



Universidad de San Carlos de Guatemala
Facultad de Ingeniería
Escuela de ciencias y sistemas

**PROTOTIPO DE UN SISTEMA DOMÉSTICO DE SEPARACIÓN DE BASURA
MEDIANTE RECONOCIMIENTO DE IMÁGENES**

Adrian Samuel Molina Cabrera

Asesorado por MSc. Ing. Javier Estuardo Navarro Delgado

Guatemala, noviembre de 2024

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA



FACULTAD DE INGENIERÍA

**PROTOTIPO DE UN SISTEMA DOMÉSTICO DE SEPARACIÓN DE BASURA
MEDIANTE RECONOCIMIENTO DE IMÁGENES**

TRABAJO DE TESIS

PRESENTADO A LA DIRECCIÓN DE LA
ESCUELA DE ESTUDIOS DE POSTGRADO
POR

ADRIAN SAMUEL MOLINA CABRERA
ASESORADO POR MSC. ING. JAVIER ESTUARDO NAVARRO DELGADO

AL CONFERÍRSELE EL TÍTULO DE
INGENIERO EN CIENCIAS Y SISTEMAS

GUATEMALA, NOVIEMBRE DE 2024

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA
FACULTAD DE INGENIERÍA



NÓMINA DE JUNTA DIRECTIVA

DECANO	Ing. José Francisco Gómez Rivera (a. i.)
VOCAL II	Ing. Mario Renato Escobedo Martínez
VOCAL III	Ing. José Milton De León Bran
VOCAL IV	Ing. Kevin Vladimir Cruz Lorente
VOCAL V	Ing. Fernando José Paz González
SECRETARIA	Ing. Hugo Humberto Rivera Pérez

TRIBUNAL QUE PRACTICÓ EL EXAMEN GENERAL PRIVADO

DECANO	Ing. José Francisco Gómez Rivera (a. i.)
EXAMINADOR	Ing. Neftali de Jesús Calderón Méndez
EXAMINADOR	Ing. Juan Alvaro Díaz Ardavín
EXAMINADOR	Ing. Manuel Haroldo Castillo Reyna
SECRETARIO	Mtro. Ing. Hugo Humberto Rivera Pérez

HONORABLE TRIBUNAL EXAMINADOR

En cumplimiento con los preceptos que establece la ley de la Universidad de San Carlos de Guatemala, presento a su consideración mi trabajo de graduación titulado:

PROTOTIPO DE UN SISTEMA DOMÉSTICO DE SEPARACIÓN DE BASURA MEDIANTE RECONOCIMIENTO DE IMÁGENES

Tema que me fuera asignado por la Dirección de la Escuela de Estudios de Posgrado, con fecha 28 de septiembre de 2024.



Adrian Samuel Molina Cabrera



EEPFI-PP-5171-2024

Guatemala, 28 de septiembre de 2024

Director

Carlos Gustavo Alonso

Escuela De Ingenieria En Sistemas

Presente.

Estimado Carlos Gustavo Alonso

Reciba un cordial saludo de la Escuela de Estudios de Postgrado de la Facultad de Ingeniería.

El propósito de la presente es para informarle que se ha revisado y aprobado el Diseño de Investigación titulado: **PROTOTIPO DE UN SISTEMA DOMÉSTICO DE SEPARACIÓN DE BASURA MEDIANTE RECONOCIMIENTO DE IMÁGENES**, el cual se enmarca en la línea de investigación: **Área de Innovación - Dispositivos y sistemas para el desarrollo de sistemas inteligentes.**, presentado por el estudiante **Adrian Samuel Molina Cabrera** carné número **201903850**, quien optó por la modalidad del "PROCESO DE GRADUACIÓN DE LOS ESTUDIANTES DE LA FACULTAD DE INGENIERÍA OPCIÓN ESTUDIOS DE POSTGRADO". Previo a culminar sus estudios en la Maestría en Artes en Tecnologías De La Inf. Y La Comunicacion.

Y habiendo cumplido y aprobado con los requisitos establecidos en el normativo de este Proceso de Graduación en el Punto 6.2, aprobado por la Junta Directiva de la Facultad de Ingeniería en el Punto Décimo, Inciso 10.2 del Acta 28-2011 de fecha 19 de septiembre de 2011, firmo y sello la presente para el trámite correspondiente de graduación de Pregrado.

Atentamente,

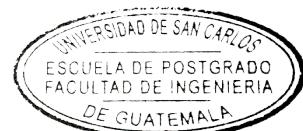
"Id y Enseñad a Todos"

Mtro. Javier Estuardo Navarro Delgado
Asesor(a)



Signer ID: AR4UCCGU013

Mtro. Marion Antonio Perez Turk
Coordinador(a) de Maestría



Mtra. Aurelia Anabela Cordova Estrada
Directora
Escuela de Estudios de Postgrado
Facultad de Ingeniería



Oficina Virtual



<https://bit.ly/EEP-OficinaVirtual>



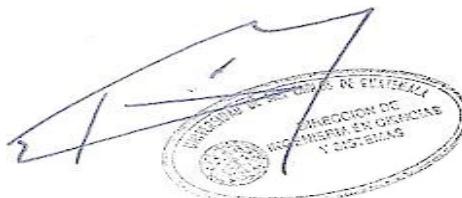
solicituddeep@ingenieria.usac.edu.gt



EEP-EICS-5033-2024

El Director de la Escuela De Ingenieria En Sistemas de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer el dictamen del Asesor, el visto bueno del Coordinador y Director de la Escuela de Estudios de Postgrado, del Diseño de Investigación en la modalidad Estudios de Pregrado y Postgrado titulado: **PROTOTIPO DE UN SISTEMA DOMÉSTICO DE SEPARACIÓN DE BASURA MEDIANTE RECONOCIMIENTO DE IMÁGENES**, presentado por el estudiante universitario **Adrian Samuel Molina Cabrera**, procedo con el Aval del mismo, ya que cumple con los requisitos normados por la Facultad de Ingeniería en esta modalidad.

ID Y ENSEÑAD A TODOS



Mtro. Carlos Gustavo Alonso
Director
Escuela De Ingenieria En Sistemas

Guatemala, septiembre de 2024

Decanato
Facultad e Ingeniería

24189101- 24189102

LNG.DECANATO.OIE.731.2024

El Decano de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer la aprobación por parte del Director de la Escuela de Ingeniería en Ciencias y Sistemas, al Trabajo de Graduación titulado: **PROTOTIPO DE UN SISTEMA DOMÉSTICO DE SEPARACIÓN DE BASURA MEDIANTE RECONOCIMIENTO DE IMÁGENES**, presentado por: **Adrian Samuel Molina Cabrera** después de haber culminado las revisiones previas bajo la responsabilidad de las instancias correspondientes, autoriza la impresión del mismo.

IMPRÍMASE:

Ing. José Francisco Gómez Rivera
Decano a.i.

Guatemala, noviembre de 2024



Para verificar validez de documento ingrese a <https://www.ingenieria.usac.edu.gt/firma-electronica/consultar-documento>

Tipo de documento: Correlativo para orden de impresión Año: 2024 Correlativo: 731 CUI: 3020721280101

Escuelas: Ingeniería Civil, Ingeniería Mecánica Industrial, Ingeniería Química, Ingeniería Mecánica Eléctrica, - Escuela de Ciencias, Regional de Ingeniería Sanitaria y Recursos Hídricos (ERIS). Postgrado Maestría en Sistemas Mención Ingeniería Vial. Carreras: Ingeniería Mecánica, Ingeniería Electrónica, Ingeniería en Ciencias y Sistemas. Licenciatura en Matemática. Licenciatura en Física. Centro de Estudios Superiores de Energía y Minas (CESEM). Guatemala, Ciudad

ACTO QUE DEDICO A:

Mis padres	Por su apoyo constante en mi camino, su esfuerzo y enseñanzas fueron importantes para mi desarrollo académico y profesional.
Mis hermanos	Por su apoyo y cariño a mi persona.
Mis tíos	Por brindarme sus consejos, cariño y apoyo.
Mis abuelos	Por brindarme su cariño y sabiduría.
Mis amigos	Por su apoyo, compresión, solidaridad y cariño.

