



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE INFORMÁTICA Y ELECTRÓNICA
CARRERA ELECTRÓNICA Y AUTOMATIZACIÓN

**“IMPLEMENTACIÓN DE UN SISTEMA PROTOTIPO PARA LA
DETECCIÓN Y RECOLECCIÓN DE BOTELLAS PET
UTILIZANDO VISIÓN ARTIFICIAL BASADA EN REDES
NEURONALES”**

Trabajo de titulación

Tipo: Dispositivo tecnológico

Presentado para optar al grado académico de:

INGENIERO EN ELECTRÓNICA Y AUTOMATIZACIÓN

AUTOR:

ALEX EDUARDO NÚÑEZ NÚÑEZ

Riobamba – Ecuador

2022



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE INFORMÁTICA Y ELECTRÓNICA
CARRERA ELECTRÓNICA Y AUTOMATIZACIÓN

**“IMPLEMENTACIÓN DE UN SISTEMA PROTOTIPO PARA LA
DETECCIÓN Y RECOLECCIÓN DE BOTELLAS PET
UTILIZANDO VISIÓN ARTIFICIAL BASADA EN REDES
NEURONALES”**

Trabajo de titulación

Tipo: Dispositivo tecnológico

Presentado para optar al grado académico de:

INGENIERO EN ELECTRÓNICA Y AUTOMATIZACIÓN

AUTOR:

ALEX EDUARDO NÚÑEZ NÚÑEZ

DIRECTOR: ING. PABLO EDUARDO LOZADA YÁNEZ M.Sc.

Riobamba – Ecuador

2022

© 2022, Alex Eduardo Núñez Núñez

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento, siempre y cuando se reconozca el Derecho de Autor.

Yo, Alex Eduardo Núñez Núñez, declaro que el presente trabajo de titulación es de mi autoría y los resultados de este son auténticos. Los textos en el documento que provienen de otras fuentes están debidamente citados y referenciados.

Como autor asumo la responsabilidad legal y académica de los contenidos de este trabajo de titulación; El patrimonio intelectual pertenece a la Escuela Superior Politécnica de Chimborazo.

Riobamba, 20 de enero de 2022

A handwritten signature in black ink, appearing to read 'Alex Núñez', is centered on a light gray rectangular background.

Alex Eduardo Núñez Núñez

180424834-0

ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE INFORMÁTICA Y ELECTRÓNICA
CARRERA ELECTRÓNICA Y AUTOMATIZACIÓN

El Tribunal del Trabajo de Titulación certifica que: El trabajo de titulación; tipo: Dispositivo tecnológico, **“IMPLEMENTACIÓN DE UN SISTEMA PROTOTIPO PARA LA DETECCIÓN Y RECOLECCIÓN DE BOTELLAS PET UTILIZANDO VISIÓN ARTIFICIAL BASADA EN REDES NEURONALES”**, realizado por el señor **ALEX EDUARDO NÚÑEZ NÚÑEZ**, ha sido minuciosamente revisado por los Miembros del Tribunal del Trabajo de Titulación, el mismo que cumple con los requisitos científicos, técnicos, legales, en tal virtud el Tribunal Autoriza su presentación.

	FIRMA	FECHA
Ing. Jorge Luis Paucar Samaniego PRESIDENTE DEL TRIBUNAL	_____	2022-02-03
Ing. Pablo Eduardo Lozada Yáñez M.Sc. DIRECTOR DE TRABAJO DE TITULACIÓN	_____	2022-02-03
Ing. José Luis Tinajero León MIEMBRO DEL TRIBUNAL	_____	2022-02-03

DEDICATORIA

Dedico este trabajo Dios por ser mi guía, bendecirme y darme fuerzas para continuar con mis metas trazadas sin desfallecer; a mis padres Freddy y Lucía, quienes son mi motivación, ejemplo y siempre supieron guiarme con sus sabios consejos durante esta trayectoria; a mis hermanos Steven y Yadira por haberme apoyado a lo largo de toda mi carrera universitaria y a mis abuelitas y tíos, que me extendieron su mano cuando fue necesario.

Alex

AGRADECIMIENTO

A mi padre Freddy por si mi ejemplo de lucha y perseverancia, a mi madre Lucía por su comprensión y saber siempre cobijarme con su cariño y amor. A cada uno de mis profesores y tutores por estar siempre abiertos a compartir los conocimientos necesarios para obtener esta profesión. A mis compañeros con quienes compartimos la misma meta y fueron los acompañantes y testigos en carne propia de este largo y difícil camino.

Alex

TABLA DE CONTENIDO

ÍNDICE DE TABLAS.....	x
ÍNDICE DE FIGURAS.....	xi
ÍNDICE DE GRÁFICOS.....	xiii
ÍNDICE DE ANEXOS.....	xiv
ÍNDICE DE ABREVIATURAS.....	xv
RESUMEN.....	xvi
SUMMARY	xvii
INTRODUCCIÓN	1
CAPÍTULO I	
1. MARCO TEÓRICO REFERENCIAL.....	6
1.1 Inteligencia artificial (IA).....	6
<i>1.1.1 Inteligencia Artificial aplicada a la Visión Artificial</i>	<i>6</i>
<i>1.1.2 Redes neuronales convolucionales (CNN)</i>	<i>7</i>
1.2 Basura y medio ambiente.....	8
<i>1.2.1 Material Polietilentereftalato (PET)</i>	<i>8</i>
1.3 Sistemas tecnológicos de tratamiento de desechos.....	9
<i>1.3.1 Sistemas de detección de desechos</i>	<i>9</i>
<i>1.3.2 Sistemas de detección por visión artificial basada en redes neuronales convolucionales.....</i>	<i>10</i>
<i>1.3.2.1 R-CNN</i>	<i>10</i>
<i>1.3.2.2 R-CNN rápido.....</i>	<i>11</i>
<i>1.3.2.3 R-CNN más rápido</i>	<i>11</i>
<i>1.3.2.4 YOLO.....</i>	<i>13</i>
<i>1.3.3 Sistemas de recolección de desechos.....</i>	<i>13</i>
<i>1.3.3.1 Recolección asistida</i>	<i>13</i>
<i>1.3.3.2 Recolección autónoma.....</i>	<i>14</i>
1.4 Hardware.....	14

1.4.1	<i>Ordenadores de placa reducida</i>	14
1.4.2	<i>Cámaras</i>	15

CAPÍTULO II

2.	PROPUESTA Y DISEÑO DEL PROTOTIPO	16
2.1	Requerimientos del sistema	16
2.2	Consolidación general de detección y recolección	17
2.2.1	<i>Módulo de procesamiento</i>	17
2.2.2	<i>Módulo de recolección</i>	17
2.3	Arquitectura del software del prototipo	18
2.3.1	<i>Herramientas software</i>	18
2.3.1.1	<i>Matlab</i>	18
2.3.1.2	<i>Raspbian Jessie</i>	19
2.3.2	Entrenamiento	19
2.3.2.1	<i>Toma de imágenes</i>	20
2.3.2.2	<i>Etiquetado y regiones de interés</i>	20
2.3.2.3	<i>División del set</i>	21
2.3.2.4	<i>Aumento de datos</i>	21
2.3.3	Entrenamiento YOLO v2	22
2.3.3.1	<i>Afinación de la red</i>	23
2.3.4	Entrenamiento en YOLO v3	23
2.3.4.1	<i>Afinación de la red</i>	24
2.3.5	Conexión ordenador-microordenador	25
2.4	Descripción del hardware del sistema	26
2.4.1	<i>Cámara infrarroja SHU 516G1</i>	26
2.4.2	<i>Motor reductor</i>	27
2.4.3	<i>Driver L298N</i>	27
2.4.4	<i>Módulo de relé 5V</i>	28
2.4.5	<i>Batería Li-Po Turnigy 3S 11V</i>	29
2.4.6	<i>Módulo de batería de Raspberry</i>	29

2.4.7	<i>Punto de acceso</i>	30
2.4.8	<i>Computador</i>	30
2.5	Construcción del módulo recolector	31
2.5.1	<i>Diseño electrónico</i>	31
2.5.2	<i>Diseño mecánico</i>	32
2.5.2.1	<i>Diseño del chasis del módulo recolector</i>	32
2.5.2.2	<i>Diseño de escobillas, brazos de escobillas y soportes de cámara</i>	34
2.5.2.3	<i>Implementación del módulo recolector</i>	35
2.5.3	Programación	36
2.5.3.1	<i>Diagrama de flujo de inicialización del sistema</i>	36
2.5.3.2	<i>Diagrama de flujo detección y recolección</i>	37
2.5.4	<i>Diseño de la interfaz gráfica</i>	38

CAPÍTULO III

3.	VALIDACIÓN DEL PROTOTIPO	40
3.1	Tiempo de retardo por procesamiento	40
3.2	Retardo por conexión inalámbrica	41
3.3	Pruebas de detección	43
3.4	Pruebas de recolección	44
3.5	Consumo de corriente del prototipo	45

CAPÍTULO IV

4.	EVALUACIÓN ECONÓMICA	47
4.1	Análisis de costos	47
4.2	Relación de costo	47

	CONCLUSIONES	49
--	---------------------------	----

	RECOMENDACIONES	50
--	------------------------------	----

BIBLIOGRAFÍA

ANEXOS

ÍNDICE DE TABLAS

Tabla 1-1:	Comparativa entre ordenadores de placa reducida comunes en el mercado.....	15
Tabla 1-2:	Parámetros de YOLO v2	22
Tabla 2-2:	Datos del entrenamiento YOLO v2.....	22
Tabla 3-2:	Parámetros e hiper parámetros de YOLO v3.....	24
Tabla 3-2:	Datos del entrenamiento YOLO v3.....	24
Tabla 5-2:	Características principales del módulo de cámara.....	27
Tabla 6-2:	Características principales del motor reductor de plástico de doble eje	27
Tabla 7-2:	Características principales del módulo L298N.....	28
Tabla 8-2:	Características principales del módulo relé 5V	28
Tabla 9-2:	Características técnicas principales Batería Li-Po Turnigy 3S 11V.....	29
Tabla 10-2:	Características técnicas principales del módulo de batería para Raspberry Pi ...	30
Tabla 11-2:	Características técnicas principales del punto de acceso	30
Tabla 12-2:	Características técnicas principales del computador	31
Tabla 1-3:	Pruebas de retardo por procesamiento con las redes entrenadas	40
Tabla 2-3:	Pruebas de retardo por conexión inalámbrica entre módulo de procesamiento y módulo de recolección.....	42
Tabla 3-3:	Pruebas de detección con YOLO v2.....	44
Tabla 4-3:	Pruebas de recolección del prototipo.....	45
Tabla 5-3:	Consumo de corriente por componente	46
Tabla 1-4:	Costos de componentes del prototipo.....	47

ÍNDICE DE FIGURAS

Figura 1-1:	Etapas de la Visión Artificial	6
Figura 2-1:	Estructura básica de una red neuronal convolucional	7
Figura 3-1:	Algoritmo de búsqueda selectiva	10
Figura 4-1:	Arquitectura del algoritmo R-CNN rápido	11
Figura 5-1:	Funcionamiento del algoritmo R-CNN más rápido	12
Figura 6-1:	Comparación de tiempo de entrenamiento entre algoritmos de detección.....	12
Figura 7-1:	Comparación de tiempos de respuesta entre algoritmos de detección	12
Figura 8-1:	Funcionamiento algoritmo YOLO	13
Figura 9-1:	Robot recolector autónomo Volvo	14
Figura 1-2:	Esquema de módulos del sistema.....	17
Figura 2-2:	Esquema de bloques del módulo recolector.....	18
Figura 3-2:	Diagrama de bloques de la fase de entrenamiento	20
Figura 4-2:	Set de datos	20
Figura 5-2:	Etiquetado de la región de interés	21
Figura 6-2:	Precisión de la red afinada con YOLO v2	23
Figura 7-2:	Precisión de la red afinada con YOLO v3	24
Figura 8-2:	Esquema de conexión inalámbrica.....	25
Figura 9-2:	Ventana de confirmación de conexión.....	25
Figura 10-2:	Obtención de imagen en Matlab desde Raspberry Pi.....	26
Figura 11-2:	Módulo de cámara infrarroja	26

Figura 12-2:	Motor reductor	27
Figura 13-2:	Driver L298N.....	28
Figura 14-2:	Módulo relé 5V	28
Figura 15-2:	Batería Li-Po 3S 11V.....	29
Figura 16-2:	Módulo de batería para Raspberry Pi.....	29
Figura 17-2:	Punto de acceso.....	30
Figura 18-2:	Computador.....	31
Figura 19-2:	Diagrama de fase de construcción	31
Figura 20-2:	Descripción de las conexiones electrónicas de los componentes del circuito... 32	
Figura 21-2:	Toma de medidas de las botellas a ser recolectadas	33
Figura 22-2:	Diseño del chasis del prototipo	33
Figura 23-2:	Construcción del chasis del prototipo	34
Figura 24-2:	Diseño de brazos para escobillas y soporte para cámara	34
Figura 25-2:	Escobillas elaboradas a base de materiales reciclados.....	35
Figura 26-2:	Ensamblaje de las piezas del chasis del prototipo.....	35
Figura 27-2:	Implementación del módulo recolector.....	36
Figura 28-2:	Interfaz gráfica del prototipo.....	39
Figura 1-3:	Prueba de conexión inalámbrica	41
Figura 2-3:	Prueba de detección en ambiente nocturno.....	43
Figura 3-3:	Prototipo en pruebas de recolección	44

ÍNDICE DE GRÁFICOS

Gráfico 1-2:	Diagrama de flujo de la inicialización del sistema	37
Gráfico 2-2:	Diagrama de flujo de la captura de imagen, detección y recolección	38
Gráfico 1-3:	Comparación de retardo por procesamiento entre YOLO v2 y YOLO v3.....	41
Gráfico 2-3:	Retardo por conexión inalámbrica.....	42
Gráfico 3-3:	Precisión de sistema de recolección	45

ÍNDICE DE ANEXOS

- ANEXO A:** DATOS TÉCNICOS DE RASPBERRY PI 4B
- ANEXO B:** DATOS TÉCNICOS CÁMARA PI NOIR CAMERA V2
- ANEXO C:** ESQUEMA DE CONEXIÓN MÓDULO L298N
- ANEXO D:** PROGRAMACIÓN DEL PROTOTIPO
- ANEXO E:** ACOTACIÓN DE LA ESTRUCTURA DEL CHASIS

ÍNDICE DE ABREVIATURAS

CNN:	Redes Neuronales Convolucionales
DL:	Aprendizaje Profundo
GPIO:	Entrada/Salida de Propósito General
IA:	Inteligencia Artificial
LED:	Diodo Emisor de Luz
PET:	Polietilentereftalato
RAM:	Memoria de Acceso Aleatorio
RCNN:	Región con características de Redes Neuronales Convolucionales
RPI:	Raspberry Pi
USB:	Bus Universal en Serie
YOLO:	You Only Look Once

RESUMEN

El presente trabajo tuvo como objetivo implementar un dispositivo móvil, capaz de detectar y recolectar botellas de tereftalato de polietileno (PET), usando visión artificial basada en redes neuronales. Este sistema consta de dos módulos conectados de manera inalámbrica mediante red WIFI. Un módulo denominado módulo de recolección es el encargado de la adquisición de imágenes y de la ejecución de movimientos del sistema móvil y el otro módulo denominado módulo de procesamiento es el encargado tanto del tratamiento de imágenes a través de la red neuronal como del control del módulo de recolección. El módulo de recolección se fabricó en base al diseño en 3D de su chasis y la conexión electrónica de los dispositivos correspondientes a este módulo, mientras que el módulo de procesamiento está conformado únicamente por un computador personal. En las pruebas se pudo evidenciar que la red neuronal de detección no presenta fallos pudiendo ser ejecutada incluso en ambientes nocturnos sin iluminación, además que su tiempo de retardo es de tan solo 0,019 milisegundos. Ambos módulos pueden establecer una conexión inalámbrica estable que fácilmente supera los 15 metros de distancia con una latencia promedio de 13 milisegundos. Por otro lado, el sistema de recolección no está exento de fallas, no obstante, con un 96,7% de precisión es altamente confiable. Con esto se concluye que el sistema es capaz de detectar y recolectar botellas PET, constituyéndolo así en un prototipo capaz de contribuir con la solución de problemas correspondientes al reciclaje. Se recomienda realizar estudios de posicionamiento global y eficiencia energética para la autonomización completa del dispositivo, así como también es recomendable mejorar el sistema de recolección del dispositivo.

Palabras clave: <BOTELLA DE TEREFTALATO DE POLIETILENO (PET)> <RECICLAJE> <DISPOSITIVO MÓVIL> <RED NEURONAL><VISIÓN ARTIFICIAL>.



Firmado electrónicamente por:
HOLGER GERMAN
RAMOS UVIDIA

0074-DBRA-UPT-2022

2022-01-19

SUMMARY

The present graduate research project implemented a mobile device capable of detecting and collecting polyethylene terephthalate (PET) bottles using artificial vision based on neural networks. This system consists of two modules connected wirelessly via a network WIFI. A module called the collection module is responsible for the acquisition of images and the execution of movements of the mobile system, and the other module called the processing module is in charge of both the processing of images through the network neural and the control of the collecting module. The collection module was manufactured based on the 3D design of its chassis and the electronic connection of the corresponding devices to this module, while the processing module is made up only of a personal computer. In the tests, it was possible to show that the neural detection network does not present faults and can be executed even in night environments without lighting, in addition, that its delay time is only 0.019 milliseconds. Both modules can set a stable wireless connection that easily exceeds 15 meters distance with an average latency of 13 milliseconds. On the other hand, the collection system is not exempt from failures; however, with 96.7% accuracy, it is highly reliable. It is concluded that the system can detect and collect PET bottles, constituting a prototype cable to contribute to the solution of problems related to recycling. It is recommended to carry out global positioning and energy efficiency studies for complete autonomy of the device, as well as it is recommended to improve the collection system of the device.

Keywords: <POLYETHYLENE TEREPHTHALATE (PET) BOTTLE> <RECYCLING>
<MOBILE DEVICE> <NEURAL NETWORK> <ARTIFICIAL VISION>.



INTRODUCCIÓN

La visión por computadora es una de las ciencias que ha evolucionado de manera relativamente acelerada desde su aparición, no obstante, fue debido a su conjunción con la inteligencia artificial a través de las redes neuronales convolucionales (CNN, por sus siglas en inglés), que este desarrollo se volvió exponencial. Gracias a las bondades de la inteligencia artificial, esta ciencia se acerca cada vez más a su objetivo más grande que es emular el funcionamiento de los receptores visuales humanos; esto no quiere decir que otros métodos clásicos de visión artificial no permitan de cierto modo imitar el funcionamiento del ojo humano, pero si, los métodos basados en inteligencia artificial se acercan mucho más a su funcionamiento real.

La adaptabilidad de esta tecnología ha desarrollado una expansión tal, que la visión por ordenador puede ser aplicada prácticamente al campo al que se le ocurra al usuario o autor sin ningún tipo de excepción. El reconocimiento de personas o rostros humanos junto con la detección de caracteres y de objetos para la conducción autónoma son los campos más explotados en la actualidad por los desarrolladores la visión artificial, no obstante, la industria, medicina y biología están expandiendo los horizontes de la visión artificial. Los problemas ecológicos no son ajenos a las posibles aplicaciones de la visión por ordenador, pues, de a poco aparecen trabajos que fusionan la visión artificial con la solución a los problemas ambientales.

El entrenamiento de una red capaz de detectar envases reciclables PET puede presentar muchos retos, que van desde la toma de cientos o miles de muestras fotográficas para el entrenamiento, el tratamiento de estas muestras una por una y el entrenamiento en sí que puede tomar entre horas y días para su consolidación, por lo mismo se hace uso de un algoritmo y equipo capaz de reducir sobre todo el tiempo de entrenamiento.

La recolección de una botella plástica o simplemente su colocación en contenedor luego de su uso puede ser una tarea fácil para un ser humano, sin embargo, déficits en el comportamiento humano han colaborado para que enormes cantidades de este tipo de desechos, que no fueron tratados correctamente, estén afectando a los demás seres vivos. Es por esto que nace la idea de crear un sistema móvil capaz de recolectar estos desechos, que además permita crear conciencia en la sociedad por medio del ejemplo. Este sistema móvil es por el momento un prototipo, pero puede ser sujeto o varias mejoras a futuro como la afinación de la red de detección, el mejoramiento de su gestión energética pudiendo incluso llegar a usar la energía solar, reducir tiempos de comunicación entre el robot y el procesador central y hasta ampliar su rango de detección permitiéndole así, no detectar solo botellas PET, si no también otro tipo de desechos reciclables.

ANTECEDENTES

La inteligencia artificial (IA) ha tenido un impacto enorme en los últimos años, tal es así que sus aplicaciones se están extendiendo a límites que parecen no encontrar fronteras; y su desarrollo no deja de impresionar, a tal punto que hoy se puede hablar de términos tales como redes neuronales, aprendizaje automático y aprendizaje profundo (VÁZQUEZ, y otros, 2018).

