

	GESTIÓN DE SERVICIOS ACADÉMICOS Y BIBLIOTECARIOS		CÓDIGO	FO-GS-15	
			VERSIÓN	02	
	ESQUEMA HOJA DE RESUMEN			FECHA	03/04/2017
				PÁGINA	1 de 1
ELABORÓ		REVISÓ	APROBÓ		
Jefe División de Biblioteca		Equipo Operativo de Calidad	Líder de Calidad		

RESUMEN TRABAJO DE GRADO

AUTOR(ES): NOMBRES Y APELLIDOS COMPLETOS

NOMBRE(S) DANNA MARCELA APELLIDOS: ORTÍZ FONSECA

FACULTAD: INGENIERÍA

PLAN DE ESTUDIOS: INGENIERÍA ELECTRÓNICA

DIRECTOR:

NOMBRE(S): SERGIO ALEXANDER APELLIDOS: CASTRO CASADIEGO

TÍTULO DEL TRABAJO (TESIS): IDENTIFICACIÓN Y CLASIFICACIÓN DE RESIDUOS SÓLIDOS MEDIANTE PROCESAMIENTO DE IMÁGENES E INTELIGENCIA ARTIFICIAL

Actualmente en Colombia, el incremento exponencial de la cantidad de residuos que cada individuo del hogar produce diariamente causa que los vertederos destinados para esto se encuentren a punto de cumplir con su vida útil, esto se debe a que un 78% de los colombianos no saben reciclar. Con el propósito de proponer una estrategia para apoyar en la solución de esta problemática, se elabora un algoritmo que tiene como propósito ayudar a las personas del sector de reciclaje, hogares e industrias con la identificación y clasificación de los residuos producidos por ellos. Este algoritmo, se realizó mediante técnicas basadas en aprendizaje profundo, en donde se encuentran tres tipos de modelos: denso, convolucional y convolucional con Drop Out. En estos modelos se aplican dos estados de activación que son sigmoideal y ReLu, y a su vez transforman imágenes de distintos tamaños a uno solo de 200x200 para una mejor lectura de los pixeles y se transforman a escalas de grises para una mejor obtención de los bordes. Como resultado, se obtienen precisiones del 81.7%, 78.9% y 78.7%, debido al entrenamiento y validación de 19.824 imágenes que fueron tomadas como muestra en la ciudad de Cúcuta, Colombia.

PALABRAS CLAVES: DETECCIÓN, RESIDUOS SÓLIDOS, APRENDIZAJE PROFUNDO, CONVOLUCIÓN, CONJUNTO DE DATOS

CARACTERÍSTICAS:

PÁGINAS: 116

ILUSTRACIONES: 41

PLANOS: 0

CD ROOM: 0

IDENTIFICACIÓN Y CLASIFICACIÓN DE RESIDUOS SÓLIDOS MEDIANTE
PROCESAMIENTO DE IMÁGENES E INTELIGENCIA ARTIFICIAL

DANNA MARCELA ORTIZ FONSECA

UNIVERSIDAD FRANCISCO DE PAULA SANTANDER

FACULTAD DE INGENIERÍA

PLAN DE ESTUDIOS DE INGENIERÍA ELECTRÓNICA

SAN JOSÉ DE CÚCUTA

2023

IDENTIFICACIÓN Y CLASIFICACIÓN DE RESIDUOS SÓLIDOS MEDIANTE
PROCESAMIENTO DE IMÁGENES E INTELIGENCIA ARTIFICIAL

DANNA MARCELA ORTIZ FONSECA

Trabajo de grado para optar por el título de Ingeniera Electrónica

DIRECTOR:

Ing. MSc. SERGIO ALEXANDER CASTRO CASADIEGO

Codirector:

Ing. CARLOS VICENTE NIÑO RONDÓN

UNIVERSIDAD FRANCISCO DE PAULA SANTANDER

FACULTAD DE INGENIERÍA

PLAN DE ESTUDIOS DE INGENIERÍA ELECTRÓNICA

SAN JOSÉ DE CÚCUTA

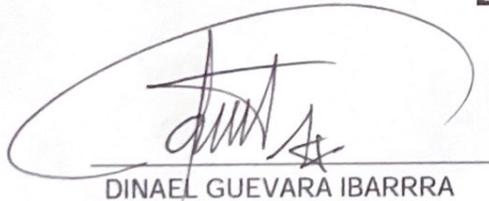
2023

ACTA DE SUSTENTACIÓN DE UN TRABAJO DE GRADO

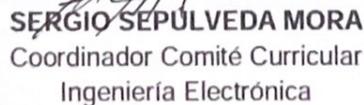
Fecha: CÚCUTA, 20 DE JUNIO DE 2023
Hora: 17:00
Lugar: EDIFICIO CREAD SALON SC301
Plan de Estudios: INGENIERÍA ELECTRÓNICA
Título del trabajo de grado: "IDENTIFICACIÓN Y CLASIFICACIÓN DE RESIDUOS SÓLIDOS MEDIANTE PROCESAMIENTO DE IMÁGENES E INTELIGENCIA ARTIFICIAL"
Jurados: DINAEL GUEVARA IBARRRA, IE.PhD
MARIO JOAQUIN ILLERA BUSTOS, IE.MSc
Director: SERGIO ALEXANDER CASTRO CASADIEGO, IE MSc
Codirector: CARLOS VICENTE NIÑO RONDON, IE.

Nombre del Estudiante: DANNA MARCELA ORTIZ FONSECA
Código: 1161465
Calificación: 5,0 (Cinco, Cero)

LAUREADA


DINAEL GUEVARA IBARRRA


MARIO JOAQUIN ILLERA BUSTOS


SERGIO SEPÚLVEDA MORA
Coordinador Comité Curricular
Ingeniería Electrónica

Dedicatorias

Este logro va dedicado a mi madre Margarita Fonseca, mi hermano James Ortíz y mi pequeña sobrina Laia Ortíz, pero en especial va dedicado a mi abuela María Dolores Morales, quien desde niña me enseñó lo que es el amor y la perseverancia.

Es necesario recordar y dedicarle este logro a aquellas personas que hoy no están presente, pero desde el cielo me cuidan, por eso, este logro se lo dedico a mi padre James Ortíz, mi tía Mónica Ortíz, mi sobrino Izan Ortíz y a una de mis mejores amigas Karla Estupiñán.

Danna Marcela Ortíz Fonseca

Agradecimientos

En primer lugar, quiero agradecer a Dios y la virgen María por permitirme cumplir mis sueños y metas. A mi madre Margarita Fonseca, mi hermano James Ortíz y mi abuela María Dolores Morales por apoyarme en cada paso de mi vida. A mis amigos Jorge Galvis, Christian Álvarez y Reinaldo Velásquez, quienes me ayudaron esta etapa en la universidad y en la vida. En segundo lugar, a mis amigas Isabella Quintero, Alejandra Gómez, Wendy Veloza, Paula Guarín quienes me escucharon y apoyaron día a día.

Al ingeniero Sergio Alexander Castro, director del proyecto de grado, agradezco todo su apoyo y consejos, además por siempre creer y confiar en mi durante el transcurso de este proyecto. Al ingeniero Carlos Vicente Niño, quien fue un gran apoyo y disposición para lograr conseguir esta meta. Al ingeniero Dinael Guevara Ibarra, director del Grupo de Investigación y Desarrollo en Electrónica y Telecomunicaciones, por permitirme pertenecer en el grupo de investigación en donde realicé el proyecto.

Tabla de contenido

Resumen	15
Introducción	16
1. Descripción del proyecto	18
1.1. Planteamiento del problema	18
1.2. Justificación	19
1.2.1. Beneficios tecnológicos	20
1.2.2. Beneficios económicos	20
1.2.3. Beneficios sociales	20
1.2.4. Beneficios institucionales	21
1.3. Objetivos	22
1.3.1. Objetivo general	22
1.3.2. Objetivos específicos	22
1.4. Limitaciones y delimitaciones	23
1.4.1. Limitaciones	23
1.4.2. Delimitaciones	23
2. Marco referencial	24
2.1. Antecedentes	24
2.2. Marco teórico	33
2.2.1. Contaminación ambiental	33

2.2.2.	Contaminación natural	33
2.2.3.	Contaminación artificial	34
2.2.4.	Clasificación de los residuos	34
2.2.5.	Inteligencia artificial (IA)	38
2.2.6.	Procesamiento de imágenes digitales	38
2.2.7.	Modelamiento de Redes Neuronales	40
2.2.8.	Librerías	45
2.2.9.	Conjunto de datos	46
2.2.10.	Raspberry Pi 4	47
2.3.	Marco legal	47
3.	Diseño metodológico	49
3.1.	Recopilación de información	49
3.2.	Selección de tecnologías y zonas	49
3.3.	Diseño del algoritmo	50
3.4.	Pruebas de funcionamiento	50
4.	Resultados	52
4.1.	Estado del arte y selección de tecnologías	52
4.2.	Selección de software	55
4.3.	Selección de la tecnología de hardware	59
4.4.	Visión computacional para identificación y clasificación de residuos	63

4.4.1.	Algoritmo propuesto para redimensión, etiquetado y cambio de canal.	64
4.4.2.	Redimensión de imágenes	65
4.4.3.	Conversión a escala de grises	66
4.4.4.	Modelo denso	66
4.4.5.	Modelo CNN	67
4.4.6.	Diseño del algoritmo y pruebas de rendimiento	69
4.4.7.	Validación de algoritmo y herramienta de hardware	83
4.4.8.	Clasificación de imágenes	87
4.4.9.	Aciertos en las detecciones	90
4.4.10.	Rendimiento del sistema	94
5.	Conclusiones	99
6.	Recomendaciones	101
7.	Trabajos futuros	102
	Referencias Bibliográficas	103

Lista de figuras

Figura 1. Procesamiento de imágenes.	38
Figura 2. Clasificación de imágenes.	40
Figura 3. Red neuronal de Modelo Denso	43
Figura 4. Esquema general de convolución	44
Figura 5. Referencias bibliográficas por temática.	52
Figura 6. Referencias por año	53
Figura 7. Algoritmo Machine Learning	53
Figura 8. Algoritmo Lógica Difusa	54
Figura 9. Algoritmo de Red Neuronal Artificial	54
Figura 10. Conversión a escala de grises.	66
Figura 11. Representación del proceso de modelo denso para procesamiento de imágenes.	67
Figura 12. Representación del proceso de modelo convolucional para procesamiento de imágenes.	67
Figura 13. Representación del proceso de modelo convolucional con Drop Out para procesamiento de imágenes.	68
Figura 14. Metodología del algoritmo.	69
Figura 15. Extracción de características.	70
Figura 16. Algoritmo propuesto para entrenamiento y validación.	72
Figura 17. Algoritmo propuesto para la predicción.	73
Figura 18. Algoritmo de identificación y clasificación de residuos sólidos	74

Figura 19. Grafica de entrenamiento y validación de residuos de cartón y residuos de papel.	76
Figura 20. Grafica de función de perdidas en el entrenamiento de cartón y de papel.	77
Figura 21. Grafica de entrenamiento y validación de residuos de metal y residuos de vidrio.	78
Figura 22. Grafica de función de perdidas en el entrenamiento de residuos de metal y residuos de vidrio	80
Figura 23. Grafica de entrenamiento y validación de residuo biológico y residuo plástico	81
Figura 24. Grafica de función de perdidas en el entrenamiento de residuos biológicos y plásticos.	82
Figura 25. Arquitectura del sistema.	84
Figura 26. Funcionamiento del sistema.	85
Figura 27. Imágenes recolectadas en el sector de la avenida 0 de Cúcuta	85
Figura 28. Imágenes recolectadas en el centro de Cúcuta.	86
Figura 29. Imágenes recolectadas en la avenida libertadores de Cúcuta.	87
Figura 30. Clasificación de la recolección de residuos sólidos.	88
Figura 31. Recolección de residuos sólidos en la avenida 0.	89
Figura 32. Recolección de residuos sólidos en la avenida 6.	89
Figura 33. Recolección de residuos sólidos en la avenida libertadores.	90
Figura 34. Evaluación de la identificación de residuos en la avenida 0.	91
Figura 35. Evaluación de la identificación de residuos en la avenida 6.	93
Figura 36. Evaluación de la identificación de residuos en la avenida libertadores	94

Figura 37. Precisión de clasificación de residuos de la avenida 0.	95
Figura 38. Precisión de clasificación de residuos de la avenida 6ta.	96
Figura 39. Precisión de clasificación de residuos de la avenida libertadores.	97
Figura 40. Conexión de raspberry pi 4 con software PyCharm®	97
Figura 41. Conexiones en raspberry pi 4	98

Índice de tablas

Tabla 1. Parámetros de tecnología de software	55
Tabla 2. Peso de los parámetros a comparar para la selección de software.	56
Tabla 3. Comparación de herramientas de software respecto al tipo de licencia.	56
Tabla 4. Comparación de herramientas de software respecto a la capacidad de integración con entornos de desarrollo.	57
Tabla 5. Comparación de herramientas de software respecto a la disponibilidad de paquetes y librerías.	57
Tabla 6. Comparación de herramientas de software respecto conectividad ofimática.	58
Tabla 7. Comparación de herramientas de software respecto a compatibilidad con inteligencia artificial.	58
Tabla 8. Matriz de decisión para la herramienta de software.	59
Tabla 9. Parámetros de selección de hardware.	59
Tabla 10. Peso de los parámetros a comparar para la selección de software.	60
Tabla 11. Comparación de herramientas de hardware respecto a la velocidad de procesamiento.	60
Tabla 12. Comparación de herramientas de hardware respecto memoria RAM.	61
Tabla 13. Comparación de herramientas de hardware respecto lenguaje de programación soportados.	61
Tabla 14. Comparación de herramientas de hardware respecto a la velocidad de procesamiento gráfico.	62
Tabla 15. Comparación de herramientas de hardware respecto precio y disponibilidad del mercado.	62

Tabla 16. Comparación de herramientas de hardware respecto a las tareas simultaneas.	62
Tabla 17. Matriz de decisión de herramientas de hardware	63
Tabla 18. Algoritmo propuesto para redimensión, etiquetado y cambio de canal.	64
Tabla 19. Colores utilizados para la realización de la gráfica de entrenamiento y validación de residuos biológico y residuos plásticos.	75
Tabla 20. Valores obtenidos en el entrenamiento y validación de los residuos de cartón y residuos de papel	76
Tabla 21. Función de perdidas en el entrenamiento de cartón y de papel	78
Tabla 22. Valores obtenidos en el entrenamiento y validación de los residuos de metal y residuos de vidrio.	79
Tabla 23. Función de perdidas en el entrenamiento residuos de metal y residuos de vidrio.	80
Tabla 24. Valores obtenidos en el entrenamiento y validación de los residuos biológicos y residuos plásticos.	81
Tabla 25. Función de perdidas en el entrenamiento de residuos biológicos y plásticos.	83
Tabla 26. Cantidad de imágenes de residuos sólidos,	87
Tabla 27. Identificación y clasificación de residuos sólidos de la avenida 0.	90
Tabla 28. Identificación y clasificación de residuos sólidos de la avenida 6.	92
Tabla 29. Identificación y clasificación de residuos sólidos de la avenida libertadores.	93

Resumen

Actualmente en Colombia, el incremento exponencial de la cantidad de residuos que cada individuo del hogar produce diariamente causa que los vertederos destinados para esto se encuentren a punto de cumplir con su vida útil, esto se debe a que un 78% de los colombianos no saben reciclar. Con el propósito de proponer una estrategia para apoyar en la solución de esta problemática, se elabora un algoritmo que tiene como propósito ayudar a las personas del sector de reciclaje, hogares e industrias con la identificación y clasificación de los residuos producidos por ellos. Este algoritmo, se realizó mediante técnicas basadas en aprendizaje profundo, en donde se encuentran tres tipos de modelos: denso, convolucional y convolucional con Drop Out. En estos modelos se aplican dos estados de activación que son sigmoïdal y ReLu, y a su vez transforman imágenes de distintos tamaños a uno solo de 200x200 para una mejor lectura de los píxeles y se transforman a escalas de grises para una mejor obtención de los bordes. Como resultado, se obtienen precisiones del 81.7%, 78.9% y 78.7%, debido al entrenamiento y validación de 19.824 imágenes que fueron tomadas como muestra en la ciudad de Cúcuta, Colombia.

Introducción

Es bien sabido que la generación de residuos sólidos destaca cada vez más como una de las principales preocupaciones medioambientales en el mundo, debido a que la gestión de residuos ha sido en su mayoría deficiente y en consecuencia genera riesgos en la salud de los ecosistemas y la salud humana (Masud et al., 2023). A pesar de que los sistemas de gestión de residuos sólidos cobran relevancia y han mejorado sus procesos, lo que ha permitido el reciclaje de materiales, el éxito de estas iniciativas depende de la precisión de la clasificación de estos desechos, lo cual supone un reto por el volumen de materiales que se deben procesar.

Es por esto por lo que el uso de herramientas computacionales para la clasificación de residuos sólidos ha cobrado relevancia a lo largo de los años, basados en los conceptos de visión por ordenador y diferentes técnicas de aprendizaje y entrenamiento de redes neuronales, ya que esta permite optimizar y automatizar el proceso de clasificación de materiales desechados (Nagajyothi et al., 2023; Pandey et al., 2023). Para implementar estas ventajas en sistemas de clasificación, se debe considerar la optimización del modelo para garantizar una inferencia eficiente en los limitados recursos computacionales de los microcontroladores, la preparación del conjunto de datos y las técnicas de aumento adaptadas para la clasificación de residuos, y las consideraciones de implementación de software para una integración perfecta con el entorno de los microcontroladores a utilizar.

Considerando estas ventajas y retos, el objetivo del presente trabajo es diseñar un sistema de clasificación de residuos sólidos basado en redes neuronales convolucionales (CNNs) en una Raspberry Pi 4, el cual pretende identificar correctamente diferentes tipos de residuos sólidos gracias al uso de aprendizaje profundo y la visión por computador. Con estas herramientas, el

proyecto se divide en fases de preprocesamiento de datos, el diseño del sistema considerando la implementación en la Raspberry Pi 4 y el análisis de rendimiento del modelo de clasificación.

El clasificador de desechos sólidos propuesto proporciona una solución escalable y accesible en tiempo real para distintos entornos y magnitudes de desechos para analizar, así como de acercar a las comunidades beneficiadas a la gestión sostenible de residuos, impactando ambientalmente en el entorno donde sea implementado.

1. Descripción del proyecto

1.1. Planteamiento del problema

Desde 1993 la normativa referente al reciclaje se ha venido consolidando en Colombia, por lo cual, en la actualidad se cuenta con 319 organizaciones en el Sistema Único de Información (SUI) de la Superintendencia de Servicios Públicos Domiciliarios, aunque a lo largo de estos años se ha intensificado labores de recolección y reciclaje, el resultado es ineficiente para la cantidad de desechos que son producidos anualmente en el país. Se estima aproximadamente que el 16.5% de 12 millones de toneladas de basura al año son recicladas, teniendo como resultado el reciclaje de 32.000 toneladas (Andesco, 2022)

Por otro lado, la Asociación Nacional de Empresas de Servicios Públicos y Comunicaciones (ANDESCO), realizó un estudio el cual fue anunciado el día Nacional del Reciclador y del Reciclaje, donde se indica que el 78% de los hogares colombianos no reciclan y a su vez dio a conocer que en los próximos 4 años la vida útil de 321 rellenos llegaría a su final, de los cuales solo 192 rellenos están autorizados para la disposición de residuos sólidos en el país (DNP Colombia, 2022). Colombia tiene como propósito alcanzar un reciclaje del 17% y una reducción del 20% de sus emisiones de gases de efecto invernadero para el 2030 (Alojamientos.us.es, 2022), de modo que aún sigue siendo una alerta ambiental debido a la cantidad de basura y de emisiones de gases que son producidas al año. En el 2017 la universidad nacional junto con organizaciones de recicladores estableció que se puede recolectar entre 2.4 a 2.7 toneladas de reciclaje al mes, en cooperación con organizaciones establecidas y con el famoso transporte de la “zorra” en un 49% (Andesco.org.co, 2022).

Por lo anterior, se planteó como alternativa la identificación y clasificación de residuos sólidos mediante procesamiento de imágenes e inteligencia artificial, permitiendo conocer datos sobre el tipo de residuos que encuentran en el hogar, oficina o comercio, por lo cual se planteó el siguiente interrogante:

¿Cómo diseñar un sistema de procesamiento de señales para la identificación y clasificación de residuos sólidos en la ciudad de Cúcuta?

1.2. Justificación

Según un estudio realizado por la organización británica Verisk Maplecroft en el 2019, existe una alerta de “creciente crisis” la cual es producida por la cantidad de plástico que es desechado cada año y se pronostica que para el año 2030 existirá 111 millones de toneladas de plástico que deberán ser tratadas a nivel mundial (DESCONT, 2022). Sin embargo, al hacer un estudio solo en Colombia, por persona se genera aproximadamente un kilogramo de basura al día (Bogota.gov.co, 2022), obteniendo al año 365 kilogramos, al parecer esta cifra no es alarmante, pero, si se toma que en Colombia existen 51.6 millones de habitantes (Statista, 2022), se obtiene un total de 12 millones de basura anualmente por un estudio realizado por la revista la república, de la cual solo el 17 % es reciclada (Diario La República, 2022), el otro 83% llega a los vertederos de basura de cada ciudad, estas estadísticas se deben a que muchos colombianos no saben cuál es la forma correcta de reciclar, por lo cual el presente proyecto tiene como propósito facilitar la identificación y clasificación de residuos sólidos, enfocados en el procesamiento de imágenes e inteligencia artificial. A continuación, se detallan los diferentes beneficios del desarrollo de este proyecto:

1.2.1. Beneficios tecnológicos

La tierra aproximadamente recibe 2.100 millones de toneladas de residuos sólidos al año, de los cuales solo se recicla 323 millones de toneladas lo que corresponde al 16% (Andesco, 2022), por este motivo es primordial que los seres humanos usen y creen herramientas tecnológicas que les ayuden a enfrentar y solucionar el problema, por lo cual, a través del procesamiento digital de imágenes e inteligencia artificial se desarrolló un programa que identifique y clasifique los residuos sólidos.

1.2.2. Beneficios económicos

A partir del año 2021 las empresas u organizaciones de envases y empaques de ventas en Colombia o del exterior deben reciclar el 10% de sus productos, lo cual permitió que estas entidades generen la necesidad de contratación a nivel nacional, de igual forma se reducen los terrenos destinados para la disposición final de los residuos. Cabe resaltar que, de las 319 organizaciones de reciclaje inscritas en el SUI (Andesco, 2022), también existe pequeñas recicladoras clandestinas en las cuales sus mayores clientes son las personas que transportan en la denominada “zorra”, la cual consiste en una carreta que es impulsada con la fuerza humana, esta labor puede ser realizada por cualquier persona lo cual genera empleo e inclusión social.

1.2.3. Beneficios sociales

La realización de la identificación y clasificación de los residuos sólidos suele ser una labor poco reconocida en Colombia, pero es una de las tareas más importantes que cualquier humano podría realizar, al practicar el reciclaje se promueve la conciencia

en relación a la importancia de nuestro planeta, además de traer una pequeña satisfacción personal, incluyendo adultos y niños, el hecho de que cada individuo contribuya desde su hogar reciclando beneficiaria en el ahorro energético y de agua, protección de la biodiversidad, reducción de proliferación de plagas, calentamiento global, reducción de la deforestación (Lifeder, 2022), lo que significaría un aumento en la calidad de vida.

1.2.4. Beneficios institucionales

En la mesa técnica realizada en el año 2.020 con el ministerio de ambiente y desarrollo sostenible, se aprobó el proyecto de ley sobre responsabilidad extendida del productor (REP) (Jurídico, 2022), la cual busca que las empresas más importantes de envases y empaques, reutilicen y reciclen sus propios residuos sólidos, generando beneficio económicos al utilizar materiales que sean amigables con el medio ambiente para la realización de sus productos, además fomentan una mejor calidad de vida, generación de empleo e inclusión social.

