cuadro 1. Parámetros de colores en CIELAB.

Parámetros Cielab	parámetros en “ColorClass”
Luminosidad Mínima (L^*)	$L^*_{min} = 65$
Luminosidad Máxima (L^*)	$L^*_{max} = 110$
Rojo/Verde Mínimo (a^*)	$a^*_{min} = 0$
Rojo/Verde Máximo (a^*)	$a^*_{max} = 250$
Amarillo/Azul Mínimo (b^*)	$b^*_{min} = 0$
Amarillo/Azul Máximo (b^*)	$b^*_{max} = 250$

Además, para tener una mayor claridad se crea una máscara binaria que permite ver los pixeles que están en el rango que se establecieron con los parámetros. No es necesario hacer especificar un rango para los parámetros a^* y b^* ya que estos definen colores, y en esta etapa solo se regula la iluminación.

Figura 34. Elección de parámetros para clasificación de etapa IR.



FUENTE: Elaboración propia

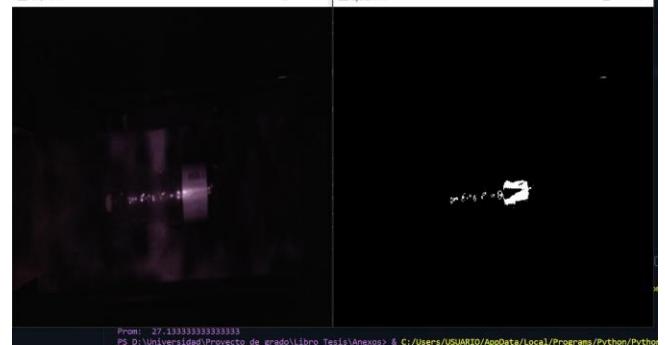
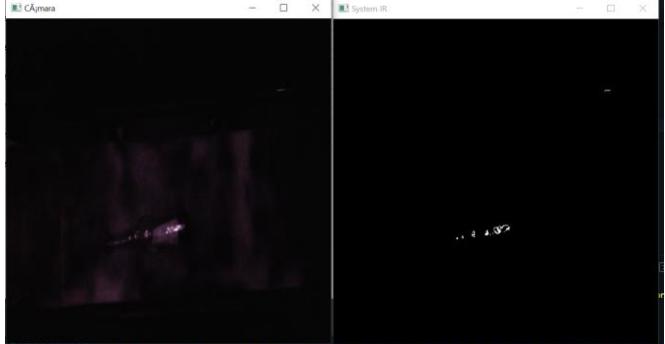
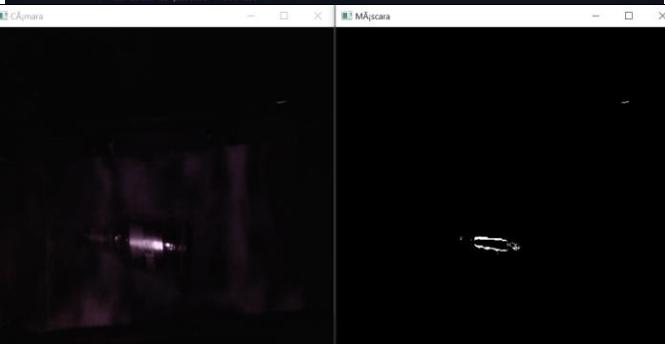
Luego de realizar diferentes pruebas, se encuentra un rango óptimo para detectar el reflejo de las botellas. Que en este caso sería de 65 a 110 de la iluminación(L^*), mencionando que el script está normalizado para trabajar con otros espacios de color, el 100% de los parámetros de CIELAB es un 255 en los parámetros del script. Los otros parámetros quedaron a 100% ya que, este sería como el color blanco y es el valor positivo ante la umbralización de los objetos.

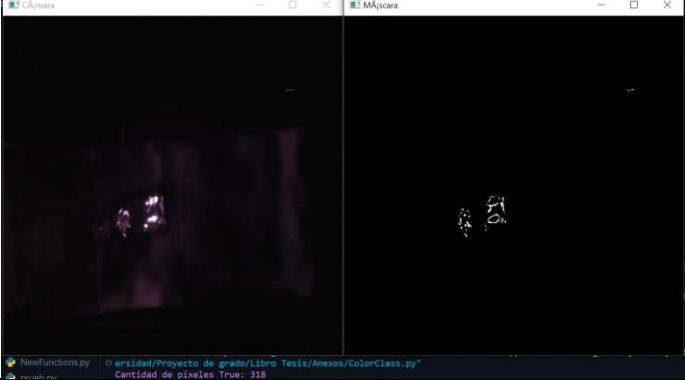
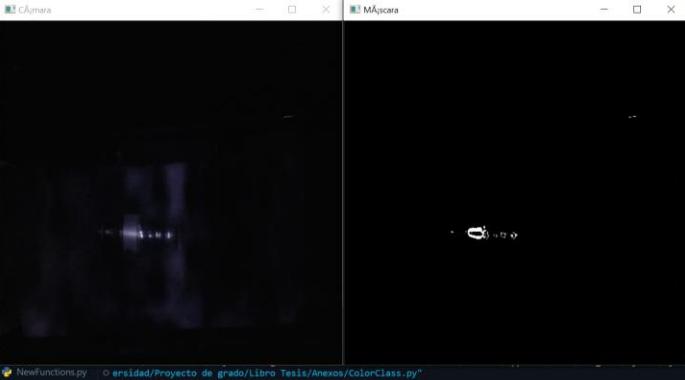
4.1.2.3. Resultados De Etapa

En el cuadro 2 podemos observar los pixeles detectados de diferentes tipos de botella y la cantidad de estos, en este caso de plástico, de aluminio y de vidrio. Para estas pruebas redimensiona a 480x480 para una mejor visualización (Este valor puede ser

parametrizable, pero de él depende el rango de pixeles como valor para clasificar el plástico).

Cuadro 2. Pruebas de la Etapa Detección de Plástico.

Tipo de botella	Imagen	Pixeles de rango
Botella plástica	 PS D:\Universidad\Proyecto de grado\Libro Tesis\Anexos> & C:/Users/USUARIO/AppData/Local/Programs/Python/Python37-32/versidad/Proyecto de grado/Libro Tesis/Anexos/ColorClass.py Cantidad de pixeles True: 2916	2916
Botella plástica	 Prom: 27.13333333333333 PS D:\Universidad\Proyecto de grado\Libro Tesis\Anexos> & C:/Users/USUARIO/AppData/Local/Programs/Python/Python37-32/versidad/Proyecto de grado/Libro Tesis/Anexos/ColorClass.py Cantidad de pixeles True: 1031	1031
Botella de vidrio sin etiqueta	 PS D:\Universidad\Proyecto de grado\Libro Tesis\Anexos> & C:/Users/USUARIO/AppData/Local/Programs/Python/Python37-32/versidad/Proyecto de grado/Libro Tesis/Anexos/ColorClass.py Cantidad de pixeles True: 166	166
Botella de vidrio con etiqueta	 NewFunctions.py PS D:\Universidad\Proyecto de grado\Libro Tesis\Anexos> & C:/Users/USUARIO/AppData/Local/Programs/Python/Python37-32/versidad/Proyecto de grado/Libro Tesis/Anexos/ColorClass.py Cantidad de pixeles True: 306	306

Botella de vidrio con etiqueta		318
Botella plástica pequeña		318

Los resultados revelan riesgos basados en los tipos de botellas. Por ejemplo, en el cuadro 2, se observa que la cantidad de píxeles en botellas de vidrio con etiqueta se asemeja a las botellas de plástico de menor tamaño. Esto se justifica por la improbabilidad de encontrar botellas de vidrio, ya que generalmente son retornables. Una justificación más detallada se proporcionará en el análisis completo junto con propuestas de mejoras a mayor escala. Además, estos valores permiten establecer un promedio de píxeles que facilitará la clasificación cuando se detecte plástico en una botella.

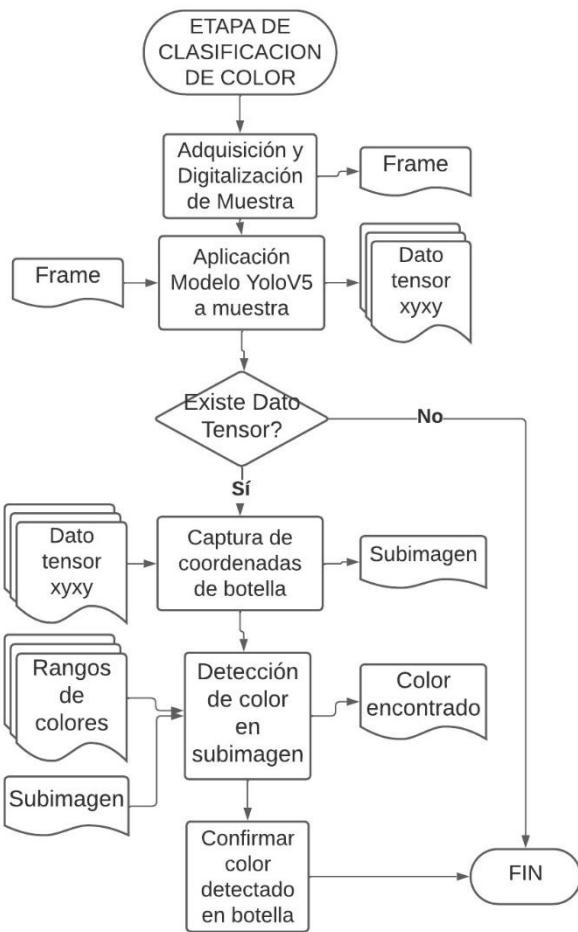
4.1.3. Etapa De Clasificación De Color

La etapa de clasificación de color se basa en la utilización de un modelo de ML más liviano pero efectivo capaz de detectar el objeto y basar la identificación de color solo en él dentro de la imagen, esto para no tener problemas con botellas pequeñas. Para esto el modelo nos proporciona la región en coordenadas de píxeles de donde se encuentra la botella y con respecto a ese objeto capturado, se realiza la detección del color con el espacio de color y los rangos establecidos para definir qué tipo de color es y así clasificarlo en alguno de estos grupos:

- Color: Botellas de color azul, rojo y amarillo
- Blanca: Botellas de color blanca de tipo HDPE
- Verdes: Botellas de color verde.
- Transparente: Botellas de plástico tipo PET.
- Malta: Botellas de color malta.

Esta clasificación se lleva a cabo siguiendo los lineamientos de las empresas encargadas de separar las botellas de plástico y la manera en que realizan esa clasificación.

Figura 35. Flujo de etapa de Clasificación de Color.



Cada frame es procesado por el modelo ML creado para detectar botellas y así poder capturar la botella con un área a su tamaño y medida, esto gracias al dato tensor que proporciona las coordenadas de la posición de la botella y así aplicar la detección de diferentes colores y reconocer qué color predomina en ese espacio delimitado en donde solo se encuentra la botella dentro del frame. Esta etapa funciona con dos espacios de color, HSV y RGB, esto debido a que la detección de algunos colores es más optima en HSV y otras en RGB, así que los rangos pueden estar dados en estos dos mencionados, luego de detectar los pixeles con los colores en la imagen, lo que hace es capturar el color que tenga mayores pixeles en la imagen y este será la respuesta de color de la botella.

FUENTE: Elaboración propia.

4.1.3.1. Materiales De Etapa

- Cámara: Cámara principal p20 lite
- Computador:
 - Procesador: Intel Core i5
 - Ram: 8GB
 - Sistema Operativo: Windows 11 Pro 64 bits
- Lampara de estudio convencional

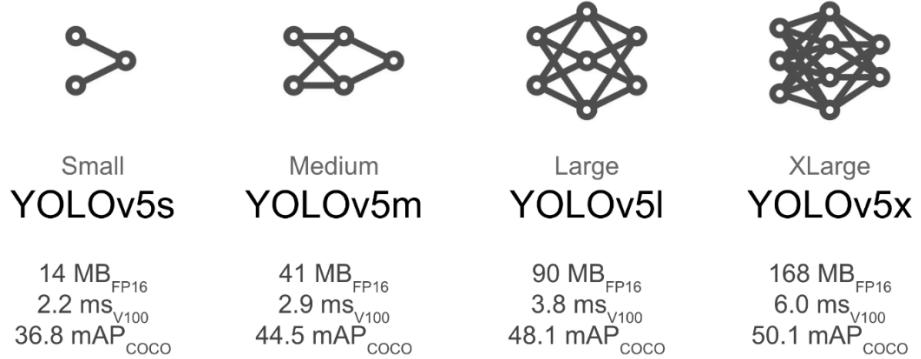
4.1.3.2. Construcción De Etapa

- **Construcción de modelo YoloV5L**

Se entrenó otro modelo YOLOv5, configurado de manera similar al utilizado en la etapa de selección de botellas, pero con una versión más ligera y una base de datos más pequeña. Esto se hizo para enfocarse en la detección de la botella y capturar su color sin verse afectado por las dimensiones del envase.