Las redes neuronales son el avance de la inteligencia artificial que permitió el desarrollo del aprendizaje automático y profundo, el mismo que se está convirtiendo en la tecnología emergente de mayor relevancia para aplicaciones y sistemas de visión por computadora. El beneficio más importante de las redes neuronales es un alto rendimiento con una gran escala de datos, ya que hoy la mayoría de las aplicaciones y no solo de visión artificial generan una gran cantidad de datos para el procesamiento. Otro beneficio es que puede extraer nuevas funciones automáticamente para diferentes problemas (LI, 2018). Al procesar información multimedia, el rendimiento del aprendizaje automático tradicional depende de la precisión de las características identificadas y extraídas. Dado que puede aprender con precisión características de alto nivel como rostros humanos en imágenes y palabras de lenguaje en voces, se puede mejorar la eficiencia del procesamiento de información multimedia, para así requerir de mucho menos tiempo para inferir información (LI, 2018).

Las redes neuronales tienen su evolución más grande en las redes neuronales convolucionales (CNN) y una de las tantas ramas en las que éstas han colaborado de manera fundamental para su desarrollo, es la visión artificial a través de aprendizaje profundo o Deep Learning (DL), permitiendo desarrollar aplicaciones que van desde la detección de personas hasta la toma de decisiones para conducción automática de vehículos; con el paso del tiempo; los detectores en cascada que revolucionaron tanto este mundo hace unas cuantas décadas empezaron a experimentar grandes problemas debido a sus evidentes limitaciones. Con la llegada de las redes neuronales artificiales convolucionales o (RCN, por sus siglas en inglés) (CAI, 2019), la visión artificial parecía ver una brillante luz en el horizonte de la detección de objetos pero su coste computacional se convirtió en una de sus grandes pesadillas debido a que redes como la Región-CNN (R-CNN) requería de miles de evaluaciones de una sola imagen para obtener una predicción y otras redes como el R-CNN rápido requería de 100 evaluaciones, esto hacía que además del tiempo que consumía cada evaluación las demandas de memoria y procesamiento sean inconmensurables (REDMON, 2016b).

Las redes neuronales convolucionales en la actualidad son flexibles a problemas en cualquier campo en el que les quiera aplicar, y esto no excluye a los problemas ecológicos que atraviesa nuestro planeta. La acumulación exponencial de materiales plásticos en calles, parques, playas y

otros lugares públicos representan un grave problema para las futuras generaciones, es por esto por lo que, las soluciones deben empezar a gestarse y que mejor que con ayuda de las bondades de la inteligencia artificial mediante un sistema que sea capaz de reconocer y recolectar botellas de politereftalato de etileno (PET) para su posterior reciclaje.

FORMULACIÓN DEL PROBLEMA

¿Cómo implementar un sistema prototipo para la detección y recolección de botellas PET utilizando visión artificial basada en redes neuronales?

SISTEMATIZACIÓN DEL PROBLEMA

- ¿Cuáles son los requerimientos mínimos de diseño y operación que debe cumplir el prototipo a implementar?
- ¿Cuál algoritmo de visión artificial basada en redes neuronales es el adecuado para la detección de imágenes para la implementación del prototipo?
- ¿Cuál es el set de datos más adecuado para que el entrenamiento se ejecute de manera idónea?
- ¿El sistema implementado cumple con los requisitos propuestos?

JUSTIFICACIÓN TEÓRICA

A inicios del siglo XXI un problema no tan nuevo aquejaba a los gobiernos y autoridades, debido a que la acumulación de basura estaba provocando muchos inconvenientes para las ciudades sobre todo para las de mayor población. El crecimiento poblacional acelerado y las prácticas consumistas han contribuido a este problema de tal manera que calles, parques, playas y hasta el campo suelen estar repleto de basura y desechos. Los materiales plásticos han cooperado de gran manera al desarrollo de la humanidad tanto por su flexibilidad de uso como su bajo costo, pero al ser materiales artificiales son difíciles de degradar naturalmente (CASTELLÓN, 2010).

Los materiales PET que son utilizados en su mayoría en bebidas carbonatadas y botellas de agua son los que mayor contaminación visual provocan (NOVOA PELÁEZ, 2012). Por esto, este tipo de materiales pueden perdurar cientos de años sin que se puedan degradar y a su vez causando daños a la naturaleza. De todos los desechos que se generan en el planeta solo el 11% corresponde a material plástico, pero sus mayores efectos se pueden evidenciar en el volumen que ocupan, la estética de estos y la velocidad con la que se riegan para ocupar mayor espacio (CASTELLÓN, 2010). Cabe mencionar que tal vez el inconveniente más grande no sea la acumulación misma de este tipo de desechos, sino más bien la indiferencia humana al tratar estos temas.

El interés principal de este estudio se enfoca en cooperar con la solución del problema anteriormente mencionado apoyándose una de las herramientas tecnológica más potentes y óptimas de la actualidad, basándonos en que, en los últimos años las redes neuronales están obteniendo una gran ventaja en la resolución de problemas que por años han puesto resistencia a los mejores intentos de la comunidad de inteligencia artificial debido a que resultó ser un aliado perfecto para descubrir estructuras complejas en datos de alta dimensión y, por lo tanto, es aplicable a muchos dominios de la ciencia, los negocios y el gobierno. Además de batir récords en reconocimiento de imágenes y reconocimiento de voz, ha superado técnicas para predecir la actividad de posibles moléculas de fármacos, analizar datos del acelerador de partículas, reconstruir circuitos cerebrales y predecir los efectos de mutaciones en el ADN no codificante en la expresión génica y enfermedad (LECUN, 2015a).

Uno de los aspectos más sorprendentes de las redes neuronales a través del aprendizaje automático y profundo es que ha generado resultados extremadamente prometedores para diversas tareas en la comprensión del lenguaje natural, especialmente la clasificación de temas, el análisis de sentimientos, la respuesta a preguntas, corrección de ortografía, predicción de texto y la traducción de idiomas.

YOLO (You only look once o solo miras una vez) es el algoritmo puntal de la visión artificial en estos días, como su nombre lo dice solo necesita evaluar la imagen una vez para hacer una predicción a diferencia de sus predecesores como el R-CNN o el fast R-CNN que son sistemas de detección que reutilizan clasificadores o localizadores para realizar la detección. Estos clasificadores aplican el modelo a una imagen en múltiples ubicaciones y escalas; las regiones de alta puntuación de la imagen se consideran detecciones (FARHADI, y otros, 2017).

Actualmente YOLO experimenta su tercera generación que es mucho más eficiente que las dos versiones anteriores. Pero ¿Por qué YOLO es el mejor algoritmo para la visión artificial? La respuesta en teoría no es tan complicada pues YOLO aplica una única red neuronal a la imagen en su totalidad, esta red divide la imagen en regiones y predice cuadros delimitadores y probabilidades para cada región, estos cuadros delimitadores a su vez están ponderados por las probabilidades predichas (FARHADI, y otros, 2017).

Por tales motivos la red que permita identificar botellas PET para su posterior recolección será entrenada con las técnicas de aprendizaje profundo mencionadas en el anterior párrafo para que así su funcionalidad y flexibilidad sea elevada. Este tipo de algoritmos requieren para su entrenamiento un elevado coste computacional por lo que el uso de un ordenador de última generación con tarjeta de video NVIDIA es lo óptimo para su desempeño, no obstante, se puede utilizar ordenadores de características inferiores, pero siempre expuestos sobre todo a retardos en

el entrenamiento y detección. Para el sistema de recolección se puede usar cualquier tipo de microprocesador o microordenador capaz de conectarse con el procesador principal vía WIFI, este a su vez será el encargado hacer funcionar a los actuadores que permitirán la recolección de la botella PET detectada en un principio.

JUSTIFICACIÓN APLICATIVA

La propuesta del sistema de detección y recolección de botellas plásticas incluye 2 principales fases a realizar. La primera fase consiste desde la toma y tratamiento del conjunto de datos hasta el entrenamiento de la red con los algoritmos considerados para la detección. La segunda fase consta de dos módulos; el módulo de procesamiento ubicado en el ordenador principal y gestionado por un software capaz de recibir y enviar datos vía conexión inalámbrica y el sistema o módulo recolector consta de un robot móvil en configuración diferencial, el mismo que esta adecuado de todos los materiales necesarios para la visualización y recolección del objetivo, así como el microordenador dotado de comunicación con el ordenador principal.

Este robot móvil podrá a su vez recolectar una cantidad estimada de 3 a 5 botellas PET.

OBJETIVOS

OBJETIVO GENERAL

Implementar un sistema prototipo para la detección y recolección de botellas plásticas utilizando visión artificial basada en redes neuronales.

OBJETIVOS ESPECÍFICOS

- Estudiar cuál algoritmo de aprendizaje profundo es el idóneo para una detección rápida de botellas y con alto porcentaje de precisión.
- Identificar el set de datos de entrenamiento suficiente para que la red tenga falsos (positivos y negativos) mínimos.
- Entrenar un modelo de visión artificial capaz de detectar botellas plásticas en video en tiempo real.
- Implementar el sistema de recolección utilizando los componentes electrónicos y mecánicos establecidos en la fase de diseño.
- Evaluar el desempeño del sistema para verificar su grado de precisión.

CAPÍTULO I

1. MARCO TEÓRICO REFERENCIAL

En el presente capítulo se realiza una explicación documentada de los fundamentos tomados en cuenta para llevar a cabo este trabajo de titulación. Se considera aspectos generales acerca de inteligencia artificial, sistemas tecnológicos de tratamiento de desechos, algoritmos de clasificación basados en CNN y finalmente se determinan los principales componentes hardware y software necesarios para implementar el prototipo.

1.1 Inteligencia artificial (IA)

Se entiende como inteligencia a la capacidad de aprender, entender, razonar y tomar decisiones, estas facultades innatas de los seres humanos buscan ser emuladas por sistemas artificiales y a esto se le conoce como inteligencia artificial. Las principales aplicaciones de la IA son el tratamiento de datos y la identificación de sistemas, no obstante, esto no excluye que se puedan resolver problemas de orden más abstracto como la traducción de texto, demostración de problemas matemáticos e incluso ganar un juego de ajedrez (BENÍTEZ, 2014 pág. 9).

Las aplicaciones más actuales de la Inteligencia Artificial se centran en la robótica, análisis de texto, sistemas expertos y la visión artificial que es el campo en el que se centra el presente trabajo de titulación.

1.1.1 Inteligencia Artificial aplicada a la Visión Artificial

La visión artificial es una técnica que pretende adquirir, analizar e interpretar imágenes de una forma lo más parecida al sentido de visión humana. Esta técnica se estructura en dos etapas como son la adquisición de imágenes, generalmente en dos dimensiones, y el procesamiento de imágenes, con el fin de extraer y medir determinadas propiedades de estas imágenes (INÁCIO, y otros, 2018). Esta técnica se encuentra visualizadas en la figura 1-2.

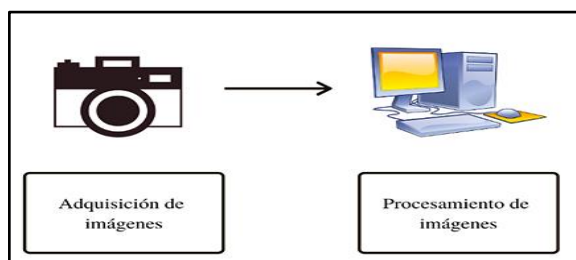


Figura 1-1: Etapas de la Visión Artificial

Realizado por: Núñez, Alex, 2022.

Como se mencionó está compuesta de dos etapas y estas son:

- **Etapa de adquisición:** Comprende en la captación del reflejo de la luz sobre objetos a través de una cámara fotográfica.
- **Etapa de procesamiento:** Esta enteramente relacionada con un ordenador o procesador.

La Inteligencia Artificial se encarga de este procesamiento a través del aprendizaje profundo o Deep Learning (DL), debido a que se encarga de métodos y técnicas para aplicaciones computacionales como la visión artificial y es capaz de modificar o adaptar sus acciones, para hacerla más precisa (INÁCIO, y otros, 2018).

Estos métodos y técnicas se consolidan en algoritmos capaces de ser entrenados para resolver un caso específico y servir de base para casos más generales y este entrenamiento se lo realiza sobre las CNN.

1.1.2 Redes neuronales convolucionales (CNN)

A partir de los problemas que suscitan al procesar imágenes en dos dimensiones las redes neuronales convolucionales incorporan restricciones y logran cierto grado de invariancia de cambio y deformación utilizando tres ideas: campos receptivos locales, pesos compartidos y submuestreo espacial. El uso de pesos compartidos también reduce la cantidad de parámetros en el sistema que ayudan a la generalización. Una de las primeras aplicaciones en las que las redes neuronales convolucionales (CNN) tuvieron éxito en el reconocimiento de caracteres (LECUN, 1990c).

Una red neuronal convolucional consta como se puede ver en la figura 1-2 de un conjunto de capas, cada una de las cuales contiene uno o más planos. En la capa de entrada entran imágenes aproximadamente centradas y normalizadas. Cada unidad en un plano recibe información de un pequeño vecindario en los planos de la capa anterior. La idea de conectar unidades a campos receptivos locales se remonta a la década de 1960 con el perceptrón y el descubrimiento de Hubel y Wiesel (LAWRENCE, 1997). Los pesos que forman el campo receptivo de un plano están obligados a ser iguales en todos los puntos del plano.

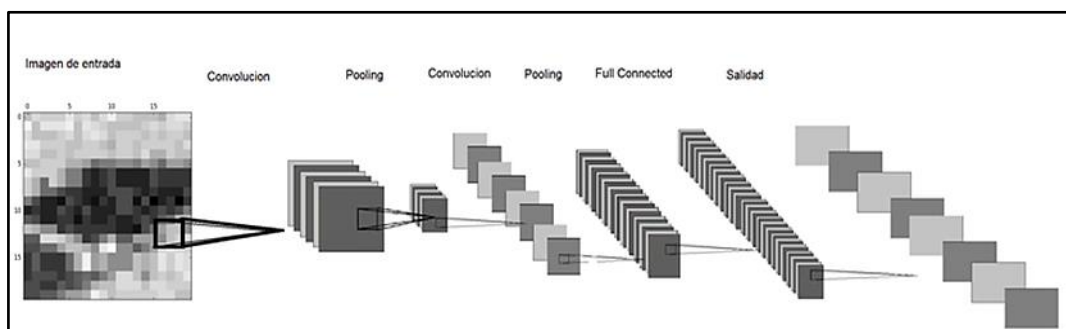


Figura 2-1: Estructura básica de una red neuronal convolucional

Fuente: (SUAREZ, 2016)

Cada plano puede considerarse como un mapa de características que tiene un detector de características fijo que está convolucionado con una ventana local que se escanea sobre los planos de la capa anterior. Por lo general, se utilizan varios planos en cada capa para que se puedan detectar varias características. Estas capas se denominan capas convolucionales. Una vez que se ha detectado una característica, su ubicación exacta es menos importante. Por lo tanto, las capas convolucionales suelen ir seguidas de otra capa que realiza una operación de promediado y submuestreo local (LAWRENCE, 1997).

1.2 Basura y medio ambiente

La acumulación de basura constituye uno de los problemas más grandes de la humanidad en relación con el medio ambiente, la forma como se efectúa en la sociedad el servicio de recolección, reaprovechamiento y/o eliminación de residuos y el impacto ambiental que tal proceso genera demanda la atención tanto de investigadores como de representantes de las instituciones socialmente responsables de ofrecer este servicio a la sociedad. La sobreacumulación de desechos causada por el uso y explotación inadecuada de los recursos naturales y la modificación de los espacios naturales por la implantación de sistemas urbanos industriales, resultan en síntomas que poseen *"un efecto significativo sobre el ser humano, a través de impactos directos o indirectos sobre la salud y la calidad de vida, así como sobre el proceso de desarrollo económico social"* (RODRÍGUEZ CONTRERAS, 2015).

El ciclo de vida de un producto es muy corto debido a la demanda del mercado, el consumidor final se ha encargado de generar basura, desperdicios de residuos que en su mayoría no reciben el tratamiento adecuado: quemas al aire libre, disposición en tiraderos o vertederos ineficientes, explotación de los trabajadores. Este ritmo de vida está causando graves problemas al planeta ya que en su colectividad los residuos son bastante peligrosos provocando contaminación, que se resume en problemas de salud y daño al ambiente, además de provocar conflictos sociales y políticos (NOVOA PELÁEZ, 2012).

1.2.1 Material Polietilentereftalato (PET)

Es uno de los plásticos más importantes y ampliamente utilizados en el mundo, especialmente para la fabricación de envases de bebidas. La producción mundial actual de PET supera los 6,7 millones de toneladas/año y muestra un aumento dramático en la región asiática debido a las recientes demandas crecientes en China e India. En Corea, la producción de botellas de PET ha crecido a 130 mil toneladas/año (SUNG BAE, 2010).

En el Ecuador el Ministerio del Ambiente (MAE), mediante del Programa Nacional de Desechos Sólidos, ha receptado la información expedida por el Servicio de Rentas Internas (SRI), respecto

a la cantidad de botellas PET recuperadas luego de la creación de la ley de Fomento Ambiental y Optimización de los Ingresos del Estado en 2011.

En el primer año se produjeron 1 406 millones de botellas PET, de las cuales se lograron recuperar 511 millones de las fábricas procesadoras y 624 millones de los centros de reciclaje, logrando recolectar en total 1 136 millones de unidades PET y cada año esta cifra va en aumento (MINISTERIO DEL AMBIENTE, 2012).

En su gran mayoría las botellas de PET se tiran después de un solo uso, generalmente estos desechos se gestionan mediante vertederos e incineración o peor aún en algunos casos no son recolectados y permanecen en la naturaleza incluso por años, estos desechos son los que hoy están provocando serios problemas ambientales debido a su lenta degradación.

Para recolectar y reciclar los desechos de PET, se requieren gastos adicionales, es por eso por lo que se hace necesaria una solución tecnológica mucho más efectiva y menos costosa para el tratamiento de los desechos PET.

1.3 Sistemas tecnológicos de tratamiento de desechos

En la década de los 90's aparecen enfoques como la utilización de la tecnología para dar soluciones a problemas ecológicos. Estos modelos han evolucionado con el paso de los años y, en general, intentan mejorar el nivel de servicio minimizando la utilización de recursos (PÉREZ ARRIAGA, 2007 pág. 2). Los enfoques más generales se centran en crear sistemas autónomos capaces de tratar los desechos pasando por las fases de detección y recolección que son las de interés y que se abordarán en este estudio; tratando de que estos procesos sean los más autónomos posibles.

1.3.1 Sistemas de detección de desechos

Los desechos por su condición sólida son susceptibles a ser detectados por sensores de proximidad, sin embargo, por esa misma condición el sistema puede ser demasiado limitado en ambientes desconocidos. Existen hoy varios robots básicos que son capaces de detectar desechos sólidos ubicados a cierta distancia y en un ambiente preconfigurado para su funcionamiento, pero sus limitaciones son grandes debido a que identifican cualquier material sólido como desecho.

Es por sus escasos beneficios que un sistema detector de desechos con las características mencionadas se vuelve tan ineficiente; justo aquí es en donde la inteligencia y la visión artificial gracias al DL, es capaz de crear sistemas de detección que no tienen comparación con los antes mencionados, dando lugar a algoritmos de detección que permiten localizar e identificar el desecho en una imagen o un video, no obstante, evidentemente estos algoritmos demandarán también un elevado coste de procesamiento.

1.3.2 *Sistemas de detección por visión artificial basada en redes neuronales convolucionales*

El aprendizaje profundo (DL, por sus siglas en inglés) es uno de los avances más representativos del uso de redes neuronales convolucionales (CNN, por sus siglas en inglés) debido a que permite que modelos computacionales compuestos por varias capas de procesamiento sean capaces de captar y aprender representaciones sobre datos con varios niveles de abstracción para después poder con autonomía descubrir representaciones precisas en grandes cantidades de datos (MASSIRIS, 2018 pág. 2), derivando como consecuencia un excelente desempeño a la hora de enfrentar problemas de reconocimiento e interpretación en imágenes y video (FANG, 2018).

Su capacidad para actuar adecuadamente en estos contextos está basada en características fundamentales: conexiones locales, pesos compartidos, *pooling* y el uso de una gran cantidad de capas. El propósito de las redes neuronales convolucionales es extraer todas las características de una imagen y luego usar dichas características para detectar o clasificar los objetos en una imagen. Los parámetros de los filtros que se pueden aprender en estas capas; se ajustarán y optimizarán junto con los componentes de clasificación para minimizar el error de clasificación total (FUKUSHIMA, 1988), (LECUN, 1998b).