Cabe resaltar, que desde el año 2.021 comenzó la implementación obligatoria por parte de los productores, los cuales deben mostrar el primer avance en el cumplimiento de las metas que es el reciclaje del 10% de sus residuos (Andesco.org.co, 2022).

1.3. Objetivos

1.3.1. Objetivo general

Identificar y clasificar los residuos sólidos en la ciudad de Cúcuta mediante procesamiento de imágenes e inteligencia artificial

1.3.2. Objetivos específicos

- Recopilar información sobre identificación y clasificación de residuos sólidos mediante procesamiento de imágenes e inteligencia artificial.
- Seleccionar tecnologías, herramientas y zonas de aplicación para la correcta identificación y clasificación de residuos sólidos.
- Diseñar de un algoritmo para el procesamiento de imágenes e inteligencia artificial.
- Realizar pruebas de funcionamiento y evaluación de la identificación y clasificación obtenido de los residuos sólidos.

1.4. Limitaciones y delimitaciones

1.4.1. Limitaciones

Con el desarrollo del proyecto se planteó una nueva estrategia para la identificación y clasificación de residuos sólidos en San José de Cúcuta, por medio de procesamiento digital de señales e inteligencia artificial, por tanto, se entrenó un sistema con una base de datos y por medio de un software de licencia libre, el cual no cuenta con una metodología de programación establecida. Por otro lado, el procesamiento digital de la imagen se encontrará limitado por la distancia y la cantidad de objetos que se encuentren presentes en la imagen.

1.4.2. Delimitaciones

Espacial: El proyecto se realizó bajo los límites académicos establecidos y así mismo, las pruebas fueron realizadas en los laboratorios de electrónica de la universidad Francisco de Paula Santander en su sede central y las imágenes serán recolectadas en varios sectores de la ciudad de San José de Cúcuta.

Conceptual: El desarrollo del proyecto se encuentra bajo los lineamientos de procesamiento digital de imágenes aplicando inteligencia artificial para la detección y clasificación de residuos sólidos, a través de un banco de imágenes, librerías y software libre.

Temporal: El proyecto se implementó en un periodo de 11 meses.

2. Marco referencial

2.1. Antecedentes

Es posible evidenciar que a nivel internacional que los sistemas de clasificación de residuos sólidos han ganado relevancia, especialmente por el contexto ambiental actual, y como no podía ser de otra forma, la electrónica ha generado diversas estrategias de clasificación utilizando modelos de visión computacional e inteligencia artificial. Un ejemplo de esto es el diseño de un prototipo de caneca inteligente para la clasificación de residuos sólidos en el contexto urbano de Malasia, debido al agotamiento de los vertederos que impulsa un nuevo enfoque eficaz de la gestión de los residuos sólidos, por lo que los investigadores diseñaron un sistema holístico basado en una RaspberryPi, sensores para detección de metales, sensores infrarrojos y detectores de movimiento que permiten al sistema reconocer los desechos que se introducen en la cavidad y separarlos en distintos compartimentos haciendo girar el tambor interior de la caneca con pasos previamente definidos. Este proyecto muestra que se requiere la detección de varias variables en los residuos para poder hacer la clasificación adecuada, mientras que el uso de computadores de placa única (SCB por sus siglas en inglés) hacen que la precisión de la clasificación sea óptima (Ismail et al., 2018).

Por otra parte, K. Sreelakshmi et. al. construyeron un sistema de detección y clasificación de desechos sólidos basados en redes neuronales convolucionales (CNN) con la arquitectura Capsule-Net, separando los desechos plásticos y discriminando los otros tipos. Esto lo realizan con dos conjuntos de datos, donde el primero representa los materiales recogidos en lugares públicos y el conjunto de datos 2 representa los materiales recogidos en entornos privados. La arquitectura propuesta con capsule-Net da una precisión

del 96,3% para el conjunto de datos 1 y del 95,7% para el conjunto de datos. Este sistema muestra que las redes neuronales para la adquisición y procesamiento de datos permite clasificar grandes volúmenes de datos en tiempo real, logrando grandes resultados en el área (Sreelakshmi et al., 2019).

Entre tanto, João Sousa; Ana Rebelo y Jaime S. Cardoso en Brasil realizan un sistema de detección y clasificación basados en técnicas de visión por ordenador con un enfoque de aprendizaje profundo jerárquico para la detección y clasificación de residuos en bandejas de alimentos, el cual conserva las ventajas de los detectores de objetos recientes (como Faster R-CNN) y permite soportar la tarea de clasificación en cajas delimitadoras de mayor resolución, entregando asimismo un nuevo paquete de datos denominado Labeled Waste in the Wild, con fines de investigación y evaluación comparativa. Este modelo fue comparado con técnicas de clasificación convencionales y obtuvo mejores resultados, debido a que, como aporta este proyecto, las redes neuronales convolucionales requieren datasets lo suficientemente grandes para hacer el proceso de entrenamiento y clasificación (Sousa et al., 2019).

Por su parte, en Tailandia, investigadores desarrollaron un sistema de clasificación considerando las directrices del Departamento de Control de la Contaminación de Tailandia para segregación de residuos sólidos. Esto fue logrado con clasificadores de tipos de residuos basados en CNN (VGG-16, ResNet-50, MobileNet V2 y DenseNet-121) para clasificar los tipos de residuos de 9.200 imágenes de residuos sólidos urbanos, identificando cuatro tipos de residuos: residuos generales, residuos compostables, residuos reciclables y residuos peligrosos. Estos pueden identificarse directamente a partir del clasificador de tipo de residuo o derivarse de la clase de artículo de residuo, superando a sus correspondientes clasificadores directos en el experimento y obteniendo una precisión

máxima de 94,86% con el clasificador derivado ResNet-50. Este proyecto permite analizar los cuatro tipos de residuos que se deben clasificar en función de su tipo para las posteriores tareas de reciclaje y tratamiento de desechos (Srinilta & Kanharattanachai, 2019).

Además, Janusz Bobulski and Mariusz Kubanek utiliza un vector de características basado en el gradiente para clasificar las imágenes en cuatro categorías distinguibles: PS, PP, PE-HD y PET. aplicable en una planta de clasificación. Mediante el análisis del histograma, toman la imagen (extraída de la base de datos WaDaBa Database) y la separan en los canales RGB para determinar si la composición de la fotografía corresponde al tipo de plástico que se desea seleccionar. Si bien los resultados obtenidos (alrededor del 84% de precisión) no parecen atractivos en primera instancia, este sistema simplifica considerablemente el análisis y los equipos a utilizar para el análisis de desechos, debido a que no se realizan análisis espectrales que de igual forma consumen grandes recursos computacionales (Bobulski & Kubanek, 2020).

Por su parte, en la Federación Rusa, donde solo se recicla el 10% de los desechos plásticos producidos, utilizan un sistema que aplica dos etapas de separación: la espectrometría y la visión por ordenador. La implantación de un sistema de clasificación de residuos sólidos urbanos mediante el uso de espectrómetros de espectro visible e infrarrojo cercano puede aumentar considerablemente la eficacia del proceso de separación en comparación con la clasificación manual. Para esto implementan la primera fase rápida con espectrometría y la segunda fase fina con métodos ópticos de varios niveles, con un primer nivel de detección de la presencia del objeto en la línea y el análisis del enfoque de la cámara, junto con el segundo es la clasificación del objeto de plástico utilizando la solución conjunta de varias redes neuronales. Se obtienen resultados favorables que muestran que la

combinación de las técnicas ópticas y espectrales por fases permiten rectificar el proceso de clasificación para la reducción de errores (Kokoulin et al., 2020a).

Por otra parte, investigadores combinan varios sistemas CNN de la red TrashNet basados en detectores de disparo único (SSD) y redes de propuesta regional (RPN) que se ejecutan en un sistema robótico autónomo capaz de recoger del suelo los residuos detectados basándose en la retroalimentación de la CNN. Para obtener un sistema fiable basado en redes neuronales preentrenadas, se aumentan los datos en el momento del entrenamiento, seguido de la extracción de características de la CNN y los módulos de predicción de caja para la localización y la clasificación en diferentes tamaños de mapa de características, obteniendo un mejor rendimiento que todos los demás detectores de objetos entrenados en TrashNet u otros conjuntos de datos de basura, con una precisión del 97,63% para SSD y del 95,76% para Faster R-CNN, respectivamente. Este trabajo muestra que la combinación de redes neuronales preexistentes permite obtener sistemas más complejos que logren mejores resultados en la clasificación de desechos y la ejecución de sistemas de reciclaje completos (Melinte et al., 2020).

Entre tanto, en China investigadores realizan un sistema de detección y clasificación de residuos de construcción y demolición (RCD), los cuales representan más del 25% de los residuos sólidos de Hong Kong y cerca del 40% de los de Australia y la UE. esta investigación adopta la tecnología de localización y mapeo simultáneos (SLAM) y el método de segmentación de instancias para que el robot pueda hacer frente a situaciones complejas del lugar, desarrollando una base de datos para entrenar un modelo de visión por ordenador para reconocer tuberías y cables residuales. La viabilidad de los métodos y algoritmos desarrollados se evaluó mediante experimentos de laboratorio y de obra,

mostrando grandes resultados en contextos de obras y escombros de grandes cantidades, logrando la clasificación y transporte de manera eficiente (Z. Wang et al., 2020).

Ya para 2021, científicos desarrollaron un sistema automático de recolección de residuos aplicado en barcos y buques para solucionar el problema plásticos en las masas de agua. Esto consiste en el desarrollo de un mecanismo/modelo de ordenación y clasificación de la basura recogida por el buque/barco incorporando la aplicación de la red neuronal convolucional (CNN) entrenadas con una base de datos con licencia abierta compuesta por 500 imágenes procesadas y editadas a un tamaño estándar de 254x254 y la visión por ordenador con el objetivo de extraer las características de la basura y clasificarlas en biodegradables y no biodegradables con una precisión de predicción superior al 90%, que puede incrementarse aún más aumentando la cantidad del conjunto de datos para el modelo. Este trabajo permite observar que con este tipo de redes se pueden crear sistemas que permitan realizar la clasificación adecuada de residuos sólidos en función de sus características físicas, facilitando la implementación del mismo (V et al., 2021).

Por otra parte, en Bélgica desarrollaron un sistema que permite separar las aleaciones fundidas de las aleaciones forjadas de aluminio (Al) en tiempo real con una cinta transportadora utilizando métodos de aprendizaje de transferencia, como el ajuste fino y la extracción de características. Para este propósito, evaluaron cinco CNN que utilizan imágenes en color y profundidad y métodos de aprendizaje de transferencia, considerando escenarios de fusión temprana de imágenes en color y profundidad de fundición y forjado del aluminio. Para la fusión temprana, los datos se añaden como un canal de entrada extra a la primera capa de convolución de la CNN, y para la fusión tardía, las imágenes se alimentan en dos subredes separadas con la misma arquitectura, donde los parámetros de las capas totalmente conectadas se concatenan en ambas subredes, obteniendo con esto

resultados del 98% de precisión en la clasificación de materiales. Este proyecto muestra la fusión de técnicas de procesamiento de imágenes basado en parámetros físicos de los materiales como una etapa de desarrollo importante para mejorar la precisión de la clasificación. (Díaz-Romero et al., 2021)

Asimismo, en la India implementan un sistema embebido de clasificación de residuos sólidos en una tarjeta Raspberry Pi empleando los programas TensorFlow y OpenCV en función de su aspecto visual. El sistema CV se entrena utilizando módulos contenidos en la API de TensorFlow con dos conjuntos de datos, a saber, la TrashNet y una combinación de la TrashNet y un conjunto de imágenes web, lo que permite obtener permite una mayor un rendimiento de referencia del 90% que baja al 70% cuando se despliega en la plataforma integrada, debido a la calidad de las imágenes tomadas por una cámara integrada para la clasificación en tiempo real, con una velocidad de referencia de 10 cuadros por segundo (FPS) que se reducen a 1.4 FPS en la ejecución de plataforma. Este proyecto permite obtener, con herramientas predefinidas y de licencia abierta, resultados eficientes que se compensan por los costos y el tamaño del sistema clasificador de residuos en la implementación final (Myers & Secco, 2021).

De otra forma, aplicando estos conceptos en escenarios de construcción por la complejidad de la detección y clasificación de escombros que pueden causar daños serios a los ecosistemas, investigadores modelan un sistema de clasificación basados en una base de datos propia desarrollada por los autores con un total de 5.366 imágenes, a las cuales les aplican una técnica de segmentación semántica de última generación, DeepLabv3+, para desarrollar un modelo de segmentación de escombros, para finalmente probar varios hiperparámetros de entrenamiento mediante experimentos ortogonales para calibrar el rendimiento del modelo. El enfoque propuesto logró una Intersección media sobre la Unión

(mIoU) de 0,56 en la segmentación de nueve tipos de materiales/objetos con un rendimiento de tiempo de 0,51 s por imagen, lo que se traduce en un proceso robusto ante la variación de la iluminación y los tipos de vehículos. En este proyecto, es importante resaltar que el uso de una base de datos propia les permitió a los autores caracterizar mejor el entorno de aplicación y obtener mejores resultados (Lu et al., 2022).

Por su parte, otros investigadores crearon un sistema cuyo objetivo principal es clasificar los residuos domésticos mediante visión por ordenador y ordenarlos automáticamente según la normativa de cuatro categorías, proponiendo un novedoso algoritmo de reconocimiento y recuperación de residuos (W2R) en dos etapas, las cuales consisten en entrenar un Modelo de Reconocimiento (RegM) que reconoce los residuos en una de las trece subcategorías y construir el Modelo de Reconocimiento-Recuperación (RevM) que clasifica la subcategoría reconocida en una de las cuatro categorías. Además, entrenaron un un Modelo de Clasificación de Residuos (ClfM) de una etapa como comparación, cuyos resultados, comparados con los de diez voluntarios que clasificaron y ordenaron el mismo conjunto de residuos, muestran que la precisión media del RevM, $94,71\% \pm 1,69$, fue significativamente superior a la del ClfM-VGG, $69,66\% \pm 3,43$, y a la del MS, $72,50\% \pm 11,37$. Este proyecto muestra cómo la implementación y combinación de distintas redes de inteligencia artificial permiten obtener mejores resultados de precisión y velocidad en los procesos (Zhang et al., 2021).

Así mismo, considerando los avances en los sistemas inteligentes de clasificación de residuos sólidos aplicando DSP y visión computacional en Colombia, se observa que es un aspecto que aún no se ha desarrollado lo suficiente en el país, resaltando que Norte de Santander carece de trabajos o productos científicos relacionados con esta temática. Como aporte, se tiene el proyecto desarrollado por investigadores en Córdoba, Colombia, donde

utilizaron la librería ML5.JS que provee algoritmos de aprendizaje, el algoritmo K-Nearest Neighbor para hacer el proceso de selección y clasificación. Este sistema fue embebido en una Raspberry Pi que, junto con otros dispositivos electrónicos, crearon un punto ecológico en el campus universitario capaz de seleccionar los residuos sólidos en tiempo real en función de su composición y posibilidad de reciclaje. Este trabajo, como en otros proyectos anteriormente mencionados, permiten visualizar las posibilidades que tiene el desarrollo de sistemas inteligentes mediante la combinación de redes predefinidas y dispositivos electrónicos (Guevara et al., 2021).

En el departamento de Cauca, desarrollaron un prototipo de punto ecológico inteligente basado en Deep Learning, utilizando la metodología LEAN de Toyota y una arquitectura para la red neuronal basada en MobileNet, NASNetMobile, EfficenteNetB4, DenseNet y ResNet, la cual clasifica los residuos sólidos en orgánicos aprovechables, inorgánicos aprovechables y residuos no aprovechables, que comparan la información recibida por el sistema con la base de datos Zenodo, obteniendo una precisión del 96.66% para imágenes de 128x128 implementada finalmente sobre una Raspberry Pi 3 (Pinto Rodríguez et al., 2021).

En el año 2017 Vu & Kaddoum presentaron un nuevo método de recolección inteligente de residuos con un bajo costo, el cual consiste en la geolocalización de los contenedores de basura para la recolección, clasificación y monitoreo del desperdicio por medio de algoritmos genético (GA) y de regresión logística para predicción y actualización del peso de cada basurero, esto se hizo con el fin de crear nuevas rutas óptimas para la recolección de basura y un bajo consumo de combustible (Vu & Kaddoum, 2017a).

Por otro lado, en el año 2020 Thokrairak et al, realizaron una red neuronal SSD-MobileNet, para la clasificación de botellas plásticas, vidrio y latas de metal, para obtener

una mayor precisión realizaron un entrenamiento de 24.000 pasos y un valor de pérdida del 0.2711, además de una precisión en la clasificación del 95% en botellas de plástico, 82% botellas de vidrio y 86% en latas de metal, demostrando que un dataset amplio y con buen entrenamiento puede ser preciso (Thokrairak et al., 2020a).

Sudha et. al. Diseñaron un método de clasificación automática del medio ambiente en el año 2016, el cual consistía en un reconocimiento automatizado que utiliza un algoritmo de aprendizaje profundo en inteligencia artificial aplicando Deep Learning, para la realización de ello utilizaron librerías de C++, software como Matlab y Python, logrando una clasificación eficaz y automática de desechos biodegradables y no degradables. Se obtuvo como resultado un pseudocódigo en el cual se identifica las etapas por las cuales atraviesa la imagen para la clasificación las cuales son: la toma de fotografías de los objetos, análisis de imágenes con datos entrenados, detección y localización de algoritmo de frontera, predicción e identificación, del cual se extrae una mayor probabilidad de identificación de salida del desecho (Sudha et al., 2016a).

Finalmente, pero no menos importante, en Indonesia en el año 2020 Puspaningrum et. al. utilizaron una máquina de método de aprendizaje para la diferenciación de tipo de basuras, para ello emplearon diferentes conjuntos de datos como TrashNet, VGG16, ResNet-50 y Xception, estos conjuntos fueron evaluados en las épocas 20 y 50 de entrenamiento, obteniendo la precisión de cada uno, al analizar los datos el modelo Xception superó los conjuntos de datos anteriormente mencionados con una precisión alta del 88% y media del 84% (Puspaningrum et al., 2020).

2.2. Marco teórico

En el área la identificación y clasificación de residuos sólidos mediante procesamiento de imágenes e inteligencia artificiales es importante resaltar los conceptos básicos en los que se fundamenta el proyecto, tomando en cuenta dichos aspectos se proporcionara una perspectiva de lo que se pretende presentar. Por lo cual, las definiciones más relevantes se pueden observar en los siguientes ítems.

2.2.1. Contaminación ambiental

El Programa de las Naciones Unidas para el Medio Ambiente (PNUMA) define la contaminación como “la presencia o acumulación de sustancias en el medio ambiente que afectan negativamente el entorno y las condiciones de vida, así como la salud o la higiene de los seres vivos” (Fundación Aquae, 2022), al año se producen 11.200 millones de toneladas de residuos sólidos en el mundo (Naciones Unidas, 2022) pertenecientes a las acciones del ser humano por el consumo excesivo y sobreexplotación de recursos, del cual solo el 9% del plástico producido se ha reciclado, un 12% incinerado y el restante de residuos se encuentra en basureros del mundo. La organización mundial de la salud afirma que la contaminación ambiental está superando los límites establecidos como saludables, afectando negativamente a los seres bióticos y abióticos de los diferentes ecosistemas.

2.2.2. Contaminación natural

La contaminación ambiental es una amenaza que se viene presentando con un mayor incremento desde la revolución industrial, debido al alto consumo que se generó

por la producción rápida de productos y recursos generando dos diferentes agentes contaminantes (Recytrans, 2022).

La contaminación natural se produce cuando fenómenos como incendios, maremotos, tsunamis, erupciones volcánicas, no son causados por obra del hombre.

2.2.3. Contaminación artificial

A diferencia del anterior ítem, la contaminación artificial es producida por el hombre por medio de industrias, productos químicos, entre otros, lo cual produce un desequilibrio en el ecosistema ante los diferentes contaminantes físicos, químicos y biológicos. Los contaminantes químicos son productos tóxicos como los ácidos, disolventes, orgánicos, plásticos, derivados de petróleo, abonos sintéticos y pesticidas (BBVA, 2022), físicos se encuentran toda la actividad que realiza el ser humano y el biológico son la descomposición y la fermentación de desechos orgánicos.

2.2.4. Clasificación de los residuos

Los desechos se definen como aquel material que es necesario eliminar debido a su contaminación en el medio ambiente, existen diversos tipos de desechos por lo cual se clasifican según su peligrosidad, origen y composición.

2.2.4.1. Clasificación de los residuos según su origen

En esta clasificación se podrá encontrar el origen de los residuos y algunos ejemplos de cuales residuos se pueden encontrar.

- **Residuos domésticos**

Este tipo de residuos son generados exclusivamente por los habitantes del hogar y se incluyen residuos como papel, cartón, aparatos electrodomésticos, ropa, muebles, entre otros (Pachapp - Gestión integral de residuos, 2022).

- **Residuos comerciales**

Son residuos que pueden ser producidos al mayor y al detal por el comercio, en lugares como restaurantes, oficinas, mercados y otros servicios. Entre ellos encontramos envases ligeros, papel, cartón, vidrio, aparatos eléctricos, electrónicos, pilas, acumuladores, textil, calzado, medicamentos (Safety Docs, 2022).

- **Residuos industriales.**

Estos residuos son el producto de procesos de fabricación y consumo de las grandes o pequeñas industrias. Entre ellos encontramos aceites industriales usados, trapos contaminados, disolventes, pinturas, baterías, pilas, etc (Safety Docs, 2022).

- **Biorresiduos**

Son aquellos residuos que provienen de jardines, parques, y a su vez también de hogares, restaurante, servicios colectivos. Entre ellos encontramos cáscaras de fruta o verdura, heces de animales, huesos, semillas, flores, pasto y hojarasca (Safety Docs, 2022).

- **Escombros y residuos de la construcción**

Como su nombre lo indica, este tipo de residuos son producidos por construcciones y demoliciones, cuando se realizan excavaciones la tierra puede ser reutilizada para otra obra o para la misma (Safety Docs, 2022).

- **Residuos sanitarios**

Son aquellos residuos que se generan en establecimientos de la salud, sociosanitaria, investigaciones biomédicas o en negocios veterinarios. Entre ellos encontramos jeringas, agujas, bisturís y cuchillas desechables, disolventes utilizados para preparados de laboratorio, desinfectantes, y metales pesados contenidos en los dispositivos médicos (Velásquez et al., 2022).

- **Residuos mineros**

Son residuos que se producen por procesos metalúrgicos los cuales tienen gran cantidad de metales pesados como hierro, plomo, cobre y arsénico, por esa razón generan toxicidad en el ambiente. Entre ellos encontramos cianuro, mercurio, ácido sulfúrico y disolventes para separar los minerales de la mena, ácido nítrico, nitrato de amonio, petróleo combustible (ANFO) utilizado para la voladura de túneles, mercurio, uranio y plomo (Hesperian Health Guides, 2022).

- **Residuos radioactivos**

Este tipo de residuo no tiene un propósito práctico, son elementos químicos radioactivos de un proceso nuclear como la fisión nuclear, los cuales son clasificados como exentos, de baja, media y alta radiactividad (CSN España, 2022).

- **Subproductos animales**

A diferencia de los residuos mencionados, este residuo es el subproducto de animales que no son del consumo humano, sean por motivos sanitarios o por decisión del consumidor.

2.2.4.2. Clasificación de los residuos según su composición

Esta clasificación suele ser la más común y más utilizada en hogares, instituciones, industrias y comercio, en las cuales se encuentran residuos orgánicos, inorgánicos y peligroso.

- **Residuo orgánico**

El residuo inorgánico es aquel que proviene de orígenes biológicos, al ser un elemento que provino de un ser vivo o fue un ser vivo, contiene minerales, metales, fitotóxicas, entre otros elementos que son muy tóxicos para el medio ambiente, por lo cual, es recomendable separar estos residuos para que puedan ser procesados y desechados de una forma segura y no contaminen el suelo, el agua o la atmosfera, dependiendo del tipo de residuo que se esté procesando (VOLTA, 2022).