Es relevante mencionar que el modelo YOLOv5x, debido a su alta precisión, requiere recursos computacionales significativos. En este contexto, podría ser beneficioso considerar una red neuronal más liviana para evitar latencia y ralentización del procesamiento, especialmente en equipos con especificaciones más bajas.

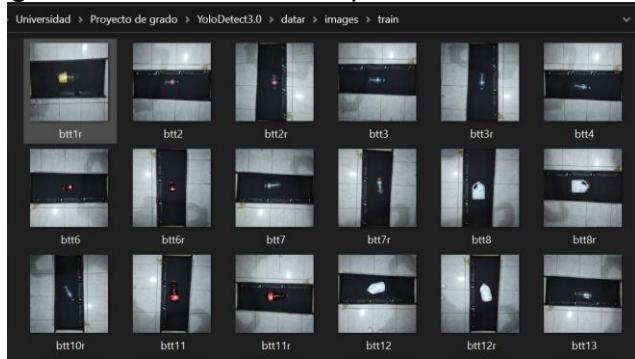
Figura 36. Tipos de modelos de YoloV5.



FUENTE: Github [Sitio Web]. Ultralytics –YoloV5. Disponible en: <https://github.com/ultralytics/yolov5>.

En la Figura 36, se observa que YoloV5L es aproximadamente un 50% más ligero que YoloV5x. Tras entrenar esta red neuronal con YoloV5x, se establece una base de datos más precisa, con un fondo y entorno estandarizados para mejorar la precisión, incluso si el modelo es algo menos robusto.

Figura 37. Base de datos para modelo YoloV5L.

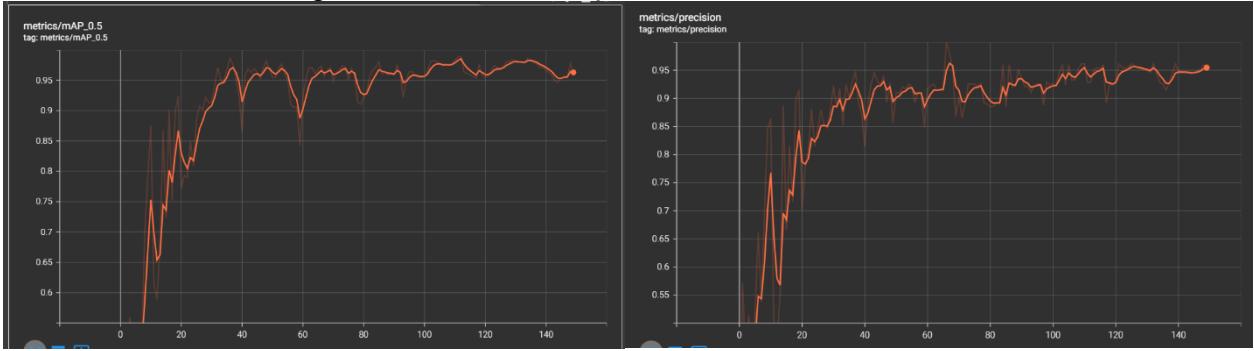


FUENTE: Elaboración propia.

Para este modelo se utiliza solo 200 imágenes, las cuales se distribuyen en 138 para entrenamiento y 62 para validación. Ya preparado todo para el entrenamiento en YoloV5 se debe ir nuevamente a Colab gracias al repositorio público de Yolo para realizar el entrenamiento correspondiente.

Para este entrenamiento, se incluyen todos los parámetros esenciales para el entrenamiento junto con la base de datos personalizada. En este caso, se configuró el tamaño del lote (batch) en 8 y se estableció un entrenamiento de 150 épocas. Esto permite obtener un modelo liviano y casi igual de preciso que el modelo YoloV5x.

Figura 38. Modelo de precisión Modelo YoloV5L.

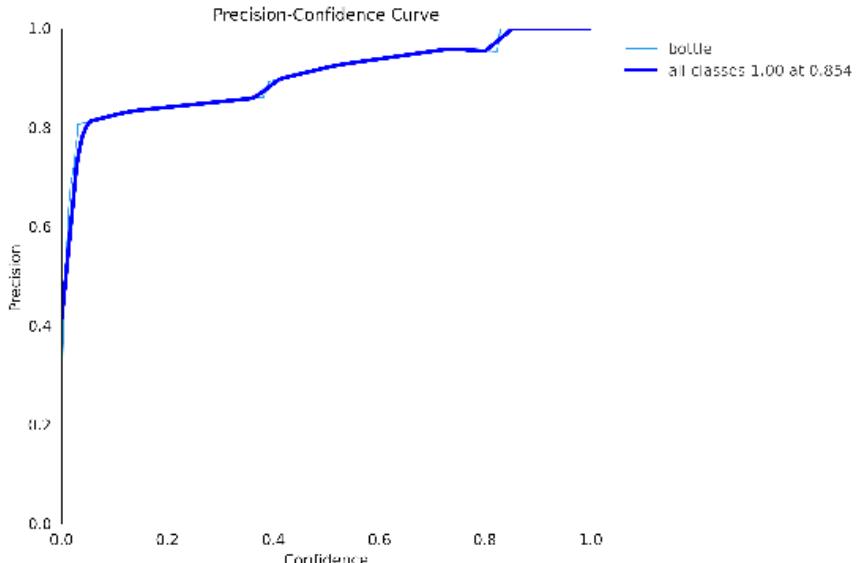


FUENTE: Elaboración propia.

En la figura anterior, se puede observar que a partir de la época 100, ya el modelo cuenta con una buena precisión. Esto indica que la base de datos fue efectiva y que, gracias a la cantidad de épocas ingresadas, se tiene una buena respuesta del modelo hacia la detección de botellas.

En la siguiente, se puede apreciar la gráfica de porcentaje de confianza vs su precisión, esto para saber en qué valor entregado por el modelo, se puede considerar que sí es una botella.

Figura 39. Precisión de la confianza del modelo.



FUENTE: Elaboración propia.

Conforme a la gráfica, cuando el modelo proporciona un porcentaje de confianza igual o superior al 85%, se puede concluir de manera efectiva que el objeto es una botella.

En la Figura 40 que se presenta a continuación, se pueden observar las métricas relacionadas con la función de interés, que corresponde al cuadro que detecta el objeto (Box_Loss). Es importante recordar que esta función, además de detectar el objeto, proporciona las coordenadas correspondientes, lo que resulta en la generación de un recuadro preciso que indica la ubicación de la botella.

Figura 40. Métricas de Box Loss en YoloV5L.



FUENTE: Elaboración propia

Estos valores consideran que el modelo entrenado si será muy útil para la captura de la botella en la imagen y así poder capturar el color de esta sin importar su tamaño.

- **Generación de los rangos de colores a detectar.**

Con el mismo script llamado “ColorClass.py” que se podrá ver en anexos 2, se busca los rangos de los colores que se desea detectar. Según los colores más frecuentes de las botellas son: Amarillo, Rojo, Verde, Azul, Transparente, Malta, Blanco.

Figura 41. Ejemplo de obtención de rango de colores.



FUENTE: Elaboración propia.

En la figura anterior, se puede apreciar la manera en que realizamos la detección de los rangos para cada color (para ese caso, el color Rojo). De cierta forma es necesario realizarlo con las pruebas ya que depende de la calidad de nuestra cámara y de iluminación, debido a esto todos los colores a capturar a excepción del blanco, se hicieron en el espacio de color HSV⁵² por su fácil configuración para diferentes tipos de cámaras e iluminación, generando así que el sistema sea adaptable y configurable a cualquier

⁵² HSV Color Model in Computer Graphics [sitio web]. GeeksforGeeks. [Fecha de consulta: 1 de septiembre 2023]. Disponible en: <https://www.geeksforgeeks.org/hsv-color-model-in-computer-graphics/>

ambiente. En el cuadro 3, se observa los rangos capturados para los colores en el espacio HSV donde el término “Trans” significa transparente.

Cuadro 3. Rangos de colores en HSV.

Colores	Tonalidad	Saturación	Iluminación
Amarillo Mínimo	19	83	211
Amarillo Máximo	35	145	255
Rojo Mínimo	160	30	120
Rojo Máximo	179	255	255
Verde Mínimo	50	117	93
Verde Máximo	101	247	240
Azul Mínimo	76	92	171
Azul Máximo	188	255	255
Trans Mínimo	60	7	84
Trans Máximo	190	29	174
Malta Mínimo	0	65	0
Malta máximo	11	240	150

El blanco se tomó en un rango de espacio de color RGB⁵³ ya que, al realizar diferentes pruebas, en HSV se detectaba también en otros colores, esto porque el blanco también se encontraba en sus rangos. En el siguiente cuadro 4 se visualiza el rango en RGB para este color.

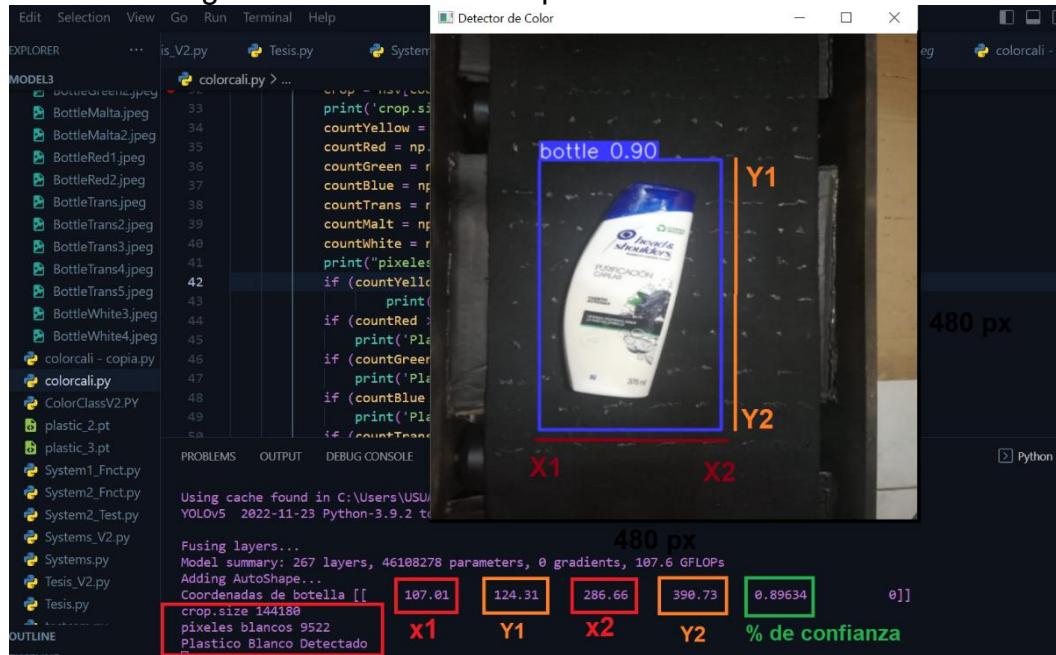
Cuadro 4. Rango de color RGB para el blanco.

Color	Red	Green	Blue
Blanco Mínimo	215	215	216
Blanco Máximo	252	255	240

Ya con estos rangos hay la posibilidad de detectar en una imagen diferentes colores que estos presenten, ya que un fotograma puede mostrarnos diferentes colores, es ahí donde interviene modelo YoloV5L para ayudar a capturar solo el objeto de interés y mirar qué tanto color la botella.

⁵³ RGB colour model [sitio web]. Britannica. [Fecha de consulta: 16 de octubre 2023]. Disponible en: <https://www.britannica.com/science/RGB-colour-model>

Figura 42. Muestra de etapa de detección de color.



FUENTE: Elaboración propia.