AGRADECIMIENTOS A:

- Universidad de San Carlos de Guatemala** Por ser mi casa de estudios y formarme como profesional.
- Mis amigos** Por apoyarme durante las distintas etapas de la carrera.
- Ingenieros** Por motivarme, enseñarme y guiarme a ser un mejor profesional.
- Asesor** Por ser la persona que con su experiencia y dirección me apoyó durante este trabajo de investigación.

ÍNDICE GENERAL

ÍNDICE DE ILUSTRACIONES	V
1. INTRODUCCIÓN	1
2. ANTECEDENTES	3
3. PLANTEAMIENTO DEL PROBLEMA	7
3.1. Contexto general	9
3.2. Descripción del problema	9
3.3. Formulación del problema	9
3.3.1. Pregunta central	10
3.3.2. Preguntas auxiliares	10
3.4. Delimitación del problema	10
4. JUSTIFICACIÓN	13
5. OBJETIVOS	15
5.1. General.....	15
5.2. Específicos	15
6. NECESIDADES POR CUBRIR Y ESQUEMA DE SOLUCIÓN	17
7. ALCANCES	21
7.1. Alcance investigativo	21
7.2. Alcance técnico	21

7.3.	Alcance de Resultados.....	22
8.	MARCO TEÓRICO	23
8.1.	Tecnologías IoT en la gestión de residuos.....	23
8.1.1.	Definición y componentes básicos del IoT	23
8.1.2.	Fundamentos teóricos del IoT	23
8.1.2.1.	Arquitectura del IoT: dispositivos, gateways y plataformas.....	24
8.1.2.2.	Protocolos de comunicación en IoT	24
8.1.2.3.	Dispositivos y Hardware IoT.....	26
8.2.	Inteligencia Artificial en la Gestión de Residuos.....	27
8.2.1.	Introducción a la Inteligencia Artificial (IA).....	27
8.2.2.	Aplicaciones de la IA en la gestión de residuos	27
8.2.2.1.	Técnicas de IA utilizadas en la gestión de residuos.....	28
8.2.2.2.	Sistemas de clasificación basados en IA.....	31
8.2.3.	Fundamentos teóricos de la Inteligencia Artificial....	32
8.2.3.1.	Algoritmos de clasificación en IA.....	32
8.2.3.2.	Infraestructura técnica para la implementación de IA.....	32
8.3.	Reconocimiento de imágenes para la gestión de residuos	33
8.3.1.	Capacidades técnicas de Amazon Rekognition	33
8.3.1.1.	Aprendizaje por Transferencia (Transfer Learning).....	33
8.3.1.1.1.	Congelación y ajuste fino de capas (Freezing and Fine-Tuning)	35

8.3.1.1.2.	Adaptación de modelos preentrenados	35
8.3.1.1.3.	Mecanismos de transferencia.....	36
8.3.1.2.	Deep Learning y modelos avanzados	37
8.3.1.3.	Procesamiento de imágenes y reducción de dimensionalidad	37
8.3.1.4.	Desafíos y limitaciones técnicas	38
9.	METODOLOGÍA.....	41
9.1.	Características del estudio	41
9.2.	Unidades de análisis	41
9.3.	Variables.....	42
9.4.	Fases del Estudio	43
9.4.1.	Fase 1: revisión de literatura.....	43
9.4.2.	Fase 2: diseño del prototipo.....	43
9.4.3.	Fase 3: gestión y recolección de la información	44
9.4.4.	Fase 4: análisis de la información.....	44
9.4.5.	Fase 5: interpretación de resultados e información	44
9.5.	Resultados esperados.....	45
10.	TÉCNICAS DE ANÁLISIS DE INFORMACIÓN.....	47
10.1.	Análisis de precisión.....	47
10.2.	Análisis del tiempo de respuesta.....	47
10.3.	Análisis de eficiencia	48
10.4.	Comparación y optimización.....	48

11.	CRONOGRAMA	49
12.	ANÁLISIS DE FACTIBILIDAD.....	51
12.1.	Factibilidad operativa	51
12.2.	Factibilidad técnica.....	52
12.3.	Factibilidad económica.....	52
12.3.1.	Costos operativos.....	53
13.	PROPUESTA DE ÍNDICE DE CONTENIDOS	55
14.	REFERENCIAS	57

ÍNDICE DE ILUSTRACIONES

FIGURAS

Figura 1.	Esquema de solución.....	18
Figura 2.	Arquitectura MQTT	25
Figura 3.	Arquitectura CoAP	26
Figura 4.	Modelo CNN para la clasificación de imágenes.....	28
Figura 5.	Modelo ResNet para la clasificación de imágenes	29
Figura 6.	Modelo ResNet para la clasificación de imágenes	34
Figura 7.	Cronograma.....	49

TABLAS

Tabla 1.	Definición de variables.....	42
Tabla 2.	Costos del prototipo	53

1. INTRODUCCIÓN

La creciente generación de residuos sólidos ha puesto en evidencia la necesidad de desarrollar soluciones tecnológicas que optimicen los procesos de reciclaje y gestión de basura. Este proyecto tiene como objetivo crear un prototipo de sistema automatizado para la separación de basura mediante reconocimiento de imágenes, utilizando tecnologías como el Internet de las Cosas (IoT) e inteligencia artificial (IA) para mejorar la eficiencia en la clasificación de residuos.

El Capítulo 1 aborda los antecedentes, ofreciendo una vista de las tecnologías previamente implementadas en la gestión de residuos y su evolución hacia sistemas más automatizados. Se revisan las soluciones existentes que han mejorado el proceso de separación y reciclaje de desechos mediante sensores y sistemas de recolección automatizada.

En el Capítulo 2, se presenta la justificación del proyecto, argumentando la importancia de implementar un sistema que permita la separación eficiente de residuos en el hogar. La propuesta tiene un impacto positivo en la sostenibilidad ambiental y busca educar a los usuarios sobre la importancia de una correcta gestión de residuos.

El Capítulo 3 describe los alcances del prototipo, que estará enfocado en la clasificación de residuos domésticos comunes, tales como plásticos, vidrio, papel y desechos orgánicos. También se establecerán las limitaciones del sistema, como la exclusión de residuos industriales o peligrosos y el uso de una infraestructura tecnológica accesible para el entorno doméstico.

En el Capítulo 4, el marco teórico explica el fundamento detrás de las tecnologías utilizadas en el proyecto, como el IoT y la IA. Se profundizará en el uso de redes neuronales convolucionales (CNN) para el reconocimiento de imágenes y cómo estas pueden aplicarse en la clasificación automatizada de residuos, aprovechando modelos de aprendizaje profundo que han mostrado gran precisión en tareas similares.

El Capítulo 5 se centra en la presentación de resultados, donde se expondrán los datos recolectados durante la fase experimental del prototipo. Se evaluarán parámetros clave como la precisión en la clasificación, el tiempo de respuesta y la eficiencia operativa del sistema. Estos resultados serán presentados a través de tablas y gráficas, permitiendo una mejor comprensión de su rendimiento en condiciones controladas.

Por último, el Capítulo 6 incluirá una discusión de los resultados, donde se analizarán las fortalezas del prototipo, como su capacidad para mejorar la eficiencia del reciclaje, y las limitaciones encontradas durante el desarrollo, tales como problemas técnicos en la captura de imágenes. Se propondrán recomendaciones para futuras mejoras y optimización del sistema en entornos domésticos.

Con este proyecto, se pretende contribuir al desarrollo de soluciones tecnológicas que puedan ser utilizadas para mejorar la gestión de residuos. La automatización de la clasificación de residuos reduce la carga de trabajo manual, y optimiza el reciclaje, lo que puede tener un impacto positivo en la sostenibilidad ambiental. Este protocolo representa un esfuerzo por demostrar la viabilidad de combinar tecnologías avanzadas con dispositivos accesibles para resolver un problema clave en la gestión moderna de residuos.