- **Residuo inorgánico**

En comparación al residuo mencionado anteriormente, el inorgánico no proviene de un ser vivo o de origen biológico, sino que es un elemento creado y fabricado por las industrias a partir de materiales elaborados por el hombre (Pineda, 2022). El residuo inorgánico es denominado uno de los más contaminantes debido a que necesita un tratamiento diferente para su reciclaje o eliminación, se debe tener en cuenta que este tipo de residuo no siempre puede ser reutilizable.

- **Residuo peligroso.**

Se considera un residuo peligroso a todo aquel elemento o desecho que sea potencialmente peligroso para la salud humana y el medio ambiente, en esta clasificación se pueden encontrar residuos orgánicos e inorgánicos.

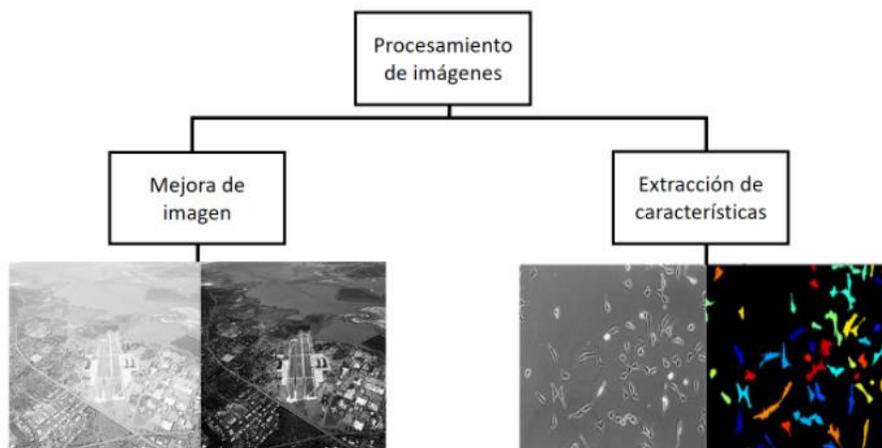
2.2.5. Inteligencia artificial (IA)

Desde el siglo I a.C. el ser humano se ha planteado la posibilidad de crear maquinas que imiten el cerebro humano, debido a la cantidad de datos que son necesarios para realizar algunos procesos, el ser humano y la maquina por si solos no cumplen las necesidades de la industrial, por lo tanto, se ha creado un sistema que realiza procesos de inteligencia humana, mejorando iterativamente a partir de la información que se recopila. Este sistema es creado a partir de algoritmos dinámicos de la computación y su objetivo no es reemplazar al hombre si no atribuir a una mejor eficiencia, facilitando la vida del ser humano (Oracle, 2022).

2.2.6. Procesamiento de imágenes digitales

Figura 1. *Procesamiento de imágenes.*

Procesamiento de imágenes.



Nota. División de procesamiento de imágenes. Tomada de Github.io [Fotografía], 2023, (Medina, 2022)

Desde los años 60 el procesamiento de imágenes es una de las ramas científicas más importantes, debido a este proceso se ha logrado mejorar la calidad de la imagen o facilitar la extracción de características. Una imagen está definida como una función dos-dimensional $f(x, y)$, las cuales cuentan con una amplitud de f que define la intensidad del nivel de gris de la imagen, estas cuentan con un número finito de elementos con una localización y valor específico, estos elementos son comúnmente denominados píxeles.

A lo largo del tiempo los ordenadores han mejorado la capacidad, por lo cual los expertos en la rama han podido crear algoritmos de procesamiento de imágenes más avanzados a través del análisis, manipulación y transmisión, obteniendo como resultados imágenes en 2D y 3D. Esta rama se encarga de la transformación de intensidades, procesamiento en el dominio de la frecuencia, restauración de imágenes, procesamiento de color, comprensión de imágenes digitales, procesamiento morfológico, segmentación, representación y descripción, reconocimiento de formas y objetos e interpretación (Alojamientos.us.es, 2022)

2.2.6.1. Métodos de detección de objetos

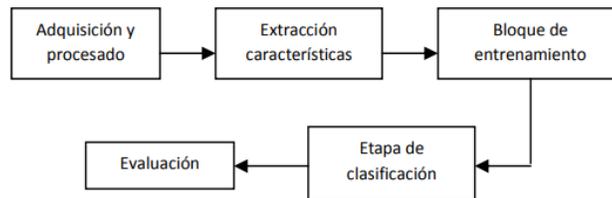
Actualmente se utilizan dos categorías para la detección de objetos los cuales son: el algoritmo de detección de objetivos en dos etapas donde como primer paso crea una cantidad de cuadros candidatos de muestra y luego los clasifica a través de una red neuronal convolucional siendo más preciso en la detección y posicionamiento, y el algoritmo de detección de objetivos en una etapa, convierte directamente el problema del posicionamiento del cuadro objetivo en un problema de regresión, por lo cual, es superior en velocidad de algoritmo (Programadorcllc.com, 2022).

2.2.6.2. Clasificación de imagen

Para obtener una clasificación de imagen es necesario la adquisición y procesamiento en donde se introduce la imagen y el sistema deberá categorizarla automáticamente, como segundo paso se realiza la extracción de características como el número de líneas horizontales y verticales, colores típicos, texturas, uniformidad, entre otras (Pawar et al., 2019). Como tercer paso se tiene el bloque de entrenamiento en cual se introducirán con anterioridad una serie de imágenes parecidas a la que se desea clasificar, como cuarto paso tenemos la etapa de clasificación y por último la evaluación del sistema.

Figura 2. Clasificación de imágenes.

Clasificación de imágenes.



Nota. Proceso realizado para la extracción y clasificación de imágenes. Tomado de Universidad Carlos III de Madrid [Fotografía], Julio Villena Román, 2022, (Villena, 2022)

2.2.7. Modelamiento de Redes Neuronales

Una red neuronal es aquel modelo de red que intenta tener una gran similitud con el cerebro humano, debido a que por medio de un procesamiento interconectado que simula una neurona. La red suele estar divididas en tres partes, en primer lugar, encontramos la capa de entrada, la cual consiste en las imágenes que ingresamos al sistema para entrenar la red neuronal, la segunda consiste en varias capas ocultas en las

cuales se realizan procesos como la activación, convolución, matriz max pooling, entre otros, este proceso dependerá del tipo de red neuronal que se quiera crear, sin embargo, en estas capas ocultas es donde se realiza el entrenamiento a profundidad de la red, debido a que a medida que realiza de forma más repetitivo su aprendizaje, el porcentaje de precisión va aumentando, logrando obtener como resultado una red neuronal más precisa, y por último, encontramos la capa de salida en la cual encontramos todo el aprendizaje que se obtuvo (IBM, 2023).

2.2.7.1. *Max pooling*

También conocida como “agrupación máxima” es aquel método el cual permite sobre ajustar la cantidad de parámetros o pixeles que ofrece una imagen, este proceso se realiza con el fin de reducir los parámetros que son introducidos a la computadora y obtener subregiones que no se superpongan a la imagen principal. Para ello, se realiza la “acumulación” de las características de mapas generados al convolucionar un filtro sobre la imagen, permitiendo la reducción de los parámetros (Aprende ML, 2020).

2.2.7.2. *Kernel*

Es un método comúnmente utilizado para el análisis de patrones que contiene un conjunto de datos, su característica principal es que puede operar en cualquier tipo de espacio sin tener coordenadas explícitas, lo cual permite tener una forma más eficiente y menos costosa de transformar los datos a dimensiones superiores (Keepcoding, 2023a).

2.2.7.3. *Activaciones*

Es una función que permite a la red neuronal aprender diferentes patrones de datos complejos simulando el comportamiento de una neurona del cerebro humano, esta activación permite que ha una señal de salida de una celda anterior, sea transformada en

una nueva forma para poder tomarse como entrada en una nueva celda (Codificandobits, 2022).

2.2.7.4. ReLu

El rectificador lineal unitario, mejor conocido como “ReLU”, es la función de activación más usada para el aprendizaje profundo de redes neuronales, debido a que los valores negativos serán convertidos a 0, ya que no son importantes en el proceso de imágenes y si son superiores se devuelven al mismo número, lo cual permite tener una línea continua, no lineal, la cual comprende un intervalo desde 0 a infinito positivo (Codificandobits, 2022).

$$f(x) = \max(0, x) = \begin{cases} 0, & \text{for } x < 0 \\ x, & \text{for } x \geq 0 \end{cases} \quad (1)$$

2.2.7.5. Sigmund

A diferencia de función de activación anterior mencionada, esta función se llega a saturar, de lenta convergencia, no se encuentra centrada en cero y está limitada entre los parámetros 0 y 1, pero es de útil uso cuando se requiere un modelo que indique la probabilidad como un resultado debido a sus dos parámetros (Codificandobits, 2022).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

2.2.7.6. Canales

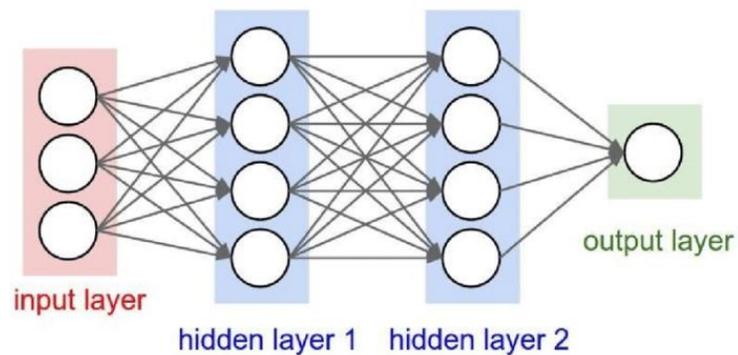
El término “canal” es utilizado frecuentemente para referirse al componente de una imagen digital, las cuales se encuentran hechas de pixeles. En las imágenes podemos encontrar de un canal (imágenes en blanco y negro) o de tres canales (imágenes de color), cuando se refiere a un solo canal la imagen se va a encontrar en escala de grises,

pero, cuando se refiere a una de tres canales, se encuentran colores primarios como el rojo, azul y verde (Korznikov et al., 2021).

2.2.7.7. *Modelo Denso*

Figura 3. Red neuronal de Modelo Denso

Red neuronal de Modelo Denso



Nota. Visualización del modelo denso red neuronal. Tomado de ResearchGate [Fotografía], (Ferro et al., 2020)

Como se puede observar en la figura 3, una red neuronal densa es aquella en la cual todas las neuronas de entrada comparten su información con todas las neuronas de la siguiente capa y estas se encuentran conectadas entre capas, este procedimiento se realiza hasta la última capa obteniendo una sola neurona. Esta red es una de las más eficaces debido a la cantidad de información que cada neurona almacena y trasmite hasta la última neurona, sin embargo, al almacenar tantos datos al procesar la red se vuelve pesada y lenta (Ferro et al., 2020).

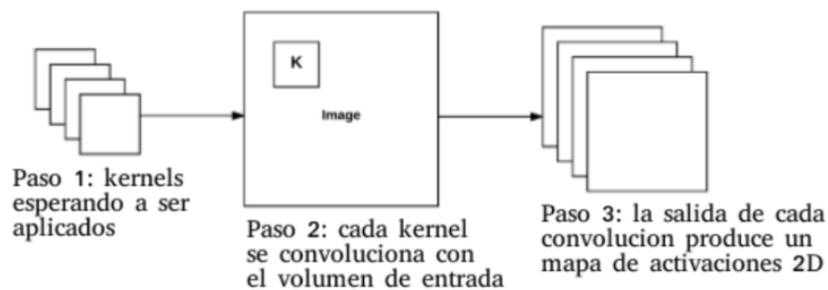
2.2.7.8. *Modelo de Red Neuronal Convolutacional*

Este modelo también conocido como convolutional neural networks (CNN) es una red creada para imitar el funcionamiento del cerebro, debido a que es capaz de

aprender conforme se vaya desarrollando el entrenamiento, generalmente, en la primera capa se aprende a diferenciar las formas, colores o bordes, en cambio en la última capa es capaz de diferenciar y distinguir con exactitud la figura. La red neuronal convolucional es capaz de extraer automáticamente características útiles para la clasificación de los objetos (Keepcoding, 2023c).

Figura 4. Esquema general de convolución

Esquema general de convolución



Nota. Regularización por dropout en red convolucional, KeepCoding Bootcamps. Tomado de KeepCoding [Fotografía], (Keepcoding, 2022)

Con base en la figura 4, se puede diferenciar los tres pasos que son realizados en una red neuronal convolucional, en el primer paso se encuentra el número de filtro/kernels, el cual sirve para aplicar a la imagen un cierto número de matrices por la cual se va a convolucionar las imágenes de entrada, en el segundo paso se le realiza una convolución según el volumen de la entrada, el tamaño de los filtros suelen ser cuadrados en un 99%, y por ultimo al tener una entrada RGB se aplicará una convolución por separado a cada canal (R, G y B), para obtener al final un resultado de cada canal los cuales serán sumados para obtener un solo canal y una única matriz 2D (Keepcoding, 2023d).

2.2.7.9. Drop Out

Es un método actualmente usado para mejorar el entrenamiento de redes neuronales, el cual consiste en que un número de neuronas de la red serán desactivadas de forma aleatoria, con el fin de forzar a las neuronas a trabajar de forma individual y no depender de otras para lograr un mejor entrenamiento de la red (Keepcoding, 2022).

2.2.8. Librerías

En la actualidad las librerías que son usadas en la programación, son archivos de códigos desarrollados por otros programadores, los cuales proporcionan funcionalidades que son requeridas comúnmente por la comunidad, estos archivos cumplen el objetivo que es facilitar y reducir el tiempo de desarrollo, y a su vez minimizar errores o duplicidad de códigos (Ministerio de Asuntos Económicos y transformación digital - España, 2022).

2.2.8.1. Keras

Esta biblioteca fue diseñada para construir bloques de arquitectura de cada red neuronal, en las cuales se incluyen redes convolucionales y recurrentes, como se evidencio en conceptos anteriores, este tipo de red permite entrenar modelos Deep Learning. La librería Keras es una biblioteca de redes neuronales artificiales de código abierto, la cual se encuentra desarrollada en Python (Keepcoding, 2023b).

2.2.8.2. TensorFlow

A diferencia de la librería mencionada anteriormente, TensorFlow entrena y ejecuta redes neuronales profundas (DNN) para el reconocimiento de imágenes, clasificación de dígitos e incrustación de palabras (González, 2023).

2.2.8.3. *Numpy*

En el desarrollo del proyecto se utilizó una gran cantidad de imágenes por lo cual fue necesaria la librería numpy, esta se encarga del cálculo numérico y el estudio de datos a gran volumen, esto se debe a la clase de objetos denominada “arrays” las cuales son muy eficientes y permiten representar colecciones de datos de un mismo tipo en varias dimensiones, esta librería ayuda que el procesamiento en Python sea hasta 50 veces más rápida (Alberca, 2022).

2.2.8.4. *Open CV*

Para la realización de trabajos de alto nivel para el avance de aplicaciones de visión por computador en tiempo real la librería ideal es OpenCV, la cual permite desarrollar estructuras y procesamiento de datos, análisis de imágenes, entre otros (Arévalo et al., 2023).

2.2.8.5. *TensorBoard*

La herramienta TensorBoard permite una visualización de la comprensión y depuración de redes neuronales profundas, permitiendo ver los gráficos del modelo y trazar valores escalares, mientras avanza la red (Microsoft, 2023).

2.2.9. *Conjunto de datos*

Se refiere a la organización de datos, que permiten almacenar la información necesaria sobre un tema en específico (Historia de la empresa, 2022). Estos conjuntos son normalmente usados como bases investigativas y a su vez para programas de estudios o trabajo, los cuales pueden ser de dominio público o privado, dependiendo de la información suministrada.

2.2.10. Raspberry Pi 4

El ordenador mencionado es uno de los más utilizados para proyectos de prototipos en colegios o universidad, esto se debe a su bajo costo y su fácil accesibilidad para el desarrollo informático, una raspberry pi 4 se caracteriza por tener una frecuencia de reloj, diversidad de puertos, accesorios, una memoria desde 1 GB a 4 GB y un GPU Video Core VI, además de tener una mejor potencia y conexiones bluetooth 5.0 y wifi 802.11ac (Solé, 2021). Por otro lado, un elemento muy interesante de este procesador es que su hardware es libre y se pueden instalar diferentes sistemas operativos para su funcionamiento.

2.2.10.1. Cámara Raspberry Pi 4

El módulo puede ser conectado en cualquiera de los dos sockets pequeños de la parte superior de la placa Raspberry. Esta conexión utiliza una interfaz CSI especial que es ideal para conectar cámaras debido a su alta capacidad de transferencia de datos y su sensor óptico tiene una resolución de 8 megapíxeles (MP) y tiene una lente de enfoque fijo. La cámara puede capturar imágenes de hasta 3280 x 2464 píxeles (Raspberry Pi, 2023).

2.3. Marco legal

El marco legal para el desarrollo del proyecto se hace con fines investigativos e innovadores basados en conceptos y teorías de procesamiento digital de señales e inteligencia artificial, las cuales se basan en la jurisprudencia correspondiente para las licencias de software, como el control y protección del producto final obtenido en el proceso del mismo.

Por otra parte, la normativa general de la constitución política de Colombia reglamenta en el Art. 79, que todos los seres humanos tienen derecho a un ambiente sano, permitiendo que gocen de una buena salud y ejerciendo su derecho a la vida, por lo cual, al estado y a las personas se le impone en los Art. 8 y Art. 95 el deber de proteger, cuidar y preservar las riquezas naturales y el medio ambiente (Ley 09 de 1979: Medidas sanitarias sobre manejo de residuos sólidos, 1979). Así mismo, en la resolución 1407 del 2018 el gobierno reglamenta y establece el compromiso que tiene las empresas de recoger los empaques y envases que sean producidos por ellos mismos (Ley 99 de 1993: Sistema Nacional Ambiental, 1993), de la misma forma el documento “política para la gestión integral de residuo” y la ley 142 de 1994 define que las empresas deben promover y minimizar los residuos generados, y a su vez la tratamiento, eliminación y disposición, por medio del aprovechamiento de la nueva tecnología, estableció el consejo nacional para la económica social (Ley 99 de 1993: Sistema Nacional Ambiental, 1993).

Es importante resaltar que no solo las empresas poseen un compromiso primordial con el medio ambiente, si no que junto a los ciudadanos tienen la obligación de almacenar y trasladar los residuos sólidos de forma correcta según las normas y especificaciones de los Art.22 y Art. 23 del decreto nacional 1140 del 2003, generando beneficios sanitarios ambientales y sociales, por lo cual, con el marco de gestión integral de residuos sólidos se busca que las industrias implementen una forma eficiente la reincorporación al ciclo económico la utilización, reciclaje e incineración de residuos, con la participación e inclusión de recicladores estableció el decreto nacional 1505 del 2003, en el que se encargan las autoridades distritales y municipales de su cumplimiento y ejecución.

3. Diseño metodológico

A continuación, será presentado la metodología que se llevó a cabo para el cumplimiento de cada objetivo del proyecto enumerando las actividades a realizar.

3.1. Recopilación de información

Actividades

- Recopilación sobre la clasificación de residuos solidos
- Consulta en bases de datos científicas indexadas
- Definición de conceptos teóricos

Metodología

Fue necesario para el desarrollo del proyecto la realización de la investigación con evidencias científicas basadas en experiencias, para ello se llevó a cabo una investigación sobre la identificación y clasificación de residuos sólidos enfocado en la ciudad de Cúcuta y a su vez se realizó una investigación general sobre la inteligencia artificial (IA) para dar una solución a la problemática planteada.

3.2. Selección de tecnologías y zonas

Actividades

- Recopilación de información sobre tecnologías y procesamiento digital de señales
- Selección del lenguaje de programación
- Selección del algoritmo de programación

Metodología

Se selecciono el tipo de identificación y clasificación que conformo la “interfaz gráfica para la identificación y clasificación de residuos sólidos en la ciudad de Cúcuta mediante procesamiento de imágenes e inteligencia artificial” se seleccionó el lenguaje de programación que se utilizó para el desarrollo del programa, teniendo en cuenta los entornos de programación disponibles actualmente, además, se seleccionó el algoritmo de programación lo cual es importante para los procesos que se debe llevar a cabo las imágenes.

3.3. Diseño del algoritmo

Actividades

- Elaboración del código en el lenguaje de programación establecido
- Compilación y generación de archivos ejecutables

Metodología

Se seleccionó la tecnología y las herramientas de software, se comenzó el desarrollo del código para lo cual fue necesario la utilización y recopilación de diferentes manuales, interfaces, bibliografías y cursos de programación, con el fin de la elaboración de un código de programación sencillo y práctico para la identificación y clasificación de imágenes. Al realizar el código se procedió a la compilación y ejecución del mismo.

3.4. Pruebas de funcionamiento

Actividades

- Comprobar la eficiencia del sistema
- Documentar los resultados del proyecto

Metodología

Se realizó pruebas del programa a través de ejemplos basados en escenarios diarios de la identificación y clasificación de residuos, evaluando la precisión y fiabilidad del programa, estos resultados serán documentados y anexados en el proyecto.

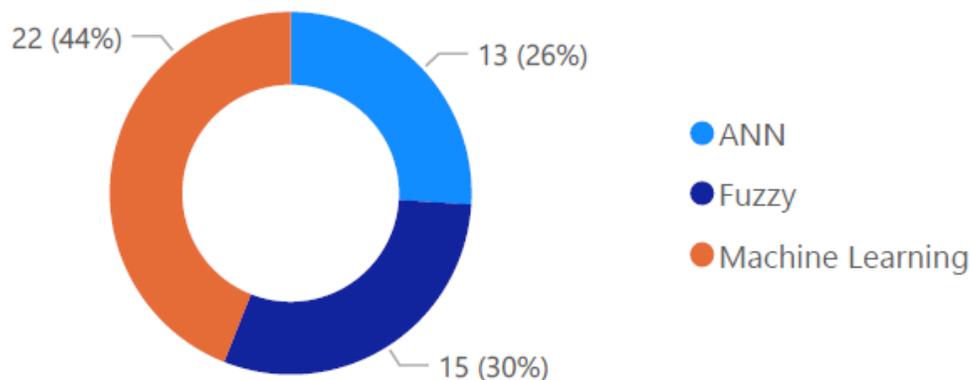
4. Resultados

4.1. Estado del arte y selección de tecnologías

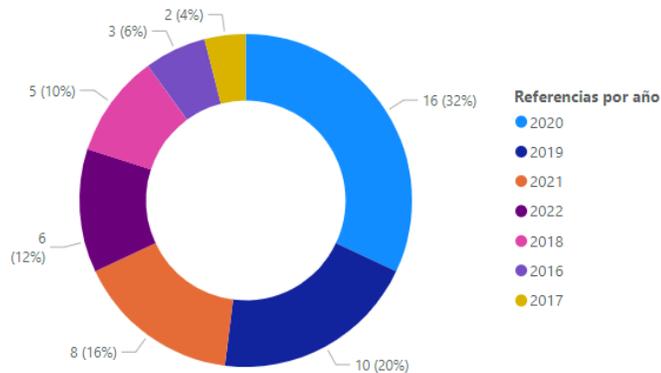
Para la elección de referencias bibliográficas, se delimita la búsqueda al desarrollo de algoritmos computacionales con inteligencia artificial para el uso de herramientas de simulación, por lo cual se realizó una investigación de 50 referencias bibliográficas a partir del año 2016. Como resultado del análisis se obtuvo 5 graficas en la cual se logra evidenciar los tipos de algoritmos que son utilizados y las sub temáticas correspondientes a cada uno de ellos, en la figura 5 se observan los tipos de referencias bibliográficas por temática que fueron utilizadas, las cuales un 26% corresponde a la utilización de la Red Neuronal Artificial (ANN), un 30% Fuzzy y con un mayor porcentaje Machine Learning con 44%, cabe destacar que al realizar un análisis de la figura 11, se ve reflejado una mayor selección de referencias en el año 2020 y al comparar con años anteriores, la preferencia fue de un 12%. (Abdullah et al., 2019)

Figura 5. Referencias bibliográficas por temática.