En la Figura 42, se puede apreciar el script “colorcali.py” que se puede encontrar en el anexo 2, el cual lee la imagen a procesar (para estas pruebas se redimensionaron a 480x480 px) y da como salida los parámetros señalados en el terminal de Visual Studio:

- Coordenadas de botella: Son las coordenadas del recuadro creado por el modelo al detectar una botella.
 - X1: Punto horizontal inicial de la caja de detección de objeto
 - X2: Punto horizontal final de la caja de detección de objeto
 - Y1: Punto vertical inicial de la caja de detección de objeto
 - Y2: Punto vertical final de la caja de detección de objeto
 - % de confianza: El valor que da al modelo al objeto de parecerse a una botella. Para esta etapa no lo tendremos en cuenta.
- Crop.size: área de la caja o subframe recortado por el modelo. Este dato está multiplicado por 3 ya que el espacio está en 3 dimensiones, por eso la cantidad de pixeles es demasiada. Según los datos capturados, se puede hallar con la formula:

$$\text{Area de caja (subframe)} = (X2 - X1) * (Y2 - Y1) * 3$$

$$\begin{aligned} \text{Area de caja (subframe)} &= (286.66 - 107.01) * (390.73 - 124.31) * 3 \\ &= 143587.059 \text{ px} \cong 144180 \text{ px} \text{ (Resultado del sistema)} \end{aligned}$$

- Pixeles blancos: La cantidad de pixeles encontrados en el rango establecido en ese subframe o caja delimitada por el modelo. (9522 para esta prueba según la Figura 42)
- Plástico Blanco detectado: Respuesta a validación de si el sistema encuentra una cantidad considerable de pixeles de color blanco.
 - Rango = 0.04

Si los pixeles de los rangos encontrados son mayores a la cantidad de pixeles del área de la caja por el rango, se debe enviar la respuesta de que detectó dicho color.

Ejemplo para esta prueba:

- Área de la caja = 144180, Rango = 0.04, Pixeles del color entrado = 9522

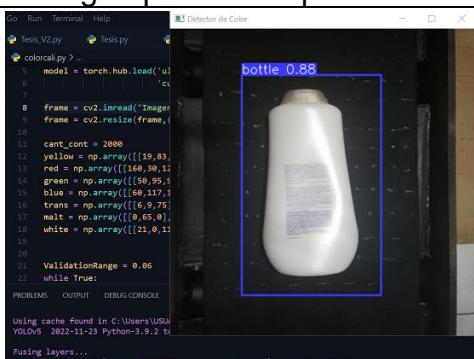
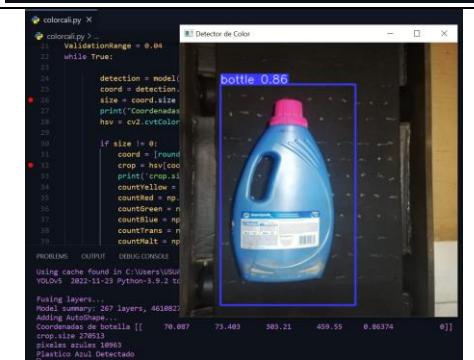
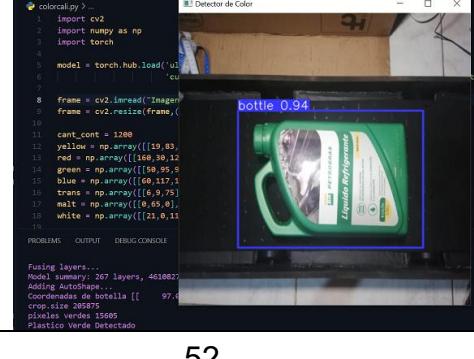
$$9522 \geq 144180 * 0.04$$

$$9522 \geq 5767.2 \rightarrow \text{Validación correcta}$$

4.1.3.3. Resultados De Etapa

En el cuadro 5, se visualiza los resultados de diferentes imágenes de botellas y la respuesta del sistema para comprobar que esté realizando correctamente su procesamiento, captura de rangos de color y validaciones en el script de Python "colorcali.py".

Cuadro 5. Resultados en imágenes de etapa de Clasificación por Color.

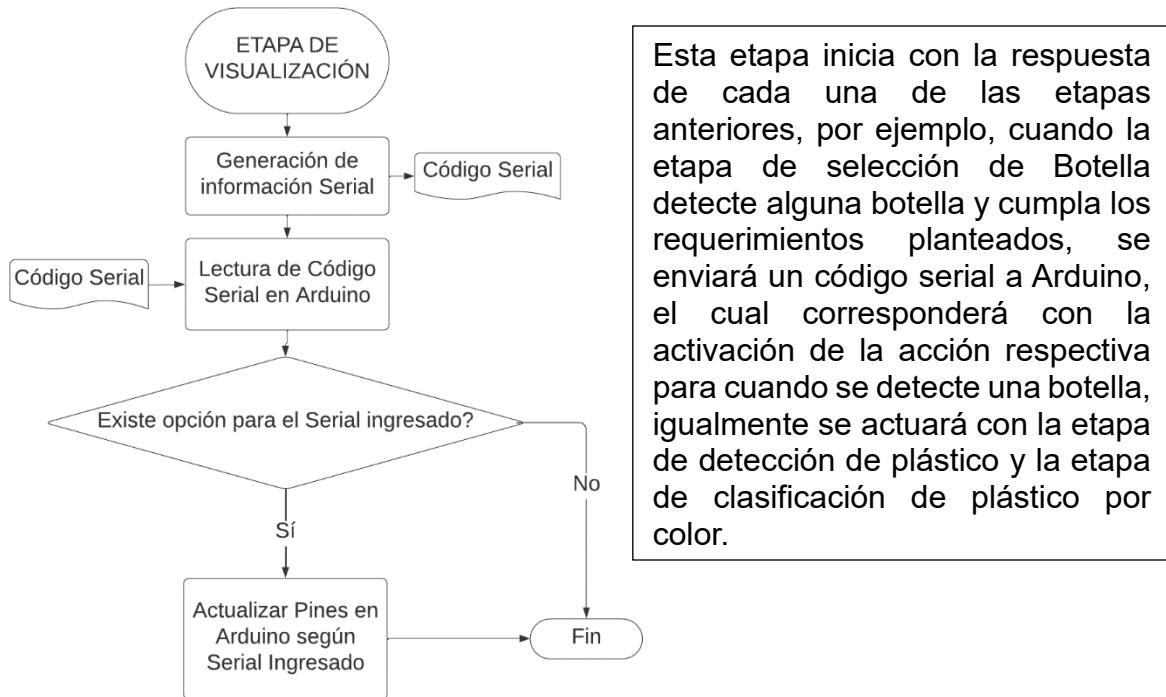
Imagen	Imagen procesada por modelo	Resultados
	 Screenshot of the 'colorcali.py' script showing the detection of a white bottle. The script uses a model to detect the bottle and prints its coordinates and confidence score (0.88). The terminal output shows the model summary, validation range, and crop size (223944 px).	Coordenadas: X1=112.59 Y1=72.85 X2=330.31 Y2=416.9 crop.size = 223944 px pixeles blancos = 27215 Blanco Detectado
	 Screenshot of the 'colorcali.py' script showing the detection of a blue bottle. The script uses a model to detect the bottle and prints its coordinates and confidence score (0.86). The terminal output shows the model summary, validation range, and crop size (270513 px).	Coordenadas: X1=70.087 Y1=73.40 X2=303.21 Y2=459.5 crop.size = 270513 px pixeles azules = 10963 Azul Detectado
	 Screenshot of the 'colorcali.py' script showing the detection of a green bottle. The script uses a model to detect the bottle and prints its coordinates and confidence score (0.94). The terminal output shows the model summary, validation range, and crop size (205875 px).	Coordenadas: X1=97.075 Y1=160.47 X2=401.71 Y2=385.44 crop.size = 205875 px pixeles verdes = 15605 Verde Detectado

4.1.4. Etapa De Visualización

La etapa de visualización de datos se basa en la representación de las posibles acciones que se pueden realizar a partir de un microprocesador Arduino⁵⁴ UNO y la información proporcionada por las etapas anteriores, estas acciones pueden ir desde simplemente encender y apagar un LED, a determinar el ángulo de un servomotor según el estado presentado.

⁵⁴ Arduino [sitio web]. [Fecha de consulta: 2 de septiembre de 2023]. Disponible en: <https://www.arduino.cc/>

Figura 43. Diagrama etapa de visualización.



FUENTE: Elaboración propia.

4.1.4.1. Materiales De Etapa

- Arduino UNO.
- Cable USB AM-AF de 5m.
- Resistencias de 220 Ω.
- 3 leds de color Azul, 4 leds de colores variados (Rojo, Amarillo, Blanco, Verde). → Corriente de funcionamiento: 20mA. Voltaje de Barrera: 2 V.
- PinHeader Verticales 2.54mm.1 de Tamaño 1x10. 2 de Tamaño 1x8.1 de Tamaño 1x6.
- Baquela Virgen 20x15cm.
- Ácido Férrico.
- Papel fotografía.
- Plancha.
- Cinta de enmascarar.
- Motortool.
- Cautín y Estaño.

4.1.4.2. Construcción De Etapa

- Desarrollo de Código para Arduino UNO

En el Anexo 2, se encuentra disponible el código "ArduinoTesis.ino" desarrollado para una placa Arduino UNO. En este código, se implementa la comunicación serial que será generada desde los scripts dedicados a cada sistema de la planta. Para llevar a cabo

esta comunicación serial, se inicia el puerto correspondiente mediante el siguiente comando.

```
uno = serial.Serial('COM3', 9600, timeout = 1)
```

Una vez que el puerto se ha inicializado, es posible utilizarlo para transmitir información a la placa Arduino. Esto se logra al incluir en el código la variable asignada al puerto, seguida de ".write(b'serial')", donde "serial" representa el código serial que se está enviando.

En cuanto al desarrollo del código Arduino, este comienza con la asignación de variables, considerando los pines que se utilizarán para cada acción. En este caso, al encender LEDs, se emplearán salidas digitales del Arduino. Además, se crea una variable destinada a almacenar la información serial que se recibirá desde el procesamiento de imágenes de la planta.

Después de completar este paso, se procede a elaborar el código de inicialización de la placa. En esta etapa, se configura la velocidad con la que se actualizará la lectura del puerto serial y se realizan las asignaciones de pines como salidas.

En la última sección del código, se dedica a la recepción de información serial, y esta se divide en tres acciones principales, cada una correspondiente a un sistema de la planta. A continuación, se detallan estas acciones:

- 1) Activación y Desactivación de LED para Detección de Botellas:
 - Cuando se identifica una botella, se activa un LED correspondiente.
 - Si no se detecta una botella, se desactiva el LED asociado a la detección.
- 2) Activación y Desactivación de LED para Detección de Plástico:
 - Cuando se detecta plástico, se enciende un LED específico.
 - Si no se identifica plástico, se apaga el LED relacionado con la detección.
- 3) Clasificación de Botellas por Color:
 - Para la clasificación por color, hay cinco opciones posibles: Color, Malta (por ejemplo, botellas de pony malta), Verde, Transparente y Blanco.
 - Cada opción tiene un LED asignado que se encenderá durante 800 milisegundos (0.8 segundos) por cada fotograma capturado.
 - Si una opción se mantiene estable durante 3 fotogramas consecutivos, el LED correspondiente se activará durante 2.4 segundos.
 - Si no se recibe información del sistema de clasificación de color, se desactivarán las acciones relacionadas con dicho sistema.

Este enfoque permite controlar los LEDs de acuerdo con la información serial recibida, lo que proporciona una respuesta visual a las detecciones y clasificaciones realizadas por los sistemas de la planta.

- **Montaje de circuito en PCB**

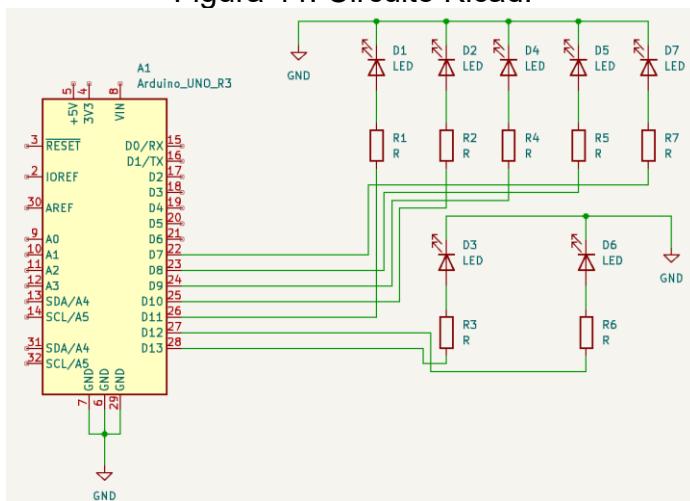
Para la implementación del circuito se realiza un diseño en PCB en la plataforma Kicad⁵⁵, la cual provee las opciones para visualizar previamente el circuito impreso y el modelado 3D de la implementación, para esto se tiene en cuenta que al trabajar con diodos leds, se necesitan unas resistencias de protección de los leds, el cálculo de estas es a través del siguiente calculo.

$$R_{led} = \frac{V_{CC} - V_D}{I_D}$$

Donde la resistencia de protección del diodo led será igual al voltaje de alimentación proveniente de la salida de Arduino menos el voltaje de barrera del led, y eso dividido la corriente requerida por el led para encender correctamente, de este cálculo obtenemos que siendo el voltaje de alimentación proveniente de la salida digital de Arduino 5V, la resistencia protectora tendría un valor de 150 Ω.