Los algoritmos de detección como RCNN (Region Neural Network) y YOLO (You Only Look Once) intentan dibujar un cuadro delimitador alrededor del objeto de interés para ubicarlo dentro de la imagen. Además, es posible que no dibuje necesariamente un solo cuadro delimitador en un caso de detección de objetos, podría haber muchos cuadros delimitadores que representan diferentes objetos de interés dentro de la imagen y no sabría cuántos de antemano (GANDHI, 2018).

1.3.2.1 *R-CNN*

Este sistema toma una imagen de entrada, extrae alrededor de 2000 propuestas de regiones de abajo hacia arriba, calcula las características para cada propuesta utilizando una gran red neuronal convolucional, y luego clasifica cada región utilizando máquina de vectores de soporte (SVM) lineales específicos de clase (GIRSHICK, 2014b pág. 1). Esta propuesta de 2000 regiones se genera utilizando el algoritmo de búsqueda selectiva que se representa en la figura 3-1.




Figura 3-1: Algoritmo de búsqueda selectiva

Fuente: (GIRSHICK, 2014b)

Para mejor comprensión, si se tiene el algoritmo es capaz de detectar una persona, no obstante, la probabilidad de que se detecte también el rostro de esta persona se reduce a la mitad, los valores de compensación permiten realizar un ajuste al marco delimitador de la propuesta de la región (GIRSHICK, 2014b pág. 1).

1.3.2.2 R-CNN rápido

Este algoritmo resolvió algunos de los inconvenientes de R-CNN y se llamó Fast R-CNN o R-CNN rápido. El principio es similar al algoritmo R-CNN. Pero, como en la figura 4-1 se puede ver en lugar de alimentar las propuestas de la región a la CNN, se alimenta la imagen de entrada a la CNN para generar un mapa de características convolucional. A partir del mapa de características convolucionales, se identifica la región de las propuestas y las deforma en cuadrados y, al usar una capa de agrupación RoI, las rediseña en un tamaño fijo para que se pueda alimentar a una capa completamente conectada. Desde el vector de características RoI, utiliza una capa softmax para predecir la clase de la región propuesta y también los valores de desplazamiento para el cuadro delimitador (GIRSHICK, 2015a).

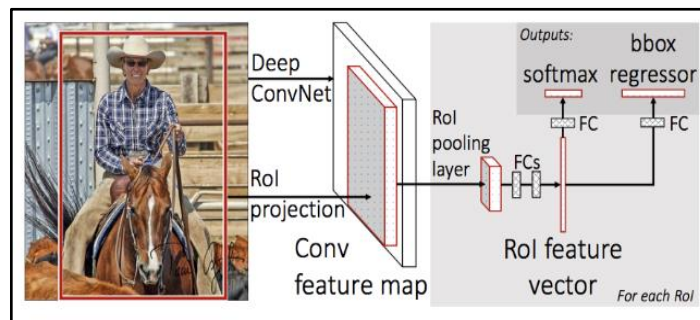


Figura 4-1: Arquitectura del algoritmo R-CNN rápido

Fuente: (GIRSHICK, 2015a)

La razón por la que "Fast R-CNN" es más rápido que R-CNN es porque no tiene que alimentar las propuestas de 2000 regiones a la red neuronal convolucional en cada iteración, pues este proceso de convolución se ejecuta solo una vez por imagen y genera un mapa de características a partir de ella (GIRSHICK, 2015a).

1.3.2.3 R-CNN más rápido

La búsqueda selectiva es un proceso que hace R-CNN y R-CNN rápido sean algoritmos lentos, es por esto por lo que R-CNN más rápido o faster R-CNN corrigió este defecto debido a que elimina la búsqueda selectiva y utiliza una red separada para predecir las propuestas de la región (REN, 2016).




Figura 5-1: Funcionamiento del algoritmo R-CNN más rápido

Fuente: (REN, 2016)

Las propuestas de región pronosticadas que se muestran en la figura 5-1 se vuelven a formar utilizando una capa de agrupación RoI que luego se usa para clasificar la imagen dentro de la región propuesta y predecir los valores de desplazamiento para los cuadros delimitadores (REN, 2016).



Figura 6-1: Comparación de tiempo de entrenamiento entre algoritmos de detección

Fuente: (ROHITH, 2018)




Figura 7-1: Comparación de tiempos de respuesta entre algoritmos de detección

Fuente: (ROHITH, 2018)

En las figuras 6-1 y 7-1 se aprecian comparaciones de tiempo de entrenamiento y velocidad de respuesta de los algoritmos expuestos, en donde se ve claramente que R-CNN más rápido es mucho mejor en ambas características que los demás algoritmos de este tipo.

1.3.2.4 YOLO

Es un algoritmo de aprendizaje profundo en el cual una sola red neuronal predice cuadros delimitadores y probabilidades de clase directamente de imágenes completas en una evaluación. Como toda la tubería de detección es una red única, se puede optimizar de extremo a extremo directamente en el rendimiento de detección. Esta arquitectura unificada es extremadamente rápida (REDMON, 2016b). El modelo base YOLO que se muestra en la imagen 8-1 procesa imágenes en tiempo real a 45 cuadros por segundo. Una versión más pequeña de la red, Fast YOLO, procesa la asombrosa cantidad de 155 fotogramas por segundo mientras logra el doble de mAP que otros detectores en tiempo real. En comparación con los sistemas de detección de vanguardia, YOLO comete más errores de localización, pero es menos probable que prediga falsos positivos en segundo plano. Finalmente, YOLO aprende representaciones muy generales de objetos. Supera a otros métodos de detección, incluidos DPM y la familia R-CNN, al generalizar desde imágenes naturales a otros dominios como obras de arte (REDMON, y otros, 2017a).




Figura 8-1: Funcionamiento algoritmo YOLO

Fuente: (REDMON, 2016b)

1.3.3 Sistemas de recolección de desechos

Principalmente se centran en la recolección asistida y autónoma. Estos sistemas se describen brevemente en los siguientes apartados.

1.3.3.1 Recolección asistida

Este tipo de recolección como su nombre lo indica no lo realiza el robot o el sistema por sí mismo si no que necesita de un humano tele operando su movimiento a distancia ya sea por medio de algún tipo de conexión inalámbrica o por medio de algún cable unido al sistema. Existen muchos trabajos la mayoría aficionados que realizan este tipo de recolección. Se puede mencionar a “Inca

Robot” un robot realizado por estudiantes peruanos, ganador de un concurso de robots recicladores en Japón (PALOMINO, 2010).

1.3.3.2 *Recolección autónoma*

En la actualidad este tipo de sistemas aún son escasos, debido que para su funcionamiento no es necesaria la intervención directa del hombre para dar instrucciones al sistema, no obstante, puede supervisarlo. Hoy se puede citar a “*Volvo*” (SOSA, 2016) que se puede ver en la figura 9-1 y es un robot recolector de basura desarrollado por estudiantes universitarios estadounidenses.



Figura 9-1: Robot recolector autónomo Volvo

Fuente: (SOSA, 2016)

La recolección autónoma en el caso que se aborda en el presente estudio será guiada de manera inalámbrica por el procesador principal a través de la información obtenida desde la cámara del robot móvil.

1.4 Hardware

A continuación, se hace un análisis de los componentes más importantes del prototipo como el microordenador, cámara y software para determinar cuáles son los más adecuados para formar parte de este.

1.4.1 *Ordenadores de placa reducida*

En el mercado existe diversos tipos de microordenadores u ordenadores de placa reducida, en la tabla 1-1 se especifican las características principales de algunos de ellos.

Tabla 1-1: Comparativa entre ordenadores de placa reducida comunes en el mercado

Dispositivo	Procesador	RAM	Memoria Interna	Conectividad	SO	Precio
Jaguar One	Inteal Atom Z3735G	1 GB DDR3	16 GB	3 USB, HDMI y Ethernet	Win 8,10	\$79,00
pcDuino	ARM A7 4 Núcleos	1 GB DDR3	8GB	2 USB, HDMI y Ethernet	Android	\$49,00
Cubiboard5	ARM A7 8 Núcleos	2 GB DDR3	8GB+ SATA	USB, HDMI, Displayport, Wifi, BT 4.2	Android	\$99,00
Beaglebone Black	ARM A8 1 Ghz	512 MB DDR3	4 GB	1 USB, HDMI Y Ethernet	Linux	\$45,00
Hummingboard	ARM A9 Dual Core	Hasta 2 GB	Tarjeta de memoria	2 USB, HDMI Y Ethernet	Android	\$70,00
Odroid-C2	ARM A53 4X2 Ghz	2 GB DDR3	Tarjeta de memoria	4 USB, HDMI Y Ethernet	Android	\$40,00
Orange Pi	ARM A7 4X1.2 Ghz	512 MB	Tarjeta de memoria	3 USB, HDMI Y Ethernet	Linux	\$10,00
Raspberry Pi4	1,5 Ghz 4 núcleos ARM Cortex-A72	1, 2, 4 GB LPDDR2	Tarjeta de memoria	Gigabit LAN inalámbrica y Bluetooth 5	Linux	\$120,00

Fuente: (OCAÑA, 2017)

Realizado por: Núñez, Alex, 2022.

Según la tabla 1-1 la Raspberry pi 4 posee la mejor relación de características de conectividad inalámbrica, procesamiento y precio, además que su crecimiento en popularidad ha permitido que su disponibilidad en el mercado sea muy alta.

1.4.2 Cámaras

Existen también en el mercado gran cantidad de cámaras USB compatibles con RPI, sin embargo, el módulo de cámara de Raspberry es un módulo de extensión desarrollado específicamente para trabajar con las placas Raspberry pi, ofrece imágenes de vídeo de alta velocidad y sensibilidad. Además, ofrece también contaminación de imagen reducida como ruido de patrón fijo y borrones (RASPBERRY PI, 2016).

Existen también distintos tipos de cámaras infrarrojas compatibles con Raspberry pi como la serie NoIR, no obstante, no es sensible a la radiación por infrarrojos de onda larga (calor), por lo que se requiere iluminación LED para poder ver en la oscuridad (IBERBOTICS, 2021).

Es por todo lo mencionado anteriormente que, se usará la cámara de infrarrojos para visión nocturna SKU 516G1 ideal para trabajar en la noche o en ambientes de poca luz (HUBOT, 2018).

CAPÍTULO II

2. PROPUESTA Y DISEÑO DEL PROTOTIPO

El presente capítulo contiene un desglose de las etapas y procesos necesarios para el diseño e implementación de *hardware* y *software*, especificando los componentes utilizados, sus características y esquemas.

2.1 Requerimientos del sistema

Una vez comprendidos los términos básicos gracias al estudio realizado en el capítulo anterior, ahora se definen los requerimientos necesarios para el desenvolvimiento del sistema prototipo de detección y recolección de botellas PET. El módulo recolector será capaz de:

- Comunicar de forma inalámbrica los módulos de recolección y procesamiento en tiempo real, es decir, con tiempos de latencia muy cortos (MICROSOFT , 2018).
- Poseer una interfaz gráfica amigable y de fácil comprensión con el operario.
- Visualizar imágenes con una resolución adecuada a través de la cámara adaptada en el módulo de recolección.
- Constar de un sistema mecánico capaz de recolectar un máximo de cinco botellas PET de tamaño máximo equivalente a una botella de 300 ml.
- Movilizarse en superficies horizontales sin obstáculos mediante una configuración diferencial de sus ruedas.
- Tener un tiempo de operación mínimo de 30 minutos antes de que sus baterías se descarguen.
- Capacidad de rastreo de botellas por giro en su propio eje hasta encontrar un objetivo o dar una vuelta completa sin encontrar objetivos.
- Sistema de aviso visual de la detección y recolección.
- Detectar botellas a una distancia máxima de 15 metros.
- Volver al punto de partida cuando se haya completado su capacidad de almacenamiento, o ya no se detecten objetivos.
- Encendido y apagado a través de conexión de cable tipo C.
- Sistema de carga de batería manual sin extracción.
- Detectar botellas en diferentes ambientes y grados de iluminación incluyendo ambientes nocturnos.

2.2 Consolidación general de detección y recolección

La consolidación total del sistema prototipo para la detección y recolección de botellas PET utilizando visión artificial basada en redes neuronales, está constituido por los módulos de procesamiento y recolección como se muestra en la figura 1-2. Estos dos módulos se comunican inalámbricamente vía *wifi* y en conjunto serán capaces de detectar botellas PET en video a través de una red neuronal entrenada y posteriormente recolectarlas.

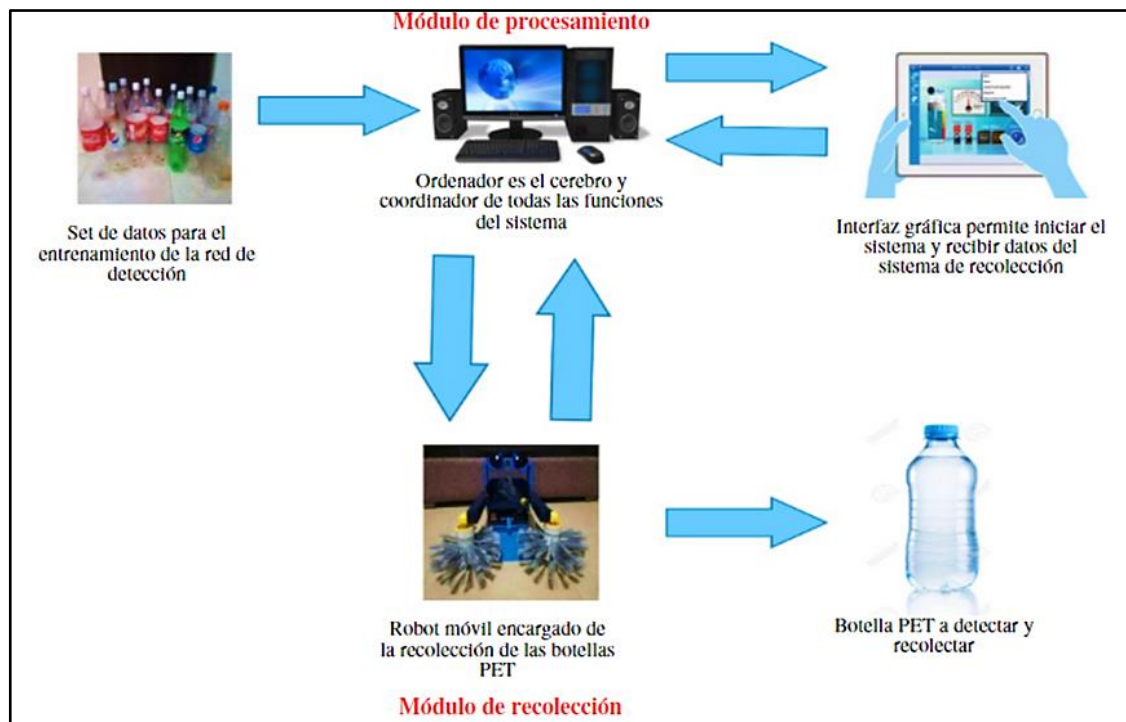


Figura 1-2: Esquema de módulos del sistema

Realizado por: Núñez, Alex, 2022.

2.2.1 Módulo de procesamiento

Este módulo consta únicamente de un ordenador ya sea de escritorio o portátil y es el cerebro y coordinador de todas las funciones del proceso. En la fase de entrenamiento se encarga de recibir el set de datos, tratarlos y finalmente entrenar la red con los mismos datos. Luego en la fase de detección y recolección el módulo de procesamiento es el encargado de receptor las imágenes captadas por la cámara del módulo recolector, procesarlas y dibujar rectángulos sobre las botellas PET detectadas.

2.2.2 Módulo de recolección

Los bloques que componen este módulo se indican en la figura 2-1. Este módulo constituye un robot móvil formado por un bloque de adquisición de imágenes, un bloque de micro

procesamiento, un bloque de movilización, un bloque de recolección, y un bloque de alimentación.

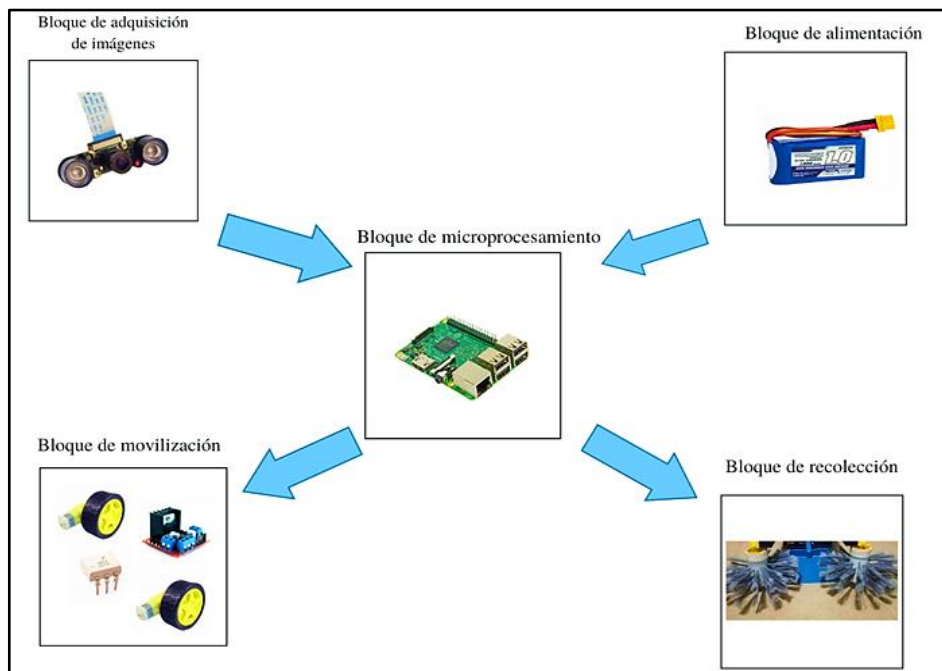


Figura 2-2: Esquema de bloques del módulo recolector

Realizado por: Núñez, Alex, 2022.

2.3 Arquitectura del *software* del prototipo

En este apartado se hará una breve descripción de las características y preparación de las herramientas *software* para obtener el modelo de red neuronal para detección de botellas PET en video en vivo.

2.3.1 *Herramientas software*

A continuación, se realiza un breve análisis de del *software* que será parte del prototipo.

2.3.1.1 *Matlab*

Es empleada para resolver diversos problemas entre los más relevantes están los científicos y de ingeniería. Matlab se encuentra basado en matrices, es la forma que emplea para expresar las matemáticas computacionales. Las gráficas integradas facilitan la visualización de los datos y la obtención de información a partir de ellos. Tiene una vasta biblioteca de herramientas llamadas “*Toolboxes*”, que se encuentran integradas en el *software* lo que permite empezar a trabajar inmediatamente con algoritmos esenciales para su dominio. El entorno de escritorio invita a experimentar, explorar y descubrir. Todas estas herramientas y funciones de MATLAB están probadas rigurosamente y diseñadas para trabajar juntas (MATHWORKS, 2019c).

Las herramientas de Matlab conocidas como *toolbox* son entornos preconfigurados para trabajar con alguna área en específico, existen *toolbox* para visión artificial, aprendizaje profundo, comunicación con la tarjeta Raspberry pi y para compatibilidad entre Matlab y GPUs NVIDIA que son los de interés de este trabajo. A continuación, se detallan los *toolbox* que se usarán durante el desarrollo del presente.

- Computer Vision Toolbox
- Deep Learning Toolbox
- Deep Learning Toolbox Model for ResNet-50 Network
- Image Processing Toolbox
- Matlab Support Package for Raspberry Pi Hardware
- Code generation Toolbox
- Support Package for Raspberry Pi Hardware

2.3.1.2 Raspbian Jessie

Es un lenguaje de programación de propósito general, en el que se puede realizar cualquier tipo de algoritmo orientado a objetos, posee una serie de librerías que permiten acoplar varios conjuntos de operaciones para el desarrollo de aplicaciones en diversas áreas (OCAÑA, 2017). Además, Python cuenta con librerías especializadas para IA y DL como Keras, Tensorflow.

MathWorks a través del paquete de soporte de Matlab y Simulink para Raspberry Pi dispone una imagen de Linux personalizada para Raspberry Pi. Esta imagen consta de la imagen predeterminada de Raspbian jessie con todos los paquetes de software y bibliotecas necesarios instalados para que el hardware Raspberry Pi sea compatible con el paquete de soporte de Matlab (GITHUB, 2021).

2.3.2 Entrenamiento

Para ejecutar este entrenamiento se necesita antes un conjunto de datos o imágenes de entrada para la red, como se puede ver en la figura 3-2 estos datos necesitan de un tratamiento que los hace aptos para ser asimilados por el software encargado del procesamiento, este tratamiento. Estos pasos se describen a partir del siguiente apartado.