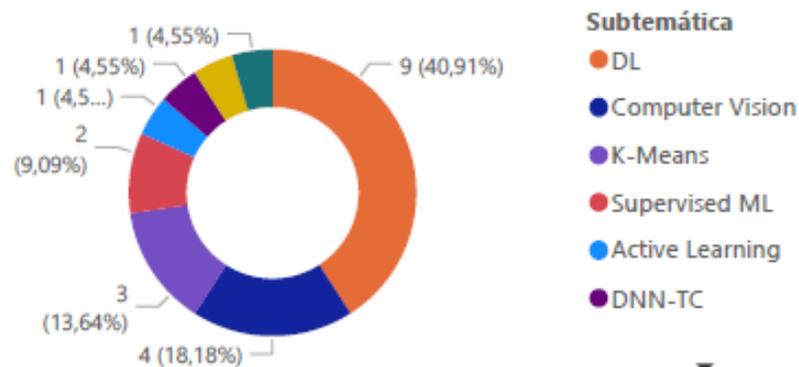
Referencias bibliográficas por temática.



Nota. El grafico representa la clasificación en tres tipos de referencias bibliográficas, ANN, Fuzzy y machine Learning.

Figura 6. Referencias por año*Referencias por año*

Como se mencionó anteriormente, los algoritmos Machine Learning son la preferencia respecto a las referencias bibliográficas consultadas, en el cual se incluyen proyectos, tesis, artículos, en otros. Como se observará en la figura 5 este algoritmo consta de varias sub temáticas, las cuales son diferenciadas por el tipo de aprendizaje que realizara la máquina, clasificándolo en 3 tipos: aprendizaje supervisado, aprendizaje sin supervisión y aprendizaje por refuerzo, como resultado la Deep Learning obtiene un 40,91%, es decir, que el aprendizaje reforzado es el más utilizado.

Figura 7. Algoritmo Machine Learning*Algoritmo Machine Learning*

De igual forma, también encontramos algoritmos de lógica difusa que son de gran utilidad cuando se realiza un proceso en el cual el sistema debe tomar una decisión de forma intermedia, es decir, que el algoritmo debe ser programado para tratar información no precisa y además se le debe aplicar algunas reglas para la toma de decisiones; A continuación, se observa en la figura 8 la clasificación de 8 sub temáticas de este algoritmo encontradas en la investigación de referencias bibliográficas.

Figura 8. Algoritmo Lógica Difusa

Algoritmo Lógica Difusa

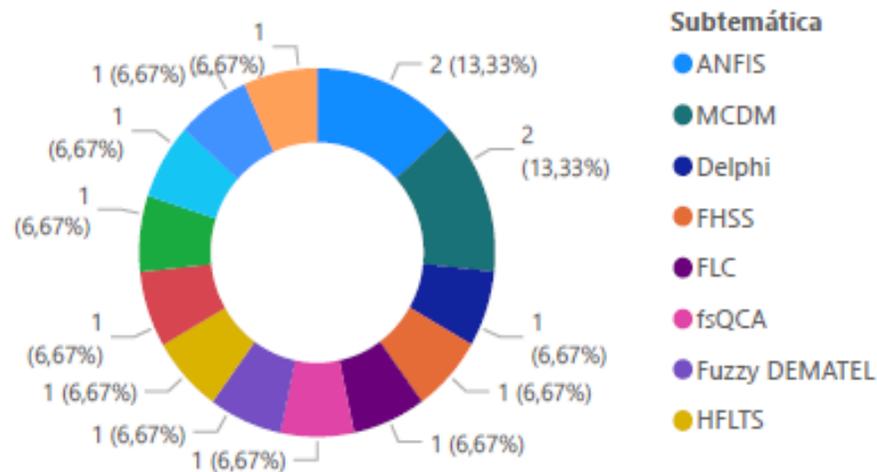
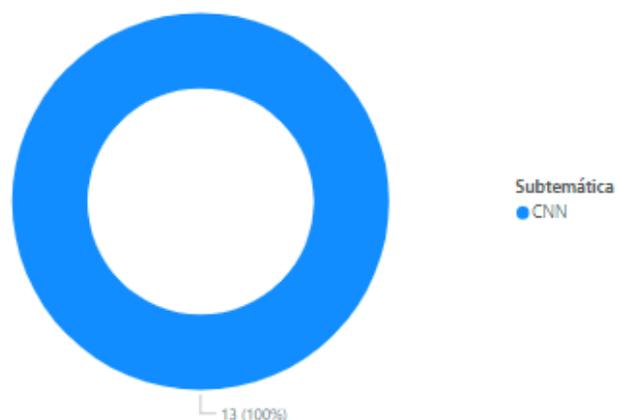


Figura 9. Algoritmo de Red Neuronal Artificial

Algoritmo de Red Neuronal Artificial



Por otra parte, al realizar un análisis de los tipos de redes neuronales artificiales utilizadas, como se evidencia en la figura 5 donde la ANN obtiene un total de 13 referencias bibliográficas, se observa en la figura 9 un porcentaje del 100% el cual corresponde a redes neuronales convolucionales (CNN), dado que este tipo de redes son más utilizadas por su tipo de aprendizaje y sus resultados de reconocimiento son altamente precisos.

4.2. Selección de software

Para lograr obtener los parámetros comparativos de tecnologías de software se establecieron los cinco parámetros más importantes para la realización del proyecto en la tabla 1.

Tabla 1. *Parámetros de tecnología de software*

Parámetros de tecnología de software.

Denotación	Parámetros
A	Costo de licencia
B	Disponibilidad de librerías
C	Entornos de desarrollo
D	Conectividad con ofimática
E	Comparación de herramientas de software respecto a la especialidad para inteligencia artificial

Como se puede observar en la tabla 1, a cada parámetro se le asigna una denotación para la comparación de pesos de cada uno como se evidencia en la tabla 2, con el fin de poder seleccionar el software.

Tabla 2. *Peso de los parámetros a comparar para la selección de software.**Peso de los parámetros a comparar para la selección de software.*

	A	B	C	D	E	Suma	Factor
A	X	1	1	5	1	8	0,17
B	1	X	5	5	1	12	0,26
C	1	1/5	X	10	1	12,2	0,27
D	1/5	1/5	1/10	X	1/10	0,6	0,01
E	1	1	1	10	X	13	0,28

Como se evidencia en la tabla 2, el parámetro que tiene un mayor porcentaje fue el de comparación de herramientas de software respecto a la especialidad para inteligencia artificial con un 28%, el segundo con mayor índice son los entornos de desarrollo con un 27% y con un 26% la disponibilidad de librerías y por último se tiene el costo de licencia con un 17% y una conectividad ofimática del 1%.

Por lo tanto, para la realización de los pesos de los parámetros fue necesario hacer la comparación de diversas herramientas de software, como se puede ver en la tabla 3, lo cual desarrolla la comparación del tipo de licencia.

Tabla 3. *Comparación de herramientas de software respecto al tipo de licencia.**Comparación de herramientas de software respecto al tipo de licencia.*

	Lenguaje R	Python	Java	SQL	Suma	Factor
Lenguaje R	X	1/10	1/5	1/5	0,50	0,014
Python	10	X	5	5	20,00	0,554
Java	5	1/5	X	5	10,20	0,283
SQL	5	1/5	1/5	X	5,40	0,150

De la anterior tabla se obtiene el mayor porcentaje con un 55% por el software de Python. Sin embargo, en la tabla 4 se encuentra un igual porcentaje de capacidad de integración de entornos de desarrollo por Python y Java, con un porcentaje del 47% cada uno.

Tabla 4. Comparación de herramientas de software respecto a la capacidad de integración con entornos de desarrollo.

Comparación de herramientas de software respecto a la capacidad de integración con entornos de desarrollo.

	Lenguaje R	Python	Java	SQL	Suma	Factor
Lenguaje R	X	1/10	1/10	1	1,20	0,03
Python	10	X	1	10	21,00	0,47
Java	10	1	X	10	21,00	0,47
SQL	1	1/10	1/10	X	1,20	0,03

En la tabla 5, se encuentra la comparación de herramientas de software respecto a la disponibilidad de paquetes y librerías.

Tabla 5. Comparación de herramientas de software respecto a la disponibilidad de paquetes y librerías.

Comparación de herramientas de software respecto a la disponibilidad de paquetes y librerías.

	Lenguaje R	Python	Java	SQL	Suma	Factor
Lenguaje R	X	1/10	1/5	5	5,30	0,13
Python	10	X	5	10	25,00	0,61
Java	5	1/5	X	5	10,20	0,25
SQL	1/5	1/10	1/5	X	0,50	0,01

A su vez, en la tabla 6 se muestra la comparación de herramientas de software respecto conectividad ofimática.

Tabla 6. *Comparación de herramientas de software respecto conectividad ofimática.*

Comparación de herramientas de software respecto conectividad ofimática.

	Lenguaje R	Python	Java	SQL	Suma	Factor
Lenguaje R	X	1/10	1/10	1/10	0,30	0,01
Python	10	X	1	10	21,00	0,48
Java	10	1	X	10	21,00	0,48
SQL	1	1/10	1/10	X	1,20	0,03

Del mismo modo, en la tabla 7 se realiza la comparación de herramientas de software respecto a la compatibilidad con inteligencia artificial.

Tabla 7. *Comparación de herramientas de software respecto a compatibilidad con inteligencia artificial.*

Comparación de herramientas de software respecto a compatibilidad con inteligencia artificial.

	Lenguaje R	Python	Java	SQL	Suma	Factor
Lenguaje R	X	1/5	1/5	5	5,40	0,19
Python	5	X	1	5	11,00	0,39
Java	5	1	X	5	11,00	0,39
SQL	1/5	1/5	1/5	X	0,60	0,02

Luego de realizar la comparación de las herramientas de software respecto a cada parámetro, se procede a obtener una matriz de decisión en la cual se exponen los resultados adquiridos de cada una de las tablas mencionadas anteriormente, por lo tanto, al realizar una comparación con el peso de los parámetros, se obtiene la tabla 8.

Tabla 8. *Matriz de decisión para la herramienta de software.**Matriz de decisión para la herramienta de software.*

	A	B	C	D	E	Suma
Lenguaje R	0,004239923	0,0395719	0,0044126	0,00014	0,0393586	0,087724
Python	0,169596925	0,18666	0,0772201	0,00985	0,0801749	0,523504
Java	0,086494432	0,0761573	0,0772201	0,00985	0,0801749	0,329899
SQL	0,003052745	0,0037332	0,0044126	0,00056	0,0043732	0,016135

Como se puede observar en la tabla 8, la herramienta que será seleccionada para la realización del proyecto será el software Python, el cual tiene un porcentaje del 52,35%, los otros tres softwares con los cuales fueron comparados obtuvieron como segundo lugar por un porcentaje del 32,99% el lenguaje Java, por tercer lugar con un 8% el lenguaje R y como último lugar se encuentra el lenguaje SQL con un 1.6%.

4.3. Selección de la tecnología de hardware

Para lograr obtener los parámetros comparativos de tecnologías de hardware se establecieron los seis parámetros más importantes para la realización del proyecto en la tabla 9.

Tabla 9. *Parámetros de selección de hardware.**Parámetros de selección de hardware.*

Parámetros	Denotación
Velocidad de procesador	A
Memoria RAM	B
lenguaje de programación soportados	C
Velocidad de procesamiento grafico	D

Precio y disponibilidad	E
Tareas simultaneas	F

En la siguiente tabla 10, se evidenciará el mayor peso que comprenda cada uno de los parámetros.

Tabla 10. *Peso de los parámetros a comparar para la selección de software.*

Peso de los parámetros a comparar para la selección de software.

	A	B	C	D	E	F	Suma	Factor
A	X	5	2	8	1/5	10,00	25	0,33
B	1/5	X	5	5	1/5	5,00	15,40	0,20
C	1/2	1/5	X	5	1/3	5,00	11,03	0,14
D	1/8	1/5	1/5	X	2/5	2/5	1,33	0,02
E	5	5	3	5,00	X	5,00	23,00	0,30
F	1/10	1/5	1/5	3/5	1/5	X	1	0,02

Se obtuvo un porcentaje del 33% en la velocidad del procesador, como segundo se obtiene por un 30% el precio y disponibilidad del hardware, por tercero con un 20% la memoria RAM, como últimos parámetros con el 14% el lenguaje de programación y con un 2% las tareas simultaneas y la velocidad de procesamiento gráfico. Sin embargo, para tener más detallado cada ítem se vera la tabla 11 a la 16.

Tabla 11. *Comparación de herramientas de hardware respecto a la velocidad de procesamiento.*

Comparación de herramientas de hardware respecto a la velocidad de procesamiento.

	Raspberry Pi 4	Jetson Nano	Arduino UNO	Nexys 3	Suma	Factor
Raspberry Pi 4	X	1	10	10	21,00	0,44

Jetson Nano	1	X	10	10	21,00	0,44
Arduino UNO	1/10	1/10	X	1/5	0,40	0,01
Nexys 3	1/10	1/10	5	X	5,20	0,11

A su vez, en la tabla 12 se realizará la comparación de herramientas de hardware respecto memoria RAM.

Tabla 12. Comparación de herramientas de hardware respecto memoria RAM.

Comparación de herramientas de hardware respecto memoria RAM.

	Raspberry Pi 4	Jetson Nano	Arduino UNO	Nexys 3	Suma	Factor
Raspberry Pi 4	X	5	10	6	21,00	0,58
Jetson Nano	1/5	X	6	5	11,20	0,31
Arduino UNO	1/10	1/6	X	1/3	0,60	0,02
Nexys 3	1/6	1/5	3	X	3,37	0,09

Por otro lado, en la tabla 13 se observará la comparación de herramientas de hardware respecto lenguaje de programación soportados

Tabla 13. Comparación de herramientas de hardware respecto lenguaje de programación soportados.

Comparación de herramientas de hardware respecto lenguaje de programación soportados.

	Raspberry Pi 4	Jetson Nano	Arduino UNO	Nexys 3	Suma	Factor
Raspberry Pi 4	X	1	10	5	16,00	0,52
Jetson Nano	1	X	5	5	11,00	0,36
Arduino UNO	1/10	1	X	1	2,10	0,07
Nexys 3	1/5	1/5	1	X	1,40	0,05

En la tabla 14, se visualiza la comparación de herramientas de hardware respecto a la velocidad de procesamiento gráfico.

Tabla 14. *Comparación de herramientas de hardware respecto a la velocidad de procesamiento gráfico.*

Comparación de herramientas de hardware respecto a la velocidad de procesamiento gráfico.

	Raspberry Pi 4	Jetson Nano	Arduino UNO	Nexys 3	Suma	Factor
Raspberry Pi 4	X	1/5	1	2	3,20	0,16
Jetson Nano	5	X	5	1/2	10,50	0,51
Arduino UNO	1	1/5	X	1/2	1,70	0,08
Nexys 3	1/2	2	2	1/2	5,00	0,25

De igual forma, en la tabla 15 se observa la comparación de herramientas de hardware respecto precio y disponibilidad del mercado.

Tabla 15. *Comparación de herramientas de hardware respecto precio y disponibilidad del mercado.*

Comparación de herramientas de hardware respecto precio y disponibilidad del mercado.

	Raspberry Pi 4	Jetson Nano	Arduino UNO	Nexys 3	Suma	Factor
Raspberry Pi 4	X	3/5	1/10	5	5,70	0,11
Jetson Nano	5	X	1/8	1/10	5,23	0,10
Arduino UNO	9	8	X	10	27,00	0,53
Nexys 3	5	8	1/10	X	13,10	0,26

En la tabla 16, se puede visualizar la comparación de herramientas de hardware respecto a las tareas simultaneas.

Tabla 16. *Comparación de herramientas de hardware respecto a las tareas simultaneas.*

Comparación de herramientas de hardware respecto a las tareas simultaneas.

	Raspberry Pi 4	Jetson Nano	Arduino UNO	Nexys 3	Suma	Factor
Raspberry Pi 4	X	3	2	5	10,00	0,54
Jetson Nano	1/3	X	2/3	1,67	2,67	0,15
Arduino UNO	1/2	1,5	X	2,5	4,50	0,25
Nexys 3	1/5	3/5	2/5	X	1,20	0,07

Y, por último, se realiza la matriz de decisión referente a la herramienta de hardware respecto a cada uno de los seis parámetros investigados y los cuatro hardware seleccionados en la tabla 17.

Tabla 17. *Matriz de decisión de herramientas de hardware*

Matriz de decisión de herramientas de hardware.

	A	B	C	D	E	F	Suma
Raspberry Pi 4	0,14390	0,1157	0,0749	0,0027	0,0333	0,0092	0,3797
Jetson Nano	0,1439	0,0617	0,0515	0,0088	0,0305	0,0024	0,2989
Arduino UNO	0,00274	0,0033	0,0098	0,0014	0,1575	0,0041	0,1789
Nexys 3	0,0356	0,0186	0,0066	0,0042	0,0764	0,0011	0,1425

De lo anterior, se puede observar que con un porcentaje del 37,97% el hardware seleccionado sería el Raspberry pi 4, en segundo lugar, el Jetson Nano con un 29,89%, y como los dos últimos el Arduino UNO con un 17,89% y Nexys 3 con un 14,25%, estas selecciones fueron realizadas a base de las necesidades del proyecto.

4.4. Visión computacional para identificación y clasificación de residuos

Con las metodologías mencionadas anteriormente, se presenta algunas técnicas necesarias para la clasificación de objetos.

4.4.1. Algoritmo propuesto para redimensión, etiquetado y cambio de canal.

Como se ilustra en la tabla 18, se especifica el algoritmo propuesto para la redimensión, etiquetado y cambio de canal que se le realiza a cada imagen para poder ser procesada en la fase de entrenamiento y validación. Se realiza con el fin de obtener imágenes con la misma cantidad de pixeles, realizar el etiquetado de cada una en las carpetas de entrenamiento y la validación, y a su vez, las imágenes se cambiaron a un solo canal de escalas grises para obtener una mejor detección de borde.

Tabla 18. *Algoritmo propuesto para redimensión, etiquetado y cambio de canal.*

Algoritmo propuesto para redimensión, etiquetado y cambio de canal.

1	Importar librerías
2	Cargar el entrenamiento de residuos solidos
3	Cargar la validación de residuos solidos
4	Redimensionar la imagen tomara un tamaño de 200x200 pixeles
5	Etiquetar las imágenes de entrenamiento
6	Etiquetar las imágenes de validación
7	Leer las fotos de entrenamiento
8	Asignar etiqueta a cada imagen de entrenamiento
9	Leer imagen con etiqueta en entrenamiento
10	Realizar interpolación de las imágenes
11	Representar la imagen en un solo canal en la escala de grises
12	Añadir imagen en EDG
13	Leer las fotos de validación
14	Asignar etiqueta a cada imagen de validación

15	Leer imagen con etiqueta de validación
16	Realizar interpolación de imágenes
17	Representar la imagen en un solo canal en la escala de grises
18	Añadir imagen en EDG
19	Normalizar imágenes de entrenamiento y validación
20	Realizar capa densa
21	Aplicar Kernel
22	Ejecutar matriz max pooling
23	Realizar convolución
24	Aplicar Kernel
25	Ejecutar matriz max pooling
26	Realizar convolución con Drop Out
27	Aplicar Kernel
28	Ejecutar matriz max pooling

4.4.2. Redimensión de imágenes

Como se mencionó anteriormente, las fotografías fueron tomadas desde dispositivos móviles con diferentes megapíxeles, además de otras alternativas con la que viene incorporados los móviles, las imágenes recolectadas no tienden a tener un mismo tamaño o una misma calidad, por tal motivo, se realizó una redimensión de todas las imágenes que serían almacenadas en el dataset, esto se hace con el fin, que al comenzar a procesar la red neuronal convolucional se lea un total de 40.000 neuronas por imagen.

4.4.3. Conversión a escala de grises

A continuación, se tomará del dataset mencionado anteriormente una imagen de cada tipo de residuo seleccionado, a los cuales se les realizará la conversión de colores a escalas de grises como se evidencia en la Figura 10. En dicha figura se observará que la imagen 10a es un residuo de papel, 10b metal, 10c vidrio, 10d cartón, 10e biológico y 10f plástico.

Figura 10. *Conversión a escala de grises.*

Conversión a escala de grises.

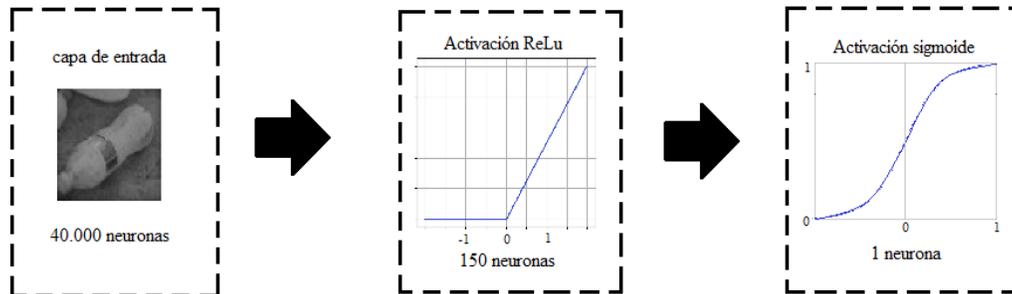


4.4.4. Modelo denso

La Figura 11 muestra las etapas que componen el modelo denso, que consiste en la inclusión de una capa de entrada y dos funciones de activación, compuestas por la función ReLu y la función sigmoide, con el objetivo de crear salidas positivas en el sistema. Con esa configuración, la imagen entra a una capa de 40.000 neuronas como capa de entrada, la cual se conecta con 150 neuronas con función de activación ReLu, que a su vez se conecta con una capa compuesta por una única neurona con función Sigmoide.

Figura 11. Representación del proceso de modelo denso para procesamiento de imágenes.

Representación del proceso de modelo denso para procesamiento de imágenes.

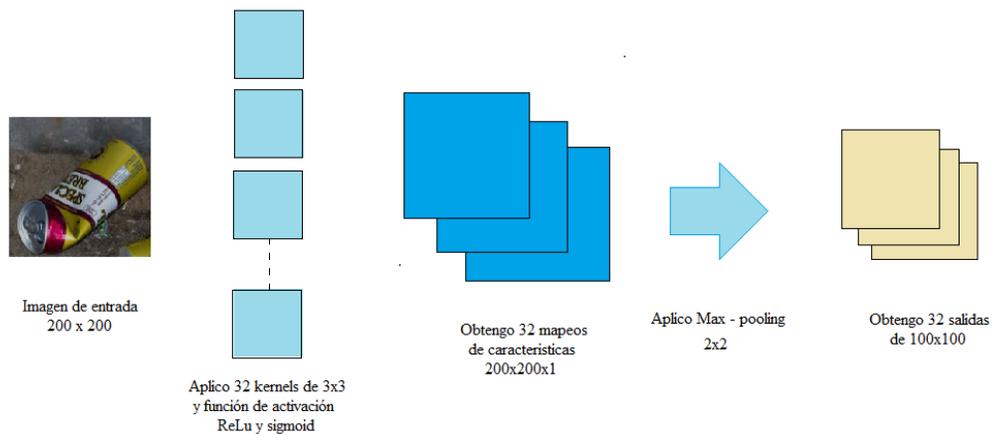


4.4.5. Modelo CNN

Para comprender el proceso llevado a cabo por la red, en la Figura 12 se puede observar una imagen convertida a escala 200x200 píxeles, a la cual se le aplicaron 32 filtros que permitieron obtener 32 matrices de salida que combinadas dan un total de 1.280.000 neuronas en la primera capa oculta.

Figura 12. Representación del proceso de modelo convolucional para procesamiento de imágenes.