Después de efectuar los cálculos pertinentes, se procede con el montaje del circuito en la interfaz de KiCad. En esta etapa, se establece la conexión con Arduino UNO, enlazándolo a los LEDs correspondientes junto con sus respectivas resistencias. Estos detalles se pueden apreciar en la Figura 44.

Figura 44. Circuito Kicad.



FUENTE: Elaboración propia

Después de realizar los cálculos necesarios, se inicia la selección de los componentes que se utilizarán en la PCB. Dentro de la librería de KiCad, se opta por elegir componentes que sean comunes y fáciles de encontrar en el mercado. En este sentido, se utilizan componentes Through-Hole (THT).

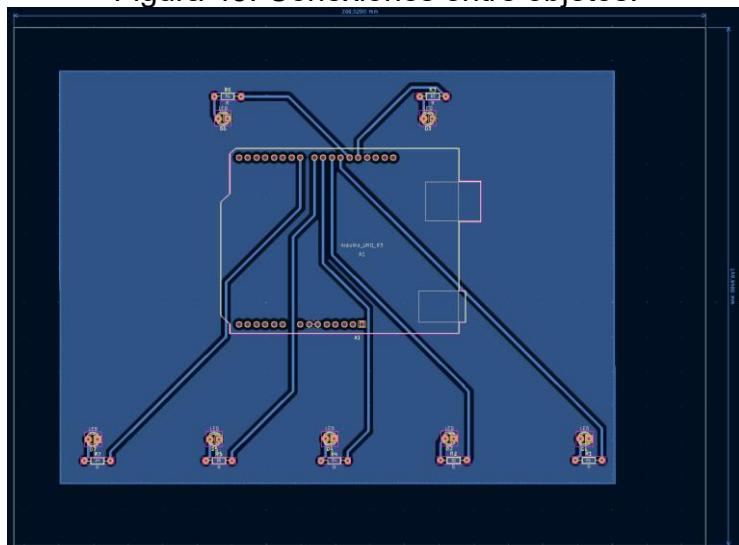
Específicamente, se emplea la referencia "LED_THT:LED_D3.0mm" de KiCad para los LEDs y la referencia "Resistor_THT:R_Axial_DIN0204_L3.6mm_D1.6mm_P7.62mm_Horizontal" para las resistencias, las cuales son resistencias de 1/4 de vatio.

⁵⁵ Kicad [sitio web]. [Fecha de consulta: 2 de septiembre de 2023]. Disponible en: <https://www.kicad.org/>

Una vez se han seleccionado los componentes adecuados, se procede al diseño de la PCB en KiCad. En esta etapa, se establece el tamaño de la placa de circuito para gestionar eficazmente el espacio disponible. Luego, se colocan los componentes en la posición deseada, de manera que las conexiones entre ellos sean lo más sencillas posible.

Después de completar esta etapa, se procede a establecer las conexiones apropiadas entre los componentes utilizados en la PCB, con el objetivo de mantener la simplicidad del diseño. Además, se ha optado por llenar las áreas vacías de cobre de la placa con una red de tierra. Esto se hace para garantizar puntos de conexión a tierra en caso de que ocurra algún cortocircuito con objetos externos. El resultado de este proceso se puede apreciar en la Figura 45.

Figura 45. Conexiones entre objetos.



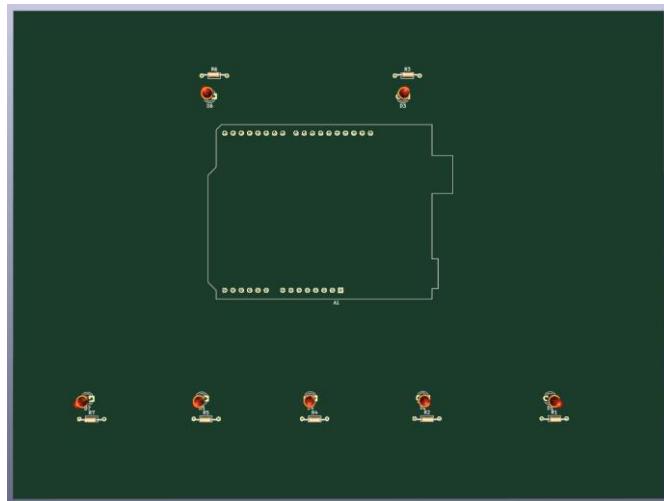
FUENTE: Elaboración propia.

Kicad ofrece una herramienta de visualización en 3D de la placa, y se obtuvo el resultado que se muestra en la Figura 46. Sin embargo, como se puede observar, no se refleja claramente la idea propuesta para la conexión de la placa Arduino a la PCB. Por lo tanto, se lleva a cabo una actualización de los modelos 3D de la placa Arduino utilizando un modelo descargado de la página web GrabCad Community⁵⁶.

Una vez finalizado este proceso de actualización de modelos, se puede apreciar la idea propuesta con mayor claridad. Se emplean PinHeaders para establecer la conexión entre la placa Arduino y la PCB, como se ilustra en la Figura 47.

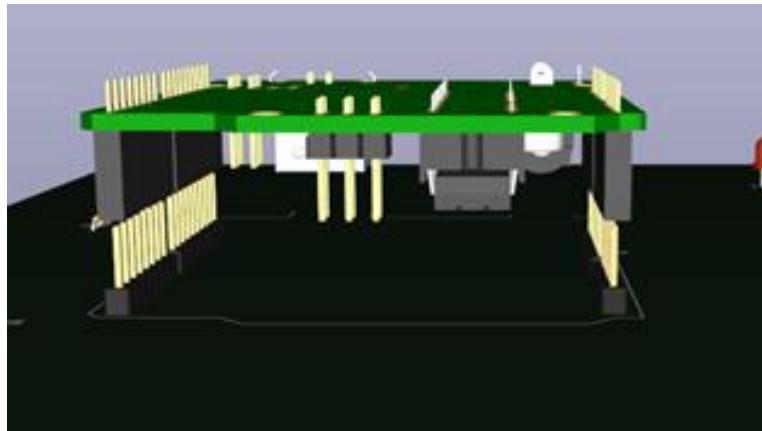
⁵⁶ GrabCad [sitio web]. [Fecha de consulta: 4 de julio 2023]. Disponible en: <https://grabcad.com/>

Figura 46. Modelado 3D PCB.



FUENTE: Elaboración Propia

Figura 47. Modelado 3D Arduino.



FUENTE: Elaboración Propia

Luego de finalizar el diseño de la PCB, se procede a concretar el circuito en su forma física. Para lograrlo, se emplea papel de fotografía junto con una impresora láser para imprimir la capa de cobre deseada en la placa. Después de este paso, se sigue con el método del planchado para transferir el diseño impreso desde el papel fotográfico a la superficie de cobre de la placa. Este proceso requiere el uso de una plancha y cinta de enmascarar, y se realiza aplicando calor para transferir la impresión desde el papel fotográfico.

Una vez finalizado el proceso de planchado, se procede a retirar cuidadosamente el papel fotográfico. En el mejor escenario, el circuito se transfiere por completo a la placa. Sin embargo, si no se transfiere completamente, se puede completar con un marcador negro de punta fina para evitar conexiones no deseadas.

Luego de completar este paso, se prepara una solución de ácido férrico con agua. En nuestro caso, se utilizó una solución proveniente de un sobre que se diluye en 1 litro de agua. Con la solución lista, la placa se sumerge en el ácido férrico con precaución. Se

deja reposar durante un tiempo determinado. Si nota que el proceso de eliminación del cobre no avanza rápidamente, puede agitar ligeramente la solución para aumentar la interacción con el cobre.

Después de completar el proceso de eliminación del cobre para crear las rutas de información, se procede a limpiar la placa en la parte de cobre para eliminar la tinta negra de la impresión láser. Luego de llevar a cabo este procedimiento de limpieza, se procede a realizar las perforaciones necesarias en la placa para permitir la inserción de las resistencias, LEDs y PinHeaders THT, como se puede observar a continuación.

Finalmente, se procede a soldar los componentes en sus ubicaciones correspondientes, asegurando una correcta conexión y cuidando la polaridad, especialmente en el caso de los LEDs, con el objetivo de lograr un resultado estético en ambas superficies de la placa. Además, se coloca la placa Arduino UNO sobre sus PinHeaders para verificar que la conexión sea correcta y que cada salida sea activada según lo previsto.

Se realizan pruebas de tiempo de respuesta, tanto con la extensión de cable USB como sin ella, se ajusta la intensidad de iluminación y se verifica que las respuestas sean las deseadas. Finalmente, se etiquetan los LEDs para una mejor visualización de los resultados obtenidos.

Figura 48. PCB Final.



Fuente: Elaboración Propia.

4.1.4.3. Resultados De Etapa

En el cuadro 6 se pueden observar distintos estados presentados en la planta que poseen una acción en la implementación realizada, en este caso, el encendido de un LED correspondiente a su etapa.

Cuadro 6. Resultados Etapa de Visualización.

Etapa	Imagen de Referencia	Acción Esperada	Resultado
Selección de Botella		Encender LED Botella	
Selección de Botella		Apagar LED Botella	
Detección de Plástico		Encender LED Plástico	
Detección de Plástico		Apagar LED Plástico	
Clasificación de Color		Encender LED Blanco	

Clasificación de Color		Encender LED Color	
Clasificación de Color		Encender LED Verde	
Clasificación de Color		Encender LED Malta	
Clasificación de Color		Encender LED Color	
Clasificación de Color		Encender LED Transparente	

Clasificación de Color		Encender LED Transparente	
------------------------	---	---------------------------	---

4.1.5. Etapa De Implementación De Planta A Baja Escala

Se agregan las etapas anteriormente diseñadas para concluir el sistema total de este trabajo de grado.

4.1.5.1. Materiales De Etapa

- Caja de etapa de detección de plástico
- Cámara Web: **Genius FaceCam 1000x**
 - Tipo de sensor: CMOS
 - Interfaces: USB
 - Resolución máxima de video: 1280 px x 720 px
- Cámara Web: **Logitech C920** sin filtro IR
 - Interfaces: USB 2.0
 - Resolución máxima de video: 1920 px x 1080 px
 - Full HD 30FPS
- Cámara: Cámara principal p20 lite
- Computador:
 - Procesador: Intel Core i5
 - Ram: 8GB
 - Sistema Operativo: Windows 11 Pro 64 bits
- Banda Transportadora
- Motorreductor N20 1 KG-CM 100RPM
- Tela Lino.

4.1.5.2. Construcción De Etapa

- **Construcción de banda Transportadora**

Se llevó a cabo la construcción de una banda transportadora a escala reducida debido a las restricciones de recursos. No obstante, el equipo logró demostrar el funcionamiento del prototipo de planta seleccionadora y clasificadora de plástico.

Figura 49. Construcción de la banda Transportadora.



FUENTE: Elaboración propia.

Para esta banda se utilizó como base lateral tablas de un grosor de 9 mm con alrededor de 15 cm de ancho y 1.2m de largo, tubo de PVC de 2 pulgadas para que funcionen como rodillos junto con los tornillos sinfín que funcionan para que estos tubos puedan moverse sin la fricción de las tablas laterales. Además, para el movimiento se utilizó un Motorreductor DC que funcionaría alrededor de 10 voltios para que proporcione una fuerza y velocidad considerable.

Posterior a esto, ya que se debe considerar evitar una mínima existencia de reflexión, los rodillos y la parte superior de la banda debe ser pintado de negro, como se puede ver en la siguiente Figura 50.

Figura 50. Pintado de Banda Transportadora.



FUENTE: Elaboración propia.

Luego, ya con el material de cinta para nuestra banda transportadora dependiendo de diversas pruebas, se eligió la tela de lino, adicionando también más pintura negro mate para que tuviese un color más oscuro y este generara menos reflexión.

Figura 51. Terminación de banda Transportadora con Tela Lino.



FUENTE: Elaboración propia.

- **Agrupación de etapas principales**

En la siguiente Figura 52 se podrá ver gráficamente la implementación física de las 3 principales etapas (Selección de Botella, Detección de Plástico y Clasificación de Color) para ya observar la construcción del prototipo.

Figura 52. Agrupación Física de las etapas principales.



FUENTE: Elaboración propia.

En el siguiente cuadro se recapitula los materiales y los modelos utilizados en cada etapa.

Cuadro 7. Materiales y modelos de etapas.