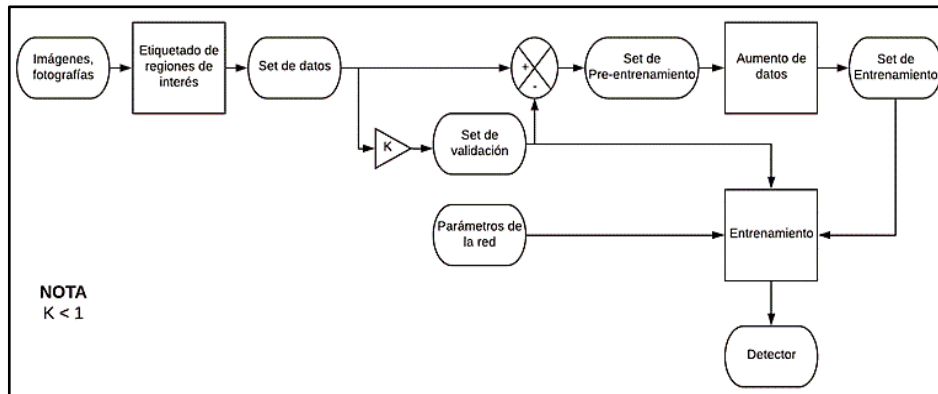


Figura 3-2: Diagrama de bloques de la fase de entrenamiento

Realizado por: Núñez, Alex, 2022.

2.3.2.1 Toma de imágenes

Para la toma de los datos de entrada para el entrenamiento de la red se tomaron fotos de distintos tipos de botellas PET en todo tipo de ambientes con todo tipo de fondos y expuestas a distintas y condiciones de luz ambiental como se puede ver en la figura 4-2. Es importante recordar que el conjunto no debe ser muy pequeño para que el modelo converja ni muy grande para evitar pérdidas de tiempo por procesamiento.



Figura 4-2: Set de datos

Realizado por: Núñez, Alex, 2022.

2.3.2.2 Etiquetado y regiones de interés

La preparación del set se la puede realizar desde el mismo Matlab con la Herramienta imageLabeler. Lo que se hace en la preparación es dibujar manualmente la región en donde se encuentra el objeto de interés y la clase a la que pertenece como se muestra en la figura 5-2, de

este modo Matlab genera una matriz de dos columnas que contiene la ubicación de la imagen y tamaño del cuadro delimitador en donde se encuentra el objeto a detectar.

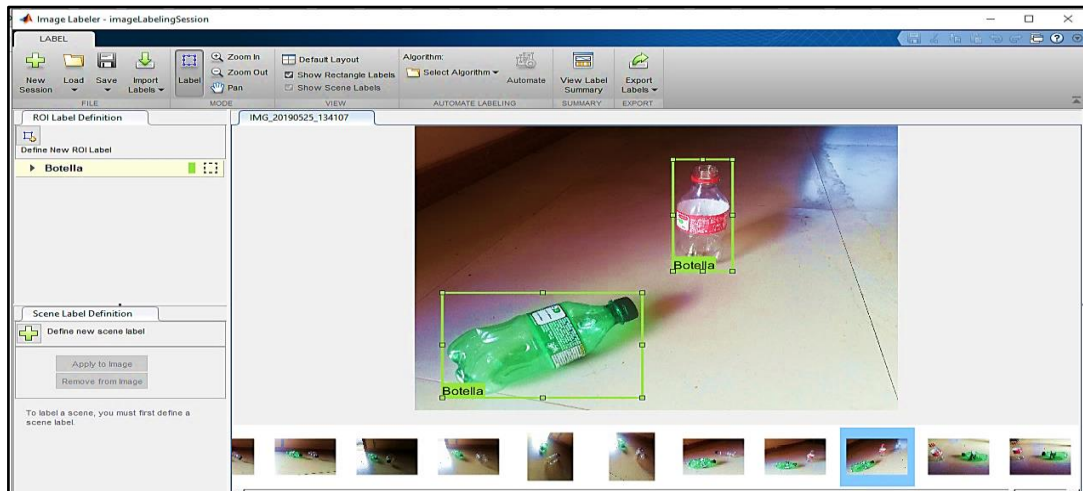


Figura 5-2: Etiquetado de la región de interés

Realizado por: Núñez, Alex, 2022.

Este procedimiento se realiza con todas las imágenes pertenecientes al set de datos.

2.3.2.3 División del set

El set en el que se realizó el proceso de etiquetado debe ser luego dividido principalmente en dos grupos, el de entrenamiento y el de validación. El set de entrenamiento será tomado con entrada de la red neuronal y sobre él será realizado el entrenamiento como tal; el set de validación en cambio será utilizado por la red para comprobar el avance del entrenamiento y servirá para una modificación de los hiper parámetros en caso de ser necesario. El set de entrenamiento debe ser mucho más grande que el set de validación, por ejemplo, en un set de 500 fotos se puede dividir en 400 imágenes para el entrenamiento y 100 para la validación.

Además, se puede considerar la creación de un tercer grupo de imágenes denominado set de prueba, que debe contener imágenes diferentes a las utilizadas en los otros dos sets y se lo utiliza para comprobar el resultado del entrenamiento.

2.3.2.4 Aumento de datos

Para que el entrenamiento sea el más adecuado el set de entrenamiento debe ser variado en cuanto a iluminación, perspectiva y ambientación, es por esto, que para evitar el proceso de tomar y preparar más imágenes desde 0. El entorno de Matlab brinda la herramienta denominada aumento de datos o *data augmented* que permite modificar las propiedades de las imágenes ya obtenidas y preparadas para puedan ser asimiladas por la red y además sean consideradas como imágenes diferentes a las ya existentes.

2.3.3 Entrenamiento YOLO v2

El entrenamiento es YOLO v2 es ejecutado aplicando una única red neuronal convolucional a cada imagen del set, subdividiéndola en regiones y prediciendo las probabilidades de detección por medio de cuadros delimitadores realizando una sola evaluación de red para hacer una predicción (REDMON, y otros, 2017a).

Es así como, una vez que los datos a usarse estén tratados y normalizados es preciso configurar ciertos parámetros que cada algoritmo de detección necesita como requisitos para ejecutar la red estos parámetros. En la tabla 1-2 se especifican los parámetros del algoritmo YOLO v2 a configurar, el entrenamiento del modelo de detección de botellas PET puede durar minutos horas o incluso días, esto depende de los ciertos parámetros de la red y del tamaño del set de entrenamiento, además son de gran relevancia aspectos externo como la capacidad de procesamiento del ordenador.

Tabla 1-2: Parámetros de YOLO v2

Tamaño de imagen	[224 224 3]
Número de clases	1
Red pre entrenada	ResNet -50
Función de activación	Activation_40_relu
Tasa de aprendizaje	1e-3
Número de iteraciones	1500
Tamaño del lote	16

Realizado por: Núñez, Alex, 2022.

La tabla 2-2 muestra los valores correspondientes a tiempo, pérdida y precisión arrojados por los entrenamientos en YOLO v2 variando el tamaño del set de datos. Como se puede ver el tiempo de entrenamiento no depende del tamaño del set de datos, por otro lado, la precisión si es bastante dependiente del tamaño del set de datos, por lo que se puede concluir que una mayor cantidad de imágenes en el set de datos del entrenamiento derivará en un mayor porcentaje de precisión en las detecciones. La pérdida total es un valor para tomar en cuenta durante el entrenamiento debido a que cuando su valor no experimenta cambios significativos o se comporta como una montaña rusa con valores muy apegados quiere decir que la red ya ha no está aprendiendo y ya no puede aprender mucho más a partir del set de datos y parámetros de la red determinados. En cambio, valores de pérdida total muy grande significan que la red aún no se ha entrenado lo suficiente y no es capaz de detectar el objeto deseado.

Tabla 2-2: Datos del entrenamiento YOLO v2

Set de datos	Número de iteraciones	Pérdida Total	Tiempo	Precisión
100	1500	0,02	4h 36min	30%
200	1500	0,98	6h 42min	56%
300	1500	1,19	5h 29min	81%
400	1500	1,17	5h 10min	86%

Realizado por: Núñez, Alex, 2022.

2.3.3.1 Afinación de la red

Este proceso consiste en que sin la necesidad de aumentar el tamaño del set de datos se pueda mejorar la precisión del modelo de detección. Para la afinación de la red solo es necesario configurar la red de salida del paso anterior como entrada o red pre entrenada en este nuevo proceso y ponerlo a entrenar como en los pasos anteriores. Es recomendable también disminuir el número de iteraciones debido a que la pérdida desde la primera iteración ya es muy pequeña, en este caso se redujo a un número de 750 iteraciones, por lo que el tiempo de entrenamiento también será menor que los procesos de entrenamiento anteriores.

La precisión de la red de detección de botellas PET aumentó considerablemente como se aprecia en la figura 6-2 de 0.86 a 0.97 luego del proceso de afinación que duró 2 horas con 57 minutos.

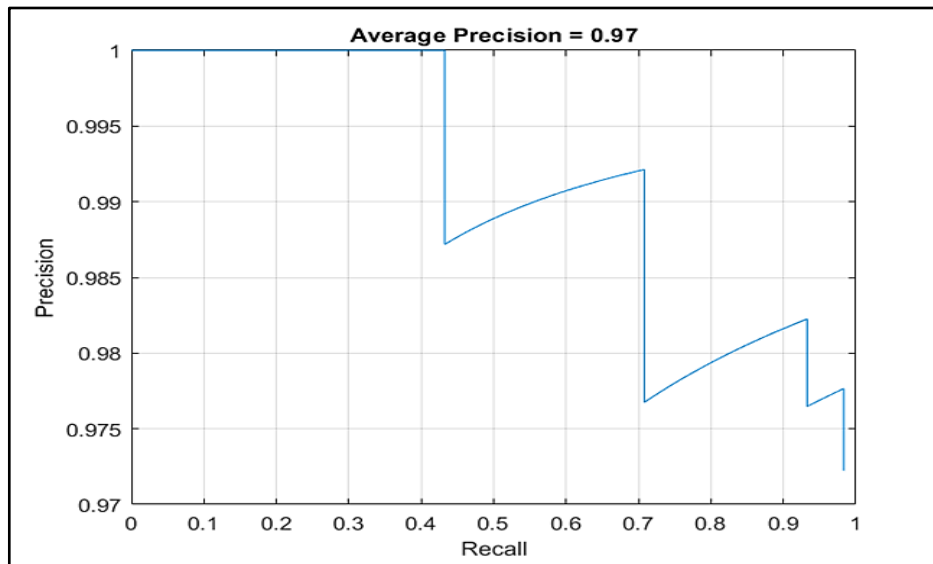


Figura 6-2: Precisión de la red afinada con YOLO v2

Realizado por: Núñez, Alex, 2022.

2.3.4 Entrenamiento en YOLO v3

Implementa la adición de detección a múltiples escalas para ayudar a detectar objetos más pequeños. Además, la función de pérdida utilizada para el entrenamiento se separa en un error cuadrado medio para la regresión del cuadro delimitador y la entropía cruzada binaria para la clasificación de objetos para ayudar a mejorar la precisión de la detección (MATHWORKS, 2020a)

Para ejecutar YOLO v3 es necesario configurar otros parámetros diferentes a YOLO v2, estos parámetros se los encuentra en su totalidad (MATHWORKS, 2020b). Los más importantes se los resumen en la tabla 3-2. El entrenamiento se lo realizó al igual que el algoritmo en 4 ocasiones empezando con un set de 100 imágenes en el primer proceso y finalizando con un total de 400 imágenes en el último, aumentando 100 imágenes en cada entrenamiento.

La tabla 3-2 muestra los valores correspondientes a tiempo, pérdida y precisión arrojados por los entrenamientos en YOLO v3 con variación del tamaño del set de datos.

Tabla 3-2: Parámetros e hiper parámetros de YOLO v3

Tamaño de imagen	[227 227 3]
Número de clases	1
Red pre entrenada	Squeezenet
Función de activación	Activation_40_relu
Tasa de aprendizaje	1e-3
Número de iteraciones	1500
Tamaño del lote	16

Realizado por: Núñez, Alex, 2022.

La tabla 4-2 muestra los valores correspondientes a tiempo, pérdida y precisión arrojados por los entrenamientos en YOLO v3 con variación del tamaño del set de datos, se han colocado los mismos parámetros que YOLO v2 para poder realizar un análisis comparativo de ambos.

Tabla 4-2: Datos del entrenamiento YOLO v3

Set de datos	Pérdida Total	Tiempo	Precisión
100	0,0003	2h 40min	36%
200	0,000	3h 21min	75%
300	0,000	2h 55min	78%
400	0,0001	2h 58min	88%

Realizado por: Núñez, Alex, 2022.

2.3.4.1 Afinación de la red

Al igual que con el algoritmo anterior se realizó la afinación de la red tomando la red entrenada con 400 imágenes como red de entrada para la afinación y con 750 iteraciones. Este proceso duró 1 hora con 15 minutos y su precisión subió a 0.88 como se puede ver en la imagen 7-2.

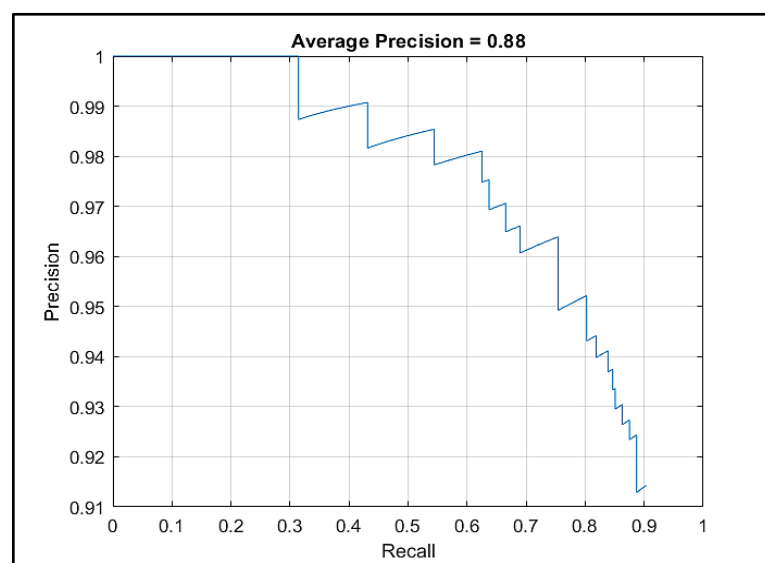


Figura 7-2: Precisión de la red afinada con YOLO v3

Realizado por: Núñez, Alex, 2022.

2.3.5 Conexión ordenador-microordenador

La interacción entre los módulos componentes del sistema será ejecutada de manera inalámbrica como muestra la figura 8-2.




Figura 8-2: Esquema de conexión inalámbrica

Realizado por: Núñez, Alex, 2022.

El sistema operativo en el que Raspberry pi usará sus recursos debe ser instalado en una memoria MicroSD externa, debido a que la placa no cuenta con una memoria integrada. La tarjeta externa necesita como requerimientos mínimos contar con una capacidad de almacenamiento de 8gb y ser de clase 10, para ser compatible con Raspberry.

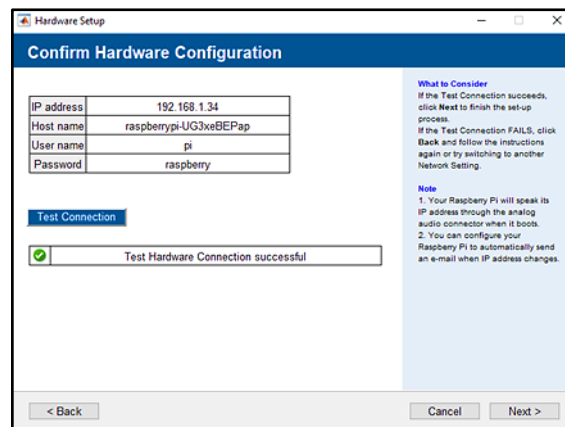


Figura 9-2: Ventana de confirmación de conexión

Realizado por: Núñez, Alex, 2022.

El sistema operativo más práctico y compatible con Matlab es el que el mismo entorno de Matlab suministra, para su instalación basta con contar con el toolbox Support Package for Raspberry Pi *hardware* e instalar el sistema en la MicroSD desde el ordenador principal. En la figura 9-2 se puede apreciar la ventana de Matlab que confirma una conexión exitosa con la tarjeta Raspberry pi, en donde se observa entre otras cosas la dirección IP.

Finalmente, la figura 10-2 muestra cómo desde el entorno de Matlab ya se está recibiendo señal de la cámara de Raspberry pi de manera inalámbrica.

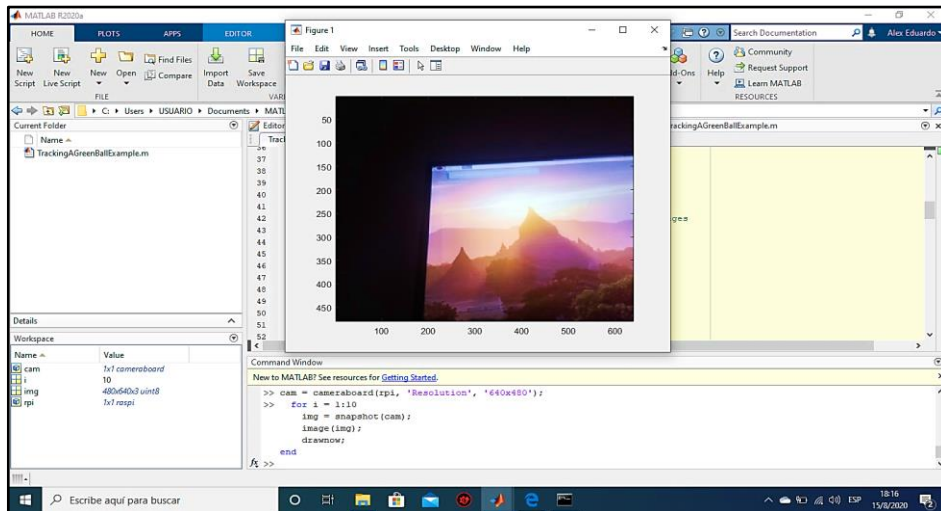


Figura 10-2: Obtención de imagen en Matlab desde Raspberry Pi

Realizado por: Núñez, Alex, 2022.

2.4 Descripción del *hardware* del sistema

Ahora se presentan todos los componentes *hardware* que integran el sistema y se detallan ciertas características relevantes para la construcción del prototipo.

2.4.1 Cámara infrarroja SHU 516G1

Esta cámara HD para Raspberry Pi soporta visión nocturna. Para usarla en modo visión nocturna hay que usar 2 módulos Led de infrarrojos como se muestra en la figura 11-2. El módulo principal se conecta a la Raspberry Pi, a través de un cable de cinta de 15 pines, a la interfaz de serie de la cámara MIPI (CSI) de 15 pines. Este bus es capaz de velocidades de datos altas y transmite exclusivamente datos de píxeles al procesador (HUBOT, 2018). Sus características más relevantes se mencionan en la tabla 5-2.



Figura 11-2: Módulo de cámara infrarroja

Realizado por: Núñez, Alex, 2022.

Tabla 5-2: Características principales del módulo de cámara

Características	Rango
Voltaje de funcionamiento	5 V
Resolución	5 MP
Ángulo de visión	60 grados
Cantidad de píxeles	2592 x 1944
Longitud focal	3,6 mm (ajustable manualmente)
Dimensiones	125 x 24 x 9 mm

Fuente: (HUBOT, 2018)

Realizado por: Núñez, Alex, 2022.

2.4.2 Motor reductor

Los motores reductores son los encargados del movimiento del robot recolector a través de ruedas ubicadas a cada lado de la parte posterior del robot, además forman parte del sistema de escobillas que succiona la botella PET. El motor con caja de reducción de plástico como el de la figura 12-2, es uno de los más comunes y baratos del mercado; debido a que los requerimientos del módulo recolector en cuanto a torque y velocidad no son tan estrictos, este motor es ideal para este sistema, en la tabla 6-2 se encuentran las características más importantes de este tipo de motor.




Figura 12-2: Motor reductor

Realizado por: Núñez, Alex, 2022.

Tabla 6-2: Características principales del motor reductor de plástico de doble eje

Características	Rango
Voltaje de alimentación	3-12 Vdc
Torque máximo	1KgF x cm
Velocidad sin carga	230 rpm
Reducción	1:48
Consumo de corriente	180 mA
Peso	35 g
Dimensiones	7 x 2,25 x 2,3 cm

Fuente: (ROBODACTA, 2020)

Realizado por: Núñez, Alex, 2022.

2.4.3 Driver L298N

Es utilizado para realizar el control de diferencial de giro y velocidad de motores mediante la técnica PWM. Este módulo tiene muchas ventajas debido a su funcionamiento como doble puente H, además puede permite controlar de manera independiente cada motor, todo esto de manera simultánea (MENDOZA MENDOZA, 2017).




Figura 13-2: Driver L298N

Realizado por: Núñez, Alex, 2022.

La figura 13-2 muestra el driver L298N y sus características principales se especifican en la tabla 7-2.