2. ANTECEDENTES

La gestión de residuos ha evolucionado significativamente, adoptando tecnologías avanzadas para abordar la problemática creciente en áreas urbanas densamente pobladas. Uno de los enfoques más innovadores es el uso de sistemas automatizados para la recolección de residuos.

Yankova & Grigorova (2020) mencionan que los sistemas automatizados de recolección de residuos (AWCS) se han identificado como el mejor método para promover y facilitar el reciclaje. Estos sistemas proporcionan un marco integrado para el manejo de residuos como recurso, y también ayudan a mejorar la higiene al prevenir malos olores, emisiones y contaminación acústica. Además, estos sistemas reducen la necesidad de camiones y la manipulación manual de residuos, proporcionando flexibilidad para gestionar mayores volúmenes de residuos a medida que la población crece.

Yankova & Grigorova (2020) mencionan que los sistemas automatizados de recolección de desechos han sido implementados exitosamente en numerosas ciudades alrededor del mundo. Por ejemplo, la empresa sueca Envac ha desarrollado y desplegado sistemas de recolección automatizada desde 1961, con más de 700 sistemas instalados en 40 países. Estos sistemas utilizan tecnología de vacío o neumática para transportar residuos a través de tuberías subterráneas, eliminando la necesidad de camiones de recolección en áreas urbanas densamente pobladas.

Los sistemas mencionados demuestran cómo la automatización puede mejorar la eficiencia y la higiene en la gestión de residuos. Estos sistemas han sido probados y mejorados a lo largo de los años, ofreciendo confiabilidad y efectividad para inspirar y respaldar el desarrollo del prototipo.

Anagnostopoulos et al. (2017) destacan la importancia de los modelos dinámicos en la recolección de residuos. Estos modelos utilizan tecnologías de identificación por radiofrecuencia (RFID), sensores y actuadores para optimizar la planificación y las rutas de recolección en tiempo real. Esta optimización reduce los costos operativos y las emisiones contaminantes, y también mejora la eficiencia general del sistema de gestión de residuos.

Anagnostopoulos et al. (2017) mencionan que el uso de algoritmos de optimización y análisis de datos en tiempo real permite ajustar las rutas de recolección en función de la generación de residuos, el tráfico y otros factores externos. Esto resulta en una recolección más eficiente y sostenible, reduciendo la huella de carbono en aproximadamente un 25 % y mejorando el servicio a la comunidad.

Malik et al. (2022) abordan la clasificación de residuos utilizando técnicas de reconocimiento de imágenes con modelos de redes neuronales profundas. Este enfoque permite la categorización de residuos sólidos municipales en diversas categorías, incluyendo plástico, vidrio, metal, papel, entre otros. La técnica más eficiente propuesta hasta ahora incluye el uso de redes neuronales convolucionales (CNN), específicamente el modelo EfficientNet-B0. Este modelo, preentrenado en ImageNet, se ajusta para clasificar imágenes de residuos específicas de regiones demográficas particulares, logrando una eficiencia significativamente mejorada en términos de operaciones de punto flotante por segundo (FLOPS) y precisión.

Se presenta un enfoque avanzado utilizando redes neuronales profundas para la clasificación de residuos, específicamente el modelo EfficientNet-B0. Este tipo de tecnología es central para el prototipo, ya que se basa en el reconocimiento de imágenes para clasificar residuos. La aplicación de técnicas similares puede aumentar la precisión y eficiencia del sistema a implementar.

Hasan et al. (2017) presentan un sistema de gestión de residuos basado en IoT diseñado específicamente para países en desarrollo como Bangladesh. Este sistema utiliza sensores para monitorear el nivel de llenado de los contenedores de basura en tiempo real, enviando esta información a una oficina regional. Basado en los datos recopilados, el sistema asigna automáticamente tareas a los empleados mediante el uso de algoritmos como el Decreasing Time Algorithm (DTA), que prioriza las tareas según la cantidad de residuos acumulados. Este enfoque mejora la eficiencia en la recolección de residuos al asegurar que los contenedores más llenos se vacíen primero, reduciendo tiempo y la energía necesarios para completar las rutas de recolección.

El uso de algoritmos de aprendizaje automático permite predecir la cantidad de residuos que se generarán en una determinada área, optimizando así la asignación de recursos y personal. Hasan y colaboradores. Destacan que el uso de algoritmos como la regresión lineal y otros modelos predictivos puede mejorar significativamente la planificación y gestión de la recolección de residuos, adaptándose a las fluctuaciones en la generación de residuos debido a factores socioeconómicos.

Esmaeilian et al. (2018) discuten cómo la integración de tecnologías IoT en la gestión de residuos ha revolucionado la eficiencia y la sostenibilidad del

proceso. El estudio destaca la implementación de sensores inteligentes que permiten la monitorización en tiempo real de los niveles de residuos en contenedores y la utilización de datos para optimizar las rutas de recolección. Esto reduce los costos operativos y las emisiones de carbono al minimizar los viajes innecesarios de los camiones de recolección.

Estas plataformas utilizan datos recopilados para identificar patrones y tendencias en la generación de residuos, lo que permite una toma de decisiones más informada y proactiva. La implementación de tales sistemas en ciudades inteligentes ha demostrado mejorar la eficiencia operativa y reducir el impacto ambiental de la gestión de residuos.

Hasan et al. (2017) mencionan cómo su trabajo sobre sistemas de gestión de residuos basados en IoT y el uso de sensores inteligentes proporciona una visión de cómo la tecnología puede transformar la gestión de residuos. La integración de IoT en el prototipo podría mejorar la monitorización y el control del sistema, permitiendo una gestión más efectiva y en tiempo real de los residuos domésticos.

La automatización y el uso de sensores para la recolección de datos y la optimización de procesos descritos en los antecedentes son directamente aplicables en el proyecto. Estas investigaciones proporcionan métodos y tecnologías probadas que pueden ser adaptadas y aplicadas a la separación de residuos domésticos.

3. PLANTEAMIENTO DEL PROBLEMA

La gestión de residuos es un desafío global que afecta tanto a las áreas urbanas como rurales. La separación correcta de los residuos es necesaria para facilitar el reciclaje y reducir la carga en los vertederos de basura. Muchas personas no separan adecuadamente la basura debido a la falta de conocimiento, tiempo o motivación. La automatización de este proceso podría representar una solución efectiva.

La separación manual de residuos en los hogares es ineficiente y propensa a errores. Muchas personas no están debidamente educadas sobre cómo separar correctamente los diferentes tipos de desechos como lo son orgánicos, plásticos, vidrio y papel en un solo contenedor, lo que complica el proceso de reciclaje y aumenta la cantidad de basura que termina en vertederos de basura. Los métodos tradicionales de separación manual en los centros de reciclaje son costosos y demandan mucho tiempo y esfuerzo humano.

Hace falta un sistema doméstico eficiente y automatizado que facilite la separación de basura mediante el uso de tecnologías modernas. Actualmente, no existe una solución doméstica accesible y práctica que pueda identificar y clasificar automáticamente los diferentes tipos de residuos en el momento en que se desecharán, lo que limita la eficiencia del reciclaje y la sostenibilidad medioambiental.

Cuando los residuos reciclables se mezclan con residuos orgánicos o no reciclables, la efectividad del reciclaje disminuye. Esto no solo afecta la

cantidad de materiales que pueden ser reciclados, sino que también aumenta los costos de procesamiento en las plantas de reciclaje.

Los sistemas tradicionales de gestión de residuos, que dependen de la intervención humana para la clasificación, son costosos y demandan mucho tiempo. En las plantas de reciclaje, la separación manual requiere mucha mano de obra, lo que incrementa los costos operativos y reduce la eficiencia.

Existe una falta de educación y conciencia ambiental entre la población sobre la importancia de la separación de residuos. Esto contribuye a una baja tasa de reciclaje y una mayor generación de residuos que terminan en los vertederos de basura, agravando los problemas ambientales.