Materiales \ Etapas	Selección de Botella	Detección de Plástico	Clasificación de color
Cámara Web: Genius FaceCam 1000x	✓	No aplica	No aplica
Modelo YoloV5x	✓	No aplica	No aplica
Cámara Web: Logitech C920 sin filtro IR	No aplica	✓	No aplica
Caja de etapa de detección de plástico	No aplica	✓	No aplica
Cámara web: Cámara principal p20 lite	No aplica	No aplica	✓
Modelo YoloV5L	No aplica	No aplica	✓
Banda Transportadora	✓	✓	✓
Computador:	✓	✓	✓

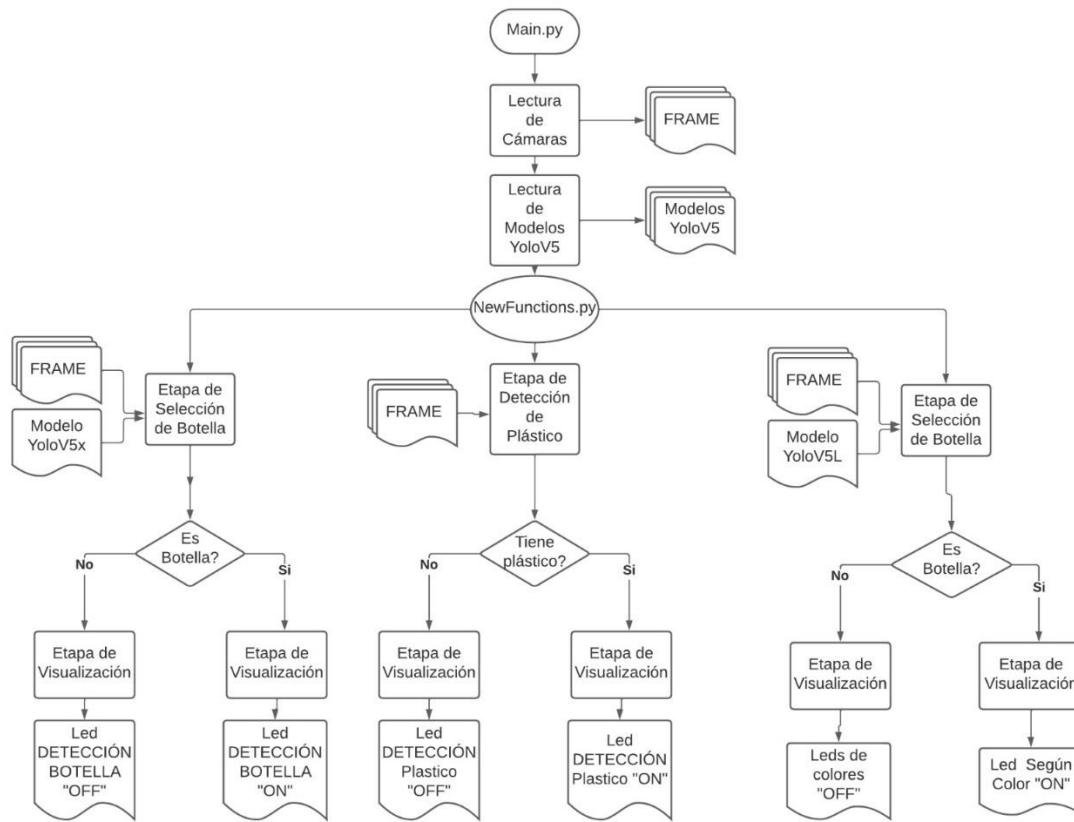
- **Explicación de agrupación de etapas a nivel de software**

Se ha implementado la función de threading con el propósito de permitir que las etapas operen de manera simultánea y sin depender unas de otras, asegurando así una ejecución adecuada en el script "Main.py". En el script "NewFunctions.py", se encuentran

definidas todas las etapas como funciones, junto con algunas clases fundamentales para el desarrollo de cada una de ellas. Es importante destacar que este script también estará disponible en el repositorio de GitHub en el anexo 2.

La Figura 53 proporciona una visión general de alto nivel del funcionamiento de "Main.py", que activa las etapas definidas en el algoritmo "NewFunctions.py" y muestra las respuestas de cada etapa.

Figura 53. Funcionamiento de "main.py".

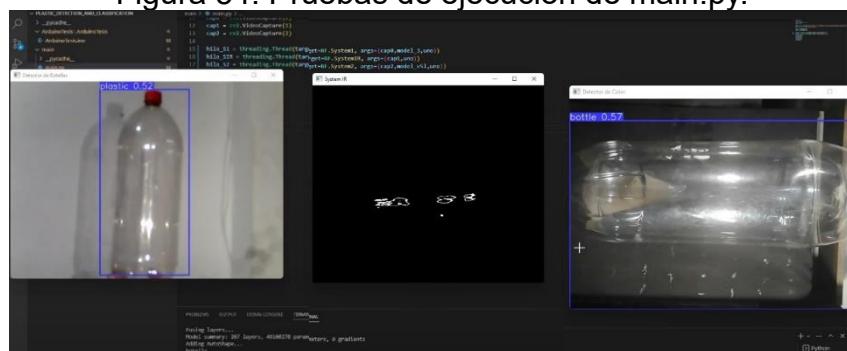


FUENTE: Elaboración propia.

4.1.5.3. Resultados De Etapa

Al ejecutar estos scripts empezamos a realizar diferentes pruebas, observando las salidas de nuestras etapas en las ventanas generadas por Python.

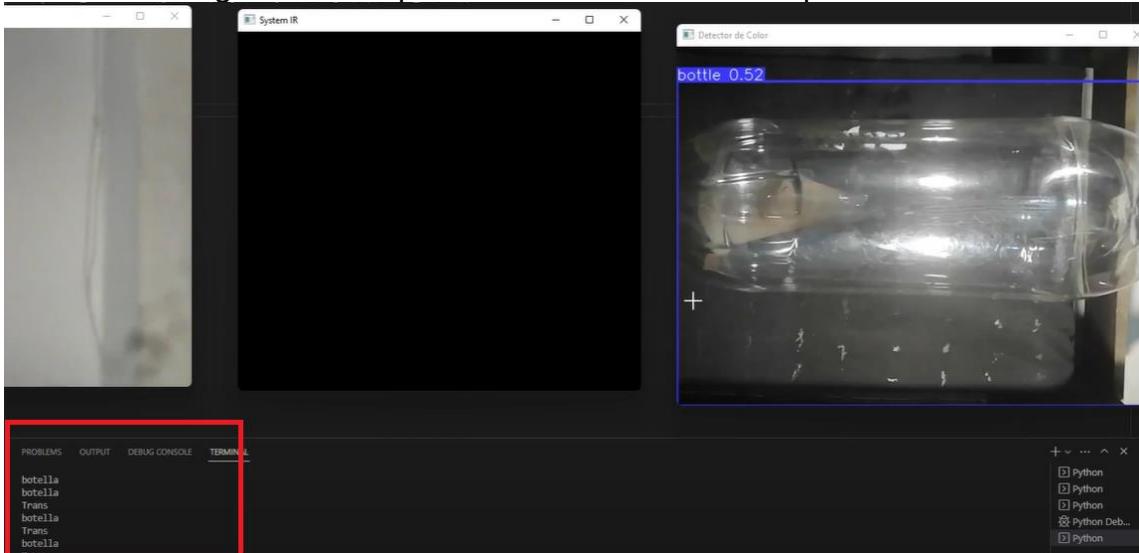
Figura 54. Pruebas de ejecución de main.py.



FUENTE: Elaboración propia.

En la figura anterior, se visualiza el paso de una botella transparente por las tres etapas, en la primera pantalla se observa que su valor de confianza es mayor a 0.43, indicando que es botella, en la segunda se puede ver que se detecta luz reflectiva debido a que la botella tiene plástico y en la última pantalla se puede ver que el segundo modelo detectó que es botella y valida su color, este resultado se puede ver en la Figura 55. Luego se realizó un cuadro de resultados de cada etapa para analizar la respuesta de nuestros sistemas y conocer su funcionalidad ya compacta en nuestra planta.

Figura 55. Respuesta del sistema a botella procesada.



FUENTE: Elaboración propia.

En la figura anterior, se muestra la primera etapa en la que el modelo YOLOv5x detecta botellas. En el cuadro 8 se presentan los resultados de cada etapa, en donde las siglas “Sys” hace referencia a la palabra Sistema, “Trans” hace referencia a la clasificación Transparente de plástico, “White” hace referencia a la clasificación Blanca de plástico, “B.” que hace referencia a la palabra botella, “C.” que hace referencia a la palabra cerveza, “E.” que hace referencia a la palabra etiqueta, “A.” que hace referencia a la palabra aplastada y el símbolo “%” que hará referencia al porcentaje de confianza del dato. El registro depende de los resultados de cada etapa, lo que significa que si la primera etapa detecta una botella con un porcentaje superior al 0.43, se procede al registro en la etapa de plástico. Si se detecta plástico en la botella, se realiza el registro en la etapa de color para capturar el color de la botella seleccionada.

Cuadro 8. Resultados de planta completa a baja escala.

Dato	Sys Botella			Sys Plástico		Sys Color		Descripción
	%	Sys	Real	Sys	Real	Sys	Real	
1	0.49	SI	SI	SI	SI	Trans	Trans	B. de Agua (A.)
2	0.39	NO	SI	N/A	N/A	N/A	N/A	B. Costeña (C.)
3	0.45	SI	SI	SI	NO	Trans	Trans	B. Aguil (C.E.)
4	0.61	SI	SI	NO	NO	N/A	N/A	B. Aguil (C. sin E.)
5	0.44	SI	SI	NO	NO	N/A	N/A	B. Poker (C. sin E.)
6	0.47	SI	SI	SI	SI	Trans	Trans	B. Aguil (C. E.)
7	0.49	SI	SI	SI	SI	Trans	Trans	B. Aguardiente (Sin E.)
8	0.29	NO	NO	N/A	N/A	N/A	N/A	Vaso Plástico

9	0.65	SI	SI	SI	SI	White	White	B. Crema
10	0.47	SI	SI	SI	SI	Color	Color	B. Tarrito Rojo
11	0.28	NO	NO	N/A	N/A	N/A	N/A	Pedazo de Cartón
12	0.36	NO	NO	N/A	N/A	N/A	N/A	Caja de Cartón
13	0.00	NO	NO	N/A	N/A	N/A	N/A	Estuche de Gafas
14	0.00	NO	NO	N/A	N/A	N/A	N/A	Lamina de madera
15	0.00	NO	NO	N/A	N/A	N/A	N/A	E. de B.
16	0.00	NO	NO	N/A	N/A	N/A	N/A	Libro
17	0.00	NO	NO	N/A	N/A	N/A	N/A	Perfume
18	0.41	NO	NO	N/A	N/A	N/A	N/A	Bolsa Plástica
19	0.36	NO	NO	N/A	N/A	N/A	N/A	Tapa de Icopor
20	0.48	SI	SI	SI	SI	Trans	Trans	B. Coca-Cola 3L
21	0.50	SI	SI	SI	SI	Malta	Malta	B. Pony 1.5L
22	0.45	SI	SI	SI	SI	Malta	Malta	B. Pony 0.2L
23	0.48	SI	SI	SI	SI	White	White	B. Talcos
24	0.63	SI	SI	SI	SI	White	White	B. Crema
25	0.46	SI	SI	NO	NO	N/A	N/A	B. de Agua 0.2L
23	0.57	SI	SI	SI	SI	Color	Color	B. de Suavizante
24	0.48	SI	SI	SI	SI	Verde	Verde	B. de Lubricante
25	0.65	SI	SI	SI	SI	White	White	B. de Limpido
26	0.51	SI	SI	SI	SI	Trans	Trans	B. Jugo hit
27	0.55	SI	SI	SI	SI	Color	Color	B. Cocacola Retornable
28	0.46	SI	SI	SI	SI	Trans	Trans	B. Cocacola 400ml (Sin E.)
29	0.48	SI	Si	SI	SI	Color	Color	B. Cocacola 400ml (E.)
30	0.60	SI	SI	SI	SI	Color	Color	B. Tampico 250ml (E.)
31	0.51	SI	SI	SI	SI	Trans	Trans	B. Tampico 250ml (Sin E.)
32	0.61	SI	SI	SI	SI	White	White	B. de Leche Condensada
33	0.48	SI	SI	SI	SI	White	White	B. Jabón Intimo
34	0.44	SI	SI	SI	SI	Trans	Trans	B. Gatorade
35	0.55	SI	SI	SI	SI	White	White	B. de Tampico Grande
36	0.57	SI	SI	SI	SI	White	White	B. Acondicionador
37	0.47	SI	SI	SI	SI	White	White	B. de Leche Condensada
38	0.53	SI	SI	SI	SI	Color	Color	B. Cloro (E.)
39	0.61	SI	SI	SI	SI	White	White	B. Cloro (Sin E.)
40	0.54	SI	SI	SI	SI	White	White	B. de Shampoo
41	0.44	SI	SI	SI	SI	Trans	Trans	B. de Agua
42	0.56	SI	SI	SI	SI	Trans	Trans	B. de Agua (A.)
43	0.52	SI	SI	SI	SI	Trans	Trans	B. de Gatorade (A.)
44	0.48	SI	SI	SI	SI	Trans	Trans	B. Manzana grande
45	0.44	SI	SI	SI	SI	Trans	Trans	B. Manzana grande (A.)
46	0.52	SI	SI	SI	SI	White	White	B. aceite (E.)
47	0.50	SI	SI	SI	SI	Trans	Trans	B. aceite (Sin E.)
48	0.60	SI	SI	SI	SI	Trans	Trans	B. aceite (A. sin E.)
49	0.00	NO	NO	N/A	N/A	N/A	N/A	Papel
50	0.27	NO	NO	N/A	N/A	N/A	N/A	Papel Arrugado

5. ANALISIS DE RESULTADOS

5.1. LIMITACIONES DEL SISTEMA.

Durante las pruebas realizadas con los algoritmos diseñados para la ejecución del sistema completo, se encontraron algunas limitaciones que se deben tener presente a la hora de ejecutar el programa, estas fueron:

1. Fuente de luz en la caja de detección de plástico.

Como se ha destacado previamente en la sección 4.1.2.2, es imperativo que la única fuente de iluminación presente dentro de la caja sea de naturaleza infrarroja. Además, es fundamental que se garantice una altura mínima de 70 centímetros para permitir una adecuada captación de la diferencia de reflectancia entre el plástico y el vidrio. Esta disposición es esencial para asegurar la precisión y la fiabilidad de las mediciones realizadas en el contexto de este estudio o proyecto.