Tabla 7-2: Características principales del módulo L298N

Características	Rango
Voltaje de alimentación	7-46 Vdc
Corriente máxima por canal	2 A
Potencia de salida	25 W
Consumo de corriente	36 mA
Peso	0,1 Kg
Dimensiones	4,4 x 4,4 x 2,4 cm

Fuente: (MAKER ELECTRÓNICO, 2020), (NAYLAMPMECHATRONICS, 2021), (VISTRÓNICA, 2020)

Realizado por: Núñez, Alex, 2022.

2.4.4 Módulo de relé 5V

Este integrado que se aprecia en la figura 14-2 actúa como un interruptor que responde a señales recibidas desde un microcontrolador, sus características más importantes se pueden ver en la tabla 2-8 y en este caso se utiliza para aislar eléctricamente los motorreductores de los pines GPIO de la Raspberry pi.



Figura 14-2: Módulo relé 5V

Realizado por: Núñez, Alex, 2021.

Tabla 8-2: Características principales del módulo relé 5V

Características	Rango
Entrada	Tipo DC
Señal de control	5 Vdc a 12 Vdc
CC máxima	10 A 30 Vdc
Consumo de corriente	70 mA
Tipo de contacto	NC y NO
Dimensiones	27mm x 34 mm

Fuente: (ARDUINOMODULES, 2020), (COMPONENTS101, 2021)

Realizado por: Núñez, Alex, 2022.

2.4.5 Batería Li-Po Turnigy 3S 11V

Las baterías de Litio y polímero (Li-Po) como la que se muestra en la figura 15-2, son baterías recargables compuesta en ocasiones de múltiples celdas, usadas en aplicaciones que requieren corrientes superiores a 1A con bajo peso y tamaño reducido (DYNAMO ELECTRONICS, 2019).

Estas características con los valores se pueden apreciar en la tabla 9-2 las hacen muy amigables para la alimentación del módulo recolector.



Figura 15-2: Batería Li-Po 3S 11V

Realizado por: Núñez, Alex, 2022.

Tabla 9-2: Características técnicas principales Batería Li-Po Turnigy 3S 11V

Características	Rango
Voltaje de salida	11,1 V
Almacenamiento de carga	2 200 mAh
Número de celdas	3
Peso	199 g
Dimensiones	10,6 x 3,5 x 2,4 mm

Fuente: (SANDOROBOTICS, 2019)

Realizado por: Núñez, Alex, 2022.

2.4.6 Módulo de batería de Raspberry

Este es un módulo fabricado específicamente para alimentar tarjetas Raspberry pi, su apariencia física se observa en la figura 16-2, cuenta con dos salidas USB y sus características principales se encuentran en la tabla 10-2.




Figura 16-2: Módulo de batería para Raspberry Pi

Realizado por: Núñez, Alex, 2022.

Tabla 10-2: Características técnicas principales del módulo de batería para Raspberry Pi

Características	Rango
Voltaje de salida	3,7 Vdc
Almacenamiento de carga	3 800 mAh
Número de celdas	1
Dimensiones	8,5 x 5,3 mm

Realizado por: Núñez, Alex, 2022.

2.4.7 Punto de acceso

Es un dispositivo que crea una red local inalámbrica WLAN y proyecta una señal WI-FI a la que se pueden conectar a la vez varios dispositivos (LOS MEJORES GADGETS, 2019). Su forma física se la aprecia en la figura 17-2 y sus características más importantes en la tabla 11-2.



Figura 17-2: Punto de acceso

Realizado por: Núñez, Alex, 2022.

Tabla 11-2: Características técnicas principales del punto de acceso

Características	Rango
Voltaje de entrada	12 Vdc
Frecuencia	2,4 Ghz
Estándar inalámbrico	802.11n
Velocidad	300 MPS
Alcance	50 m

Fuente: (ALL-SPECS, 2018)

Realizado por: Núñez, Alex, 2022.

2.4.8 Computador

Para el desarrollo correcto de este trabajo se necesitó de un computador dotado de ciertas características de procesamiento que permitan al prototipo desenvolverse de la mejor manera. El procesamiento del computador debe ser capaz de entrenar la red neuronal en poco tiempo y además evitar pérdidas de tiempo por procesamiento considerables para que el funcionamiento del prototipo sea en tiempo real. Es por esto que, el trabajo se realizó con un computador Asus TUF Gaming A15 como la que se aprecia en la figura 18-2 y cuyas características más importantes se mencionan en la tabla 12-2.




Figura 18-2: Computador

Realizado por: Núñez, Alex, 2022.

Tabla 12-2: Características técnicas principales del computador

Características	Rango
Procesador	Ryzen 7
RAM	16 GB
Disco duro	512 GB
GPU	RTX 2060
Memoria GPU	6 GB

Fuente: (ASUS, 2020)

Realizado por: Núñez, Alex, 2022.

2.5 Construcción del módulo recolector

La fase de construcción como se aprecia en la figura 19-2 y comprende todo el proceso de diseño tanto electrónico como mecánico e implementación del prototipo, quedando así listo para su puesta en funcionamiento.

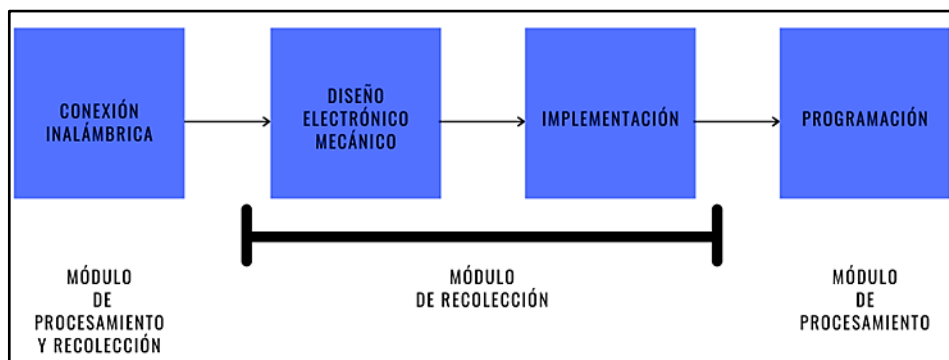


Figura 19-2: Diagrama de fase de construcción

Realizado por: Núñez, Alex, 2022.

2.5.1 Diseño electrónico

Debido a que cada componente electrónico del sistema posee pines de entrada o salida no es tan necesaria la impresión de una pista PCB, no obstante, cada componente debe estar correctamente ubicado y aislado en la construcción física del circuito.

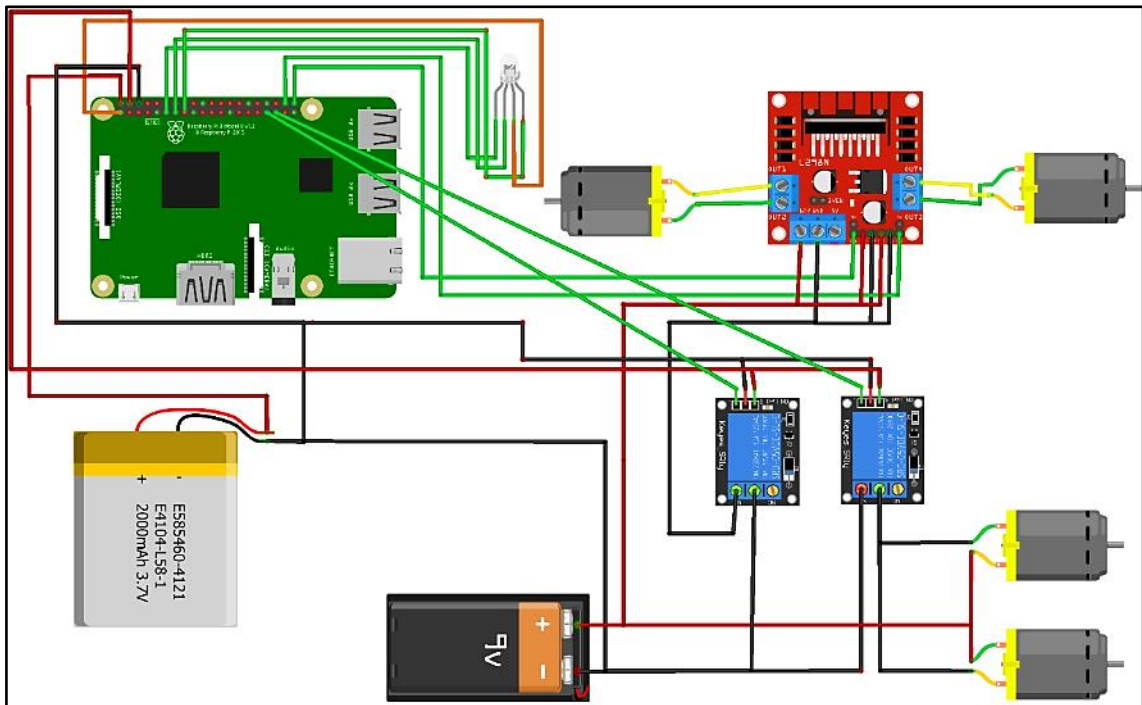


Figura 20-2: Descripción de las conexiones electrónicas de los componentes del circuito

Realizado por: Núñez, Alex, 2022.

En la figura 20-2 se puede observar que 2 de los 4 motores están conectados al puente H, esto se debe a que estos motores corresponden a los que se ubicarán en cada una de las ruedas del sistema recolector, y el módulo L298N se encarga de asimilar los pulsos PWM enviados por las RPI y suministrar la tensión correspondiente a estos motores. Por otro lado, los motores sobrantes corresponden a las escobillas de succión de la botella detectada, es por esto que, el control de velocidad de estos motores no necesita ser ejecutado por un driver, no obstante, el encendido y apagado se lo realiza a través de un módulo de relé controlado por un pin GPIO de salida de la RPI.

2.5.2 *Diseño mecánico*

A continuación, se realiza el diseño e implementación de los componentes que integran el módulo recolector.

2.5.2.1 *Diseño del chasis del módulo recolector*

Para el dimensionamiento del chasis se consideran las medidas de las botellas que se aprecia en la figura 21-2, debido a que estas podrán ser recolectadas por el prototipo.




Figura 21-2: Toma de medidas de las botellas a ser recolectadas

Realizado por: Núñez, Alex, 2022.

En la figura 22-2 se muestra el diseño en Solid Works de la parte que contendrá a los componentes electrónicos, motores de ruedas, así como las botellas recolectadas. El diseño se complementa gracias a las dimensiones de cada componente especificadas en la descripción del *hardware*.

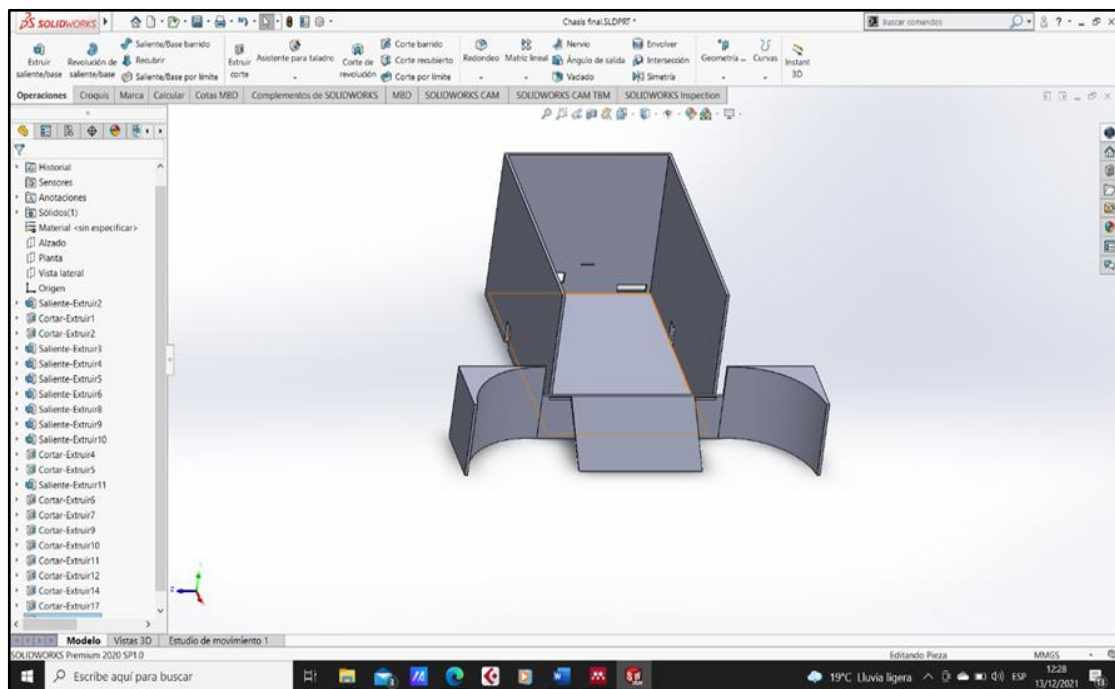


Figura 22-2: Diseño del chasis del prototipo

Realizado por: Núñez, Alex, 2022.

La figura 23-2 muestra el chasis debidamente impreso en 3d, en él se contendrán todos los demás componentes tanto mecánicos como electrónicos.



Figura 23-2: Construcción del chasis del prototipo

Realizado por: Núñez, Alex, 2022.

2.5.2.2 Diseño de escobillas, brazos de escobillas y soportes de cámara

Para concluir con el armado del módulo recolector es necesario diseñar los brazos que serán el soporte de las escobillas y la base en donde se montará la cámara de visión nocturna. La figura 24-2 muestra los respectivos diseños de estas piezas en Solid Works.

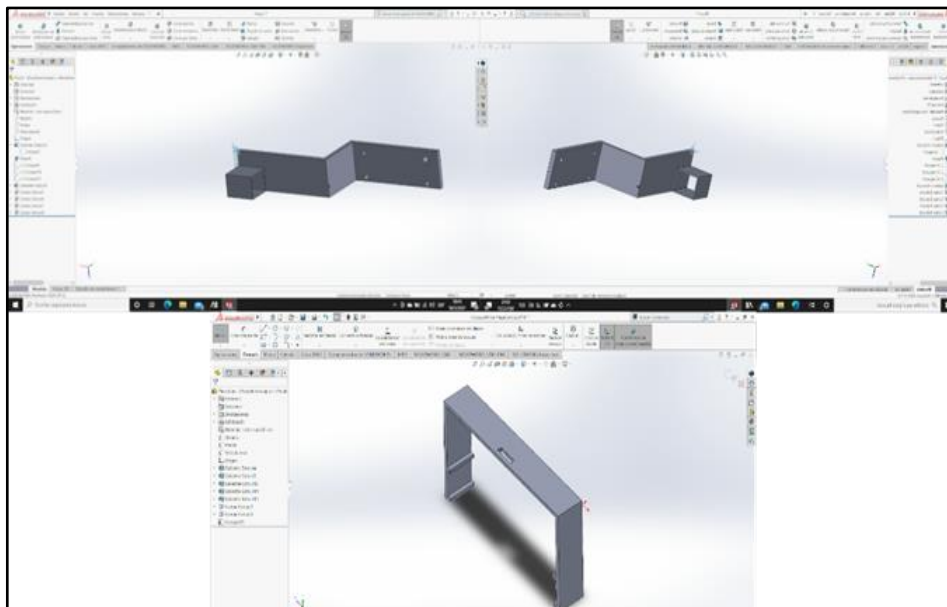


Figura 24-2: Diseño de brazos para escobillas y soporte para cámara

Realizado por: Núñez, Alex, 2022.

Por otro lado, las escobillas se fabrican a base de botellas como escobas recicladas, tal como se aprecia en la figura 25-2 y se adaptan debidamente sus dimensiones tanto al chasis como a las botellas PET a ser recolectadas.



Figura 25-2: Escobillas elaboradas a base de materiales reciclados

Realizado por: Núñez, Alex, 2022.

2.5.2.3 Implementación del módulo recolector

Una vez finalizado el proceso de impresión de los componentes se procede al ensamblarlos de acuerdo con el ensamblaje realizado en SolidWorks y que se puede ver en la figura 26-2.




Figura 26-2: Ensamblaje de las piezas del chasis del prototipo

Realizado por: Núñez, Alex, 2022.

Mediante el uso de tornillos M3 se sujeta la RPI a la caja, colocan la batería y el puente h en los socalos al interior de la caja y se introducen los motores de tal manera que sus ejes sobresalgan de la caja para la colocación de las ruedas como se aprecia en la figura 2-26. Adicionalmente se han colocado 2 ruedas locas en la base de la rampa para facilitar la movilidad del módulo

recolector y se ha ensamblado también las escobillas adaptadas a los motores DC colocados en los sócalos correspondientes como también muestra la figura 26-2. Mientras tanto la figura 27-2 muestra el prototipo armado completamente con todo el cableado dentro de la estructura principal y todo debidamente colocado, estando así listo para iniciar con la programación y fase de pruebas.



Figura 27-2: Implementación del módulo recolector

Realizado por: Núñez, Alex, 2022.

2.5.3 Programación

En el siguiente apartado se presenta los diagramas de flujo elaborados para desarrollar la programación del prototipo.

2.5.3.1 Diagrama de flujo de inicialización del sistema

En el gráfico 1-2 se aprecia el algoritmo para la inicialización del sistema, que va desde la declaración de variables, hasta que el sistema esté listo para detectar y recoger objetivos.

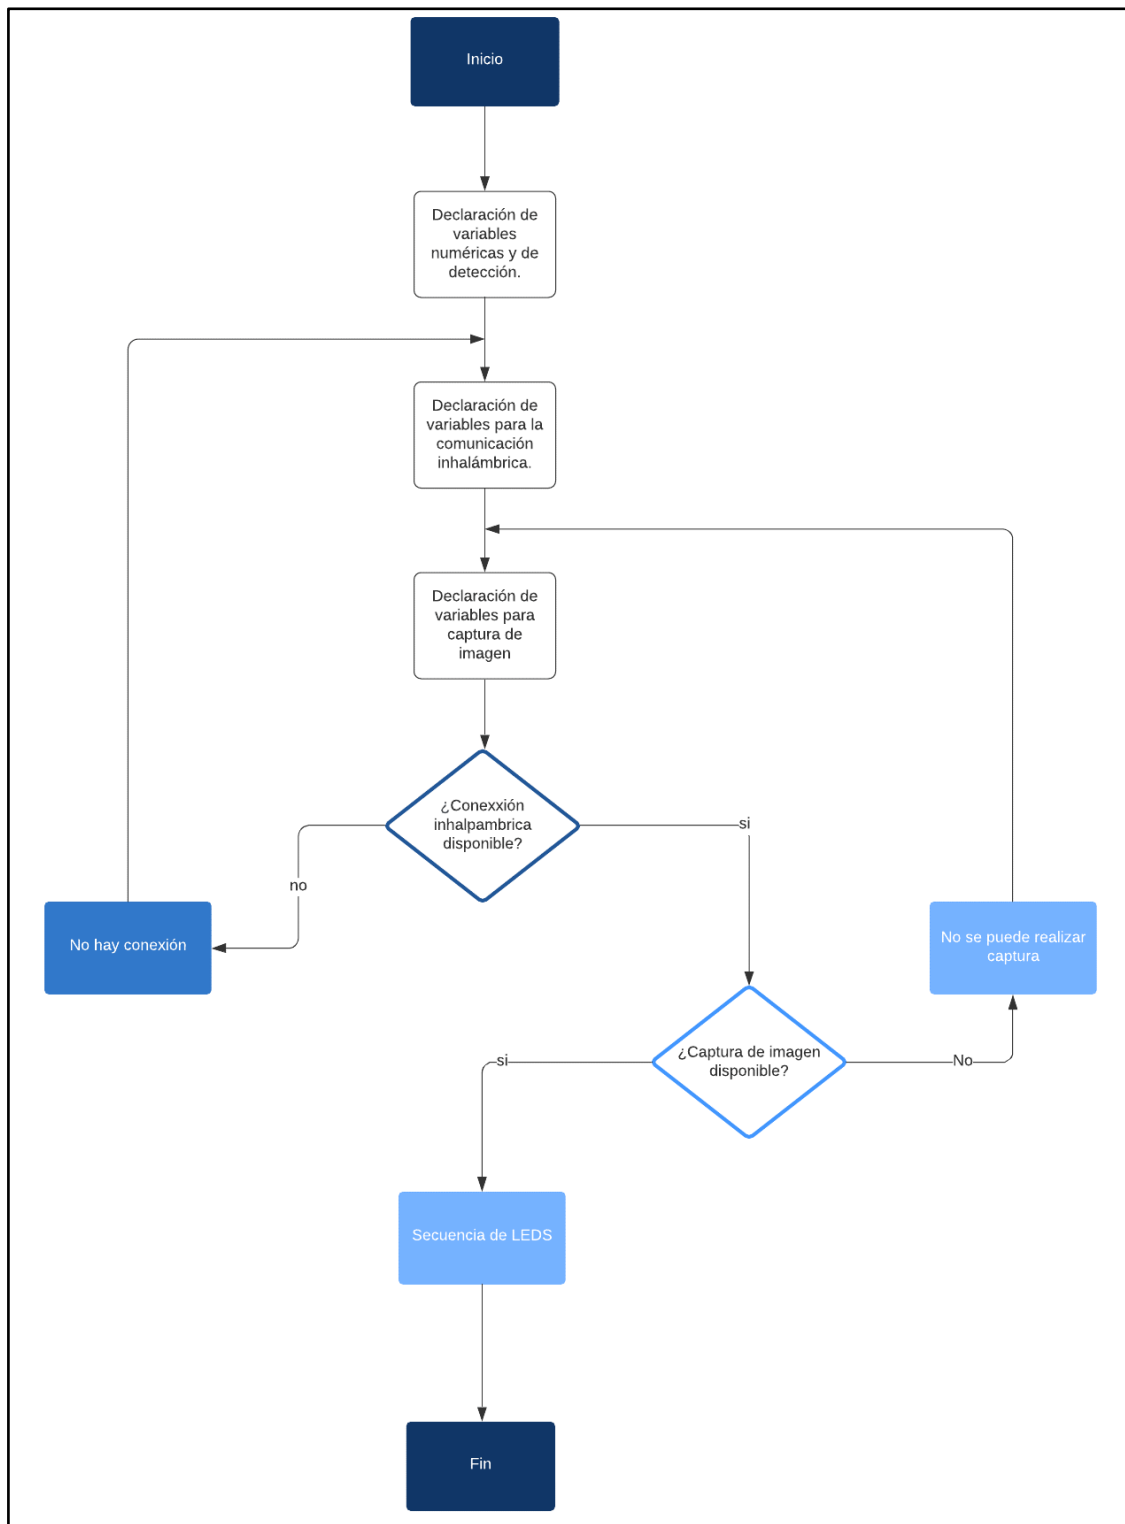


Gráfico 1-2: Diagrama de flujo de la inicialización del sistema

Realizado por: Núñez, Alex, 2022.