La implementación de sistemas avanzados de gestión de residuos a nivel municipal o industrial requiere una infraestructura considerable y costosa, que no está disponible en todas las regiones.

La acumulación inadecuada y la mezcla de residuos pueden tener implicaciones negativas para la salud pública. Los residuos mal gestionados pueden atraer plagas y contribuir a la propagación de enfermedades.

Existe la necesidad de desarrollar un sistema doméstico automatizado que facilite la separación de basura mediante el uso de tecnologías modernas como lo es el reconocimiento de imágenes. Este sistema debe ser capaz de identificar y clasificar automáticamente los diferentes tipos de residuos en el momento en que se desechan, mejorando así la eficiencia del reciclaje y promoviendo la sostenibilidad ambiental. Fácil de usar y capaz de educar a los usuarios sobre prácticas sostenibles de gestión de residuos.

3.1. Contexto general

El problema de la separación incorrecta de residuos se observa en gran medida para muchas áreas urbanas y rurales. Desde hace varios años, se han intentado diversas soluciones educativas y campañas de concientización, pero el problema persiste debido a la falta de motivación y conocimiento por parte de la población. La implementación de un sistema automatizado a nivel doméstico no se ha intentado de manera directa, lo que presenta una oportunidad significativa para mejorar la eficiencia del reciclaje.

3.2. Descripción del problema

La situación que se quiere resolver se centra en la ineficiencia de la separación manual de residuos en los hogares. La mezcla de residuos reciclables con no reciclables disminuye la efectividad del reciclaje y aumenta los costos de procesamiento. Las posibles causas incluyen la falta de educación sobre la separación correcta de residuos y la falta de tiempo o motivación para realizar esta tarea. Las consecuencias de esta situación son el incremento de residuos en los vertederos de basura, mayores costos de operación en las plantas de reciclaje y un impacto ambiental negativo.

3.3. Formulación del problema

La gestión ineficiente de residuos en los hogares limita el reciclaje efectivo y contribuye a problemas ambientales. La falta de sistemas accesibles y prácticos para separar materiales reciclables hace que el proceso sea complejo y poco eficaz.

3.3.1. Pregunta central

¿Cómo puede un sistema doméstico automatizado de separación de basura basado en reconocimiento de imágenes mejorar la eficiencia del reciclaje y promover la sostenibilidad ambiental en los hogares?

3.3.2. Preguntas auxiliares

Para abordar el problema de la separación ineficiente de residuos en los hogares y mejorar la eficiencia del reciclaje mediante un sistema automatizado basado en reconocimiento de imágenes, se plantean las siguientes preguntas auxiliares. Estas preguntas permitirán desglosar el problema principal en aspectos más específicos:

- ¿Qué tipos de residuos pueden ser identificados y clasificados de manera efectiva mediante tecnologías de reconocimiento de imágenes en un entorno doméstico?
- ¿Cuáles son las principales dificultades técnicas y operativas en el desarrollo de un sistema doméstico de separación automatizada de residuos?
- ¿Cómo se puede diseñar un sistema automatizado de separación de residuos que sea fácil de usar y accesible para los usuarios domésticos?

3.4. Delimitación del problema

El problema se resolverá en hogares que carecen de sistemas eficientes de separación de residuos. Se centrará en el desarrollo de un prototipo que utilice reconocimiento de imágenes para clasificar

automáticamente los residuos en el momento de su desecho. La solución buscará ser accesible, fácil de usar y capaz de educar a los usuarios sobre la importancia de la separación correcta de residuos para promover la sostenibilidad ambiental.

4. JUSTIFICACIÓN

Este trabajo pertenece a la línea de investigación de dispositivos y sistemas para el desarrollo de sistemas inteligentes.

La gestión de residuos es un desafío global con importantes complicaciones ambientales, sociales y económicas. La automatización de la separación de residuos en el hogar ofrece una solución innovadora y necesaria. La relevancia de este trabajo se guía en las líneas de investigación prioritarias de la maestría, que buscan promover el desarrollo, la eficiencia en la gestión de recursos y la implementación de tecnologías avanzadas para resolver problemas prácticos.

La implementación de un sistema de este tipo contribuirá significativamente a mejorar la eficiencia del reciclaje en los hogares, reduciendo la cantidad de residuos que terminan en vertederos de basura. Disminuirá la contaminación ambiental y la explotación de recursos naturales.

Este trabajo introduce el uso de tecnologías de reconocimiento de imágenes en un ámbito doméstico, lo cual representa una innovación en la gestión de residuos. El sistema automatizado facilitará la separación correcta de residuos, también educará a los usuarios sobre prácticas sostenibles, fomentando una mayor conciencia ambiental.

El sistema propuesto beneficiará a la población al simplificar el proceso de separación de residuos, haciéndolo más accesible y menos demandante en términos de tiempo y esfuerzo. Además, servirá como una herramienta

educativa que promoverá la adopción de prácticas sostenibles en los hogares, creando una cultura de reciclaje y responsabilidad ambiental.

Una correcta separación de residuos en los hogares puede reducir la acumulación inadecuada y la mezcla de residuos, lo que tiene implicaciones positivas para la salud pública. La gestión eficiente de residuos reduce la atracción de plagas y la propagación de enfermedades, mejorando la calidad de vida en las comunidades.

La realización de este prototipo aborda una problemática práctica en la gestión de residuos, también aporta soluciones innovadoras y sostenibles con un impacto positivo en la sociedad. Al desarrollar un sistema automatizado de separación de basura, se espera generar conocimientos y tecnologías aplicables a otros contextos, promoviendo así un cambio positivo hacia un futuro más consciente del medio ambiente.

5. OBJETIVOS

5.1. General

Desarrollar un sistema doméstico automatizado de separación de basura basado en reconocimiento de imágenes para mejorar la eficiencia del reciclaje y promover la sostenibilidad ambiental en los hogares.

5.2. Específicos

- Identificar y clasificar de manera efectiva diferentes tipos de residuos utilizando tecnologías de reconocimiento de imágenes en un entorno doméstico.
- Identificar y abordar las dificultades técnicas y operativas en el desarrollo de un sistema doméstico de separación automatizada de residuos.
- Diseñar un sistema automatizado de separación de residuos que sea fácil de usar y accesible para los usuarios domésticos.

6. NECESIDADES POR CUBRIR Y ESQUEMA DE SOLUCIÓN

El problema de la incorrecta separación de residuos sólidos en los hogares es una necesidad ambiental significativa en el ámbito nacional y regional. La ineficiente gestión de residuos domésticos contribuye a la contaminación, pérdida de materiales reciclables y aumento de costos en la gestión de residuos.

Las necesidades específicas que este prototipo pretende cubrir son:

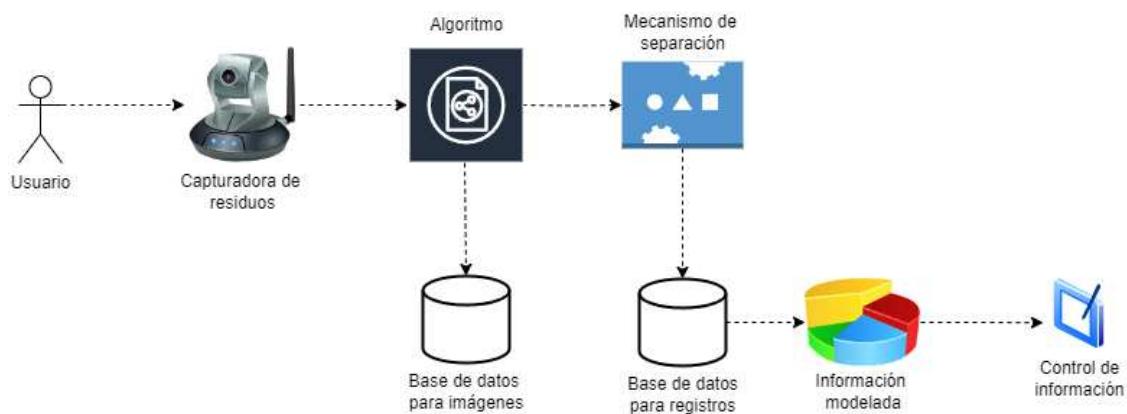
- Mejora de la Eficiencia en la Separación de Residuos: automatizar la identificación y clasificación de residuos en los hogares para aumentar la tasa de reciclaje y reducir la contaminación.
- Reducción de Errores Humanos: minimizar los errores en la clasificación manual de residuos mediante un sistema automatizado, garantizando una separación más precisa y efectiva.
- Conciencia Ambiental: promover la conciencia y educación ambiental entre los usuarios, facilitando la correcta separación de residuos a través de una tecnología accesible y fácil de usar.
- Sostenibilidad: contribuir a la sostenibilidad y gestión eficiente de recursos mediante la reducción de residuos no reciclables enviados a los vertederos de basura.