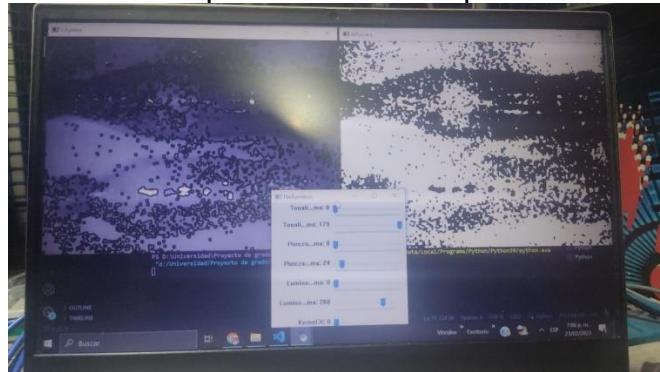
Figura 56. Fotograma de etapa de detección de plástico con baja altura.



FUENTE: Elaboración propia.

En la Figura 56, se muestra claramente una de las repercusiones derivadas de la reducida altura de la cámara utilizada para la detección de plástico. Como se ha mencionado previamente, resulta altamente recomendable que la caja cuente con una altura de al menos 70 centímetros y que esté completamente sellada, con el fin de evitar que otras fuentes de luz interfieran o perjudiquen el proceso de detección. Esta precaución es esencial para garantizar la integridad y la precisión de las mediciones llevadas a cabo en el marco de este proyecto. En la siguiente figura se puede ver el ruido que genera este error.

Figura 57. Detección de plástico con ruido por exceso de luz.



FUENTE: Elaboración propia.

2. Limitación en Desarrollo de Implementación por Falta de Requerimientos.

A lo largo del desarrollo de las diversas etapas mencionadas en la sección 4.1, se optó por utilizar principalmente Python en la fase de implementación a baja escala de la planta. Esta elección se basó en la intención de montar estos sistemas en una Raspberry Pi 3 Modelo B+, que fue proporcionada por el programa de ingeniería electrónica de la Universidad Surcolombiana.

Sin embargo, al intentar instalar la paquetería necesaria para trabajar con YoloV5 en la Raspberry Pi, se encontró un obstáculo. Resultó que los paquetes no estaban disponibles para su instalación en el sistema operativo utilizado. El problema radicaba en que PyTorch y TorchVision, bibliotecas de aprendizaje automático de código abierto en Python, solo ofrecían instalaciones para máquinas x86 en su versión estable. Aunque los desarrolladores también proporcionaban versiones nightly builds compatibles con dispositivos aarch64 (ARM), estas versiones aún estaban en desarrollo y podían carecer de cierta funcionalidad⁵⁷.

Ante esta situación, se emprendió la búsqueda de las nightly builds adecuadas para la Raspberry Pi. No obstante, dado que esta versión aún no estaba oficialmente finalizada, muchos de los comandos para la instalación de paquetes de Python en estas builds resultaron inoperables. En consecuencia, se tomó la decisión de explorar alternativas más viables para la implementación de la planta. Durante esta búsqueda de soluciones, se identificó una opción muy prometedora: la utilización de una versión más actualizada del dispositivo embebido que se pretendía implementar⁵⁸, específicamente la Raspberry Pi 4 Modelo B+ con 4 GB de RAM⁵⁹. No obstante, tras consultar con ingenieros y compañeros de estudio, no se logró obtener el préstamo de dicho microprocesador, y su precio de venta resultó prohibitivo para el presupuesto de los tesis.

Por consiguiente, se decidió llevar a cabo la ejecución del código en un ordenador con suficiente capacidad y recursos. El encargado de gestionar la información suministrada por el código y de interactuar con la planta sería un microprocesador Arduino UNO, como se detalla en la sección 4.1.4.

3. Iluminación Externa para Sistema de Color.

Durante el desarrollo de la sección 4.1.3, surgió la necesidad de garantizar una iluminación estable para la correcta identificación de los colores de las botellas que atraviesan el sistema. Esto se debió a que, al definir los rangos de detección de colores en un entorno iluminado de manera específica, cualquier alteración en la iluminación podría ocasionar problemas, como falsos positivos en el modelo y clasificaciones incorrectas de colores.

⁵⁷ Tutorial: Running YOLOv5 Machine Learning Detection on a Raspberry Pi 4 [sitio web]. Jordan Johnston | Medium. [Fecha de consulta: 8 de septiembre 2023]. Disponible en: <https://jordan-johnston21.medium.com/tutorial-running-yolov5-machine-learning-detection-on-a-raspberry-pi-4-3938add0f719>

⁵⁸ Ibid.

⁵⁹ REAL TIME INFERENCE ON RASPBERRY PI 4 (30 FPS!) [sitio web]. PyTorch Tutorials. [Fecha de consulta: 9 de septiembre 2023]. Disponible en: https://pytorch.org/tutorials/intermediate realtime_rpi.html#real-time-inference-on-raspberry-pi-4-30-fps

Para abordar esta problemática, se optó por la implementación de una lámpara de escritorio, posicionada a una distancia adecuada para que su luz no interfiriera de forma negativa en la captura de imágenes por parte de la cámara del sistema. De esta manera, se aseguró una iluminación constante y controlada sobre el objeto en cuestión, evitando perturbaciones en el proceso de identificación de colores.

4. Especificaciones de banda transportadora.

Como se detalló en la sección 4.1.5.2, se llevó a cabo la concepción y construcción de una banda transportadora que tuviera en cuenta el flujo de objetos a lo largo de todas las etapas del proceso. Esto permitió observar el funcionamiento del sistema en términos de identificar la naturaleza de los objetos como botellas, detectar la presencia de plástico en dichas botellas y, finalmente, validar su composición de color.

No obstante, es importante señalar que, debido a restricciones presupuestarias y las dimensiones de la caja de detección de plástico, la longitud de la banda transportadora resultó insuficiente para garantizar la captura efectiva de estos tres sistemas de clasificación durante todo el ciclo. Por tanto, se recomienda encarecidamente que la banda transportadora sea extendida a una longitud superior a los 130 centímetros. Esta extensión es esencial para asegurar que los tres sistemas de clasificación tengan la capacidad necesaria para capturar y procesar los objetos que circulan por la banda con precisión y eficacia.

5.2. VALIDACIÓN DE RESULTADOS.

Para la validación de resultados se tienen en cuenta los resultados de la implementación completa de la planta a baja escala, estos se pueden encontrar en el cuadro 8, a continuación, se presentarán porcentajes de acierto y error de cada sistema.

Cuadro 9. Porcentajes de Acierto y Error de Sistemas.

Porcentaje %	Sistema de Selección de Botellas	Sistema de Detección de Plástico	Sistema de Clasificación por Color
Aciertos	98.11%	92.50%	89.19%
Errores	1.89%	7.50%	10.81%

Como se pudo observar, todos los sistemas poseen menos de un 11% de error a la hora de cumplir su función, las razones por las cuales ocurrieron estos errores se pueden apreciar en los siguientes puntos.

- Detección de botellas de vidrio como botellas.

Conforme se ilustra en el cuadro 8, se observa un caso particular en el dato "2", en el cual el sistema clasificó una botella de vidrio como "No Botella". Esta discrepancia se debe a que nuestra base de datos estuvo compuesta exclusivamente por botellas de plástico. Sin embargo, como se explicó en el marco teórico, debido a la similitud en la forma, es plausible que el modelo detecte una botella de vidrio como tal, ya que, en

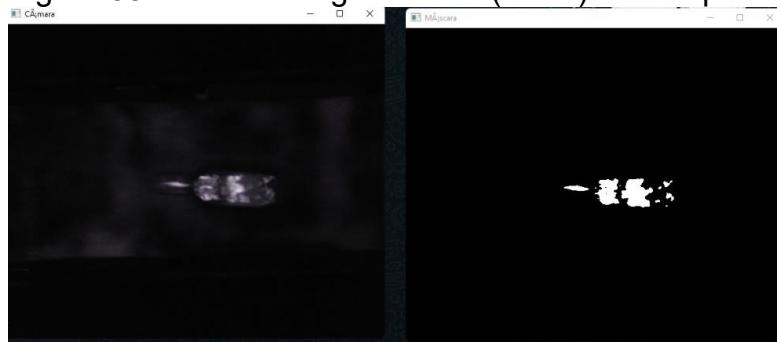
terminos de estructura y forma, lo es. Estos casos, aunque parezcan errores, en realidad pueden considerarse aciertos en un sentido más amplio, ya que sugieren la posibilidad de crear un modelo personalizado de YoloV5x para la clasificación de botellas de plástico y vidrio.

No obstante, es importante subrayar que la solución a este tipo de situaciones y, en última instancia, la eliminación efectiva de las botellas de vidrio del flujo de residuos se logra a través de la etapa de detección de plástico. Esta etapa es fundamental para asegurar que el sistema pueda diferenciar con precisión entre botellas de vidrio y botellas de plástico, cumpliendo así con los objetivos del proyecto.

➤ Detección de plástico por etiqueta.

Durante las pruebas efectuadas en la fase de detección de plástico, se encontró una situación interesante en la que el sistema se enfrentaba a la entrada de botellas de vidrio que, en algunos casos, aún conservaban sus etiquetas de marca. Estas etiquetas estaban hechas de un tipo de plástico que contenía pigmentos reflectantes, lo que ocasionalmente resultaba en la detección errónea de plástico en botellas de vidrio.

Figura 58. Botella de aguardiente (vidrio) con etiqueta.



FUENTE: Elaboración propia.

Como se puede apreciar claramente en la Figura 58, se presenta un ejemplo ilustrativo de los resultados previamente analizados en el cuadro 8. En este caso concreto, se analizan los datos numerados como "3", "4", "5" y "6", y se observa que el sistema no identifica la presencia de plástico en estas botellas cuando carecen de etiquetas. Sin embargo, cuando las mismas botellas cuentan con etiquetas, el sistema sí es capaz de detectar la presencia de plástico en ellas.

Este fenómeno resalta una tendencia interesante en el comportamiento del sistema y sugiere la influencia significativa de las etiquetas en el proceso de detección. Estos resultados subrayan la importancia de considerar todos los elementos visuales en el análisis de los objetos, ya que incluso detalles aparentemente pequeños, como la presencia de etiquetas, pueden tener un impacto crucial en la clasificación precisa de los materiales.

Es crucial destacar, de acuerdo con el marco teórico de este proyecto, que las botellas de vidrio en buen estado generalmente no se encuentran en el flujo de residuos que se está investigando, ya que, en la mayoría de las industrias, estas botellas son retornables

y se gestionan de manera diferente en comparación con otros materiales reciclables. No obstante, es importante reconocer que pueden presentarse casos excepcionales en los que se detecten fragmentos de vidrio en el flujo de residuos. Por esta razón, se tomó la decisión de llevar a cabo diversas pruebas con el fin de ajustar el sistema y hacerlo más resistente ante cualquier situación, garantizando así su capacidad para abordar posibles desafíos, incluso aquellos que involucran la detección de plástico en botellas de vidrio.