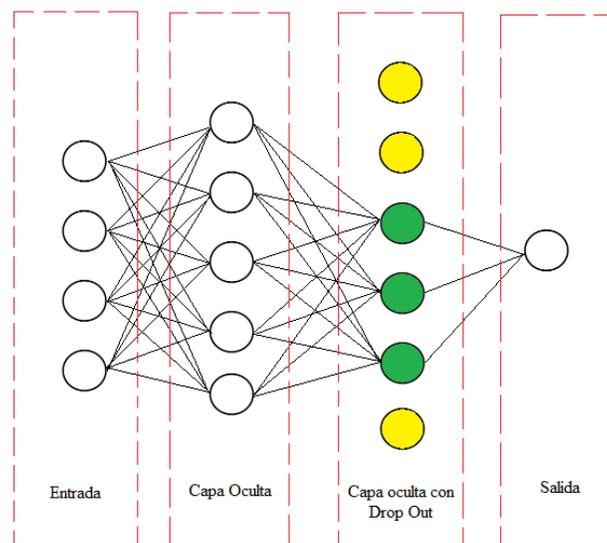
Representación del proceso de modelo convolucional para procesamiento de imágenes.



Además, con las funciones de activación ReLu y sigmoide. Posterior a esto, fue aplicado el max – pooling 2x2, que consiste en conservar los pixeles de mayor peso de la imagen, con el objetivo de preservar la integridad de la misma al almacenar una imagen a la mitad con los píxeles de mayor peso, para un total de 320.000 neuronas en el sistema clasificador.

Finalmente, para obtener un mejor desempeño en la clasificación, fue utilizado el concepto Drop-Out, que consiste en apagar la mitad de las neuronas durante cada capa, con el fin de cada neurona del sistema sea independiente y no dependa de otra para la correcta clasificación de los residuos, tal y como muestra la Figura 13. Con esto, el sistema diferenció los tipos de residuos, reconociendo formas tales como líneas o curvas, que son los tipos de línea que permiten reconocer los residuos sólidos que ingresan al sistema.

Figura 13. *Representación del proceso de modelo convolucional con Drop Out para procesamiento de imágenes.*
Representación del proceso de modelo convolucional con Drop Out para procesamiento de imágenes.



4.4.6. Diseño del algoritmo y pruebas de rendimiento

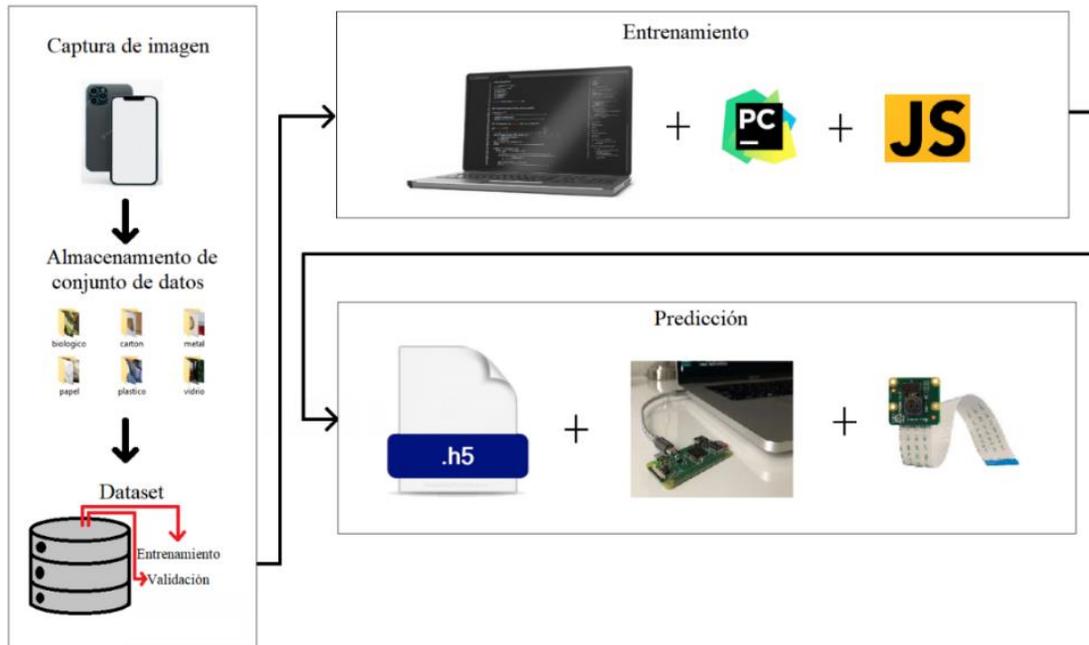
A continuación, se presenta la metodología del algoritmo que se encuentra dividida en dos secciones, el algoritmo de entrenamiento en el cual se extraen las características y clasifica las imágenes y el algoritmo de predicción en el cual permite visualizar por medio de la computadora las imágenes y a su vez encender la cámara por el sistema embebido Raspberry pi 4 para la predicción del residuo.

4.4.6.1. Metodología del algoritmo

Este algoritmo se desarrolla en tres fases, la primera comprende en la captura, almacenamiento y creación de un dataset, en dicha fase se realiza la toma de fotografías por medio de diferentes dispositivos móviles, lo cual permite almacenar imágenes con distintos pixeles de los residuos en la ciudad de Cúcuta, para ello se realizó la clasificación en seis categorías las cuales son: plástico, papel, vidrio, metal, biológico y cartón; Estos residuos son muy comunes en las calles de la ciudad, por lo tanto, se recolectó un total de 24.232 imágenes. Con esto, utilizando las librerías SciPy, NumPy, TensorFlow y Keras, fue programado el algoritmo de entrenamiento y validación del modelo con el dataset previamente diseñado, realizando las pruebas correspondientes en un ordenador y una webcam estándar conectada al mismo como variable de entrada al sistema.

Figura 14. *Metodología del algoritmo.*

Metodología del algoritmo.



Una vez el sistema obtuvo el comportamiento deseado, fue generado un archivo .h5 el cual se entrenó con la cantidad de (4.408) imágenes de cartón, (4.384) imágenes de papel, (4.400) imágenes de metal, (2.392) imágenes biológicas y (4.240) imágenes de plástico, para ser instalado en la tarjeta Raspberry Pi 4, la cual poseía una cámara periférica; y que ejecutó con éxito el algoritmo modelado en el ordenador. Todo el proceso se resume en el flujograma de la Figura 14.

4.4.6.2. *Algoritmo propuesto para extracción de características, entrenamiento, validación y predicción de objetos.*

Como se mencionó anteriormente, para el desarrollo del algoritmo se realizó en tres etapas, las cuales se verán a continuación:

- **Extracción de características**

Figura 15. *Extracción de características.*

Extracción de características.



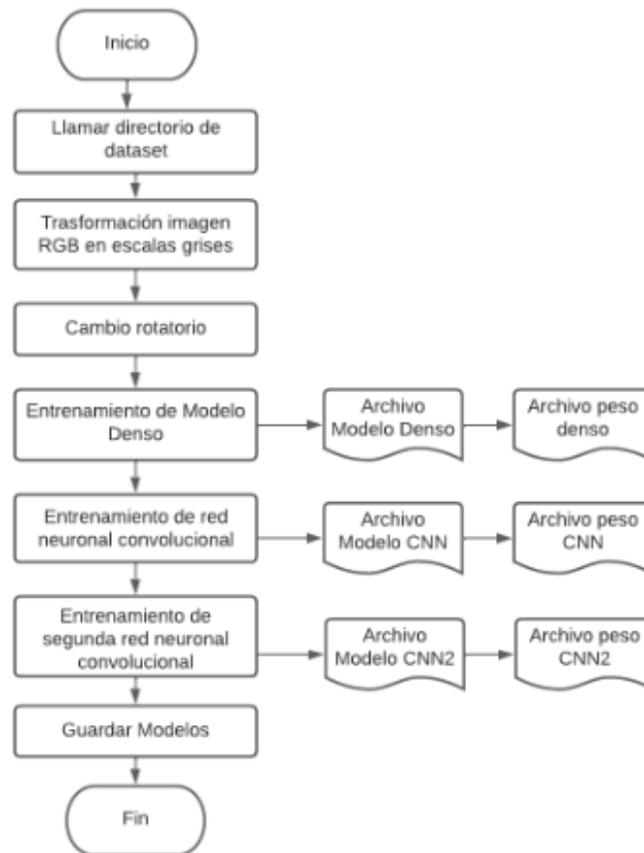
La primera etapa del proceso se representa en la Figura 15, la cual consiste en utilizar como entrada al sistema la fotografía original de un residuo sólido. Esta imagen ingresa a una capa convolutiva y una capa de agrupación que analiza y extrae las características topológicas del residuo sólido presente en la imagen para posteriormente ser clasificado por las capas ocultas de la red neuronal, y finalmente ser representada nuevamente en la salida con la etiqueta correspondiente a su categoría.

4.4.6.3. Algoritmo propuesto para entrenamiento y validación

Posterior al algoritmo de extracción de características, tal y como muestra el flujograma de la Figura 16, inicia el algoritmo de entrenamiento del sistema, que consiste en transformar las imágenes en cuanto a resolución, y conversión de RGB a escala de grises, así como realizar giros en el archivo, para así generar 7 imágenes nuevas a partir de la imagen de entrada. Cuando se consigue esto, se realizan tres entrenamientos secuenciales a lo largo de la red neuronal. Tanto para el modelo denso, como para los dos modelos CNN, se generan dos archivos que corresponden a la imagen y al peso específico dentro de la red, los cuales se integran y se guardan como un gran modelo. Esto es lo que permite realizar la predicción, la cual se detalla en la siguiente etapa.

Figura 16. *Algoritmo propuesto para entrenamiento y validación.*

Algoritmo propuesto para entrenamiento y validación.

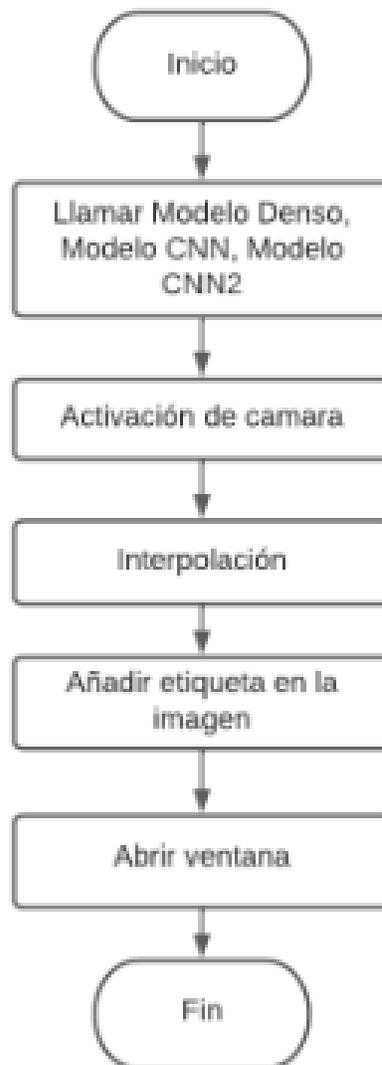


4.4.6.4. *Algoritmo propuesto para la predicción*

Una vez entrenado el modelo, el sistema posee la capacidad de etiquetar nuevas imágenes como variables de entrada dadas por la cámara conectada a la Raspberry Pi. Para esto, llama al Modelo Denso y a los dos modelos CNN para realizar la interpolación de los datos y poder etiquetar adecuadamente las imágenes que entran al sistema. Así, cuando la cámara detecta un objeto, representa en pantalla el tipo de residuo sólido a través de una etiqueta semejante a las asignadas en el proceso de entrenamiento y validación. Este proceso se simplifica en el flujograma de la Figura 17.

Figura 17. *Algoritmo propuesto para la predicción.*

Algoritmo propuesto para la predicción.

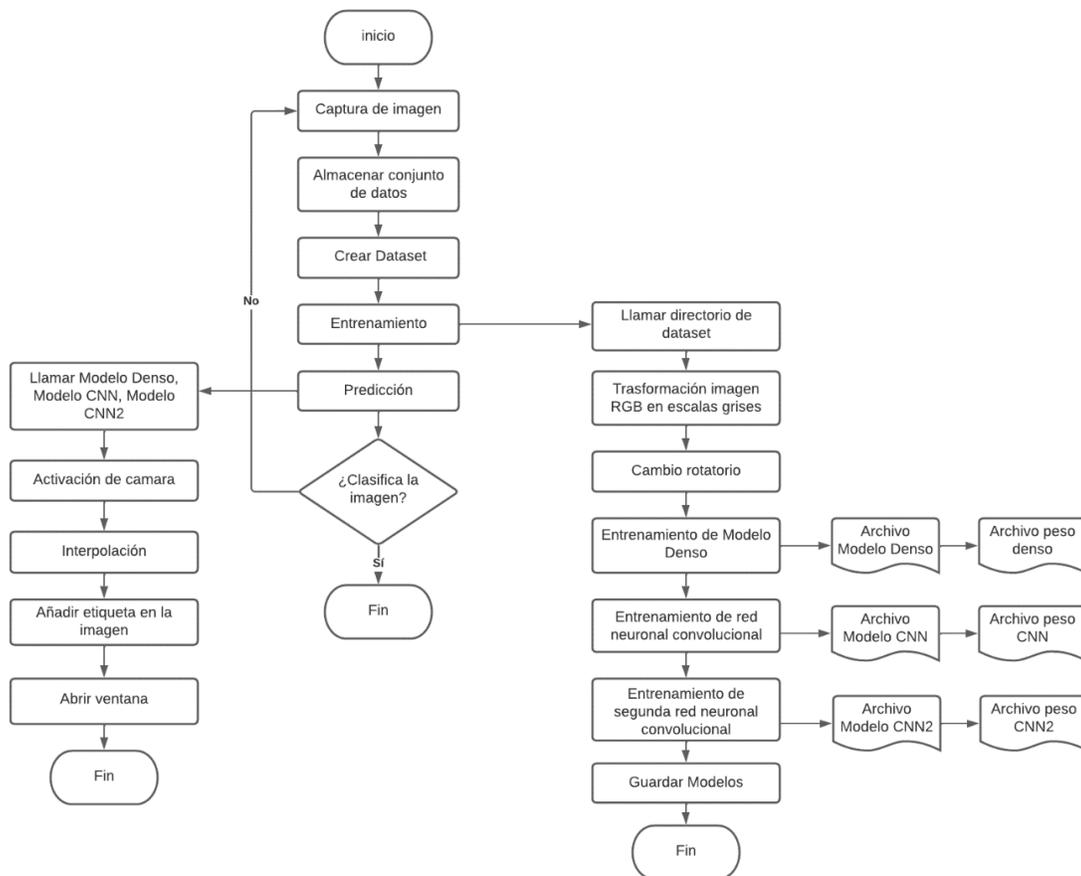


4.4.6.5. Algoritmo propuesto

En la figura 18, el algoritmo de identificación y clasificación de residuos sólidos, se encuentra la redimensión, etiquetado, cambio de canal, conversión a escala de grises e interpolación de las imágenes y la extracción de características para el entrenamiento, validación y predicción de objetos por medio de la cámara.

Figura 18. Algoritmo de identificación y clasificación de residuos sólidos

Algoritmo de identificación y clasificación de residuos sólidos



4.4.6.6. Validación de los modelos mediante parámetro de software

Como se mencionó anteriormente, se utilizaron tres tipos de modelos: denso, convolucional y convolucional con Drop Out, de los cuales, en cada modelo se encuentran dos carpetas, una de entrenamiento y otra de validación. Por lo tanto, por medio de la herramienta de visualización de la librería tensor Flow se le asignó un color a cada modelo, como se evidencia en la tabla 19, este proceso se realizó con el fin de graficar el comportamiento que se obtuvo durante las épocas del sistema, dichos colores se utilizaron para las gráficas de validación de los parámetros de software.

Tabla 19. Colores utilizados para la realización de la gráfica de entrenamiento y validación de residuos biológico y residuos plásticos.

Colores utilizados para la realización de la gráfica de entrenamiento y validación de residuos biológico y residuos plásticos.

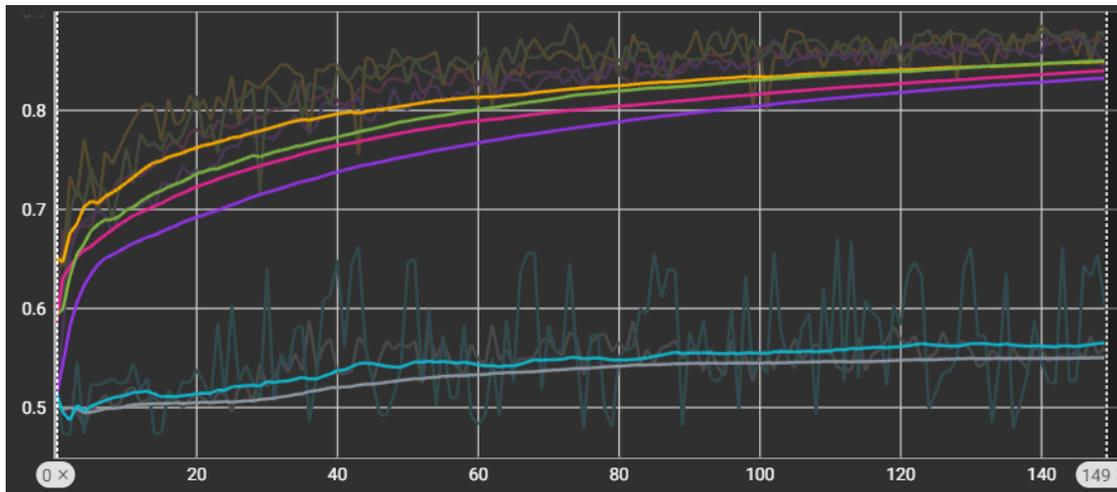
Modelo denso- entrenamiento	
Modelo denso – validación	
Modelo CNN – entrenamiento	
Modelo CNN – validación	
Modelo CNN con Drop Out – entrenamiento	
Modelo CNN con Drop Out - validación	

4.4.6.7. *Entrenamiento y validación de residuos de cartón y residuos de papel.*

A continuación, en la figura 19 se evidencia el comportamiento que se obtuvo durante el entrenamiento y la validación de los residuos de cartón y papel, y en la figura 20 la función de pérdida durante las épocas.

Figura 19. Grafica de entrenamiento y validación de residuos de cartón y residuos de papel.

Grafica de entrenamiento y validación de residuos de cartón y residuos de papel.



Sin embargo, como se evidencia en la tabla 20, el modelo de entrenamiento y validación con menor precisión es el modelo denso, de los cuales se obtiene un rango de precisión del 47.2% y 56.2%. Por otro lado, durante el entrenamiento del modelo convolucional con drop out se obtuvo una precisión del 83.2% y en la validación un 85%.

Tabla 20. Valores obtenidos en el entrenamiento y validación de los residuos de cartón y residuos de papel

Valores obtenidos en el entrenamiento y validación de los residuos de cartón y residuos de papel.

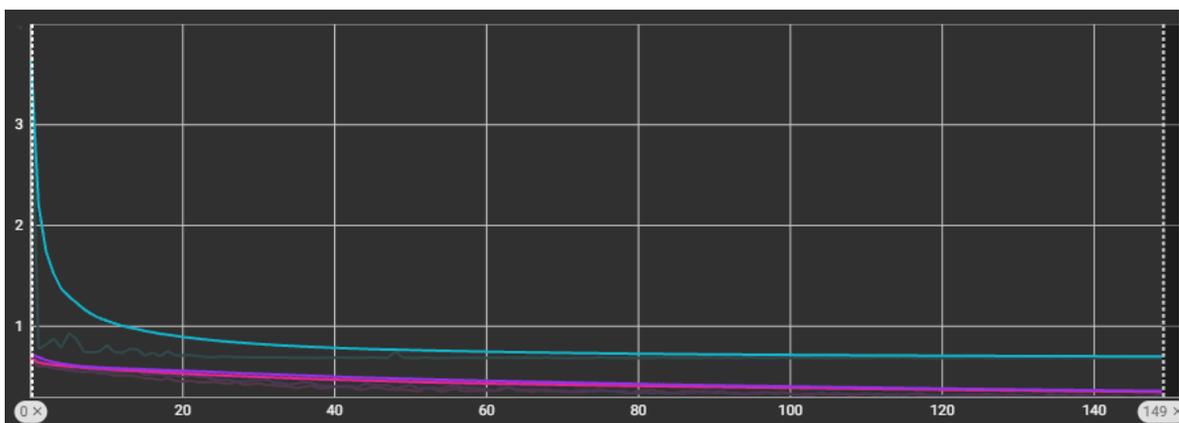
Modelos	Min	Max	Star Value	End Value	Value	% Value
Denso- entrenamiento	0,472	0,562	0,472	0,562	0,08978	19%
Denso - validación	0,497	0,547	0,497	0,547	0,05028	10%

CNN – entrenamiento	0,583	0,84	0,583	0,84	0,2575	44%
CNN – validación	0,647	0,85	0,652	0,85	0,1976	30%
CNN con Drop Out – entrenamiento	0,509	0,832	0,509	0,832	0,3237	64%
CNN con Drop Out - validación	0,594	0,85	0,594	0,85	0,2564	43%

Con respecto a la figura 20, se evidencia que el modelo denso es el de menor precisión, sin embargo, en la tabla 21 la función de perdida dicho modelo mencionado, es el que obtiene un mayor rango de aprendizaje.

Figura 20. *Grafica de función de perdidas en el entrenamiento de cartón y de papel.*

Grafica de función de perdidas en el entrenamiento de cartón y de papel.



De igual forma, los modelos convolucionales contienen un rango de error menor, en lo cual se puede observar en cada época una disminución de los mismos, indicando

que los modelos convolucionales necesitaban un menor aprendizaje que un modelo denso.

Tabla 21. *Función de perdidas en el entrenamiento de cartón y de papel*

Función de perdidas en el entrenamiento de cartón y de papel.

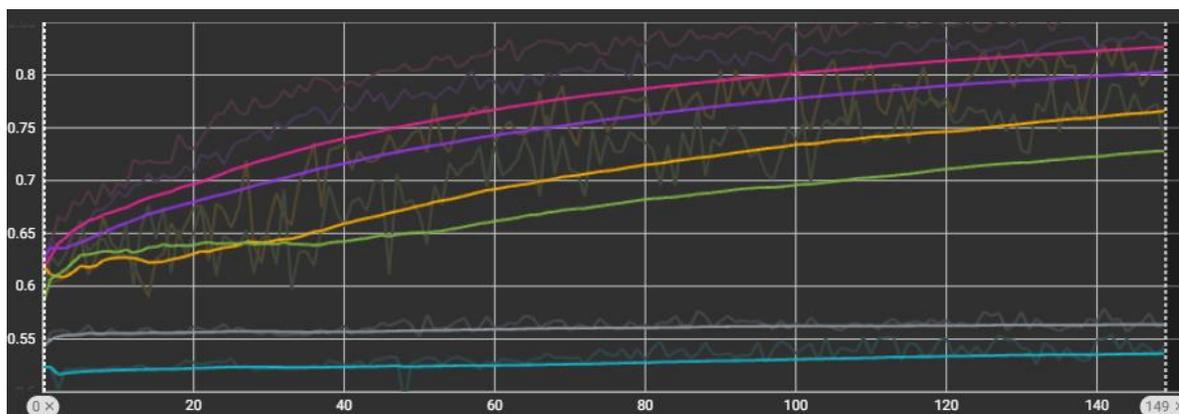
Modelos	Min	Max	Star Value	End Value
Denso- entrenamiento	0,7	3,654	3,654	0,7
CNN – entrenamiento	0,348	0,682	0,682	0,348
CNN con Drop Out – entrenamiento	0,358	0,729	0,729	0,358

4.4.6.8. *Entrenamiento y validación de residuos de metal y residuos de vidrio.*

Así mismo, durante el segundo entrenamiento se observa que se obtuvo una mayor precisión en el modelo convolucional con un rango mínimo de 61.7% y máximo de 82.7%. No obstante, al compararlo con el modelo convolucional con drop out tienen una diferencia de precisión de un 2.4%.