El esquema de solución propuesto consiste en el desarrollo de un prototipo de sistema doméstico de separación de basura basado en

tecnologías de reconocimiento de imágenes y automatización. La arquitectura de la solución incluye los siguientes componentes y características:

Figura 1.

Esquema de solución



Nota. Descripción del esquema de solución propuesto. Elaboración propia, realizado con Drawlo.

- Entrada de Residuos: los usuarios depositan residuos en el sistema, que está equipado con un mecanismo de entrada adaptado para diferentes tipos de residuos.
- Captura de Imágenes: una cámara de alta resolución que captura imágenes de los residuos depositados, proporcionando datos visuales para el procesamiento.
- Procesamiento de Imágenes: un algoritmo de reconocimiento de imágenes procesa las imágenes capturadas para identificar y clasificar los residuos. El modelo de reconocimiento se entrena utilizando una base de datos de imágenes de residuos previamente etiquetadas.
- Clasificación y Separación: el sistema de actuadores mecánicos separa automáticamente los residuos en diferentes contenedores (orgánico,

reciclabl e, no reciclabl e) segú n la clasificació n realizada por el algoritmo de reconocimiento.

- Integració n y Evaluació n: una base de datos de registro almacena datos sobre la cantidad y tipo de residuos procesados, permitiendo evaluar la eficiencia del sistema.
- Interfaz de Usuario: una vista que permite a los usuarios monitorizar el estado del sistema sobre los contenedores. La interfaz está diseñada para ser intuitiva y accesible, facilitando la interacció n con el sistema.

7. ALCANCES

7.1. Alcance investigativo

Se tomarán en consideración investigaciones y tecnologías avanzadas en la gestión automatizada de residuos y el uso de reconocimiento de imágenes para la clasificación de basura. Las principales áreas de investigación incluirán:

- Sistemas de automatización en la gestión de residuos sólidos.
- Tecnologías de reconocimiento de imágenes y su aplicación en la clasificación de residuos.

7.2. Alcance técnico

Se desarrollará un prototipo de sistema doméstico para la separación automatizada de residuos utilizando reconocimiento de imágenes. Las características y limitaciones técnicas del prototipo incluirán:

- Uso de una cámara de alta resolución para la captura de imágenes de residuos.
- Utilización de Amazon Rekognition para el análisis y reconocimiento de imágenes, evitando la necesidad de desarrollar y entrenar modelos de redes neuronales convolucionales desde cero.
- Clasificación automática de residuos en categorías como orgánicos, plásticos, vidrio y papel.

- Desarrollo del sistema en una plataforma de microcontrolador adecuada, como Raspberry Pi 4 modelo B, debido a su capacidad para manejar operaciones de procesamiento de imágenes y actuadores mecánicos.
- La funcionalidad del prototipo se limitará a la identificación y clasificación de residuos sólidos domésticos y no se extenderá a residuos industriales o peligrosos.

7.3. Alcance de resultados

Los resultados esperados del desarrollo del prototipo incluyen:

- Un sistema funcional que demuestre la viabilidad de la automatización en la separación de residuos en un entorno doméstico.
- Mediciones preliminares de rendimiento del sistema en términos de precisión de clasificación, tiempo de procesamiento y eficiencia operativa.
- Documentación detallada del desarrollo del prototipo, incluyendo el diseño del sistema, la implementación del algoritmo y los resultados de las pruebas iniciales.
- Utilización de servicios y herramientas existentes, como Amazon Rekognition, para facilitar el desarrollo y optimizar el proceso de reconocimiento de imágenes.

8. MARCO TEÓRICO

8.1. Tecnologías IoT en la gestión de residuos

El Internet de las Cosas ha mejorado la gestión de residuos al permitir una monitorización y control en tiempo real de los contenedores de basura y las operaciones de recolección. Las tecnologías mejoran la eficiencia operativa, y contribuyen a la sostenibilidad al optimizar el uso de recursos y reducir el impacto ambiental.

8.1.1. Definición y componentes básicos del IoT

El IoT es un sistema de dispositivos interconectados que recopilan y comparten datos a través de Internet. En la gestión de residuos, los componentes básicos del IoT incluyen sensores como cámaras, módulos de comunicación como Wi-Fi y plataformas de análisis de datos en la nube. Estos sensores se colocan en contenedores de basura para monitorear diversas variables, así como lo son el color, la textura y los patrones. Los datos recopilados se envían a una plataforma centralizada, donde se analizan para optimizar las operaciones de reciclaje (Masroor, 2020).

8.1.2. Fundamentos teóricos del IoT

El funcionamiento de los sistemas IoT depende de una infraestructura de comunicación y protocolos. Dos de los protocolos más utilizados en aplicaciones IoT son MQTT y CoAP. MQTT es un protocolo de mensajería ligera diseñado para dispositivos con recursos limitados y baja capacidad de

ancho de banda. CoAP está diseñado para la comunicación entre dispositivos en redes M2M y es altamente eficiente en términos de energía y ancho de banda (Ansari et al., 2018).

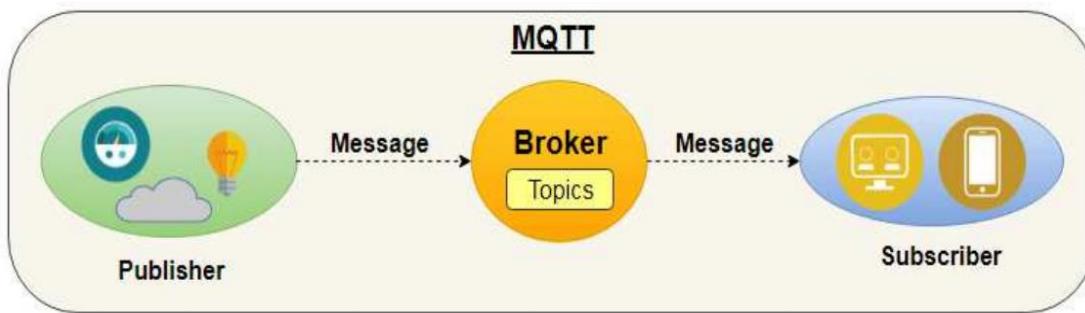
8.1.2.1. Arquitectura del IoT: dispositivos, gateways y plataformas

La arquitectura IoT en la gestión de residuos incluye edge devices, que recopilan datos y los transmiten a través de gateways a plataformas en la nube. Los gateways actúan como intermediarios, gestionando la comunicación entre los sensores y la plataforma central. Esta plataforma basada en la nube procesa los datos y genera análisis en tiempo real para tomar decisiones informadas sobre la recolección y el manejo de residuos. La arquitectura de IoT debe ser robusta y escalable para manejar la cantidad de datos generados por los sensores (Masroor, 2020).

8.1.2.2. Protocolos de comunicación en IoT

MQTT y CoAP son protocolos populares debido a su eficiencia en la transmisión de datos y su capacidad para operar en dispositivos con recursos limitados. MQTT es particularmente útil en situaciones donde se requiere una conectividad constante.