2.5.3.2 Diagrama de flujo detección y recolección

El diagrama del gráfico 2-2 muestra el proceso siguiente al anterior, empezando desde la captura de la imagen captada por el módulo de cámara, hasta la recolección de un objetivo detectado.

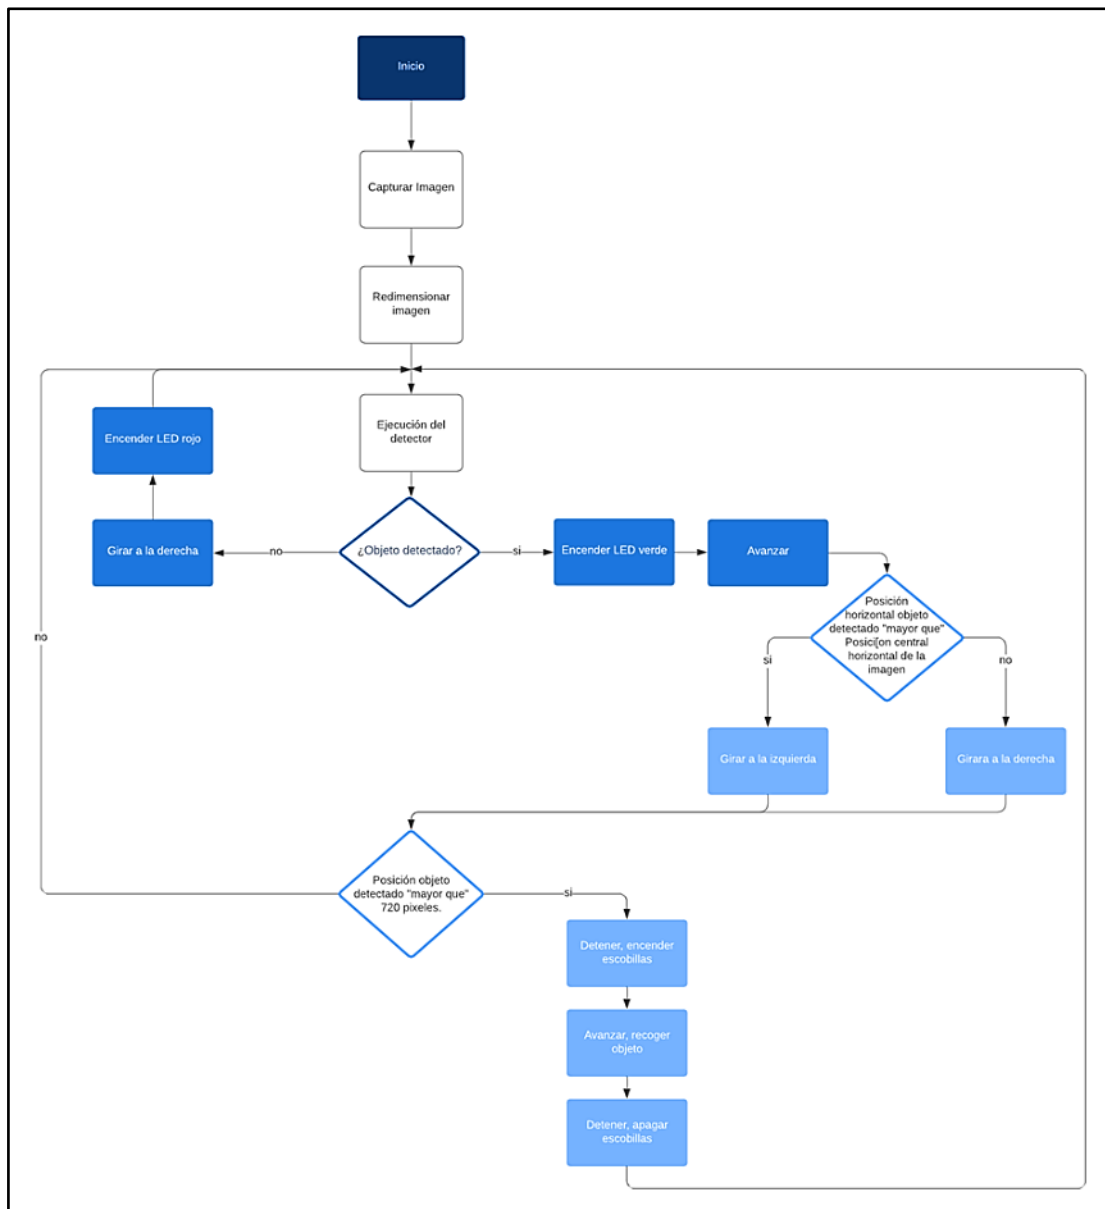


Gráfico 2-2: Diagrama de flujo de la captura de imagen, detección y recolección

Realizado por: Núñez, Alex, 2022.

2.5.4 *Diseño de la interfaz gráfica*

Para el diseño de la interfaz gráfica se ha tomado en cuenta tanto el diseño como la usabilidad, es por eso por lo que se han implementado como se puede ver en la figura 28-2 tres paneles en una misma ventana, pero con todos los recursos necesarios y suficientes para el correcto funcionamiento del prototipo.

En la parte superior de la ventana principal se ha colocado el nombre del proyecto de integración, al cuál para mejor practicidad y diseño se lo ha decidido llamar VOLTY.

En la parte central de este panel se encuentran los botones de inicialización del sistema, el botón conectar se encarga de la vinculación inalámbrica de los módulos de procesamiento y recolección,

cuando esta se haya realizado correctamente se encenderá el led correspondiente. Luego está el botón de inicialización del sistema que se encarga de declarar e inicializar todas las variables correspondientes a la raspberry pi, además de otras variables que se usan luego en la detección y recolección de botellas PET; además, se ha integrado en la parte céntrica de este panel el logo de la carrera a la que pertenece el presente trabajo de titulación.

En la parte inferior del panel central se ha agregado un campo seleccionable que consta de dos opciones: recolección autónoma y recolección asistida, cuyos roles se explican en la descripción de los otros paneles. Es importante mencionar que no se ha agregado una ventana que permita apreciar la vista desde la cámara integrada en el módulo recolector, debido a que, las versiones de appdesigner de Matlab en la que se realizó este trabajo no soporta la vista de video desde la cámara de la raspberry pi, cosa que si lo permite con cámaras web y cámaras IP.

En el panel izquierdo se ha agregado como se puede ver en la figura 28-2 el botón RECOLECTAR que permite al prototipo tanto detectar como recolectar botellas de forma autónoma, acompañado de leds indicadores de cuando se ha detectado y recolectado una botella PET, además del botón DETENER para interrumpir este tipo de recolección y se ha añadido también el logo de la ESPOCH.

En el panel izquierdo como también se puede ver en la figura 28-2 se encuentran botones direccionales para controlar el movimiento del módulo recolector hacia el frente y hacia los lados, se ha agregado de igual manera un botón para encender las escobillas y un botón más para detenerlas, y finalmente e igual que en el otro panel se ha insertado el logo de la institución.

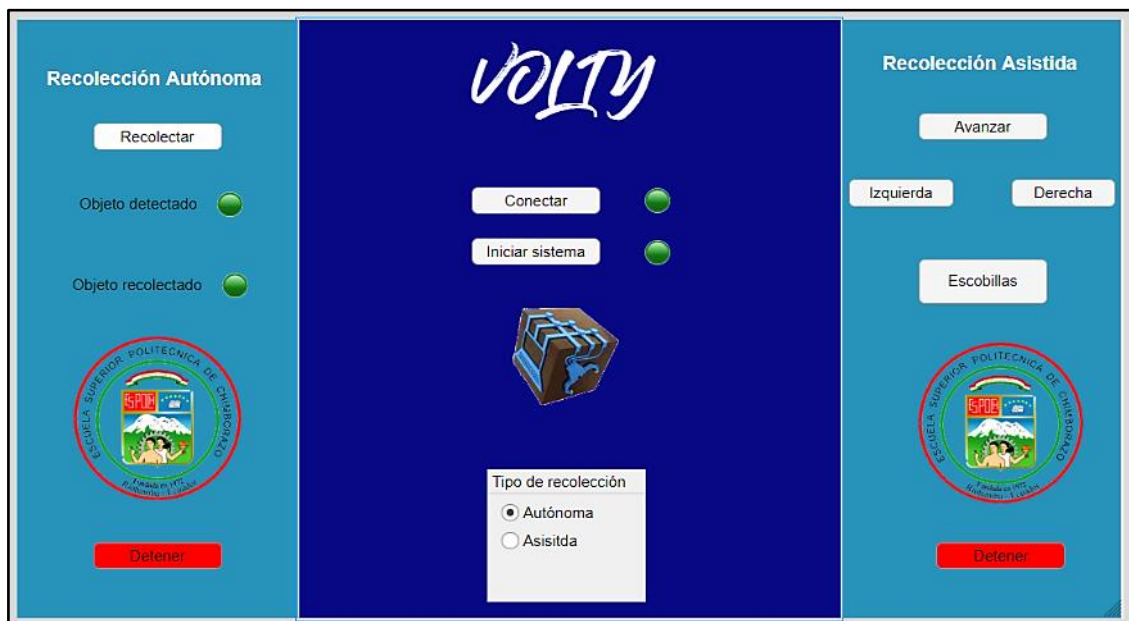


Figura 28-2: Interfaz gráfica del prototipo

Realizado por: Núñez, Alex, 2022.

CAPÍTULO III

3. VALIDACIÓN DEL PROTOTIPO

Para la realización de la validación de los datos obtenidos se realizaron diferentes pruebas en las distintas etapas del sistema, evaluando y tomando en cuenta los requerimientos establecidos para el prototipo VOLTY.

3.1 Tiempo de retardo por procesamiento

Como punto de relevancia para la decisión de cuál algoritmo es el óptimo está el tiempo de procesamiento de las redes entrenadas, es decir, el tiempo que le toma a cada red procesar todas las imágenes que entran al sistema en forma de video. Para esta prueba se hizo uso de los comandos *tic* y *toc* de Matlab que permiten determinar el tiempo entre instrucciones dentro de un programa.

Como paso inicial para la posterior comparación se determinó primero el tiempo que le tomaba a Matlab procesar una imagen sin ningún tipo de procesamiento, después se hizo el mismo procedimiento, pero esta vez pasando cada imagen por las redes entrenadas YOLO v2 y YOLO v3.

Tabla 1-3: Pruebas de retardo por procesamiento con las redes entrenadas

Rango	Tiempo Real		YOLO v2			YOLO v3		
	Nº Ciclos	Promedio de tiempo por imagen (ms)	Nº Ciclos	Promedio de tiempo por imagen (ms)	Retardo (ms)	Nº Ciclos	Promedio de tiempo por imagen (ms)	Retardo (ms)
0-30	222	8,108	217	8,295	0,187	189	9,524	1,416
30-60	225	8	225	8	0,000	225	8	0
60-90	225	8	225	8	0,000	224	8,036	0,036
90-120	224	8,036	224	8,036	0,000	215	8,372	0,336
120-150	225	8	225	8	0,000	200	9	1,000
150-180	225	8	225	8	0,000	194	9,278	1,278
180-210	224	8,036	225	8	-0,036	178	10,112	2,077
210-240	225	8	224	8,036	0,036	177	10,169	2,169
240-270	225	8	225	8	0,000	171	10,526	2,526
270-300	225	8	225	8	0,000	164	10,976	2,976
Promedio	224,5	8,018	224	8,037	0,019	193,7	9,399	1,381

Realizado por: Núñez, Alex, 2022.

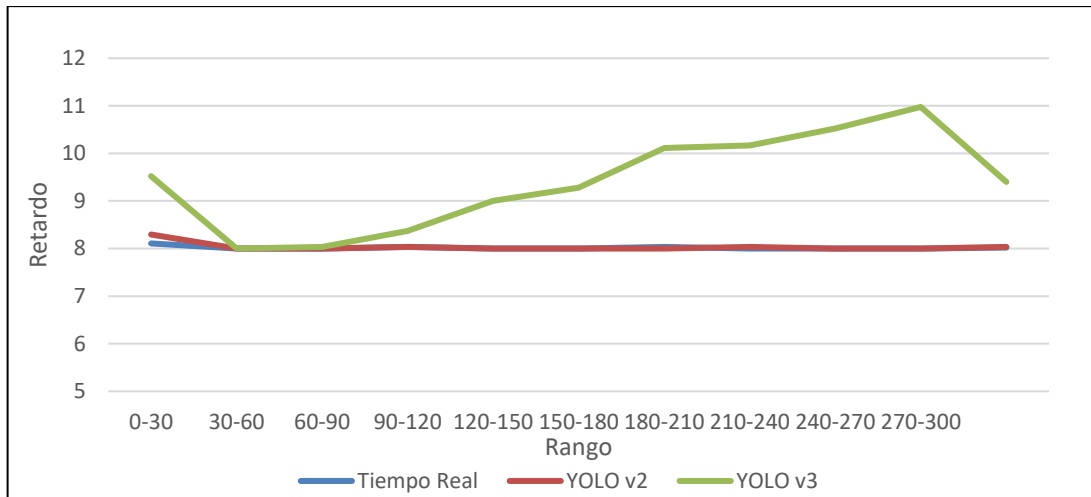


Gráfico 1-3: Comparación de retardo por procesamiento entre YOLO v2 y YOLO v3

Realizado por: Núñez, Alex, 2022.

Como se aprecia en la tabla 1-3 YOLO v2 proporciona de un menor tiempo de retardo además que, es mucho más estable conforme avanza el tiempo del proceso, esto es más visible en el grafico 1-3 en donde se puede diferenciar que el procesamiento de YOLO v2(línea roja) se asemeja mucho más al procesamiento en tiempo real (línea azul) que el procesamiento ejecutado por YOLO v3 (línea verde). En el capítulo anterior se determinó que a YOLO v2 le tomaba más tiempo el proceso de entrenamiento, no obstante, es mucho más eficiente a la hora de la detección en video que es el de verdadero interés para la implementación del prototipo, por lo que se concluye que este será el algoritmo implementado en el prototipo y con el que se harán las pruebas de conexión y detección.

3.2 Retardo por conexión inalámbrica

Para determinar el retardo relacionado con la conexión inalámbrica del sistema, se hizo uso del símbolo del sistema de Windows a través del comando ping como se muestra en la figura 1-3. Este comando es útil para determinar si existe comunicación y el tiempo de esta, entre dos dispositivos.

```

Microsoft Windows [Versión 10.0.19041.804]
(c) 2020 Microsoft Corporation. Todos los derechos reservados.

C:\Users\Edu>ping 192.168.1.20

Haciendo ping a 192.168.1.20 con 32 bytes de datos:
Respuesta desde 192.168.1.20: bytes=32 tiempo=15ms TTL=64
Respuesta desde 192.168.1.20: bytes=32 tiempo=4ms TTL=64
Respuesta desde 192.168.1.20: bytes=32 tiempo=15ms TTL=64
Respuesta desde 192.168.1.20: bytes=32 tiempo=16ms TTL=64

Estadísticas de ping para 192.168.1.20:
    Paquetes: enviados = 4, recibidos = 4, perdidos = 0
              (0% perdidos),
    Tiempos aproximados de ida y vuelta en milisegundos:
        Mínimo = 4ms, Máximo = 16ms, Media = 12ms

C:\Users\Edu>

```

Figura 1-3: Prueba de conexión inalámbrica

Realizado por: Núñez, Alex, 2022.

La tabla 2-3 muestra los resultados de las pruebas realizadas para la determinación del retardo originado la comunicación inalámbrica del prototipo. Se puede apreciar que el tiempo de conexión no varía mucho respecto de la distancia de los dispositivos; luego a este retardo se le añadió el retardo analizado en la tabla 1-3 y se determinó que el promedio de retardo total del sistema es de 13,752 ms dentro del rango de los 15 metros de distancia mencionados al inicio de este capítulo.

Tabla 2-3: Pruebas de retardo por conexión inalámbrica entre módulo de procesamiento y módulo de recolección

Muestra	Distancia (m)	Tiempo de conexión (ms)	Paquetes recibidos	Retardo por procesamiento (ms)	Retardo total (ms)
1	1	12	4	0,019	12,019
2	2	14	4	0,019	14,019
3	3	11	4	0,019	11,019
4	4	10	4	0,019	10,019
5	5	12	4	0,019	12,019
6	6	12	4	0,019	12,019
7	7	15	4	0,019	15,019
8	8	12	4	0,019	12,019
9	9	13	4	0,019	13,019
10	10	14	4	0,019	14,019
11	11	14	4	0,019	14,019
12	12	14	4	0,019	14,019
13	13	19	4	0,019	19,019
14	14	17	4	0,019	17,019
15	15	17	4	0,019	17,019
Promedio		13,733333			13,752

Realizado por: Núñez, Alex, 2022.

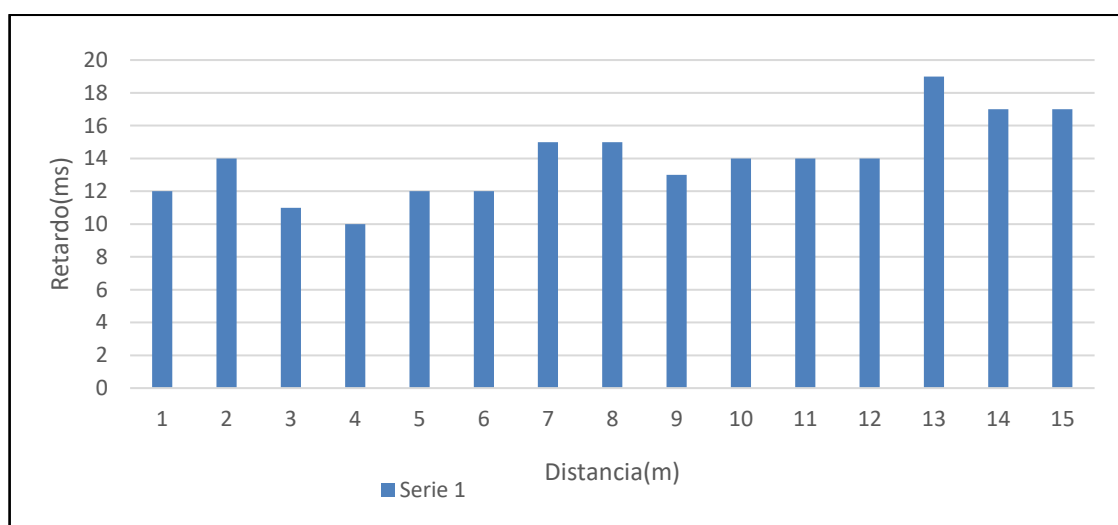


Gráfico 2-3: Retardo por conexión inalámbrica

Realizado por: Núñez, Alex, 2022.

El gráfico 2-3 representa en resumen los resultados obtenidos en la tabla 2-3 y en él se puede observar que hasta los 15 metros de distancia entre el módulo de recolección y de procesamiento el sistema responde de manera estable sin ningún retardo considerable, no obstante, a partir de los 13m el retardo empieza a elevarse no de manera abrupta, pero sí de manera considerable respecto a las distancias anteriores.