Figura 21. *Grafica de entrenamiento y validación de residuos de metal y residuos de vidrio.*

Grafica de entrenamiento y validación de residuos de metal y residuos de vidrio.



Así mismo, al realizar un análisis de la validación de los modelos convolucionales en la tabla 22, se obtiene una precisión del 76.6% y un 72.8% con la convolucional con drop out, a diferencia del modelo denso, el cual obtiene tiene un rango inferior de precisión a un 56.4%.

Tabla 22. *Valores obtenidos en el entrenamiento y validación de los residuos de metal y residuos de vidrio.*

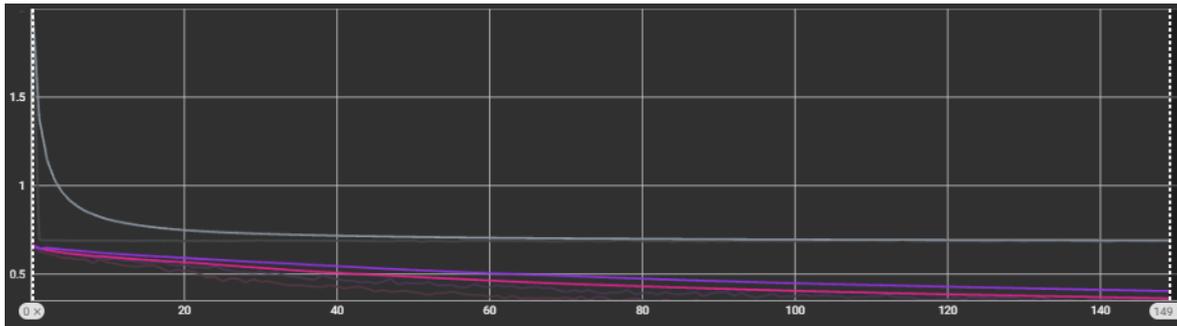
Valores obtenidos en el entrenamiento y validación de los residuos de metal y residuos de vidrio.

Modelo	Min	Max	Star Value	End Value	Value	% Value
Denso- entrenamiento	0,542	0,564	0,542	0,564	0,02122	4%
Denso - validación	0,516	0,536	0,523	0,536	0,01269	2%
CNN – entrenamiento	0,617	0,827	0,617	0,827	0,21	34%
CNN – validación	0,609	0,766	0,619	0,766	0,1465	24%
CNN con Drop Out – entrenamiento	0,626	0,803	0,626	0,803	0,1765	28%
CNN con Drop Out - validación	0,584	0,728	0,584	0,728	0,1437	25%

Por otro lado, la función de pérdida en el segundo entrenamiento el modelo denso es el que obtiene un mayor rango de aprendizaje, por lo cual, los errores comprendidos en este modelo disminuyeron de un 2.074 a 0.689.

Figura 22. Grafica de función de pérdidas en el entrenamiento de residuos de metal y residuos de vidrio

Grafica de función de pérdidas en el entrenamiento de residuos de metal y residuos de vidrio



En cambio, al comparar el modelo denso con los modelos convolucionales se evidencia que dichos modelos convolucionales tienen un rango menor de errores.

Tabla 23. Función de pérdidas en el entrenamiento residuos de metal y residuos de vidrio.

Función de pérdidas en el entrenamiento residuos de metal y residuos de vidrio.

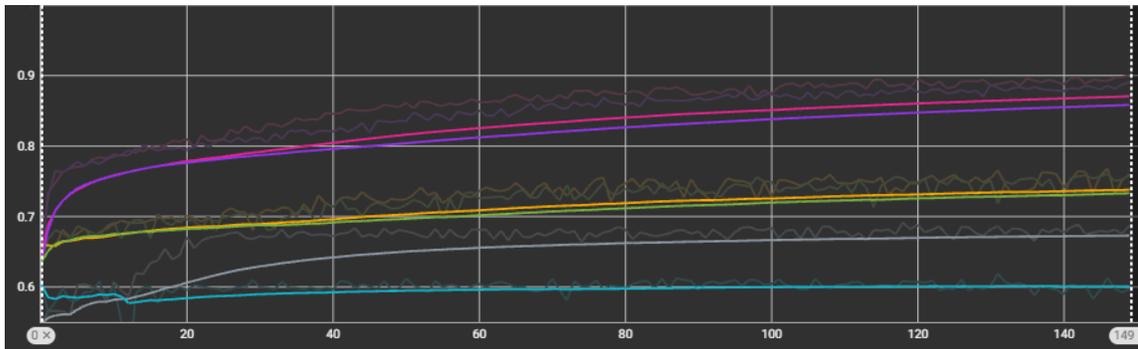
Modelo	Min	Max	Star Value	End Value
Denso- entrenamiento	0,689	2,074	2,074	0,689
CNN – entrenamiento	0,359	0,664	0,664	0,359
CNN con Drop Out – entrenamiento	0,402	0,66	0,66	0,402

4.4.6.9. Entrenamiento y validación de residuos biológicos y residuos de plásticos.

Finalmente, en la figura 23 se observa el entrenamiento y validación del sistema de residuos biológicos y plásticos.

Figura 23. Grafica de entrenamiento y validación de residuo biológico y residuo plástico.

Grafica de entrenamiento y validación de residuo biológico y residuo plástico.



Por lo tanto, en la tabla 24 se observa el valor mínimo y máximo que se comprende en un rango de 150 épocas, así mismo, de los tres modelos que se aplicaron, el modelo denso comienza con una precisión menor al 60% y un máximo de 67.3%. Sin embargo, los modelos convolucionales obtuvieron un mejor resultado en el entrenamiento con una precisión de 87% y 85.8%. No obstante, al realizar la validación de los modelos convolucionales se obtuvo una precisión del 73%, debido a que se utiliza una menor cantidad de imágenes.

Tabla 24. Valores obtenidos en el entrenamiento y validación de los residuos biológicos y residuos plásticos.

Valores obtenidos en el entrenamiento y validación de los residuos biológicos y residuos plásticos.

Modelos	Min	Max	Star Value	End Value	Value	% Value
Denso- entrenamiento	0,547	0,673	0,547	0,673	0,1259	23%
Denso - validación	0,577	0,605	0,605	0,6	0,004827	-1%

CNN – entrenamiento	0,642	0,87	0,642	0,87	0,2288	36%
CNN – validación	0,658	0,738	0,659	0,738	0,07868	12%
CNN con Drop Out – entrenamiento	0,632	0,858	0,632	0,858	0,2262	36%
CNN con Drop Out - validación	0,634	0,733	0,634	0,733	0,09881	16%

En la figura 24, se aprecia la función de pérdidas del entrenamiento del sistema de residuos biológicos y plásticos, evidenciando que el modelo denso comprende un mayor margen de error en el entrenamiento, sin embargo, los modelos convolucionales tienen un rango inicial de error bajo como se evidencia en la tabla 25.

Figura 24. Grafica de función de perdidas en el entrenamiento de residuos biológicos y plásticos.

Grafica de función de perdidas en el entrenamiento de residuos biológicos y plásticos.

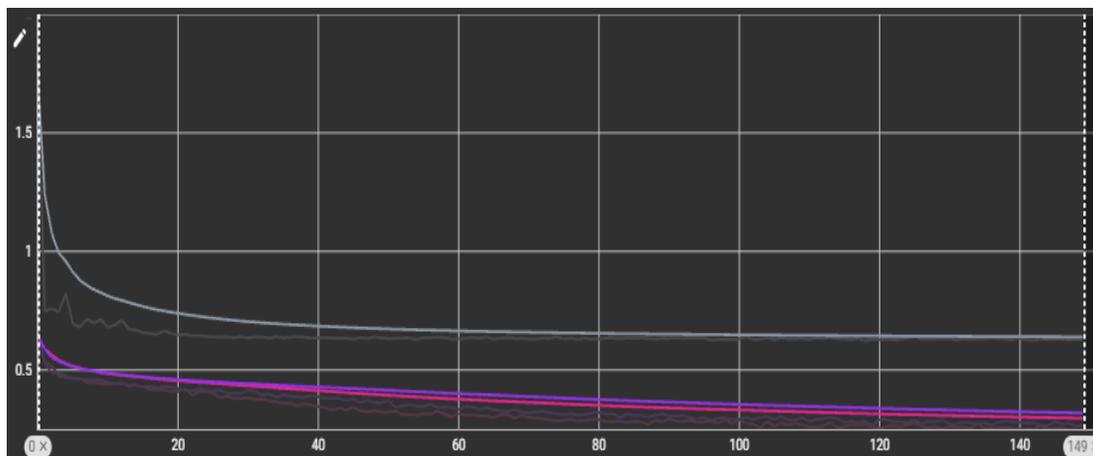


Tabla 25. *Función de pérdidas en el entrenamiento de residuos biológicos y plásticos.**Función de pérdidas en el entrenamiento de residuos biológicos y plásticos.*

Modelos	Min	Max	Star Value	End Value
Denso- entrenamiento	0,639	1,736	1,736	0,639
CNN – entrenamiento	0,295	0,64	0,64	0,295
CNN con Drop Out – entrenamiento	0,317	0,647	0,647	0,317

4.4.7. Validación de algoritmo y herramienta de hardware

A continuación, se realiza la descripción de la arquitectura, funcionamiento, aciertos y rendimiento del sistema cuando se implementa el software en el sistema embebido Raspberry Pi 4.

4.4.7.1. *Arquitectura y funcionamiento del sistema*

En primer lugar, se realiza la descripción de la arquitectura del sistema y en segundo lugar como funciona, dichas descripciones son realizadas para un mejor entendimiento del software y hardware. Como se observa en la figura 25, el algoritmo de identificación y clasificación de residuos sólidos propuesto permite visualizar a través de una cámara en tiempo real o por medio de videos pregrabados, los cuales serán conectados desde un computador a un sistema embebido de raspberry Pi OS versión 5.15, dicho sistema se alimenta de un voltaje DC de 985 Voltios.

El sistema embebido se encuentra programado en lenguaje Python en versión 3.10 y las librerías requeridas para el algoritmo son OpenCV versión 4.6.0.66, Numpy versión 1.23.5, TensorFlow versión 2.12.0, TensorBoard versión 2.12.3, matplotlib versión 3.7.1, Keras versión 2.12.0 y Scipy versión 1.10.1. Sin embargo, para una mejor identificación y clasificación de las imágenes, durante el entrenamiento del sistema se

realiza la conversión a escala de grises, extracción, redimensión y etiquetado de las imágenes, la clasificación se visualizará en una nueva ventana al ejecutar el código de predicción del sistema.

Figura 25. *Arquitectura del sistema.*

Arquitectura del sistema.

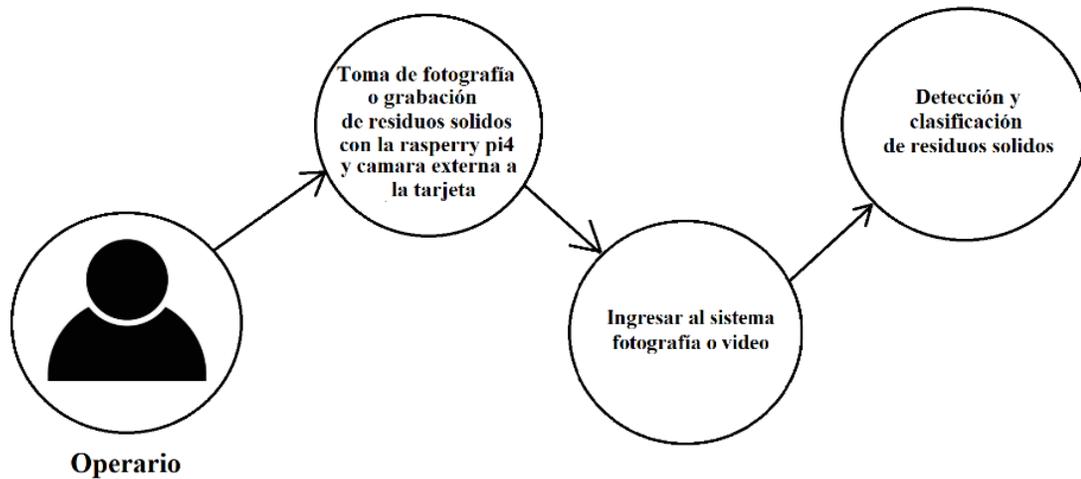


4.4.7.2. *Funcionamiento del sistema*

En la figura 26, se muestra una explicación de las actividades que se deben realizar para poder detectar y clasificar los residuos sólidos. Para ello, es necesario que el operario que se encuentre recolectando la información tome o capture imágenes de los residuos sólidos de manera individual o grupal, pero cerca de dicho elemento para obtener una mejor precisión, sin embargo, en el entrenamiento realizado se incluyeron fotografías de diferente calidad de imagen o pixeles, para lograr una mejor clasificación. El sistema necesario para poder procesar y clasificar dichos elementos, es un sistema es la última versión de 64 bits de Windows, macOS o Linux, disco SSD con 5 GB de espacio libre (o simplemente un disco con 2.5 GB libres y otro adicional para caché) y una resolución mínima del monitor 1024×768, los cuales, son elementos básicos para una computadora o Tablet, por lo tanto, puede ser utilizada por cualquier persona.

Figura 26. *Funcionamiento del sistema.*

Funcionamiento del sistema.

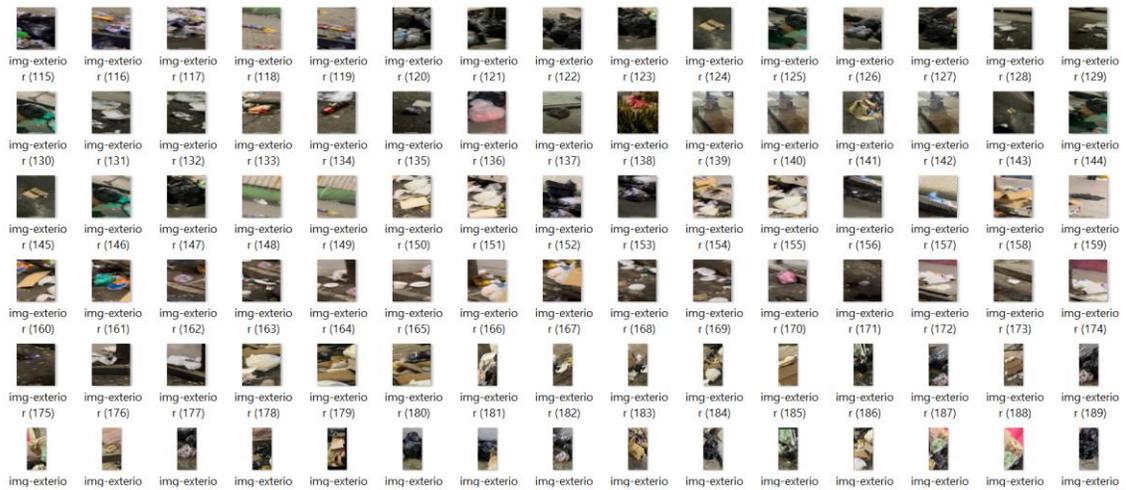


4.4.7.3. *Implementación y evaluación del software*

Para la realización de la evaluación del sistema, fue necesario la recolección de fotografías de los diferentes tipos de residuos, en tres sectores de la ciudad de Cúcuta. Para el desarrollo del proyecto fue necesario la recolección de un total de 837 imágenes que fueron tomadas en tres sectores distintos de la ciudad de Cúcuta, estos sectores fueron seleccionados al azar debido a puntos estratégicos o concurridos por los cucuteños. En primer lugar, encontramos el sector comprendido entre avenida 0 con diagonal Santander hasta la avenida 0 con primera, como se observa en la figura 27.

Figura 27. *Imágenes recolectadas en el sector de la avenida 0 de Cúcuta*

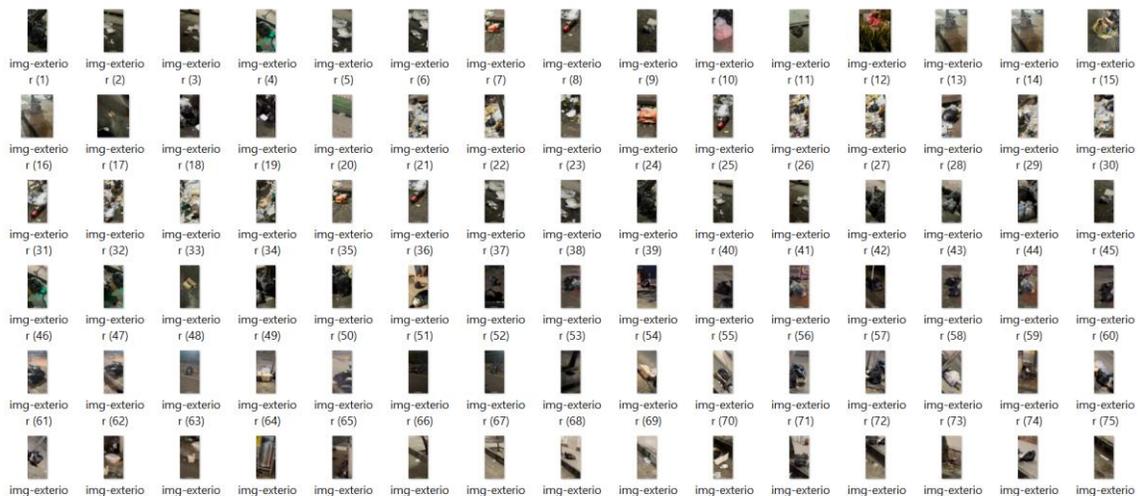
Imágenes recolectadas en el sector de la avenida 0 de Cúcuta



En segundo lugar, como se observa en la figura 28, el sector seleccionado comprende desde la avenida 6ta con calle 6ta hasta la avenida 6ta con calle 8va.

Figura 28. *Imágenes recolectadas en el centro de Cúcuta.*

Imágenes recolectadas en el centro de Cúcuta.



Y como tercer sector seleccionado como se observa en la figura 29, comprende lo que es la avenida libertadores o también conocida como “malecón”, debido a que este

sector es muy popular entre los habitantes de Cúcuta, para la recreación o punto de comidas.

Figura 29. *Imágenes recolectadas en la avenida libertadores de Cúcuta.*

Imágenes recolectadas en la avenida libertadores de Cúcuta.



Sin embargo, como se observa en la tabla 26, la cantidad de residuos no es igual en los tres sectores, aunque fueron tomadas en el lapso de las 8:00 p.m. a 9:00 p.m. durante 3 días.

Tabla 26. *Cantidad de imágenes de residuos sólidos,*

Cantidad de imágenes de residuos solidos

Sectores de la ciudad de Cúcuta	Cantidad de imágenes
Avenida 0	273
Avenida 6ta	342
Avenida libertadores	221

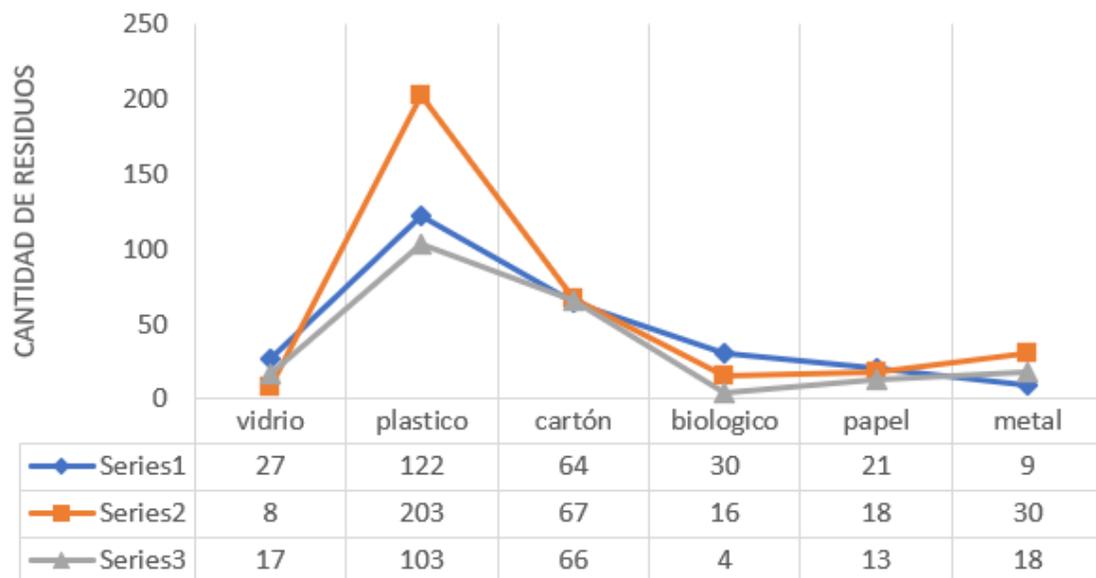
4.4.8. Clasificación de imágenes

La recolección de imágenes en tres puntos diferentes de la ciudad permitió la clasificación de las imágenes de acuerdo al tipo de residuo, por ende, se realizó la precisión con la que el sistema detectó, identificó y clasificó correctamente cada uno.

Para ello, se clasificaron los seis tipos de residuos: plástico, vidrio, papel, metal, vidrio y biológico. Por lo cual, la clasificación Series1 corresponde a los residuos recolectados de la avenida 0, en la clasificación Series2 a los residuos de la avenida 6 y la Serie3 a los residuos de la avenida libertadores, como se evidencia en la figura 30.

Figura 30. Clasificación de la recolección de residuos sólidos.

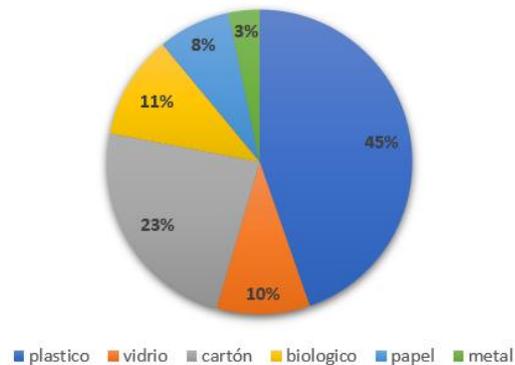
Clasificación de la recolección de residuos sólidos.



Respecto a la clasificación de la recolección de residuos sólidos de la avenida 0, se observa en la figura 31, el porcentaje de la cantidad de residuos sólidos que fueron encontrados durante la recolección de fotografías. De lo cual, se puede deducir que el plástico es el residuo más común en esta zona, y como segundo lugar el cartón, sin embargo, es el residuo con menor porcentaje en este sector es el metal.

Figura 31. *Recolección de residuos sólidos en la avenida 0.*

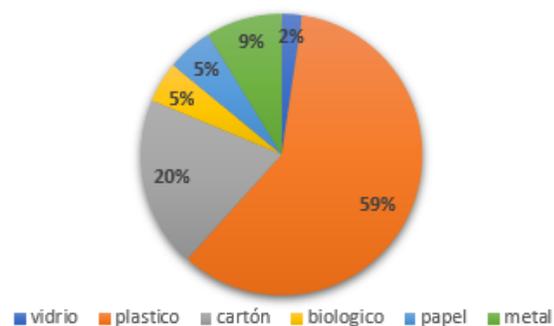
Recolección de residuos sólidos en la avenida 0.