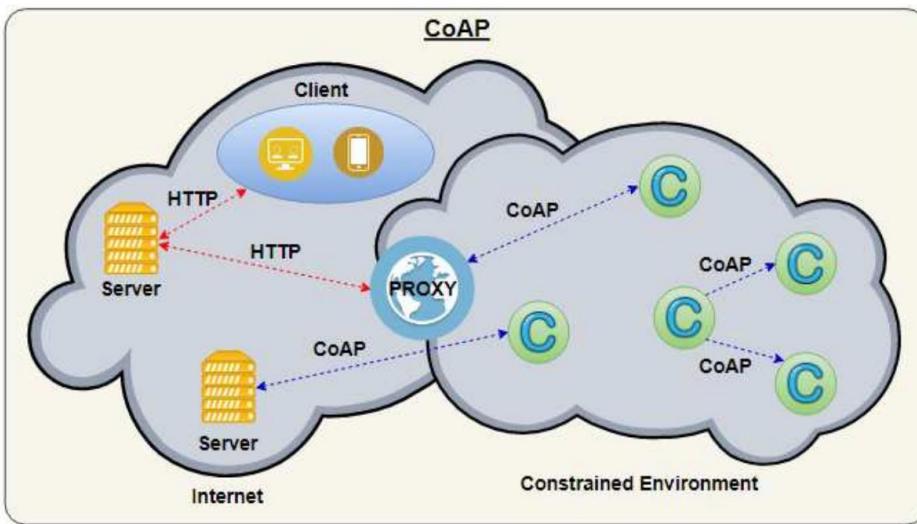
Figura 2.
Arquitectura MQTT



Nota. Descripción del funcionamiento del protocolo MQTT. Obtenido de D. Ansari, A. Rehman & R. Ali (2018). *Internet of things (iot) protocols: a brief exploration of mqtt and coap* [Protocolos de Internet de las cosas (IoT): una breve exploración de MQTT y COAP]. (p. 1.) International Journal of Computer Applications.

CoAP es ideal para aplicaciones donde el ahorro de energía es importante, por ejemplo, en sensores alimentados por baterías. Ambos protocolos garantizan que los datos de los sensores lleguen a la plataforma central de manera oportuna y segura.

Figura 3.
Arquitectura CoAP



Nota. Descripción del funcionamiento del protocolo CoAP. Obtenido de D. Ansari, A. Rehman & R. Ali (2018). *Internet of things (iot) protocols: a brief exploration of mqtt and coap* [Protocolos de Internet de las cosas (IoT): una breve exploración de MQTT y COAP]. (p. 2.) International Journal of Computer Applications.

8.1.2.3. Dispositivos y Hardware IoT

La Raspberry Pi actúa como un controlador central, gestionando la recopilación de datos de sensores, procesando la información localmente y enviándola a la nube para un análisis más detallado (Kiran & Sriramoju, 2018).

Los sensores son la base del sistema IoT, ya que recopilan datos sobre la imagen y otras variables relevantes. Estos sensores pueden estar conectados a la Raspberry Pi, que luego toma decisiones basadas en la lógica programada, como activar un relé para accionar un mecanismo de respuesta (Kiran & Sriramoju, 2018).

8.2. Inteligencia Artificial en la gestión de residuos

La capacidad de la IA para procesar grandes volúmenes de datos y realizar tareas complejas, como el reconocimiento de imágenes, la convierte en una tecnología necesaria en la modernización de los sistemas de gestión de residuos.

8.2.1. Introducción a la Inteligencia Artificial (IA)

La inteligencia artificial se refiere a la simulación de procesos de inteligencia humana mediante máquinas, especialmente sistemas informáticos. Estos procesos incluyen el aprendizaje (adquisición de información y reglas para el uso de la información), el razonamiento (uso de reglas para alcanzar conclusiones aproximadas o definitivas), y la autocorrección. En el contexto de la gestión de residuos, la IA se utiliza principalmente para el reconocimiento y clasificación de materiales a través del análisis de imágenes, permitiendo una separación eficiente y automatizada de los desechos (Sinthiya et al., 2022).

8.2.2. Aplicaciones de la IA en la gestión de residuos

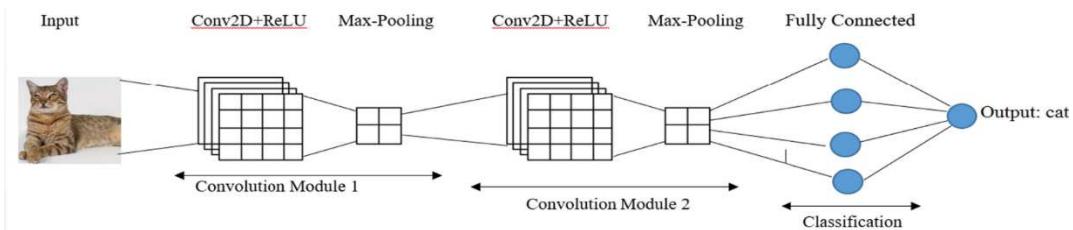
La inteligencia artificial ha encontrado múltiples aplicaciones en la gestión de residuos. La capacidad de la IA para analizar grandes cantidades de datos y tomar decisiones en tiempo real ha permitido desarrollar sistemas más eficientes y precisos.

8.2.2.1. Técnicas de IA Utilizadas en la gestión de residuos

La clasificación automatizada de residuos mediante técnicas de inteligencia artificial se basa en el uso de redes neuronales convolucionales (CNN), que son un tipo de red neuronal diseñada específicamente para procesar y analizar datos visuales. Las CNN están compuestas por múltiples capas de neuronas que pueden identificar características importantes en las imágenes, como bordes, texturas, y patrones específicos, lo que las hace eficaces para tareas de reconocimiento y clasificación (Adedeji & Wang, 2019).

Las CNNs son efectivas en la clasificación de imágenes porque pueden capturar características espaciales y jerárquicas en los datos visuales. Cada capa de una CNN se especializa en detectar diferentes características; las capas iniciales pueden identificar bordes y colores, mientras que las capas más profundas pueden reconocer formas complejas y patrones específicos (Sami et al., 2020).

Figura 4.
Modelo CNN para la clasificación de imágenes



Nota. Descripción gráfica para el modelo CNN. Obtenido de M. Sivakumar & T, Gurumekala (2022). *Design and development of smart Internet of Things-based solid waste management system using computer vision* [Diseño y desarrollo de un sistema inteligente de gestión de residuos sólidos basado en Internet de las cosas mediante visión artificial]. (p. 8.) *IGI global*.

ResNet-50 es una arquitectura avanzada de CNN que se destaca por su capacidad para entrenarse en conjuntos de datos grandes y complejos, manteniendo una alta precisión. La clave de ResNet-50 es su estructura de redes residuales, que permite a las capas de la red aprender funciones de identidad y características más complejas sin que se presente el problema del degradado en el aprendizaje. Esto se logra mediante la introducción de atajos que permiten que la información pase sin cambios a través de varias capas de la red. En la gestión de residuos, ResNet-50 se utiliza para entrenar modelos que pueden identificar y clasificar diferentes tipos de materiales, como vidrio, metal, papel y plástico, con alta precisión (Adedeji & Wang, 2019).

Figura 5.

Modelo ResNet para la clasificación de imágenes



Nota. Descripción gráfica para el modelo ResNet. Obtenido de O. Adedeji & Z. Wang (2019). *Intelligent waste classification system using deep learning convolutional neural network* [Sistema inteligente de clasificación de residuos mediante redes neuronales convolucionales de aprendizaje profundo]. (p. 2.) Procedia Manufacturing.

Una de las formas más comunes de representar ResNet-50 es mediante un diagrama de bloques que muestra la estructura residual. Este diagrama incluye las conexiones de atajo (skip connections) que permiten que las capas salten sobre otras, facilitando el aprendizaje de redes profundas.