- Botellas pequeñas confundidas como botellas sin plástico.

En relación con el dato "25" detallado en el cuadro 8, se observó una situación particular en la que la botella era de dimensiones notablemente reducidas. Esta característica resultó en que no se generara la cantidad de píxeles necesarios para que el sistema pudiera determinar con certeza la presencia de plástico, ya que los valores de reflectancia de esta botella pequeña eran comparables a los de una botella de vidrio. En tales casos, es conveniente considerar la recomendación de emplear instrumentos de mayor resolución y precisión. para mejorar estos casos que como se pueden ver, no son tan notables en un diseño a baja escala.

- Detección de color por etiqueta.

Los datos "38" y "39" del cuadro 8 corresponden a una botella de cloro de color blanco, siendo que una de ellas presenta una etiqueta mientras que la otra no. En este contexto, se observó que, al pasar por el sistema, se detectaba una mayor presencia de color azul en lugar de blanco. Este fenómeno puede ajustarse mediante la calibración de los rangos de colores definidos en el sistema, lo que contribuiría a una mejora en la detección y la jerarquización de los colores en el proceso.

5.3. RECOMENDACIONES DE USO.

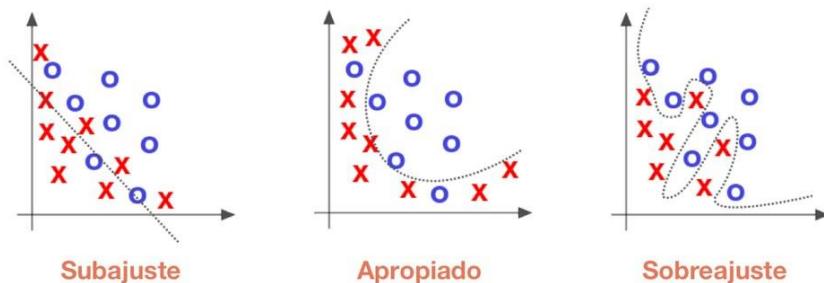
Realizando una colección de los resultados y las observaciones vistas a la hora de estar ejecutando el sistema, se presentan algunas recomendaciones para la ejecución del algoritmo y mejoras si se desea entrenar un modelo personalizado con YoloV5:

- Bases de datos personalizadas.

Al crear la base de datos personalizada se recomienda en su mejor instancia, que se tomen las imágenes de los objetos en el ambiente en donde el sistema va a realizar la clasificación ya que se podría generar el fenómeno de "sobreajuste" que tuvimos en algunos modelos que entrenamos para pruebas. En tales circunstancias, el algoritmo enfrenta dificultades al intentar realizar predicciones precisas con datos que no formaban parte de su conjunto de entrenamiento, lo que compromete su utilidad. La capacidad de generalización de un modelo a datos nuevos es esencial, ya que nos permite emplear con éxito algoritmos de aprendizaje automático para realizar predicciones y clasificar datos en situaciones del día a día⁶⁰.

⁶⁰ IBM. [sitio web]. ¿Qué es el sobreajuste? [Fecha de consulta: 08 de septiembre de 2023]. Disponible en: <https://www.ibm.com/mx-es/topics/overfitting>

Figura 59. Conceptos de ajuste a los modelos de ML.



FUENTE: IBM. [sitio web]. ¿Qué es el sobreajuste? [Fecha de consulta: 08 de septiembre de 2023]. Disponible en: <https://www.ibm.com/mx-es/topics/overfitting>

En la Figura 59 se puede observar el estado en que se puede encontrar el modelo, el objetivo es indicar que nuestro sistema de clasificación pueda enfrentarse a situaciones de validación y de con una respuesta certera, no con una respuesta equivocada y/o que solo sea efectivo con imágenes de entrenamiento. Esto también va de la mano con la determinación del número adecuado de épocas siendo esto un proceso crucial que requiere un enfoque equilibrado y que depende de varios factores como el tamaño de los datos, la complejidad del modelo, los recursos computacionales, entre otros⁶¹. En resumen, es importante realizar ajustes iterativos para determinar un número óptimo de épocas que brinden el mejor rendimiento del caso en específico.

- Entorno cerrado para la planta.

Se aconseja ubicar la planta en un entorno cerrado, donde se minimice la interferencia de fuentes de luz externas que puedan penetrar en la cámara y causar perturbaciones. Una ventaja significativa de esta configuración es que los rangos de colores los espacios de color correspondientes pueden ser adaptados y ajustados en función de la fuente de luz específica utilizada por el sistema.

- Especificaciones de computadora.

Para lograr una ejecución más veloz y eficiente de los sistemas, se recomienda disponer del siguiente conjunto de especificaciones de hardware: un procesador de AMD Ryzen 5 o Intel i5 en adelante, una tarjeta gráfica dedicada de NVIDIA GeForce GTX1650, y una memoria RAM de 8 GB o superior. Es importante destacar que estas especificaciones garantizan un óptimo rendimiento en tiempo real ya que fueron las utilizadas en este montaje. No obstante, si se cuenta con un hardware de menor capacidad, esto no impide el funcionamiento del script, pero podría resultar en tiempos de respuesta prolongados en los sistemas que incorporan modelos de inteligencia artificial.

⁶¹ AprendeIA. [sitio web]. Sobreajuste y subajuste en Machine Learning. [Fecha de consulta: 08 de septiembre 2023]. Disponible en: <https://aprendeia.com/sobreajuste-y-subajuste-en-machine-learning/>

6. CONCLUSIONES

Se demostró un hito significativo al entrenar un modelo de Machine Learning capaz de identificar botellas de manera efectiva, independientemente del entorno en el que se encuentren. Uno de los aspectos más destacados de esta solución es su eficiencia en el consumo de recursos computacionales, lo que la convierte en una herramienta viable y accesible para la clasificación de botellas en comparación con otros materiales reciclables, como el papel, cartón y vidrio. La consecución de este objetivo demuestra el potencial y la aplicabilidad de las tecnologías de aprendizaje automático en el ámbito de la gestión de residuos y el reciclaje. Al superar el desafío de la detección de botellas en diversos entornos, se sienta un precedente importante para optimizar los procesos de reciclaje y contribuir a la sostenibilidad ambiental.

Este logro subraya la importancia de la investigación interdisciplinaria y la colaboración entre la ciencia de datos y la gestión de residuos. Además, abre la puerta a futuras investigaciones y mejoras en esta tecnología, como la implementación de modelos más avanzados y la expansión de la base de datos para abordar una variedad aún mayor de escenarios. En última instancia, este proyecto representa un paso significativo hacia la automatización y mejora de los sistemas de reciclaje, promoviendo un uso más eficiente de los recursos y una gestión más efectiva de los materiales reciclables en beneficio del medio ambiente y la sociedad en general.

El algoritmo de detección de plástico ha generado una perspectiva esclarecedora sobre las capacidades de la visión artificial, combinada con métodos de detección de plástico rigurosamente investigados. Gracias a estas técnicas y aplicaciones, se ha logrado desarrollar un sistema basado en la detección de la componente de iluminación del espacio CIELAB que permite capturar la reflectancia de luz infrarroja característica del plástico, diferenciándolo de otros materiales con composiciones distintas. El algoritmo resultante ofrece un enfoque prometedor para abordar desafíos específicos relacionados con la detección de plástico en aplicaciones que requieren una alta exactitud y fiabilidad.

La utilización de la reflectancia de luz infrarroja como una característica distintiva para la detección de plástico representa una innovación de gran relevancia en la investigación de clasificación de materiales. Este avance no solo influye en la gestión de residuos y el reciclaje, sino que también tiene aplicaciones potenciales en una amplia gama de campos, que abarcan desde la industria manufacturera hasta la inspección de calidad de productos. Además, es importante destacar que este enfoque se basa en procesos de visión artificial, que, en comparación con los modelos de redes neuronales, ofrecen un mejor rendimiento y velocidad de ejecución.

El sistema implementado a pequeña escala en el presente trabajo se distingue por su bajo costo de producción y su alta eficacia en la detección y clasificación de botellas plásticas. Esto se debe a que puede ser desarrollado utilizando cámaras web o teléfonos móviles, siendo la principal inversión la adquisición de una cámara capaz de detectar la luz infrarroja. Sin embargo, el costo de esta cámara no se compara en absoluto con el valor de una cámara hiperespectrales comercial. Además, destaca por su facilidad de manipulación y la capacidad de interpretación de datos que ofrece la etapa de visualización realizada.

En el proceso de implementación de la planta a pequeña escala, se encontraron diversos imprevistos surgidos de la interacción entre los sistemas que la componen. Por lo tanto, se destaca la importancia de llevar a cabo una fase de implementación en un entorno reducido del producto. Esta etapa permite identificar problemáticas que pueden no ser tan evidentes durante el desarrollo algorítmico inicial. De esta manera, se pueden prevenir posibles inconvenientes en la implementación a una mayor escala. Es relevante subrayar que la planta implementada, al no presentar los problemas ya mencionados, se caracteriza por ser un producto robusto y eficiente, tal como lo corroboran los resultados obtenidos en su funcionamiento.

El desarrollo de la clase de registros para los sistemas de la planta se destacó por su eficaz implementación del concepto de registros digitales de desplazamiento. Esto permitió lograr respuestas estables de los sistemas en función de su velocidad de respuesta. Esta característica aseguró que, en caso de una perturbación externa en un solo fotograma, no afectaría la respuesta del sistema, sino que solo se vería afectada si la perturbación se prolongara durante un período de tiempo que excediera la estabilidad del registro. Además, durante el desarrollo del script principal encargado de integrar los tres sistemas diseñados, surgió la idea eficiente de utilizar hilos de programación. Esta elección permitió que los sistemas funcionaran de manera independiente, lo que se asemeja más al comportamiento de una planta, donde cada etapa opera de manera autónoma, contando con entradas y salidas dedicadas para cada sistema.

7. TRABAJO A FUTURO

- El modelo YoloV5x, diseñado para la detección de botellas de plástico, se ha concebido con la finalidad de distinguir con precisión estos objetos de otros materiales en diversos entornos. No obstante, a medida que se plantea su implementación en un contexto industrial a gran escala, se recomienda considerar la mejora de su precisión y confiabilidad mediante la adopción de modelos más actualizados basados en Yolo, siempre y cuando los recursos computacionales estén disponibles. Además, un aspecto de suma importancia, como se mencionó en la sección 6 del análisis, es la creación de una base de datos que contemple los objetos y sus estados físicos que transitarán de manera constante por esta planta industrial. Esta medida se adopta con el propósito de evitar problemas de sobreajuste y detecciones erróneas. En última instancia, estas estrategias contribuirán a asegurar una detección de objetos más precisa y, por lo tanto, hará factible la implementación efectiva de esta tecnología en entornos industriales.
- Para la implementación a gran escala de la planta, se contempla la utilización de un sistema de servomotores o pistones en conjunto con la banda transportadora previamente mencionada. Estos componentes se activarán en función de la información capturada por los sistemas, con el objetivo de lograr un funcionamiento similar al de los carriles de un tren o ferrocarril. De esta manera, se dirigirá el material hacia su respectiva sección de reciclaje. Para llevar a cabo esta operación, se aprovecharán los comandos que transmiten información en formato serial, en donde, en lugar de emitir una señal de alto o bajo para activar un LED, se emplearán dichos comandos para determinar el ángulo posición de un servomotor o el desplazamiento de un pistón.
- Los sistemas al ser desarrollados en Python presentan una alta viabilidad para su implementación en microprocesadores como la NVIDIA Jetson Nano o la Raspberry Pi 4. Esta elección permite evitar la necesidad de mantener la planta conectada a un ordenador desde una sala de control para la ejecución del algoritmo principal. En su lugar, se simplifica el proceso al modificar únicamente las secciones del código relacionadas con la transmisión de información serial, reemplazándolas por el comando que controle las salidas de la tarjeta implementada.

BIBLIOGRAFÍA

TÉLLEZ MALDONADO, Alejandra. La complejidad de la problemática ambiental de los residuos plásticos: una aproximación al análisis narrativo de política pública en Bogotá. [en línea]. Tesis de maestría. Universidad Nacional de Colombia, 2012 [Fecha de consulta: 27 de mayo 2023]. Disponible en: <https://repositorio.unal.edu.co/handle/unal/10015>.