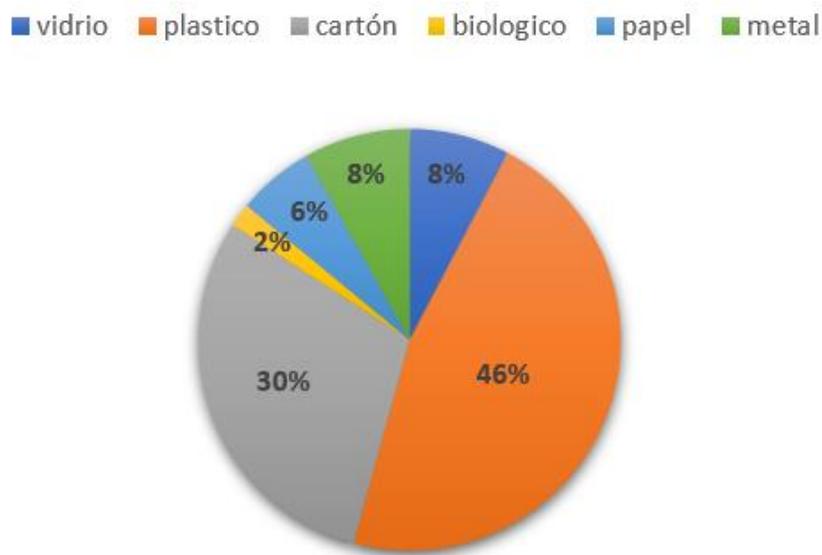
No obstante, como se evidencia en la figura 32, la cual corresponde a la recolección fotográfica de residuos en la avenida 6ta, se evidencia que al igual que en el sector de la avenida 0, el residuo más común es el plástico, el cual obtiene un porcentaje del 59%, obteniendo un porcentaje mayor a la mitad de los residuos recolectados en las fotografías en este sector.

Figura 32. *Recolección de residuos sólidos en la avenida 6.*

Recolección de residuos sólidos en la avenida 6.



Con relación a la figura 33, se puede contemplar el porcentaje de residuos que fueron recolectados en la avenida libertadores, destacando nuevamente la mayor cantidad de residuo sólido fue el plástico en un 46% y el de menor porcentaje fue el biológico con un 2%.

Figura 33. *Recolección de residuos sólidos en la avenida libertadores.**Recolección de residuos sólidos en la avenida libertadores.***4.4.9. Aciertos en las detecciones**

A continuación, se clasifican los residuos sólidos recolectados en la avenida 0, como se evidencia en la tabla 27.

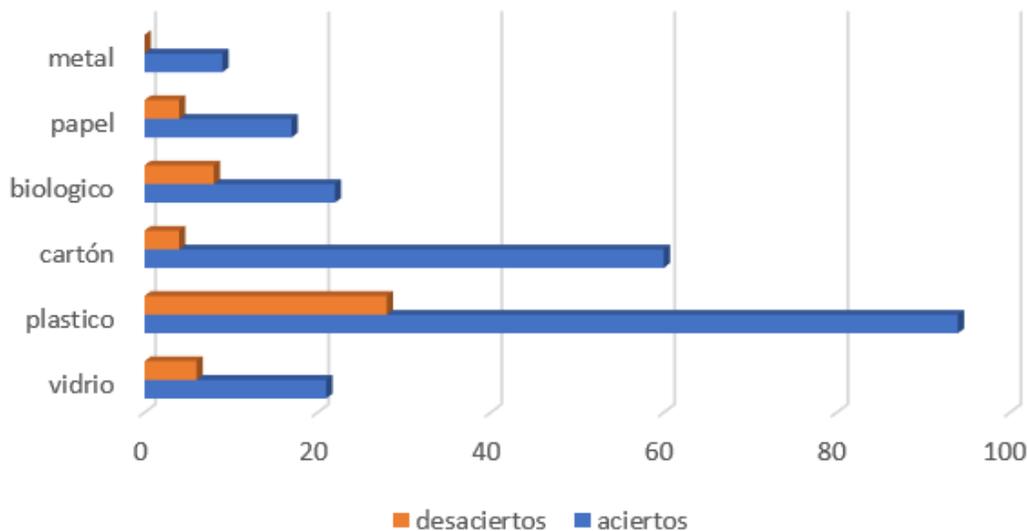
Tabla 27. *Identificación y clasificación de residuos sólidos de la avenida 0.**Identificación y clasificación de residuos sólidos de la avenida 0.*

Tipo de residuo	Cantidad de imágenes	Aciertos	Desaciertos	% precisión	% desaciertos
Plástico	122	94	28	0.77	0.23
Vidrio	27	21	6	0.78	0.22
Cartón	64	60	4	0.94	0.06
Biológico	30	22	8	0.73	0.27
Papel	21	17	4	0.8	0.2
Metal	9	9	0	1	0

Cabe destacar que en la tabla 21, se puede apreciar la cantidad de residuos que el sistema logra identificar y clasificar correcta o incorrectamente, en el sector de la avenida 0. Como consecuencia, se obtiene como resultado precisiones iguales o superiores a un 73%, sin embargo, el residuo plástico fue el que obtuvo una mayor repetición, con un total de 122 imágenes recolectadas para la predicción, de dichas imágenes fueron identificadas y clasificadas correctamente 94, lo que corresponde a una precisión del 77%. Por otro lado, el residuo biológico fue el que obtuvo una menor precisión con un 73%, esto se debe a que en el sector que se realizó la recolección, este tipo de residuo es poco frecuente; para una mejor comparación se realiza la figura 34, en la cual el color naranja es la cantidad de desaciertos y la azul los aciertos.

Figura 34. *Evaluación de la identificación de residuos en la avenida 0.*

Evaluación de la identificación de residuos en la avenida 0.



De igual forma, en la tabla 28 se evidencia la identificación y clasificación de los residuos sólidos en el sector de la avenida 6ta.

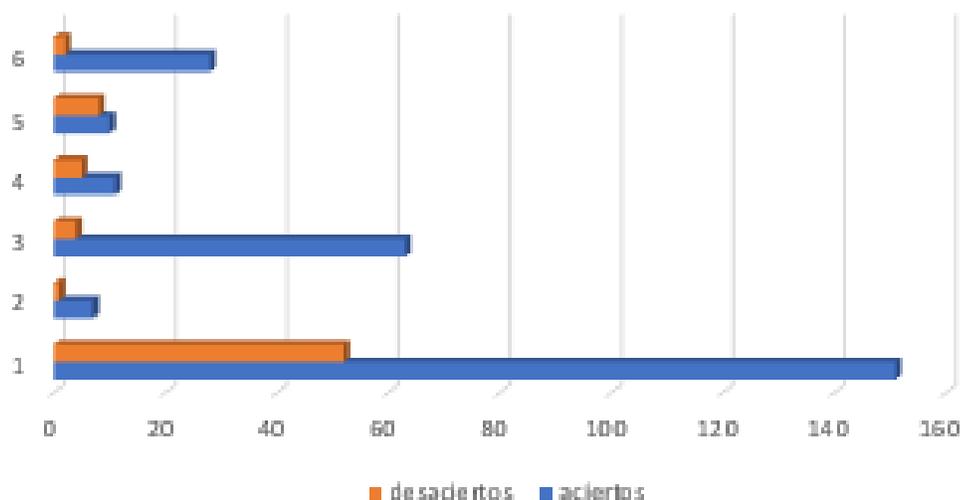
Tabla 28. *Identificación y clasificación de residuos sólidos de la avenida 6.**Identificación y clasificación de residuos sólidos de la avenida 6.*

Tipo de residuo	Cantidad de imágenes	Aciertos	Desaciertos	% precisión	% desaciertos
Plástico	203	151	52	0.74	0.26
Vidrio	8	7	1	0.875	0.125
Cartón	67	63	4	0.94	0.06
Biológico	16	11	5	0.687	0.313
Papel	18	10	8	0.56	0.44
Metal	30	28	2	0.93	0.07

De este sector, se puede inferir que el tipo de residuo más común igual que en la tabla 21, fue el plástico, sin embargo, la precisión en la identificación de dicho residuo no es la menor, pero tampoco tiene un porcentaje de precisión superior a un 80%, no obstante, el segundo residuo con mayor influencia es el cartón, el cual obtiene una precisión en la predicción de un 94%. En la figura 35, se puede observar la evaluación de la precisión de los residuos mencionados en la tabla anterior.

Figura 35. Evaluación de la identificación de residuos en la avenida 6.

Evaluación de la identificación de residuos en la avenida 6.



Por otro lado, en la tabla 29 se puede observar los porcentajes de precisión o desaciertos que se obtuvo durante la identificación y clasificación de los residuos de la avenida libertadores.

Tabla 29. Identificación y clasificación de residuos sólidos de la avenida libertadores.

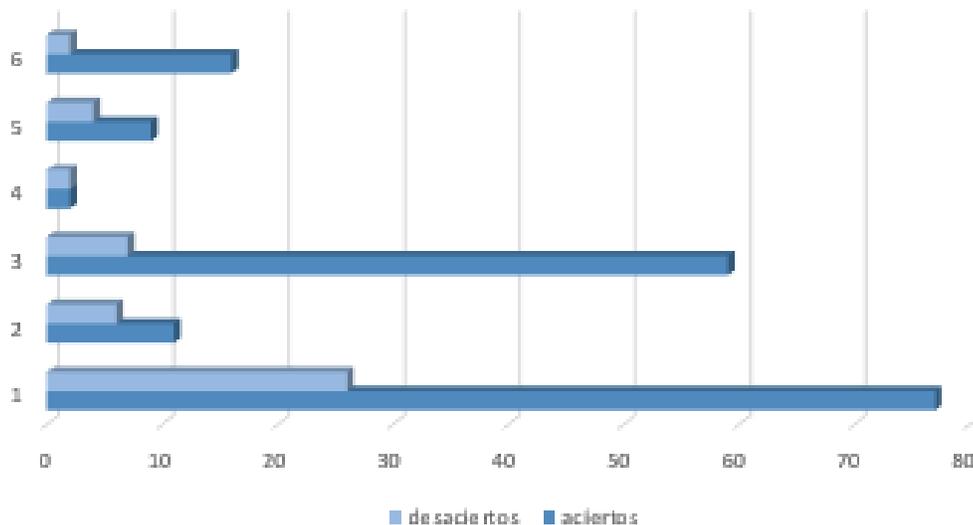
Identificación y clasificación de residuos sólidos de la avenida libertadores.

Tipo de residuo	Cantidad de imágenes	Aciertos	Desaciertos	% precisión	% desaciertos
Plástico	103	77	26	0.75	0.25
Vidrio	17	11	6	0.65	0.35
Cartón	66	59	7	0.89	0.11
Biológico	4	2	2	0.5	0.5
Papel	13	9	4	0.69	0.31
Metal	18	16	2	0.89	0.11

Sin embargo, la recolección en esta zona fue la de menor influencia, debido a que existen muchos restaurantes los cuales mantienen el sector de forma ordenada, no obstante, el residuo que obtuvo una mejor precisión en la identificación fue el cartón y el metal con un 89%, como se observa en la figura 36.

Figura 36. Evaluación de la identificación de residuos en la avenida libertadores

Evaluación de la identificación de residuos en la avenida libertadores

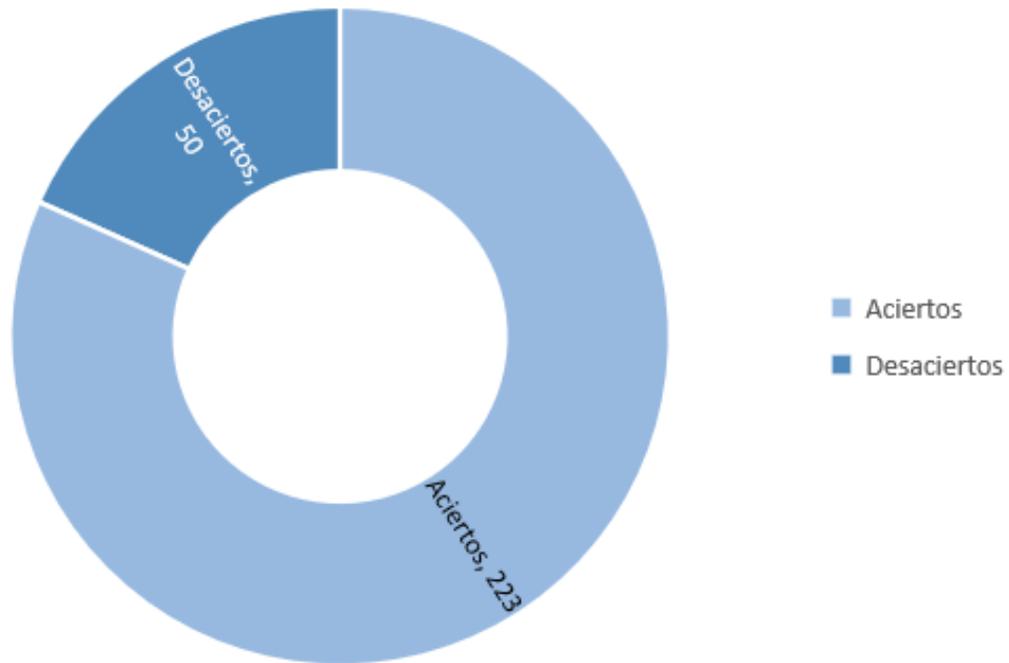


4.4.10. Rendimiento del sistema

Resumiendo lo planteado anteriormente, al haber recolectado un total de 873 imágenes en tres diferentes sectores con una gran afluencia de cucuteños diariamente, estos sectores tienden a producir una gran cantidad de residuos los cuales no son tratados o clasificados correctamente. Por lo tanto, en la avenida 0, se recolectaron un total de 273 imágenes de los seis tipos de residuos que son estudiados en el proyecto; al realizar la predicción de las 273 imágenes, se obtiene una precisión de un 81.7% en la clasificación de todos los residuos como se evidencia en la figura 37, sin embargo, también se obtuvo un desacierto del 18.3%.

Figura 37. *Precisión de clasificación de residuos de la avenida 0.*

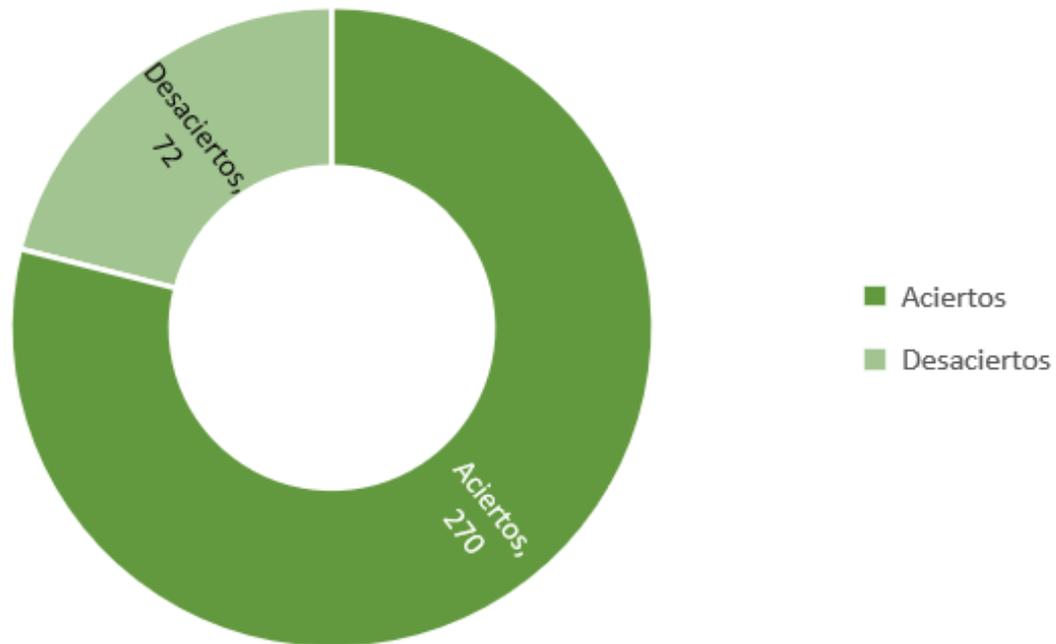
Precisión de clasificación de residuos de la avenida 0.



El segundo sector corresponde a la avenida 6ta con calle 6ta hasta la avenida 6ta con calle 8va, allí se encuentra ubicado el centro comercial Alejandría, este centro comercial es uno de los más importantes de la ciudad, debido a la cantidad de establecimientos que se encuentran en el edificio, además a sus alrededores se encuentran vendedores ambulantes durante todo el día, por ende, en este sector se logró una mayor recolección de imágenes, con un total de 342. Al realizar la predicción de los residuos sólidos, se obtuvo una precisión del 78.9% y un desacierto del 21.1%, como se observa en la figura 38.

Figura 38. *Precisión de clasificación de residuos de la avenida 6ta.*

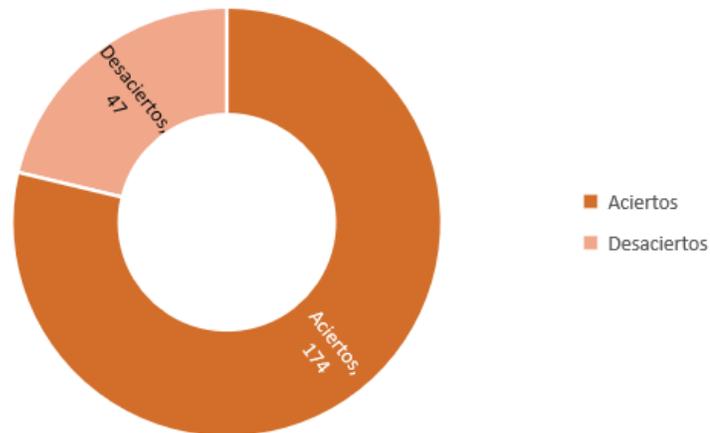
Precisión de clasificación de residuos de la avenida 6ta.



Y, por último, se realizó la recolección de imágenes en el sector de la avenida libertadores, este lugar cuenta con una extensa avenida en la cual se encuentra diversidad de restaurantes, CAI's, parques, plazoletas, droguerías, entre otros. Sin embargo, aunque es muy concurrido por los ciudadanos, la cantidad de residuos recolectados fotográficamente en este sector son muy bajos, con un total de 221 imágenes y una precisión del 78.7% y un desacierto del 21.3%, como se evidencia en la figura 39.

Figura 39. *Precisión de clasificación de residuos de la avenida libertadores.*

Precisión de clasificación de residuos de la avenida libertadores.



No obstante, al realizar las pruebas mencionadas anteriormente, se obtuvo un rango entre el 15% - 49% de uso de la CPU de las raspberry pi 4, desde el momento en que se abre el software PyCharm® hasta la ejecución del algoritmo de predicción, como se observa a en la figura 40-41, el cual comprende la precisión, encendido de la cámara externa y la visualización de la predicción, lo que produjo una temperatura mínima de 32° y máxima de 58°.

Figura 40. *Conexión de raspberry pi 4 con software PyCharm®*

Conexión de raspberry pi 4 con software PyCharm®



5. Conclusiones

Para el desarrollo del proyecto se realizó la investigación de 50 referencias bibliográficas desde el año 2016, en las cuales se evidencian los algoritmos que son utilizados para el desarrollo de dichos proyectos; como consecuencia del análisis, se obtuvo que un 26% de los proyectos usaban como herramienta las redes neuronales artificiales (ANN), un 30 % Fuzzy (Lógica difusa) y un 44% Machine Learning. Sin embargo, los algoritmos mencionados anteriormente cuentan con una gran variedad de subcategorías; observando que en el algoritmo machine Learning el aprendizaje Deep Learning es el más utilizado en un 40.9% de los proyectos, y en los algoritmos ANN se obtuvo una aplicación del 100% de redes convolucionales, lo cual permitió un mejor aprendizaje de los sistemas. Por tanto, se estableció como referencia un aprendizaje Deep Learning con redes neuronales convolucionales.

Como resultado, al haber elegido el aprendizaje y la red neuronal artificial para realizar el proyecto, se seleccionó como lenguaje de programación Python 3.10 y como software PyCharm®, debido a que este software permite la instalación directa desde la aplicación de librerías utilizadas en redes neuronales; Con esta tecnología se permitió la utilización de un sistema embebido como lo es la raspberry pi 4, permitiendo el uso de una cámara externa para la identificación y clasificación de residuos sólidos en tiempo real.

No obstante, para el diseño del proyecto se realizaron dos diferentes algoritmos, el primero consiste en un entrenamiento de imágenes que fueron tomadas en diferentes puntos de la ciudad de Cúcuta y como segundo, un algoritmo de predicción en el que se incluye el entrenamiento mencionado anteriormente. No fue utilizada una red pre-entrenada debido a que las imágenes con las que se realizó el entrenamiento, correspondían a ciudades con

un manejo de residuos diferente a la que se vive en el país, así mismo se encontraban dataset de residuos sólidos de forma individual, lo que no permitiría que el sistema logrará una predicción correcta al realizar las pruebas de funcionamiento en las calles de la ciudad de Cúcuta, por lo tanto, con las imágenes tomadas se realizó un dataset de 24.232 imágenes de los seis diferentes tipos de residuos, el sistema tuvo un entrenamiento de modelo denso, modelo convolucional y modelo convolucional con drop out, cada uno de ellos con una cantidad de 150 épocas, tomando un tiempo de entrenamiento de 12 horas en un computador con procesador icore3, sin embargo, este entrenamiento solo debe ser realizado una vez; al ejecutar el algoritmo toma un tiempo de 28.32 s, para encender la cámara externa que es conectada al sistema para la predicción en tiempo real.

Como resultado, se obtiene para la clase de plástico una eficiencia del 75.3%, para vidrio del 76.8%, cartón del 92.3%, biológico del 63.9%, papel del 68.3% y metal del 94%, como se observa las clases de menor rendimiento fueron las de biológico y papel, debido a que estos tipos de residuos son los que tienden a sufrir más transformaciones debido al ambiente donde se encuentren, sin embargo, residuos como el metal y el cartón contienen una característica o estructura con una mejor resistencia al ambiente, por lo cual, se logra obtener un mejor entrenamiento de estos residuos, produciendo una mejor predicción. Al ejecutarse el sistema en la placa embebida de raspberry se mostró que los archivos de entrenamiento tienen un tamaño de 1.915KB, por lo tanto, al ejecutar se obtuvo un tiempo de ejecución de 52.37s y un uso de CPU del 49% con una temperatura máxima de 58°.

6. Recomendaciones

Para realizar el procesamiento de la imagen en tiempo real, es necesario que la toma o captura de los diferentes residuos sólidos no sea en un ambiente desfavorable, por lo que se recomienda un entrenamiento del sistema en diferentes horas del día. Sin embargo, para mejorar la precisión del sistema es necesario una mayor recolección de dataset para el entrenamiento y validación del sistema.

Por otro lado, el sistema hardware utilizado en el desarrollo del proyecto fue un sistema embebido como es la raspberry pi 4, la cual sufre de recalentamiento al realizar el proceso de ejecución de la predicción del sistema, por ende, es recomendable manejar el sistema embebido en un lugar a temperatura ambiente, para así evitar un sobrecalentamiento en la placa.

El algoritmo propuesto puede ser potenciado por medio de diferentes técnicas de procesamiento de imágenes y aprendizaje automático que impliquen la optimización de procesos enfocados en la mejora de imágenes, extracción y reducción de características, además de etiquetado de imágenes y su clasificación.

7. Trabajos futuros

A corto plazo, se propone la implementación del sistema de procesamiento propuesto para la identificación y clasificación de residuos sólidos en una empresa prestadora de servicios públicos en la recolección de dichos residuos, con el fin de mejorar la eficiencia y separación de residuos, además de reducir costos y mitigar el impacto ambiental que se está viviendo en el país. Así mismo, la creación de un dispositivo de procesamiento basado en una aplicación móvil para cualquier tipo de usuario para poder usar en casa, trabajo o cualquier lugar en que se encuentren, este dispositivo se haría con el fin de identificar y clasificar diferentes tipos de residuos que se encuentran en el diario vivir, maximizando el potencial de reciclaje y reduciendo la cantidad de desechos.