- Input: representa la imagen de entrada que se va a procesar. Esta imagen pasará a través de varias capas de la red para extraer características relevantes.
- Convolution 64: esta es una capa convolucional que aplica 64 filtros a la imagen de entrada. Cada filtro convolucional extrae características específicas de la imagen, como bordes, texturas o patrones.
- Batch Norm: la normalización por lotes se utiliza después de la convolución para normalizar las salidas de la capa, acelerando el entrenamiento y ayudando a estabilizar el aprendizaje. Normaliza los valores activados para tener media cero y varianza unitaria.
- ReLU (Rectified Linear Unit): es una función de activación que introduce no linealidad en el modelo. Después de cada convolución y normalización, se aplica ReLU para eliminar las activaciones negativas (si el valor es menor que cero, se convierte en cero), manteniendo las activaciones positivas sin cambios.
- Average Pooling (Avg Pool 2 x 2): esta capa reduce las dimensiones espaciales de los mapas de características mediante un proceso de submuestreo. En lugar de tomar el valor máximo en una región, la capa de pooling promedio toma el valor promedio de una región de 2x2 píxeles. Esto reduce el tamaño de los mapas de características, conservando la información relevante y reduciendo el costo computacional.
- Basic Block 64/128/256/512: estos son los bloques residuales característicos de ResNet. Cada Basic Block consiste en varias capas

convolucionales y operaciones de activación (ReLU), con conexiones de atajo (skip connections) que permiten que la entrada original se salte algunas capas y se sume directamente a la salida final del bloque. Esto ayuda a mitigar el problema del gradiente desaparecido en redes muy profundas. Los números (64, 128, 256, 512) indican el número de filtros aplicados en esas capas convolucionales dentro del bloque.

- Fully Connected Layer (FC): la capa completamente conectada es donde se aplanan todos los mapas de características y se conectan a neuronas densas. En este caso, la capa final tiene 4 neuronas, lo que corresponde a 4 clases diferentes que la red está tratando de clasificar. Cada neurona en esta capa se conecta a todas las activaciones de la capa anterior, y se usa para hacer la clasificación final basada en las características aprendidas.

8.2.2.2. Sistemas de clasificación basados en IA

La SVM es un algoritmo de aprendizaje supervisado que se utiliza para tareas de clasificación y regresión. En el contexto de la gestión de residuos, la SVM puede ser utilizada junto con CNN para mejorar la precisión de la clasificación. La SVM funciona encontrando el hiperplano óptimo que separa los datos en diferentes clases. Este enfoque es particularmente útil cuando se trabaja con conjuntos de datos complejos o con muchas dimensiones. Por ejemplo, después de que una CNN ha extraído características de una imagen, una SVM puede ser utilizada para clasificar la imagen en una categoría específica, como vidrio, metal, papel, entre otros. La combinación de CNNs y SVM crea un sistema de clasificación robusto y preciso, capaz de manejar la variabilidad en los datos de entrada y mejorar la eficacia general del proceso de clasificación (Sami et al., 2020).

8.2.3. Fundamentos teóricos de la Inteligencia Artificial

La comprensión de los fundamentos teóricos de la inteligencia artificial es necesaria para aprovechar al máximo sus aplicaciones en la gestión de residuos. A lo largo de su evolución, la IA ha pasado de ser una teoría experimental a una tecnología con aplicaciones prácticas en múltiples industrias, incluida la gestión de residuos.

8.2.3.1. Algoritmos de clasificación en IA

Los algoritmos de clasificación, como las redes neuronales convolucionales (CNNs) y los árboles de decisión (Decision Trees), son herramientas clave en la gestión de residuos. Las CNNs son especialmente eficaces en el procesamiento de imágenes, lo que permite a los sistemas de IA distinguir entre diferentes tipos de residuos basándose en características visuales. Por otro lado, los árboles de decisión y los bosques aleatorios (Random Forests) se utilizan para tomar decisiones basadas en conjuntos de características extraídas, optimizando el proceso de clasificación (Sinthiya et al., 2022).

8.2.3.2. Infraestructura técnica para la implementación de IA

La implementación de sistemas de IA en la gestión de residuos requiere una infraestructura técnica robusta. Esto incluye la utilización de computación en el borde (Edge Computing) para procesar los datos de sensores y cámaras localmente, reduciendo la latencia y permitiendo decisiones en tiempo real. Además, la integración de hardware especializado, como GPUs y TPUs, es esencial para manejar el procesamiento intensivo que requieren los modelos

de aprendizaje profundo. Esta infraestructura es crucial para garantizar que los sistemas de IA funcionen de manera eficiente y escalable en entornos industriales (Sinthiya et al., 2022).

8.3. Reconocimiento de Imágenes para la gestión de residuos

El reconocimiento de imágenes es una tecnología necesaria en la automatización de la gestión de residuos, permitiendo la identificación y clasificación de materiales de manera eficiente. Amazon Rekognition es un servicio basado en la nube que utiliza algoritmos avanzados de aprendizaje profundo para llevar a cabo estas tareas.

8.3.1. Capacidades Técnicas de Amazon Rekognition

Amazon Rekognition es un servicio de análisis de imágenes y videos que aprovecha el potencial de las redes neuronales convolucionales (CNNs) para realizar tareas como la identificación de objetos, la detección de texto, el análisis facial, y otras tareas. En el caso de la gestión de residuos, Amazon Rekognition puede identificar y clasificar materiales reciclables con una alta precisión.

8.3.1.1. Aprendizaje por Transferencia (Transfer Learning)

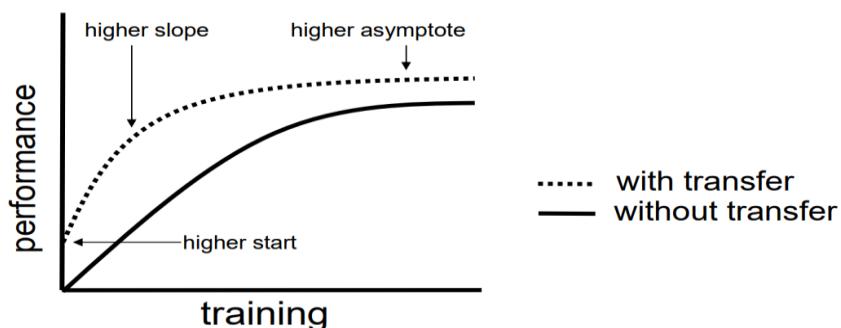
El aprendizaje transferencial es una técnica que permite a Amazon Rekognition aplicar modelos preentrenados a nuevas tareas con pequeños ajustes. Esto es útil en la clasificación de residuos, donde los datos específicos pueden ser limitados, pero el modelo puede beneficiarse del conocimiento adquirido en otras tareas de reconocimiento de imágenes.

En el aprendizaje transferencial, un modelo que ya ha sido entrenado en un gran conjunto de datos se ajusta para adaptarse a una nueva tarea. Esto se realiza congelando las primeras capas de la red, que han aprendido características básicas como bordes y texturas, y entrenando solo las últimas capas para que se especialicen en la nueva tarea. Esto permite que el modelo se ajuste rápidamente con menos datos y tiempo de entrenamiento, manteniendo una alta precisión (Poudel & Poudyal, 2022).

El uso de Transfer Learning en Amazon Rekognition permite que el sistema se adapte a diferentes tipos de materiales reciclables sin necesidad de empezar el entrenamiento desde cero. Esto es útil en entornos industriales donde la variedad de materiales y las condiciones pueden cambiar frecuentemente, permitiendo que el sistema se mantenga preciso y actualizado con un esfuerzo mínimo (Azis et al., 2020).

Figura 6.

Modelo ResNet para la clasificación de imágenes



Nota. Formas en que el aprendizaje transferencial puede mejorar el aprendizaje. Obtenido de J. Shavlik & L. Torrey (2010). *Transfer learning*. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* [Aprendizaje por transferencia. En Manual de investigación sobre aplicaciones y tendencias del aprendizaje automático: algoritmos, métodos y técnicas]. (p. 2.) IGI global.