3.3 Pruebas de detección

Esta prueba fue realizada para poner a prueba el sistema de detección, considerando los diferentes y variantes niveles de iluminación que pueden presentarse a pleno sol al medio día y sin luminosidad en la noche. La realización de esta prueba se muestra en la figura 2-3.




Figura 2-3: Prueba de detección en ambiente nocturno

Realizado por: Núñez, Alex, 2022.

En esta prueba se utilizaron 3 botellas de plástico y 3 objetos aleatorios como intrusos, y como se mira en la tabla 3-3 el sistema de detección es altamente eficaz, debido a que mostró un porcentaje de precisión de 100%.

Tabla 3-3: Pruebas de detección con YOLO v2

Hora	Botellas de Prueba	Intrusos	Falsos Negativos	Falsos Positivos	Porcentaje de precisión (%)	Porcentaje De falla (%)
5:00 a. m.	3	3	0	0	100	0
6:00 a. m.	3	3	0	0	100	0
7:00 a. m.	3	3	0	0	100	0
8:00 a. m.	3	3	0	0	100	0
9:00 a. m.	3	3	0	0	100	0
10:00 a. m.	3	3	0	0	100	0
11:00 a. m.	3	3	0	0	100	0
12:00 a. m.	3	3	0	0	100	0
1:00 p. m.	3	3	0	0	100	0
2:00 p. m.	3	3	0	0	100	0
3:00 p. m.	3	3	0	0	100	0
4:00 p. m.	3	3	0	0	100	0
5:00 p. m.	3	3	0	0	100	0
6:00 p. m.	3	3	0	0	100	0
7:00 p. m.	3	3	0	0	100	0
8:00 p. m.	3	3	0	0	100	0
9:00 p. m.	3	3	0	0	100	0
10:00 p. m.	3	3	0	0	100	0
Promedio					100	0

Realizado por: Núñez, Alex, 2022.

3.4 Pruebas de recolección

Considerando las condiciones físicas del prototipo que fueron especificadas al principio de este capítulo y que se aprecia en la figura 3-3 se ha considerado colocar para las pruebas entre 3 y 5 objetivos a recolectar e igual rango de distractores, variando tanto el número de objetos a recolectar como el número de intrusos se han obtenido los resultados que se muestran en la tabla 4-3.




Figura 3-3: Prototipo en pruebas de recolección

Realizado por: Núñez, Alex, 2022.

Tabla 4-3: Pruebas de recolección del prototipo

Número de Prueba	Botellas de Prueba	Intrusos	Botellas Recolectadas	Intrusos Recolectados	Porcentaje de precisión (%)	Porcentaje De falla (%)
5:00	3	3	3	0	100	0
6:00	4	4	3	0	87,5	12,5
7:00	5	2	5	0	100	0
9:00	4	1	4	0	100	0
11:00	5	4	5	0	100	0
13:00	4	4	4	0	100	0
15:00	3	3	3	0	100	0
17:00	5	3	4	0	87,5	12,5
18:00	5	4	5	0	100	0
19:00	5	2	5	0	100	0
21:00	4	3	3	0	85,7	14,3
23:00	3	1	3	0	100	0
Promedio					96,7	3,3

Realizado por: Núñez, Alex, 2022.

Como se puede ver el sistema de recolección del prototipo tiene un porcentaje de precisión 97,4% que es un porcentaje muy alto y que lo convierte en un dispositivo confiable. Los resultados obtenidos son mostrados en el gráfico 3-3.

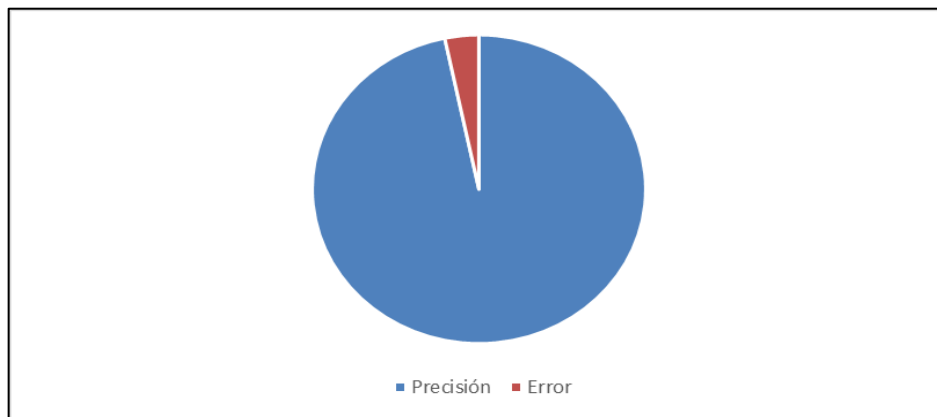


Gráfico 3-3: Precisión de sistema de recolección

Realizado por: Núñez, Alex, 2022.

3.5 Consumo de corriente del prototipo

Para determinar el tiempo de funcionamiento del prototipo se consideran los valores de consumo de corriente de cada elemento del sistema, así como la capacidad de suministro de las baterías de alimentación. Las características de cada elemento fueron especificadas en el capítulo anterior y se muestran en la tabla 5-3.

Tabla 5-3: Consumo de corriente por componente

Descripción	Cantidad*Consumo	Total
Capacidad batería 11 V	1*(2200 mAh)	2200 mAh
Consumo driver l298n	1*(36 mA)	36 mA
Consumo módulo de relé	2*(70 mA)	140 mA
Consumo de motores DC	4*(180 mA)	720 mA
Consumo continuo total		896 mA
Capacidad módulo de batería Raspberry pi	1*(3800 mAh)	3800 mAh
Consumo Raspberry pi	1*(62 mA)	370 mA
Consumo módulo de cámara	1*(256 mA)	256 mA
Consumo continuo total		626 mA

Realizado por: Núñez, Alex, 2022.

Durante las pruebas de recolección se tuvo en funcionamiento el prototipo por más de una hora valor que concuerda con los valores estimados en la tabla, puesto que el sistema que suministra la batería de 11V podría estar en funcionamiento más de 2 horas en valores teóricos y el sistema controlado por el módulo de batería de Raspberry podría estar en funcionamiento más de horas 6 en valores teóricos. Con estos resultados se evidencia que el sistema puede estar en funcionamiento fácilmente por los 30 minutos que fueron especificados en los requerimientos del sistema.

CAPÍTULO IV

4. EVALUACIÓN ECONÓMICA

En la siguiente sección se realiza un análisis de económico que permitirá determinar el precio final del robot reciclador de botellas PET y compararlo con dispositivos similares en el mercado.

4.1 Análisis de costos

Para iniciar con el análisis es preciso en primer lugar detallar el precio de cada uno de los componentes que forman parte del prototipo. En la tabla 1-4 se especifica cada uno de los componentes como su precio estimado en el mercado.

Tabla 1-4: Costos de componentes del prototipo

Componente	Cantidad	Precio Unitario (\$)	Precio Total (\$)
Computador con tarjeta gráfica dedicada	1	1200	1200
Impresión 3D chasis del prototipo	1	50	50
Impresión 3D brazos escobilla	2	5	10
Impresión 3D soporte cámara	1	10	10
Raspberry pi 3B	1	100	100
Tarjeta Micro SD	1	16	16
Cámara visión nocturna	1	50	50
Batería LIPO	1	15	15
Batería de litio	1	10	10
Driver l298n	1	7	7
Optoacoplador 4n25	2	1	2
Motor reductor DC	4	5	20
Materiales de montaje y conexión			30
Total			\$ 1520

Realizado por: Núñez, Alex, 2022.

Como se puede ver el costo del computador es el más alto de todos los componentes del robot, no obstante, debido a sus características inalámbricas y de procesamiento, puede ser usado para controlar más de un robot a la vez, o, por otro lado, se puede considerar en un futuro cargar a la Raspberry pi el control completo del robot, siempre y cuando sus capacidades computacionales así lo permitan, esto abarataría mucho el costo total del robot.

4.2 Relación de costo

Este prototipo está diseñado exclusivamente para la detección y recolección de botellas PET, no obstante, este rango se puede ampliar con el entrenamiento de redes capaces de detectar otro tipo de desechos. En la actualidad existen robot con características parecidas desarrollados en

universidades de Europa y Estados Unidos, pero ninguno es comercial aún. Para que este prototipo llegue a ser comercial demandará de una inversión capaz realizar múltiples mejoras sobre todo en cuanto al diseño mecánico, para que pueda desenvolverse en ambientes mucho más hostiles, con más tiempo de funcionamiento y mejor capacidad de carga.

Debido a que ningún robot de estas características es comercial aún es difícil plantearse un precio fijo sobre la posible competencia, sin embargo, mencionaremos a los robots DustCart y DustClean desarrollados en el marco de la iniciativa "*Tecnología para la sociedad de la información*", de la Unión Europea (DW, 2010), cuyos valores rondan los 5000 dólares.

Tomando en cuenta tanto el valor del prototipo recolector de botellas PET como del DustCart y realizando un análisis comparativo entre estos es claro notar que el recolector de botellas representa un 30,4 % del valor del DustCart, lo cual evidencia el bajo costo del prototipo frente a dispositivos de características similares.

CONCLUSIONES

- Se diseñó e implementó un dispositivo móvil capaz de detectar y recolectar botellas PET reciclables tanto en el día como en la noche.
- La red neuronal encargada de la detección es muy eficiente a la hora de clasificar imágenes, no obstante, a distancias lejanas con objetivos pequeños la red suele tener ciertos falsos negativos y con objetos grandes como cajas a distancias lejanas detecta falsos positivos.
- El prototipo es muy veloz, es por esto por lo que, aun con todos los procesos que ejecuta el sistema como la comunicación inalámbrica tanto de ida como de regreso, la captura de la imagen, la interacción de los actuadores y el procesamiento de la red neuronal, la detección es prácticamente en tiempo real.
- El sistema de recolección es altamente aceptable y aunque no es infalible tiene una efectividad superior al 95% lo que lo hace confiable.
- De acuerdo con las condiciones de diseño el prototipo demanda de una autonomía de 30 minutos no obstante el prototipo puede trabajar más de una hora antes de que se descargue por lo que presenta un 200% de autonomía respecto a la requerida.

RECOMENDACIONES

- Es recomendable entrenar la red neuronal con un set más grande debido a que mientras más imágenes diferentes se utilicen más eficaz resulta la red de detección, es así como una red neuronal para detección de personas que se puede encontrar en la red posee un set de entrenamiento superior a 50 000 imágenes.
- Es recomendable para futuros proyectos mejorar el sistema móvil, para que sea capaz de movilizarse por superficies irregulares y así poder utilizarlo en ambientes como parques o aceras.
- Es recomendable mejorar el sistema de escobillas o a su vez reemplazarlo por un sistema de brazo robótico para elevar la eficiencia de la recolección al 100%.
- Se recomienda entrenar a la red neuronal con otros objetivos como envolturas de dulces y/o vasos plásticos, para hacer así de este un robot más práctico y funcional.
- Se recomienda realizar un estudio de posicionamiento satelital y autonomía energética para que en el futuro sean robot como estos los responsables de recolectar y reciclar desechos en lugares públicos.

BIBLIOGRAFÍA

ALL-SPECS. Huawei HG532E Características. *All-specs*. [En línea] 2018. [Citado el: 11 de Junio de 2021.] <http://es.all-specs.net/model/842410/>.

ARDUINOMODULES. Módulo de relé KY-019 5V - ArduinoModulesInfo. *Arduinomodules*. [En línea] 2020. [Citado el: 01 de Junio de 2021.] <https://arduinomodules.info/ky-019-5v-relay-module/>.

ASUS. ASUS TUF Gaming A15. *Asus*. [En línea] 2020. [Citado el: 13 de Junio de 2021.] <https://www.asus.com/mx/Laptops/For-Gaming/TUF-Gaming/ASUS-TUF-Gaming-A15/>.

BENÍTEZ, Raúl; et al. Inteligencia Artificial Avanzada. *UOC*. [En línea] Universidad Oberta de Catalunya, 2014. [Citado el: 17 de Abril de 2021.] https://books.google.es/books?hl=es&lr=&id=eT7ABAAAQBAJ&oi=fnd&pg=PT4&dq=inteligencia+artificial&ots=9x8Hm64IIk&sig=qkexZbC17rQHELeqkeoTw3t_5sQ.

CAI, Bill; et al. Deep Learning-Based Video System for Accurate and Real-Time Parking Measurement. *IEEE*. [En línea] IEEE Internet of Things Journal, 2019. [Citado el: 11 de Abril de 2021.] <https://ieeexplore.ieee.org/document/8660429>.

CASTELLÓN, Hello. Plásticos oxo-biodegradables vs. Plásticos biodegradables:¿ cuál es el camino? *Udesprocesos*. [En línea] 2010. [Citado el: 14 de Abril de 2021.] http://files.udespocesos.webnode.es/200000042-df18fe0252/1_HELLO_CASTELLON.pdf.

COMPONENTS101. 5V Single-Channel Relay Module. *Components101*. [En línea] 2021. [Citado el: 02 de Junio de 2021.] <https://components101.com/switches/5v-single-channel-relay-module-pinout-features-applications-working-datasheet>.

DW. El robot que recoge la basura. *Dw*. [En línea] 2010. [Citado el: 15 de Julio de 2021.] <https://www.dw.com/es/el-robot-que-recoge-la-basura/a-6003437>.

DYNAMO ELECTRONICS. Baterías LiPo, características y cuidados. *DynamoElectronics*. [En línea] 2019. [Citado el: 04 de Junio de 2021.] <https://www.dynamoelectronics.com/baterias-lipo-caracteristicas-y-cuidados/>.

FANG, Qi; et al. Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. *ScienceDirect*. [En línea] Elsevier, 2018. [Citado el: 25 de Abril de 2021.] <https://www.sciencedirect.com/science/article/abs/pii/S0926580517304429>. 09265805.

FARHADI, Ali; & REDMON, Joseph. YOLO9000: Better, faster, stronger. *IEEE*. [En línea] 30th IEEE Conference, 2017. [Citado el: 15 de Abril de 2021.] <https://doi.org/10.1109/CVPR.2017.690.9781538604571>.

FUKUSHIMA, Kunihiko. Neocognitron: A Hierarchical Neural Network Capable of Visual Pattern Recognition. *ScienceDirect*. [En línea] Elsevier, 1988. [Citado el: 26 de Abril de 2021.] <https://www.sciencedirect.com/science/article/abs/pii/0893608088900147>. 0893-6080.

GANDHI, Rohith. R-CNN, R-CNN rápido, R-CNN más rápido, YOLO - Algoritmos de detección de objetos. *Towardsdatascience*. [En línea] 2018. [Citado el: 28 de Abril de 2021.] <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>.

GIRSHICK, Ross. Fast R-CNN. *GitHub*. [En línea] 2015a. [Citado el: 01 de Mayo de 2021.] <https://github.com/rbgirshick/>.

GIRSHICK, Ross; et al. Rich feature hierarchies for accurate object detection and semantic segmentation Tech report (v5). *Arxiv*. [En línea] 2014b. [Citado el: 28 de Abril de 2021.] <https://arxiv.org/pdf/1311.2524.pdf>.

GITHUB. Mathworks/Raspbian_OS_Setup: Setup the Raspberry Pi Raspbian OS to be compatible with MATLAB and Simulink support package for Raspberry Pi. *GitHub*. [En línea] 2021. [Citado el: 12 de Mayo de 2021.] https://github.com/mathworks/Raspbian_OS_Setup.

HUBOT. Cámara de Infrarrojos para Visión Nocturna Raspberry 5MP 1080p (SKU 516G1). *Hubot*. [En línea] HUBOT Robótica y Electrónica, 2018. [Citado el: 09 de Mayo de 2021.] <https://hubot.cl/product/camara-vision-nocturna-raspberry-pi-3-5mp-1080p-sku-516/>.

IBERBOTICS. Cámara Infrarroja para Raspberry Pi. *Iberbotics*. [En línea] 2021. [Citado el: 08 de Mayo de 2021.] <https://www.iberbotics.com/producto/camara-infrarroja-para-raspberry-pi/>.

INÁCIO, Patrício; & RIEDER, Rafael. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *ScienceDirect*. [En línea] Elsevier, Octubre de 2018. [Citado el: 18 de Abril de 2021.] <https://linkinghub.elsevier.com/retrieve/pii/S0168169918305829>. 01681699.

LAWRENCE, Steve; et al. Face recognition: A convolutional neural-network approach. *IEEE*. [En línea] IEEE Transactions on Neural Networks, 1997. [Citado el: 19 de Abril de 2021.] <https://ieeexplore.ieee.org/document/554195/>. 10459227.

LECUN, Yann; et al. Deep learning. *Nature*. [En línea] Macmillan Publishers Limited, 2015a. [Citado el: 16 de Abril de 2021.] <https://doi.org/10.1038/nature14539>. 14764687.

LECUN, Yann; et al. Efficient BackProp. *Springer link*. [En línea] Springer, 1998b. [Citado el: 26 de Abril de 2021.] https://link.springer.com/chapter/10.1007/3-540-49430-8_2. 978-3-540-49430-0.

LECUN, Yann; et al. Reconocimiento de dígitos escritos a mano con una red de retropropagación. *Nyuscholars*. [En línea] NYU scholars, 1990c. [Citado el: 19 de Abril de 2021.] <https://nyuscholars.nyu.edu/en/publications/handwritten-digit-recognition-with-a-back-propagation-network-2>.

LI, He; et al. Learning IoT in Edge: Deep Learning for the Internet of Things with Edge Computing. *IEEE*. [En línea] IEEE Network, 2018. [Citado el: 10 de Abril de 2021.] <https://doi.org/10.1109/MNET.2018.1700202>.

LOS MEJORES GADGETS. Router Huawei 4G LTE, cómo funciona, características. *Losmejoresgadgets*. [En línea] 2019. [Citado el: 09 de Junio de 2021.] <http://losmejoresgadgets.com/router-huawei-4g-lte-como-funciona-caracteristicas-donde-comprarlo/>.

MAKER ELECTRÓNICO. Driver L298N doble puente H para motores. *MakerElectronico*. [En línea] 2020. [Citado el: 17 de Mayo de 2021.] <https://www.makerelectronico.com/producto/driver-l298n-motores-doble-puente-h/>.

MASSIRIS, Manlio; et al. Detección de equipos de protección personal mediante red neuronal convolucional YOLO. *Spudc*. [En línea] Universidad de Coruña, 2018. [Citado el: 25 de Abril de 2021.] <https://doi.org/10.17979/spudc.9788497497565.1022>.

MATHWORKS. Object Detection Using YOLO v2 Deep Learning. *Mathworks*. [En línea] 2020a. [Citado el: 13 de Mayo de 2021.] https://es.mathworks.com/help/deeplearning/ug/object-detection-using-yolo-v2.html?s_tid=blogs_rc_6.

MATHWORKS. Object Detection Using YOLO v3 Deep Learning. *Mathworks*. [En línea] 2020b. [Citado el: 15 de Mayo de 2021.] <https://la.mathworks.com/help/vision/ug/object-detection-using-yolo-v3-deep-learning.html>.

MATHWORKS. Descripción del producto MATLAB. *Mathworks*. [En línea] 2019c. [Citado el: 11 de Mayo de 2021.] https://es.mathworks.com/help/matlab/learn_matlab/product-description.html.

MENDOZA MENDOZA, Ana Laura; et al. Robot móvil con planeación de trayectorias en un ambiente controlado. *Itcelaya*. [En línea] Tecnológico Nacional de México en Celaya, 2017. [Citado el: 16 de Mayo de 2021.] <http://www.itcelaya.edu.mx/ojs/index.php/pistas/article/view/910>.

MICROSOFT. Procesamiento en tiempo real. *Microsoft*. [En línea] 2018. [Citado el: 10 de Mayo de 2021.] <https://docs.microsoft.com/es-es/azure/architecture/data-guide/big-data/real-time-processing>.

MINISTERIO DEL AMBIENTE. Ecuador incrementó la recolección de Botellas PET en 2012. *Ambiente*. [En línea] Ministerio del Ambiente, Agua y Transición Ecológica, 2012. [Citado el: 22 de Abril de 2021.] <https://www.ambiente.gob.ec/ecuador-incremento-la-recoleccion-de-botellas-pet-en-2012/>.

NAYLAMPMECHATRONICS. Driver Puente H L298N 2A. *Naylampmechatronics*. [En línea] 2021. [Citado el: 18 de Mayo de 2021.] <https://naylampmechatronics.com/drivers/11-driver-puente-h-l298n.html>.

NOVOA PELÁEZ, Laura. Basura plástica, belleza oculta. *UCP*. [En línea] Universidad Católica de Pereira, 2012. [Citado el: 15 de Abril de 2021.] <https://repositorio.ucp.edu.co/bitstream/10785/741/1/completo.pdf>.