Referencias Bibliográficas

- Abdullah, L., Zulkifli, N., Liao, H., Herrera-Viedma, E., & Al-Barakati, A. (2019). An interval-valued intuitionistic fuzzy DEMATEL method combined with Choquet integral for sustainable solid waste management. *Engineering Applications of Artificial Intelligence*, 82, 207-215. <https://doi.org/10.1016/j.engappai.2019.04.005>
- Adedeji, O., & Wang, Z. (2019). Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network. *Procedia Manufacturing*, 35, 607-612. <https://doi.org/10.1016/j.promfg.2019.05.086>
- Adeleke, O., Akinlabi, S. A., Jen, T.-C., & Dunmade, I. (2022). Prediction of municipal solid waste generation: an investigation of the effect of clustering techniques and parameters on ANFIS model performance. *Environmental Technology*, 43(11), 1634-1647. <https://doi.org/10.1080/09593330.2020.1845819>
- Ahmed, L., Ahmad, K., Said, N., Qolomany, B., Qadir, J., & Al-Fuqaha, A. (2020). Active Learning Based Federated Learning for Waste and Natural Disaster Image Classification. *IEEE Access*, 8, 208518-208531. <https://doi.org/10.1109/ACCESS.2020.3038676>
- Alberca, A. S. (2022). *La librería numpy*. Aprende con Alf. <https://aprendeconalf.es/docencia/python/manual/numpy/>
- Alojamientos.us.es. (2022). *Procesamiento de imágenes digitales*. <http://alojamientos.us.es/gtocomapid/introduccion.html>
- Andesco, A. N. de E. de S. P. y C. (2022). *El 78% de los hogares colombianos no recicla*. <https://www.andesco.org.co/en/2020/03/02/el-78-de-los-hogares-colombianos-no-recicla/>

- Andesco.org.co. (2022). *El 78% de los hogares colombianos no recicla*.
<https://www.andesco.org.co/en/2020/03/02/el-78-de-los-hogares-colombianos-no-recicla/>
- Aprende ML. (2020). *¿Cómo funcionan las convolutional neural networks? Visión por Ordenador*. <https://www.aprendemachinelearning.com/como-funcionan-las-convolutional-neural-networks-vision-por-ordenador/>
- Aral, R. A., Keskin, S. R., Kaya, M., & Haciomeroglu, M. (2018). Classification of TrashNet Dataset Based on Deep Learning Models. *2018 IEEE International Conference on Big Data (Big Data)*, 2058-2062.
<https://doi.org/10.1109/BigData.2018.8622212>
- Arévalo, V. M., Gonzáles, J., & Ambrosio, G. (2023). *La Librería de Visión Artificial OPENCV Aplicación a la docencia y la investigación*.
<http://mapir.isa.uma.es/varevalo/drafts/arevalo2004lva1.pdf>
- BBVA. (2022). *¿Qué es y qué tipos de contaminación ambiental existen?* BBVA Noticias.
<https://www.bbva.com/es/sostenibilidad/que-es-y-que-tipos-de-contaminacion-ambiental-existen/>
- Bobulski, J., & Kubanek, M. (2020). *The triple histogram method for waste classification*. 420004. <https://doi.org/10.1063/5.0027020>
- Bogota.gov.co. (2022). *Reciclaje, el primer paso responsable para aprovechar la basura que generamos*. [https://bogota.gov.co/yo-participo/blogs/basura-en-bogota-una-responsabilidad-de-todos-los-ciudadanos#:~:text=Cada persona produce cerca de,mal aspecto visual del entorno](https://bogota.gov.co/yo-participo/blogs/basura-en-bogota-una-responsabilidad-de-todos-los-ciudadanos#:~:text=Cada%20persona%20produce%20cerca%20de,%20mal%20aspecto%20visual%20del%20entorno.).
- Bui, T. D., Tsai, F. M., Tseng, M.-L., & Ali, M. H. (2020). Identifying sustainable solid waste management barriers in practice using the fuzzy Delphi method. *Resources*,

Conservation and Recycling, 154, 104625.

<https://doi.org/10.1016/j.resconrec.2019.104625>

Chatzigeorgakidis, G., Karagiorgou, S., Athanasiou, S., & Skiadopoulos, S. (2018). FML-kNN: scalable machine learning on Big Data using k-nearest neighbor joins. *Journal of Big Data*, 5(1), 4. <https://doi.org/10.1186/s40537-018-0115-x>

Programadorclic.com. (2022). *Clasificación de imágenes, detección de objetos, segmentación semántica, segmentación de instancias y otros conceptos.*

<https://programmerclick.com/article/2299928720/>

Codificandobits. (2022). *La Función de Activación.*

<https://www.codificandobits.com/blog/funcion-de-activacion/>

CSN España. (2022). *Clasificación de residuos radiactivos - CSN.*

<https://www.csn.es/clasificacion-de-residuos-radiactivos>

DESCONT. (2022). *Crisis mundial por la basura: solo el 16% de los desechos son reciclados.* <https://www.descont.com.co/publicaciones/noticias/crisis-mundial-por-la-basura-solo-el-16-de-los-desechos-son-reciclados>

Diario La República. (2022). *Colombia solo recicla 17% de los 12 millones de toneladas de residuos sólidos que se dan al año.* [https://www.larepublica.co/empresas/colombia-solo-recicla-17-de-los-12-millones-de-toneladas-de-residuos-solidos-al-ano-3066464#:~:text=El reciclaje se ha convertido,1%2C8%25 del total de](https://www.larepublica.co/empresas/colombia-solo-recicla-17-de-los-12-millones-de-toneladas-de-residuos-solidos-al-ano-3066464#:~:text=El%20reciclaje%20se%20ha%20convertido%2C1%20%25%20del%20total%20de)

Díaz-Romero, D., Sterkens, W., Van den Eynde, S., Goedemé, T., Dewulf, W., & Peeters, J. (2021). Deep learning computer vision for the separation of Cast- and Wrought-Aluminum scrap. *Resources, Conservation and Recycling*, 172, 105685.

<https://doi.org/10.1016/j.resconrec.2021.105685>

DNP Colombia. (2022). *Rellenos sanitarios de 321 municipios colapsarán en cinco años, advierte el DNP*. <https://bogota.gov.co/yo-participo/blogs/basura-en-bogota-una-responsabilidad-de-todos-los-ciudadanos#:~:text=Cada persona produce cerca de,mal aspecto visual del entorno.>

Dubey, S., Singh, M. K., Singh, P., & Aggarwal, S. (2020). Waste Management of Residential Society using Machine Learning and IoT Approach. *2020 International Conference on Emerging Smart Computing and Informatics (ESCI)*, 293-297. <https://doi.org/10.1109/ESCI48226.2020.9167526>

IBM. (2023). *El Modelo de Redes neuronales*. Neural Networks.

<https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model#:~:text=Una red neuronal es un,procesamiento se organizan en capas>

Ferro, C., Celis Mayorga, N., & Casallas García, A. (2020). *Llenado de series de datos de 2014 a 2019 de PM2.5 por medio de una red neuronal y una regresión lineal*. <https://doi.org/10.13140/RG.2.2.35092.53126>

Frost, S., Tor, B., Agrawal, R., & Forbes, A. G. (2019). CompostNet: An Image Classifier for Meal Waste. *2019 IEEE Global Humanitarian Technology Conference (GHTC)*, 1-4. <https://doi.org/10.1109/GHTC46095.2019.9033130>

Fundación Aequae. (2022). *¿Qué es la contaminación ambiental?* Aequae.

<https://www.fundacionaequae.org/wiki/causas-contaminacion-ambiental/>

Gan, B., & Zhang, C. (2020). Research on the algorithm of urban waste classification and recycling based on deep learning technology. *2020 International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, 232-236. <https://doi.org/10.1109/CVIDL51233.2020.00-95>

- Garg, H., & Rani, D. (2022). An efficient intuitionistic fuzzy MULTIMOORA approach based on novel aggregation operators for the assessment of solid waste management techniques. *Applied Intelligence*, 52(4), 4330-4363. <https://doi.org/10.1007/s10489-021-02541-w>
- Gaur, A., Prakash, H., Anand, K., Kumar, G., & Hussain, A. (2022). Evaluation of Municipal Solid Waste Management Scenarios using Multi-Criteria Decision Making under Fuzzy Environment. *Process Integration and Optimization for Sustainability*, 6(2), 307-321. <https://doi.org/10.1007/s41660-021-00215-1>
- Ghasemi, M., Gorsich, D., Vantsevich, V., Moradi, L., Paldan, J., Cole, M., Goryca, J., & Singh, A. (2022). Robust Control of an Off-Road Single-Wheel Module Using Sliding Mode Control and Fuzzy Logic Control. *2022 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*, 730-735. <https://doi.org/10.1109/AIM52237.2022.9863386>
- González, L. (2023). *¿Qué es tensorflow? ¿Cómo funciona? Aprende IA*. <https://aprendeia.com/que-es-tensorflow-como-funciona/>
- Guevara, M., Castaño, S., Guevara, P., & Contreras, D. (2021). Punto ecológico automatizado para separación y clasificación de residuos a través de una neurona artificial. *Infometric@ - Serie Ingeniería, Básicas y Agrícolas*, 4(1).
- Hesperian Health Guides. (2022). *Sustancias químicas usadas en la minería*. https://es.hesperian.org/hhg/A_Community_Guide
- Historia de la empresa. (2022). *¿Qué es un conjunto de datos? Datos*. <https://historiadelaempresa.com/que-es-un-conjunto-de-datos>
- Huynh, M.-H., Pham-Hoai, P.-T., Tran, A.-K., & Nguyen, T.-D. (2020). Automated Waste Sorting Using Convolutional Neural Network. *2020 7th NAFOSTED Conference on*

Information and Computer Science (NICS), 102-107.

<https://doi.org/10.1109/NICS51282.2020.9335897>

Ismail, I. N. bin, Jayakumar, P., Eqwan, M. R., Zuhdi, A. W. M., Mohamad, D., Isa, M. R., Zahari, N. M., Zawawi, M. H., Mohamed, H., Ramli, M. Z., & Mansor, M. H. (2018). *Design and development of smart sorting recycle bin prototype*. 020202.

<https://doi.org/10.1063/1.5066843>

Jurídico, D. (2022). *Colombia debate la Ley de Responsabilidad Extendida del Productor*.

Diario Jurídico. Colombia debate la Ley de Responsabilidad Extendida del Productor

Keepcoding. (2022). *Regularización por dropout en red convolucional*.

<https://keepcoding.io/blog/regularizacion-dropout-red-convolucional/#:~:text=Lo que hace la regularizacion,de reaccionar ante ese patron.>

Keepcoding. (2023a). *¿Qué es el kernel?* Keep Coding. <https://keepcoding.io/blog/que-es-el-kernel/>

Keepcoding. (2023b). *¿Qué es keras en deep learning?* <https://keepcoding.io/blog/keras-en-deep-learning/>

Keepcoding. (2023c). *¿Qué son las redes neuronales convolucionales?*

https://keepcoding.io/blog/redes-neuronales-convolucionales/#Como_funciona_una_red_neuronal_convulacional

Keepcoding. (2023d). *Tipos de Capas de red neuronal convolucional*.

<https://keepcoding.io/blog/tipos-capas-red-neuronal-convolucional/>

Kokoulin, A. N., Uzhakov, A. A., & Tur, A. I. (2020b). The Automated Sorting Methods Modernization of Municipal Solid Waste Processing System. *2020 International Russian Automation Conference (RusAutoCon)*, 1074-1078.

<https://doi.org/10.1109/RusAutoCon49822.2020.9208039>

- Korzniakov, K. A., Kislov, D. E., Altman, J., Doležal, J., Vozmishcheva, A. S., & Krestov, P. V. (2021). Using U-Net-Like Deep Convolutional Neural Networks for Precise Tree Recognition in Very High Resolution RGB (Red, Green, Blue) Satellite Images. *Forests*, *12*(1), 66. <https://doi.org/10.3390/f12010066>
- Li, Liu, & Wei. (2019). A Dynamic Decision Making Method Based on GM(1,1) Model with Pythagorean Fuzzy Numbers for Selecting Waste Disposal Enterprises. *Sustainability*, *11*(20), 5557. <https://doi.org/10.3390/su11205557>
- Lifeder. (2022). *11 Beneficios del reciclaje en la sociedad*.
<https://www.lifeder.com/beneficios-del-reciclaje/>
- Lu, W., Chen, J., & Xue, F. (2022). Using computer vision to recognize composition of construction waste mixtures: A semantic segmentation approach. *Resources, Conservation and Recycling*, *178*, 106022.
<https://doi.org/10.1016/j.resconrec.2021.106022>
- Masud, M. H., Mourshed, M., Hossain, Md. S., Ahmed, N. U., & Dabnichki, P. (2023). Generation of waste: problem to possible solution in developing and underdeveloped nations. *Waste Management and Resource Recycling in the Developing World*, 21-59.
<https://doi.org/10.1016/B978-0-323-90463-6.00021-X>
- Maués, L. M. F., Nascimento, B. do M. O. do, Lu, W., & Xue, F. (2020). Estimating construction waste generation in residential buildings: A fuzzy set theory approach in the Brazilian Amazon. *Journal of Cleaner Production*, *265*, 121779.
<https://doi.org/10.1016/j.jclepro.2020.121779>
- Medina, B. (2022). *PDI-1/ Introducción al Procesamiento Digital de Imágenes*.
<https://bryanmed.github.io/ImagenDigital/>

- Melinte, D. O., Travediu, A.-M., & Dumitriu, D. N. (2020). Deep Convolutional Neural Networks Object Detector for Real-Time Waste Identification. *Applied Sciences*, 10(20), 7301. <https://doi.org/10.3390/app10207301>
- Microsoft. (2023). *Uso De tensorboard para la visualización - cognitive toolkit - CNTK*. Microsoft Learn. <https://learn.microsoft.com/es-es/cognitive-toolkit/using-tensorboard-for-visualization>
- Ley 09 de 1979: Medidas sanitarias sobre manejo de residuos sólidos, (1979). http://www.upme.gov.co/guia_ambiental/carbon/gestion/politica/normativ/normativ.htm
- Ley 99 de 1993: Sistema Nacional Ambiental, (1993). <https://oscurverecicle.blogspot.com/2016/05/marco-politico-y-legal-el-tema-de.html>
- Ministerio de Asuntos Económicos y transformación digital - España. (2022). *11 librerías Para Crear Visualizaciones de Datos*. datos.gob.es. <https://datos.gob.es/es/blog/11-librerias-para-crear-visualizaciones-de-datos#:~:text=Las librerias de programacion son,resueltas previamente por otros programadores.>
- Myers, K., & Secco, E. L. (2021). *A Low-Cost Embedded Computer Vision System for the Classification of Recyclable Objects* (pp. 11-30). https://doi.org/10.1007/978-981-33-4582-9_2
- Naciones Unidas. (2022). *Facts and Figures*. Datos y cifras. <https://www.un.org/es/actnow/facts-and-figures#:~:text=Becca McChaffie%2FUnsplash.-,Residuos,de gases de efecto invernadero.>
- Nagajyothi, D., Ali, S. A., Jyothi, V., & Chinthapalli, P. (2023). Intelligent Waste Segregation Technique Using CNN. *2023 2nd International Conference for*

Innovation in Technology (INOCON), 1-8.

<https://doi.org/10.1109/INOCON57975.2023.10101021>

Pachapp - Gestión integral de residuos. (2022). *Residuos sólidos no peligrosos*.

<https://pachapp.pe/blog/residuos-solidos-no-peligroso/>

Pandey, A., Jain, H., Raj, H., & Gupta, Prof. P. (2023). Identification and Classification of Waste using CNN in Waste Management. *2023 IEEE 8th International Conference for Convergence in Technology (I2CT)*, 1-6.

<https://doi.org/10.1109/I2CT57861.2023.10126312>

Pawar, K., Chen, Z., Shah, N. J., & Egan, Gary. F. (2019). A Deep Learning Framework for Transforming Image Reconstruction Into Pixel Classification. *IEEE Access*, 7, 177690-177702. <https://doi.org/10.1109/ACCESS.2019.2959037>

Pinto Rodríguez, V., Muñoz Ordóñez, J., & Pardo Burbano, M. (2021). Ecología: Inteligencia Artificial para el cuidado del medio ambiente, prototipo de clasificación de residuos sólidos en punto de origen. *Investigación e Innovación en Ingenierías*, 9(3), 46-56. <https://doi.org/10.17081/invinno.9.3.5312>

Puspaningrum, A. P., Endah, S. N., Sasongko, P. S., Kusumaningrum, R., Khadijah, Rismiyati, & Ernawan, F. (2020). Waste Classification Using Support Vector Machine with SIFT-PCA Feature Extraction. *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, 1-6.

<https://doi.org/10.1109/ICICoS51170.2020.9298982>

Oracle. (2022). *¿Qué es la inteligencia artificial (IA)?* Oracle.

<https://www.oracle.com/co/artificial-intelligence/what-is-ai/>

Rabano, S. L., Cabatuan, M. K., Sybingco, E., Dadios, E. P., & Calilung, E. J. (2018).

Common Garbage Classification Using MobileNet. *2018 IEEE 10th International*

Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), 1-4.

<https://doi.org/10.1109/HNICEM.2018.8666300>

Raspberry Pi. (2023). *About the Camera Modules*. Raspberry.

[https://www.sigmaelectronica.net/producto/rpicamera/#:~:text=Cámara para Raspberry Pi.&text=El sensor óptico%2C tiene una, cuadros por segundo \(fps\).](https://www.sigmaelectronica.net/producto/rpicamera/#:~:text=Cámara para Raspberry Pi.&text=El sensor óptico%2C tiene una, cuadros por segundo (fps).)

Recytrans. (2022). *Clasificación de los residuos*.

<https://www.recytrans.com/blog/clasificacion-de-los-residuos/>

Pineda, J. A. (2022). *Residuos Inorgánicos*. Temas de interés: Medioambiente.

<https://encolombia.com/medio-ambiente/interes-a/residuos-inorganicos/>

Rismiyati, Endah, S. N., Khadijah, & Shiddiq, I. N. (2020a). Xception Architecture

Transfer Learning for Garbage Classification. *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, 1-4.

<https://doi.org/10.1109/ICICoS51170.2020.9299017>

Rismiyati, Endah, S. N., Khadijah, & Shiddiq, I. N. (2020c). Xception Architecture

Transfer Learning for Garbage Classification. *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, 1-4.

<https://doi.org/10.1109/ICICoS51170.2020.9299017>

Saeed, M., Ahsan, M., Saeed, M. H., Mehmood, A., & El-Morsy, S. (2021). Assessment of

Solid Waste Management Strategies Using an Efficient Complex Fuzzy Hypersoft Set Algorithm Based on Entropy and Similarity Measures. *IEEE Access*, 9, 150700-

150714. <https://doi.org/10.1109/ACCESS.2021.3125727>

Safety Docs. (2022). *RESIDUOS: Clasificación de residuos, reciclaje, tipos de residuos*.

<https://www.safetydoc.es/tipos-de-residuos-definicion-y-clasifi>

- Sakr, G. E., Mokbel, M., Darwich, A., Khneisser, M. N., & Hadi, A. (2016). Comparing deep learning and support vector machines for autonomous waste sorting. *2016 IEEE International Multidisciplinary Conference on Engineering Technology (IMCET)*, 207-212. <https://doi.org/10.1109/IMCET.2016.7777453>
- Solé, R. (2021). *Raspberry Pi: Qué Es, para qué sirve y qué podemos hacer*. Profesional Review. <https://www.profesionalreview.com/2021/07/18/que-es-raspberry-pi/>
- Sousa, J., Rebelo, A., & Cardoso, J. S. (2019). Automation of Waste Sorting with Deep Learning. *2019 XV Workshop de Visão Computacional (WVC)*, 43-48. <https://doi.org/10.1109/WVC.2019.8876924>
- Souza, P. R., Dotto, G. L., & Salau, N. P. G. (2018). Artificial neural network (ANN) and adaptive neuro-fuzzy interference system (ANFIS) modelling for nickel adsorption onto agro-wastes and commercial activated carbon. *Journal of Environmental Chemical Engineering*, 6(6), 7152-7160. <https://doi.org/10.1016/j.jece.2018.11.013>
- Sreelakshmi, K., Akarsh, S., Vinayakumar, R., & Soman, K. P. (2019). Capsule Neural Networks and Visualization for Segregation of Plastic and Non-Plastic Wastes. *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*, 631-636. <https://doi.org/10.1109/ICACCS.2019.8728405>
- Srinilta, C., & Kanharattanachai, S. (2019). Municipal Solid Waste Segregation with CNN. *2019 5th International Conference on Engineering, Applied Sciences and Technology (ICEAST)*, 1-4. <https://doi.org/10.1109/ICEAST.2019.8802522>
- Statista. (2022). *Población en Colombia por departamento 2022*. <https://es.statista.com/estadisticas/1191612/numero-de-personas-en-colombia-por-departamento/>

- Sudha, S., Vidhyalakshmi, M., Pavithra, K., Sangeetha, K., & Swaathi, V. (2016b). An automatic classification method for environment: Friendly waste segregation using deep learning. *2016 IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR)*, 65-70. <https://doi.org/10.1109/TIAR.2016.7801215>
- Thokrairak, S., Thibuy, K., & Jitngernmadan, P. (2020b). Valuable Waste Classification Modeling based on SSD-MobileNet. *2020 - 5th International Conference on Information Technology (InCIT)*, 228-232. <https://doi.org/10.1109/InCIT50588.2020.9310928>
- V, S., Akshaya, S, A., Ponnaganti, S. S., Pillai, V. G., & P K, P. (2021). Waste Collection & Segregation using Computer Vision and Convolutional Neural Network for Vessels. *2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, 1043-1048. <https://doi.org/10.1109/ICCCIS51004.2021.9397092>
- Velásquez, J. R., Schwartz, M., Phipps, L. M., Restrepo-Baena, O. J., Lucena, J., & Smits, K. M. (2022). A review of the environmental and health implications of recycling mine tailings for construction purposes in artisanal and small-scale mining communities. *The Extractive Industries and Society*, 9, 101019. <https://doi.org/10.1016/j.exis.2021.101019>
- Villena, J. (2022). *Redes Neuronales Convolucionales para la Clasificación de Imágenes*. Universidad Carlos III. <http://www.it.uc3m.es/jvillena/irc/practicas/09-10/05mem.pdf>
- Vo, A. H., Hoang Son, L., Vo, M. T., & Le, T. (2019). A Novel Framework for Trash Classification Using Deep Transfer Learning. *IEEE Access*, 7, 178631-178639. <https://doi.org/10.1109/ACCESS.2019.2959033>

- VOLTA. (2022). *¿Qué son los Residuos orgánicos? ¿Cómo tratarlos?*
<https://www.voltachile.cl/residuos-organicos/>
- Vu, D. D., & Kaddoum, G. (2017a). A waste city management system for smart cities applications. *2017 Advances in Wireless and Optical Communications (RTUWO)*, 225-229. <https://doi.org/10.1109/RTUWO.2017.8228538>
- Wan, M., & Wan, L. (2020). Exploring the Pathways to Participation in Household Waste Sorting in Different National Contexts: A Fuzzy-Set QCA Approach. *IEEE Access*, 8, 179373-179388. <https://doi.org/10.1109/ACCESS.2020.3027978>
- Wang, H. (2020). Garbage Recognition and Classification System Based on Convolutional Neural Network VGG16. *2020 3rd International Conference on Advanced Electronic Materials, Computers and Software Engineering (AEMCSE)*, 252-255.
<https://doi.org/10.1109/AEMCSE50948.2020.00061>
- Wang, Z., Li, H., & Yang, X. (2020). Vision-based robotic system for on-site construction and demolition waste sorting and recycling. *Journal of Building Engineering*, 32, 101769. <https://doi.org/10.1016/j.jobe.2020.101769>
- Wu, Y., Tao, Y., Deng, Z., Zhou, J., Xu, C., & Zhang, B. (2020). A fuzzy analysis framework for waste incineration power plant comprehensive benefit evaluation from refuse classification perspective. *Journal of Cleaner Production*, 258, 120734.
<https://doi.org/10.1016/j.jclepro.2020.120734>
- Yadav, H., Soni, U., & Kumar, G. (2023). Analysing challenges to smart waste management for a sustainable circular economy in developing countries: a fuzzy DEMATEL study. *Smart and Sustainable Built Environment*, 12(2), 361-384.
<https://doi.org/10.1108/SASBE-06-2021-0097>

Zhang, S., Chen, Y., Yang, Z., & Gong, H. (2021). Computer Vision Based Two-stage Waste Recognition-Retrieval Algorithm for Waste Classification. *Resources, Conservation and Recycling*, *169*, 105543.
<https://doi.org/10.1016/j.resconrec.2021.105543>