ARTHuz-LÓPEZ, L.; PÉREZ-MORA, W. Alternativas de bajo impacto ambiental para el reciclaje del poliestireno expandido a nivel mundial. [en línea]. Artículo de revisión. Servicio Nacional de Aprendizaje SENA (Colombia), 2019 [Fecha de consulta: 27 de mayo 2023]. Disponible en: https://revistas.sena.edu.co/index.php/inf_tec/article/view/1638. ISSN: 2256-5035.

Proceso de reciclaje [sitio web]. Guadalajara: Aseca. [Fecha de consulta: 28 de mayo 2023]. Disponible en: <https://aseca.com/proceso-de-reciclaje>.

Los riesgos de la gestión de residuos – Protección laboral [sitio web]. Interempresas. [Fecha de consulta: 28 de mayo 2023]. Disponible en: <https://www.interempresas.net/Proteccion-laboral/Articulos/213083-Los-riesgos-de-la-gestion-de-residuos.html>.

CHAMÁN, Antonio Benjamín Say. Manejo de la basura y su clasificación. [En línea]. Artículo publicado en 2019, Gutamela. [Fecha de consulta: 26 de junio 2023]. Disponible en: biblioteca.usac.edu.gt.

García, Eliana Susana. Los residuos potencialmente reciclables y la elaboración de nuevos productos a través del reciclaje [En línea]. Trabajo de tesis, publicado el 09 de octubre de 2014. [Fecha de consulta: 27 de agosto 2023]. Disponible en: <https://ri.unlu.edu.ar/xmlui/handle/rediunlu/1218>.

VEOLIA. [sitio Web]. España: Gestión de Residuos. [Fecha de consulta: 02 de mayo 2023]. Disponible en: <https://www.veolia.com/latamib/es/soluciones/gestion-residuos>.

LUNA BUSTAMENTE, Genesis Janeth y VASCONEZ CAMINO, Kleyner Ariel. DESARROLLO DE UNA RED NEURONAL CONVOLUCIONAL PARA LA CLASIFICACIÓN DE BOTELLAS... [En línea]. Trabajo de grado. Universidad Estatal de Milagro, Febrero 2020. [Fecha de consulta: 26 de agosto 2023]. Disponible en: <https://repositorio.unemi.edu.ec/handle/123456789/5130>

ELIAS, Xavier y JURADO, Lorena. LOS PLASTICOS RESIDUALES Y SUS POSIBILIDADES DE VALORIZACIÓN. Madrid: Ediciones Díaz de Santos, 2012. ISBN 978-84-9969-371-2.

SERRANTI, Silvia y BONIFAZI, Giusuppe. Techniques for separation of plastic wastes. [En linea]. Department of Chemical Engineering, Materials & Environment, Sapienza University of

Rome, Rome, Italy. [Fecha de consulta: 7 de marzo 2023]. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/B9780081026762000025>.

BURBANO YULE, Hernán Camilo. Fusión de imágenes hiperespectrales y visibles para la clasificación de residuos plásticos. [En línea]. Tesis de grado. Publicado en PONTIFICIA UNIVERSIDAD JAVERIANA, 2013. [Fecha de consulta: 4 de noviembre 2022]. Disponible en: <https://repository.javeriana.edu.co/handle/10554/13600>.

MASOUMI, HAMED & SAFAVI, SEYED MOHSEN & KHANI, Z.. Identification and classification of plastic resins using near infrared reflectance spectroscopy. [en línea]. Artículo. International Journal of Mechanical and Industrial Engineering. 6. p. 213-220, 2012 [Fecha de consulta: 23 de agosto 2023]. Disponible en: https://www.researchgate.net/publication/285330830_Identification_and_classification_of_plastic_resins_using_near_infrared_reflectance_spectroscopy.

ALOMAR, Daniel, y FUCHSLOCHER, Rita. FUNDAMENTOS DE LA ESPECTROSCOPIA DE REFLECTANCIA EN EL INFRAROJO CERCANO (NIRS) COMO MÉTODO DE ANÁLISIS DE FORRAJES. [En línea]. Publicado en Universidad Austral de Chile. [Fecha de consulta: 31 de agosto 2023]. Disponible en: <http://146.83.217.169/index.php/agrosur/article/view/3840>.

TXS. [sitio web]. ¿Por qué las botellas transparentes son más amigables con el medio ambiente que las de color? Publicado el 20 septiembre de 2021. [Fecha de consulta: 26 de agosto 2023] Disponible en: <https://txsplus.com/2021/09/por-que-las-botellas-transparentes-son-mas-amigables-con-el-medio-ambiente-que-las-de-color/>.

Rosaenvases. [Sitio Web]. Envases HDPE: material, utilidades y ventajas de su uso. España: Subido 13 agosto 2020. [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://rosaenvases.com/blog/envases-plastico>.

Bluradio. [sitio web]. Envase de la Pony Malta es reciclado para usarse en la construcción y en el agro. Colombia: 29 abril 2016. [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://www.bluradio.com/medio-ambiente/envase-de-la-pony-malta-es-reciclado-para-usarse-en-la-construccion-y-en-el-agro>.

Elempaque. [sitio web]. Coca Cola anuncia que eliminará el PET verde de sus productos en América del Norte. 29 julio 2022. [Fecha de consulta: 26 de junio 2023]. Disponible en: <https://www.elempaque.com/es/noticias/coca-cola-anuncia-que-eliminara-el-pet-verde-de-sus-productos-en-america-del-norte>.

Heaton, Jeff. Artificial Intelligence for Humans, Volume 1: FundamentalAlgorithms. [En línea]. Artículo publicado por Heaton Research, Inc. St. Louis, MO, USA, fecha: noviembre 26, 2013. [Fecha de consulta: 26 de junio 2023]. Disponible en: www.heatonresearch.com.

ROJAS, Esperanza Manrique. Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. [En línea]. Artículo de investigación. Publicado en Revista Ibérica de Sistemas y Tecnologías de la información, 06 febrero 2020 [Fecha de

consulta: 26 de junio 2023]. Disponible en: <https://www.proquest.com/openview/c7e24c997199215aa26a39107dd2fe98/1?pq-origsite=gscholar&cbl=1006393>.

IBM. [sitio web]. ¿Qué es el aprendizaje supervisado? [Fecha de consulta: 16 de julio 2023]. Disponible en: <https://www.ibm.com/mx-es/topics/supervised-learning>.

OLABE, Xabier Basogain. Redes neuronales artificiales y sus aplicaciones. Publicaciones de la Escuela de Ingenieros de Bilbao, 1998. [Fecha de consulta: 29 de agosto 2023].

GENESIS, Luna y KLEYNER, Vasconez. DESARROLLO DE UNA RED NEURONAL CONVOLUCIONAL PARA LA CLASIFICACIÓN DE BOTELLAS... Ecuador, febrero 2020. [Fecha de consulta: 26 agosto 2023]. Disponible en: <https://repositorio.unemi.edu.ec/handle/123456789/5130>. pp. 23.

MicrosoftLearn. [sitio web]. ¿Cómo aprenden las redes neuronales? [Fecha de consulta: 31 de agosto 2023]. Disponible en: <https://learn.microsoft.com/es-es/archive/msdn-magazine/2019/april/artificially-intelligent-how-do-neural-networks-learn>.

IBM. [sitio web]. ¿Qué son las redes neuronales convolucionales? [Fecha de consulta: 31 de agosto 2023]. Disponible en: <https://www.ibm.com/es-es/topics/convolutional-neural-networks>.

PEINADO GARCÍA, Raúl, et al. Estudio de la calidad en las detecciones de la red YOLOv5 con transformación de imágenes. Proyecto de grado. Publicado en universidad de Málaga, 2022. [Fecha de consulta: 01 de septiembre 2023]. Disponible en: <https://riuma.uma.es/xmlui/handle/10630/26026>.

Incentro. [sitio web]. ¿Qué es TensorFlow y para qué sirve? [Fecha de consulta: 01 de septiembre 2023]. Disponible en: <https://www.incentro.com/es-ES/blog/que-es-tensorflow>.

DataScientest. [sitio web]. Keras: todo sobre la API de Deep Learning. [Fecha de consulta: 01 de septiembre 2023] Disponible en: <https://datascientest.com/es/keras-la-api-de-deep-learning>.

COCODataSet. [sitio web]. COCO common objects in Context. [Fecha de consulta: 01 de septiembre 2023]. Disponible en: <https://cocodataset.org/#home>.

How Computer Vision Has Evolved and Its Role in Waste Sorting [sitio web]. Recycleye. [Fecha de consulta: 26 de agosto 2023]. Disponible en: <https://recycleye.com/how-computer-vision-has-evolved-and-its-role-in-waste-sorting/>.

OpenCV [sitio web]. [Fecha de consulta: 28 de agosto 2023]. Disponible en: <https://opencv.org/>.

Python [sitio web]. [Fecha de consulta: 28 de agosto 2023]. Disponible en: <https://python.org/>.

NumPy [sitio web]. [Fecha de consulta: 28 de agosto 2023]. Disponible en: <https://numpy.org/>.

An Intro to Threading in Python [sitio web]. Real Python. [Fecha de Consulta: 30 de agosto 2023]. Disponible en: <https://realpython.com/intro-to-python-threading/#what-is-a-thread>

What Is the Python Global Interpreter Lock (GIL)? [sitio web]. Real Python. [Fecha de consulta: 30 de agosto 2023]. Disponible en: <https://realpython.com/python-gil/>.

HSV Color Model in Computer Graphics [sitio web]. GeeksforGeeks. [Fecha de consulta: 1 de septiembre 2023]. Disponible en: <https://www.geeksforgeeks.org/hsv-color-model-in-computer-graphics/>

RGB colour model [sitio web]. Britannica. [Fecha de consulta: 16 de octubre 2023]. Disponible en: <https://www.britannica.com/science/RGB-colour-model>

PySerial [sitio web]. [Fecha de consulta: 1 de septiembre 2023]. Disponible en: <https://pythonhosted.org/pyserial/pyserial.html>.

Arduino [sitio web]. [Fecha de consulta: 2 de septiembre de 2023]. Disponible en: <https://www.arduino.cc/>

Kicad [sitio web]. [Fecha de consulta: 2 de septiembre de 2023]. Disponible en: <https://www.kicad.org/>.

GrabCad [sitio web]. [Fecha de consulta: 4 de julio 2023]. Disponible en: <https://grabcad.com/>.

Tutorial: Running YOLOv5 Machine Learning Detection on a Raspberry Pi 4 [sitio web]. Jordan Johnston | Medium. [Fecha de consulta: 8 de septiembre 2023]. Disponible en: <https://jordan-johnston271.medium.com/tutorial-running-yolov5-machine-learning-detection-on-a-raspberry-pi-4-3938add0f719>.

EAL TIME INFERENCE ON RASPBERRY PI 4 (30 FPS!) [sitio web]. PyTorch Tutorials. [Fecha de consulta: 9 de septiembre 2023]. Disponible en: https://pytorch.org/tutorials/intermediate/realtime_rpi.html#real-time-inference-on-raspberry-pi-4-30-fps.

IBM. [sitio web]. ¿Qué es el sobreajuste? [Fecha de consulta: 08 de septiembre de 2023]. Disponible en: <https://www.ibm.com/mx-es/topics/overfitting>.

AprendeIA. [sitio web]. Sobreajuste y subajuste en Machine Learning. [Fecha de consulta: 8 de septiembre 2023]. Disponible en: <https://aprendeia.com/sobreajuste-y-subajuste-en-machine-learning/>.

ANEXOS

Anexo 1. Tutorial de uso para YoloV5

Se presenta el cuaderno proporcionado por YoloV5 de Ultralytics, el cual contiene ejemplos sencillos de entrenamiento, validación y predicción para ayudar a promover el interés y conocimiento de esta herramienta de inteligencia artificial, se puede acceder a este Colab a través del siguiente [link](#).

Anexo 2. Documentación Técnica de Códigos Realizados

Para la documentación técnica de la planta detectora y clasificadora de plástico, se hizo uso de la plataforma de alojamiento de código para el control de versiones y colaboración, GitHub, en donde fue creado el repositorio oficial del proyecto, el cual puede ser encontrado a través del siguiente [link](#).

Dentro del repositorio se encuentran carpetas con las siguientes características:

1. main: En esta carpeta se alojan los scripts finales utilizados en la implementación de este proyecto.
2. Pruebas: En esta carpeta podemos encontrar códigos utilizados para realizar pruebas, realizar el aumento de imágenes para la red neuronal y obtener los rangos de colores necesarios para detección y clasificación de plástico.
3. ArduinoTesis: En esta carpeta se encuentra el código desarrollado para Arduino UNO.

Dentro del README.md del repositorio se encontrarán las especificaciones y descripción principal para cada código subido al repositorio, junto a esto habrá unas anotaciones para la ejecución de estos en caso de necesitarlo.