OCAÑA, Angel. Diseño de prototipo electrónico para la interacción emocional de personas no videntes. *Epoch*. [En línea] 2017. [Citado el: 06 de Mayo de 2021.] <http://dspace.epoch.edu.ec/handle/123456789/8932>.

PALOMINO, Victor. Premian a "Inca Robot" en concurso internacional de tecnología en Japón. *Andina*. [En línea] 2010. [Citado el: 05 de Mayo de 2021.] <https://andina.pe/agencia/noticia-premian-a-inca-robot-concurso-internacional-tecnologia-japon-289109.aspx>.

PÉREZ ARRIAGA, Edgar; et al. Los sistemas de recolección de residuos sólidos (los métodos y sus aplicaciones). *Revista ciencia UAT*. [En línea] Unidad Académica Multidisciplinaria de Agronomía y Ciencias, 2007. [Citado el: 22 de Abril de 2021.] <https://revistaciencia.uat.edu.mx/index.php/CienciaUat/article/view/472.2007-7521>.

RASPBERRY PI. Camara Raspberry Pi. *Raspberry Pi*. [En línea] 2016. [Citado el: 07 de Mayo de 2021.] <https://www.raspberrypi.org/products/camera-module-v2/>.

REDMON, Joseph; & FARHADI, Ali. YOLO9000: Better, faster, stronger. *Arxiv*. [En línea] arXiv, 2017a. [Citado el: 04 de Mayo de 2021.] <https://arxiv.org/pdf/1612.08242.pdf>. 9781538604571.

REDMON, Joseph; et al. You Only Look Once: Unified, Real-Time Object Detection. *Pjreddie*. [En línea] 2016b. [Citado el: 12 de Abril de 2021.] <http://pjreddie.com/yolo/>.

REN, Shaoqing; et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *Arxiv*. [En línea] 2016. [Citado el: 02 de Mayo de 2021.] <https://arxiv.org/pdf/1506.01497.pdf>.

ROBODACTA. Motorreductor Plastico 1:48 doble eje. *Robodacta*. [En línea] 2020. [Citado el: 15 de Mayo de 2021.] <https://store.robodacta.mx/motores/motorreductores-plastico/motorreductor-b01-1-48-doble-eje/>.

RODRÍGUEZ CONTRERAS, Juan Carlos. Ensayo manejo integral de residuos solidos urbanos domiciliarios en Colombia: mitos y realidades. *Unimilitar*. [En línea] Universidad Militar Nueva Granada, 2015. [Citado el: 20 de Abril de 2021.] <http://hdl.handle.net/10654/7349>.

ROHITH, Gandhi. R-CNN, Fast R-CNN, Faster R-CNN, YOLO - Object Detection Algorithms. *Towardsdatascience*. [En línea] 2018. [Citado el: 03 de Mayo de 2021.] <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>.

SANDOROBOTICS. Batería LiPo Turnigy nano-tech 2200mAh 3S . *Sandorobotics*. [En línea] 2019. [Citado el: 04 de Junio de 2021.] <https://sandorobotics.com/producto/n2200-3s/>.

SOSA, Diana. Volvo ROAR, un recolector de basura autónomo. *Autocosmos*. [En línea] 2016. [Citado el: 05 de Mayo de 2021.] <http://noticias.espanol.autocosmos.com/2016/03/10/volvo-roar-un-recolector-de-basura-autonomo>.

SUAREZ, Arnol; et al. Clasificación automática de coberturas del suelo en imágenes satelitales utilizando redes neuronales convolucionales: Un caso aplicado en Parques Nacionales Naturales de Colombia. *Researchgate*. [En línea] 2016. [Citado el: 30 de Abril de 2021.] https://www.researchgate.net/profile/Andres-Jimenez-13/publication/317226045_Clasificacion_automatica_de_coberturas_del_suelo_en_imagenes_satelitales_utilizando_redes_neuronales_convolucionales_Un_caso_aplicado_en_Parques_Nacionales_Naturales_de_Colombia/.

SUNG BAE, Kim; et al. Evaluación del rendimiento material y estructural del hormigón reforzado con fibra de PET reciclado. *ScienceDirect*. [En línea] Elsevier, 2010. [Citado el: 21 de

Abril de 2021.] <https://www.sciencedirect.com/science/article/abs/pii/S0958946509001668>.
0958-9465.

VÁZQUEZ, Juan; & CONSTABLE, Leticia. RNA-AP: Redes Neurales Artificiales con Aprendizaje Profundo. [En línea] 2018. [Citado el: 10 de Abril de 2021.] <http://sedici.unlp.edu.ar/handle/10915/77385>.

VISTRÓNICA. Módulo L298N para Control de Motores. *Vistronica*. [En línea] 2020. [Citado el: 19 de Mayo de 2021.] <https://www.vistronica.com/robotica/modulo-l298n-para-control-de-motores-detail.html>.

ANEXOS

ANEXO A: DATOS TÉCNICOS DE RASPBERRY PI 4B



Raspberry Pi 4 Model B Datasheet
Copyright Raspberry Pi (Trading) Ltd. 2019

2 Features

2.1 Hardware

- Quad core 64-bit ARM-Cortex A72 running at 1.5GHz
- 1, 2 and 4 Gigabyte LPDDR4 RAM options
- H.265 (HEVC) hardware decode (up to 4Kp60)
- H.264 hardware decode (up to 1080p60)
- VideoCore VI 3D Graphics
- Supports dual HDMI display output up to 4Kp60

2.2 Interfaces

- 802.11 b/g/n/ac Wireless LAN
- Bluetooth 5.0 with BLE
- 1x SD Card
- 2x micro-HDMI ports supporting dual displays up to 4Kp60 resolution
- 2x USB2 ports
- 2x USB3 ports
- 1x Gigabit Ethernet port (supports PoE with add-on PoE HAT)
- 1x Raspberry Pi camera port (2-lane MIPI CSI)
- 1x Raspberry Pi display port (2-lane MIPI DSI)
- 28x user GPIO supporting various interface options:
 - Up to 6x UART
 - Up to 6x I2C
 - Up to 5x SPI
 - 1x SDIO interface
 - 1x DPI (Parallel RGB Display)
 - 1x PCM
 - Up to 2x PWM channels
 - Up to 3x GPCLK outputs

ANEXO B: DATOS TÉCNICOS CÁMARA PI NOIR CAMERA V2

Raspberry Pi Camera v2

Part number: RPI 8MP CAMERA BOARD



- 8 megapixel camera capable of taking photographs of 3280 x 2464 pixels
- Capture video at 1080p30, 720p60 and 640x480p90 resolutions
- All software is supported within the latest version of Raspbian Operating System

The Camera v2 is the new official camera board released by the Raspberry Pi foundation.

The Raspberry Pi Camera Module v2 is a high quality 8 megapixel Sony IMX219 image sensor custom designed add-on board for Raspberry Pi, featuring a fixed focus lens. It's capable of 3280 x 2464 pixel static images, and also supports 1080p30, 720p60 and 640x480p60/90 video. It attaches to Pi by way of one of the small sockets on the board upper surface and uses the dedicated CSI interface, designed especially for interfacing to cameras.

- 8 megapixel native resolution sensor-capable of 3280 x 2464 pixel static images
- Supports 1080p30, 720p60 and 640x480p90 video
- Camera is supported in the latest version of Raspbian, Raspberry Pi's preferred operating system

The board itself is tiny, at around 25mm x 23mm x 9mm. It also weighs just over 3g, making it perfect for mobile or other applications where size and weight are important. It connects to Raspberry Pi by way of a short ribbon cable.

The high quality Sony IMX219 image sensor itself has a native resolution of 8 megapixel, and has a fixed focus lens on-board. In terms of still images, the camera is capable of 3280 x 2464 pixel static images, and also supports 1080p30, 720p60 and 640x480p90 video.

Applications

- CCTV security camera
- motion detection
- time lapse photography

ANEXO C: ESQUEMA DE CONEXIÓN MÓDULO L298N

L298N Dual H-Bridge Motor Driver

This dual bidirectional motor driver, is based on the very popular L298 Dual H-Bridge Motor Driver Integrated Circuit. The circuit will allow you to easily and independently control two motors of up to 2A each in both directions. It is ideal for robotic applications and well suited for connection to a microcontroller requiring just a couple of control lines per motor. It can also be interfaced with simple manual switches, TTL logic gates, relays, etc. This board equipped with power LED indicators, on-board +5V regulator and protection diodes.

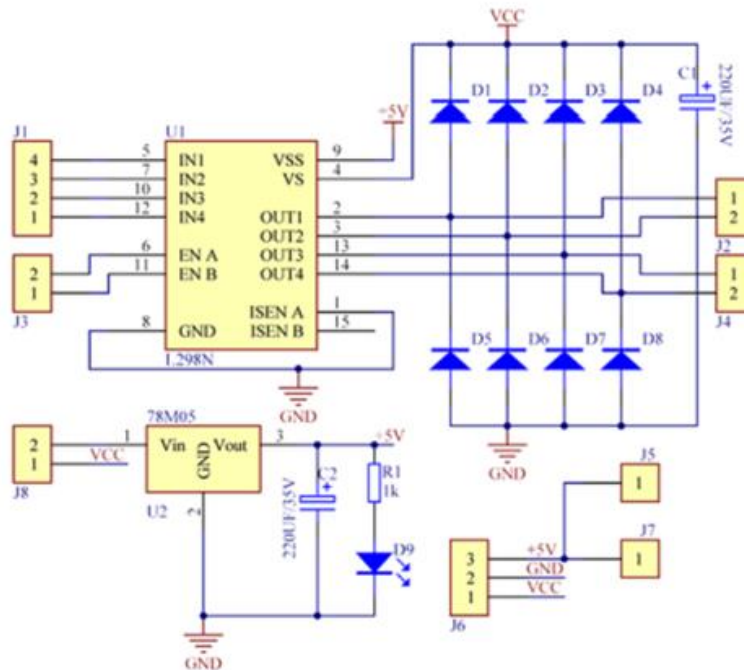


SKU: MDU-1049

Brief Data:

- Input Voltage: 3.2V-40Vdc.
- Driver: L298N Dual H Bridge DC Motor Driver
- Power Supply: DC 5 V - 35 V
- Peak current: 2 Amp
- Operating current range: 0 ~ 36mA
- Control signal input voltage range :
 - Low: $-0.3V \leq V_{in} \leq 1.5V$.
 - High: $2.3V \leq V_{in} \leq V_{ss}$.
- Enable signal input voltage range :
 - Low: $-0.3 \leq V_{in} \leq 1.5V$ (control signal is invalid).
 - High: $2.3V \leq V_{in} \leq V_{ss}$ (control signal active).
- Maximum power consumption: 20W (when the temperature $T = 75^\circ C$).
- Storage temperature: $-25^\circ C \sim +130^\circ C$.
- On-board +5V regulated Output supply (supply to controller board i.e. Arduino).
- Size: 3.4cm x 4.3cm x 2.7cm

Schematic Diagram:



ANEXO D: PROGRAMACIÓN DEL PROTOTIPO

```
%Inicio y configuracion de variables
clear;
clc;
mypi = raspi();
myCam = cameraboard(mypi, 'Resolution', '1024x768');
SP = 512;
PMV = 384;
ErrorA = 0;
VN = 0.7;
VN1 = 0.7;
data = load('C:\Users\Edu\Documents\Deep
Learning\YOLOv2Botellas\detector_afinado.mat');
detector = data.detector;
b = 0;

pwm = 0;
pwm1 = 0;
configurePin(mypi, 21, 'PWM');
writePWMDutyCycle(mypi, 21, pwm)
writePWMFrequency(mypi, 21, 2000);

configurePin(mypi, 20, 'PWM');
writePWMDutyCycle(mypi, 20, pwm)
writePWMFrequency(mypi, 20, 2000);

flag = 1;

%% Apagado de todos los leds
writeDigitalPin(mypi, 17, 1)
writeDigitalPin(mypi, 27, 1)
writeDigitalPin(mypi, 22, 1)
configurePin(mypi,13,'DigitalInput')
% Ciclo de encendido led
writeDigitalPin(mypi, 17, 0)
pause(0.5)
writeDigitalPin(mypi, 17, 1)
writeDigitalPin(mypi, 22, 0)
pause(0.5)
writeDigitalPin(mypi, 22, 1)
writeDigitalPin(mypi, 27, 0)
pause(0.5)
writeDigitalPin(mypi, 27, 1)
pause(0.5)
writeDigitalPin(mypi, 27, 0)
configurePin(mypi,13,'DigitalOutput')

while flag
    % Leer y mostrar imagen
    bbox = 0;
    temp = 0;
    tic
    mySnap = snapshot(myCam);
    [bbox,scores] = detect(detector,mySnap);
    TF = isempty(bbox);
    h = 0;
    while TF == 1
        if h == 0
```

```

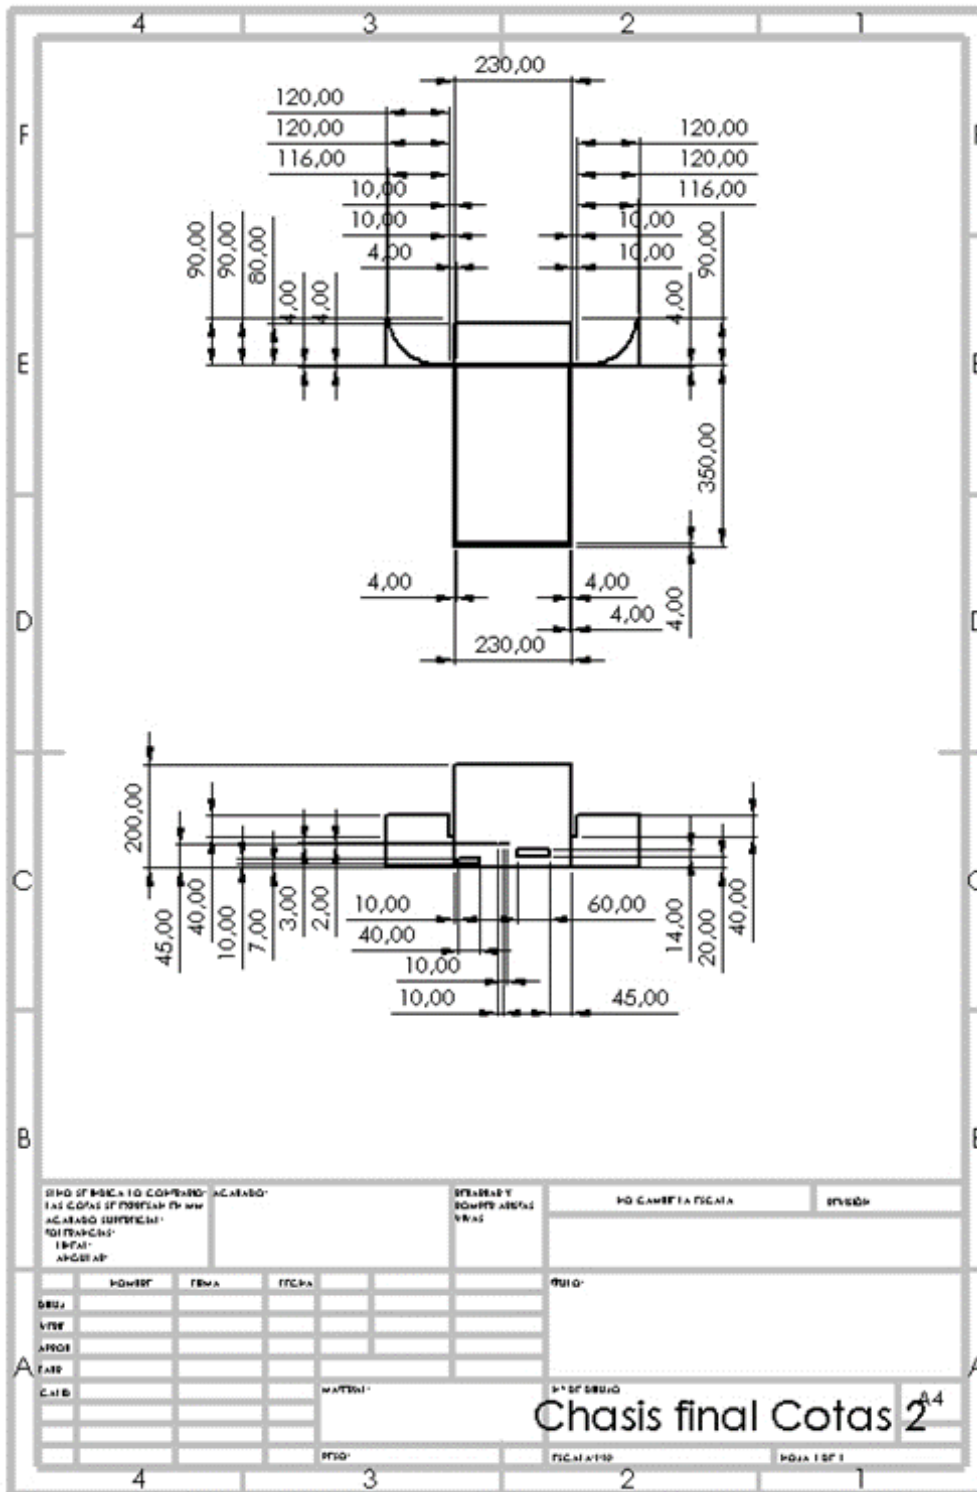
writePWMDutyCycle(mypi, 21, 0)
writePWMDutyCycle(mypi, 20, 0)
end
mySnap = snapshot(myCam);
[bbbox,scores] = detect(detector,mySnap);
TF = isempty(bbbox);
imageOut = insertObjectAnnotation(mySnap,'rectangle', bbbox,
'Botella');
imshow(imageOut);
title('Detectando Botellas');
hold on
drawnow
temp = toc;
if temp > 3
    pwm = 0;
    pwm1 = 0.75;
    writePWMDutyCycle(mypi, 21, pwm1)
    writePWMDutyCycle(mypi, 20, pwm)
end
h = h + 1;
end
%%
%%Si se detectan botellas
if bbbox ~= 0
writeDigitalPin(mypi, 27, 1)
writeDigitalPin(mypi, 17, 0)
%Calculo de punto medio de objetivo
LatSup = bbbox(1);
VertSup = bbbox(2);
LatInf = bbbox(1)+ bbbox(3);
VertInf = bbbox(2)+ bbbox(4);
PML0 = (LatSup + LatInf)/2;
%Calculo de errores y definición de valores de control
ErrorAbs = PML0 - SP;
Error = abs(ErrorAbs)/SP;
Der = Error - ErrorA;
Int = Error + ErrorA;
Control = 0.18*(Error) + 0.1*(Der) + 0.1*(Int);
if VertInf > 720
    pwm = 0;
    pwm1 = 0;
    writePWMDutyCycle(mypi, 21, pwm1)
    writePWMDutyCycle(mypi, 20, pwm)
else
if ErrorAbs > 0
%Encendido de LED y configuración de PWM
    pwm = VN + Control;
    if pwm > 1
        pwm = 1;
    end
    pwm1 = VN1;
    writePWMDutyCycle(mypi, 20, pwm)
    writePWMDutyCycle(mypi, 21, pwm1)
else
    pwm1 = VN1 + Control;
    if pwm1 > 1
        pwm1 = 1;
    end
    pwm = VN;
    writePWMDutyCycle(mypi, 20, pwm)
    writePWMDutyCycle(mypi, 21, pwm1)
end
end
end

```

```
    end
    end
    bboxes = [LatSup, LatInf, VertSup, VertInf];
    ErrorA = Error;
    b = 0;
else
    if b == 0
        writeDigitalPin(mypi, 27, 0)
        writeDigitalPin(mypi, 17, 1)
        pwm = 0;
        pwm1 = 0;
        writePWMDutyCycle(mypi, 21, pwm1)
        writePWMDutyCycle(mypi, 20, pwm)
        b = b+1;
    else


        end
    end
    imageOut = insertObjectAnnotation(mySnap, 'rectangle', bbox,
'Botella');
    imshow(imageOut);
    title('Detectando Botellas');
    hold on
    drawnow

end
```



**ESCUELA SUPERIOR POLITÉCNICA DE
CHIMBORAZO**



**DIRECCIÓN DE BIBLIOTECAS Y RECURSOS DEL
APRENDIZAJE**

UNIDAD DE PROCESOS TÉCNICOS

REVISIÓN DE NORMAS TÉCNICAS, RESUMEN Y BIBLIOGRAFÍA

Fecha de entrega: 10 / 02 / 2022

INFORMACIÓN DEL AUTOR/A (S)
Nombres – Apellidos: ALEX EDUARDO NÚÑEZ NÚÑEZ
INFORMACIÓN INSTITUCIONAL
Facultad: INFORMÁTICA Y ELECTRÓNICA
Carrera: ELECTRÓNICA Y AUTOMATIZACIÓN
Título a optar: INGENIERO EN ELECTRÓNICA Y AUTOMATIZACIÓN
f. Analista de Biblioteca responsable: Lcdo. Holger Ramos, MSc.



0074-DBRA-UPT-2022