8.3.1.1.1. Congelación y ajuste fino de capas (Freezing and Fine-Tuning)

El proceso de aprendizaje transferencial implica dos etapas clave:

- Congelación de Capas (Freezing Layers): al aplicar transferencia de aprendizaje, las capas iniciales de una red neuronal convolucional, que han aprendido a detectar características básicas como bordes, texturas, y patrones, se congelan. Esto significa que, durante el ajuste a una nueva tarea, estas capas no se entrenan nuevamente, ya que ya han capturado características generales útiles que son aplicables a una amplia gama de imágenes. Esta técnica reduce significativamente el tiempo de entrenamiento y la necesidad de grandes conjuntos de datos (Torrey & Shavlik, 2010).
- Ajuste Fino (Fine-Tuning): las capas superiores de la red, que son más específicas y están más relacionadas con la tarea final, se ajustan finamente para adaptarse a la nueva tarea. Estas capas se entrenan con un conjunto de datos específico para la tarea en cuestión, permitiendo que el modelo aprenda las características distintivas necesarias para diferenciar entre los diferentes tipos de materiales (Torrey & Shavlik, 2010).

8.3.1.1.2. Adaptación de modelos preentrenados

Los modelos preentrenados, como ResNet, Inception, o DenseNet, están preentrenados en conjuntos de datos extensos como ImageNet. Estos

modelos ya han aprendido una jerarquía rica de características visuales. Durante el aprendizaje transferencial:

- Extracción de Características: las capas preentrenadas pueden actuar como un extractor de características que se utiliza para otras tareas. Por ejemplo, se puede usar un modelo preentrenado en ImageNet y, sin modificar las primeras capas, usar la salida de estas capas como entrada para un nuevo clasificador que ha sido entrenado en un conjunto de datos específico (Torrey & Shavlik, 2010).
- Transferencia Interdominio: incluso cuando las tareas están en diferentes dominios, la transferencia de aprendizaje puede ser efectiva porque las primeras capas de la red aprenden características que son universales (como bordes y texturas) y útiles en múltiples tareas (Torrey & Shavlik, 2010).

8.3.1.1.3. Mecanismos de transferencia

El éxito del aprendizaje transferencial también depende de cómo se realiza la transferencia. Existen dos mecanismos principales:

- Transferencia Inductiva: ocurre cuando la tarea del modelo objetivo es la misma o muy similar a la tarea original para la que el modelo fue preentrenado. En este caso, los pesos y estructuras aprendidos se reutilizan con modificaciones mínimas (Torrey & Shavlik, 2010).
- Transferencia Transductiva: se refiere a la transferencia de conocimientos a una tarea diferente pero relacionada. Aquí, es común ajustar más capas del modelo o cambiar ciertas partes de la arquitectura para acomodar las nuevas características (Torrey & Shavlik, 2010).

8.3.1.2. Deep Learning y modelos avanzados

El deep learning es el corazón del reconocimiento de imágenes en Amazon Rekognition. Este enfoque utiliza redes neuronales con múltiples capas (deep neural networks) que son capaces de aprender representaciones complejas de datos.

Las CNNs son eficaces en el procesamiento de imágenes debido a su capacidad para reconocer patrones visuales a través de operaciones de convolución y pooling. En Amazon Rekognition, estas redes están diseñadas para identificar características específicas en imágenes de residuos, como texturas y formas, que permiten diferenciar entre materiales reciclables y no reciclables (Indla, 2021).

Amazon Rekognition emplea modelos avanzados de CNN que son conocidos por su capacidad para manejar tareas complejas con alta precisión. Estas arquitecturas están optimizadas para capturar características más abstractas y complejas de las imágenes, lo que permite entrenar redes profundas sin sufrir problemas como el gradiente desaparecido.

8.3.1.3. Procesamiento de imágenes y reducción de dimensionalidad

El procesamiento eficiente de imágenes es necesario para el rendimiento de Amazon Rekognition, especialmente cuando se trata de manejar grandes volúmenes de datos en tiempo real.

- Submuestreo (Pooling): las capas de pooling, como max-pooling, son utilizadas para reducir la dimensionalidad de los mapas de

características, preservando la información más relevante y eliminando redundancias. Esto mejora la eficiencia del procesamiento y evita el sobreajuste, asegurando que el modelo pueda generalizar bien en nuevas imágenes de residuos (Azis et al., 2020).

- Optimización del Procesamiento en Tiempo Real: Amazon Rekognition debe procesar y clasificar imágenes en tiempo real. Esto se logra mediante la implementación de técnicas de optimización que reducen el tiempo de procesamiento sin comprometer la precisión. La eficiencia en el procesamiento es esencial para manejar las grandes cantidades de datos generadas en entornos industriales (Indla, 2021).

8.3.1.4. Desafíos y limitaciones técnicas

A pesar de sus capacidades avanzadas, Amazon Rekognition tiene ciertos desafíos y limitaciones que deben ser considerados en su implementación.

- Calidad de las Imágenes: la precisión de Amazon Rekognition depende en gran medida de la calidad de las imágenes que procesa. Imágenes de baja resolución, con mala iluminación, o capturadas desde ángulos inadecuados pueden afectar la capacidad del sistema para identificar correctamente los materiales. Por lo tanto, es crucial utilizar cámaras de alta calidad y optimizar las condiciones de captura para maximizar la efectividad del sistema (Mao et al., 2021).
- Costos Operativos y Escalabilidad: aunque Amazon Rekognition ofrece potentes capacidades de análisis, el procesamiento de grandes volúmenes de imágenes en tiempo real puede ser costoso. Es importante considerar estrategias de optimización, como la reducción de la frecuencia de captura de imágenes o el uso de procesamiento

selectivo, para controlar los costos operativos sin comprometer la eficiencia del sistema (Indla, 2021).

9. METODOLOGÍA

9.1. Características del estudio

El enfoque del estudio propuesto es cuantitativo debido a que se centra en la recolección y análisis de datos numéricos que permitirán evaluar la eficacia de un prototipo de clasificación de residuos. Este enfoque es apropiado para medir la precisión y la eficiencia del sistema.

El alcance del estudio es explicativo, ya que busca establecer una relación de causa y efecto entre las variables, como la capacidad del sistema para reconocer y clasificar residuos, y los resultados obtenidos tras la implementación del prototipo. El diseño adoptado será experimental debido a que se manipularán ciertas variables (como los tipos de residuos) para observar su efecto en la precisión y eficiencia del prototipo. Este diseño permitirá evaluar el desempeño del sistema en un entorno controlado y realizar los ajustes necesarios.

9.2. Unidades de análisis

La población en estudio está compuesta por diversos tipos de residuos comunes en entornos domésticos, tales como plástico, vidrio, metal, papel, y residuos orgánicos. Estos residuos representan la materia prima que el prototipo deberá clasificar. La muestra se extraerá de esta población, seleccionando ejemplos representativos de cada tipo de residuo para ser sometidos a pruebas experimentales. La selección se realizará mediante un

muestreo aleatorio simple, asegurando que cada tipo de residuo tenga la misma probabilidad de ser incluido en el estudio.

9.3. Variables

Las variables en estudio se describen a continuación. La precisión, el tiempo de respuesta y la eficiencia son indicadores que permitirán medir la efectividad del prototipo en la clasificación de residuos y optimización de recursos.

Tabla 1.

Definición de variables

Variable	Definición Teórica	Definición Operativa
Precisión	Capacidad del sistema para identificar correctamente el tipo de residuo.	Porcentaje de residuos clasificados correctamente por el prototipo en comparación con la clasificación manual.
Tiempo de Respuesta	Tiempo que tarda el sistema en procesar una imagen y proporcionar un resultado.	Se medirá en segundos desde el momento en que la imagen es capturada hasta que se genera una clasificación.
Eficiencia	Relación entre los recursos utilizados y la precisión lograda.	Se evaluará considerando el número de errores de clasificación y el tiempo total de procesamiento en función de la capacidad de procesamiento de residuos por hora.

Nota. Detalle de la definición de las variables e indicadores. Elaboración propia, realizado con Word.

9.4. Fases del estudio

El proceso por medio del cual se realizará el estudio incluye las siguientes fases, cada una de ellas diseñada para asegurar un desarrollo fundamentado del sistema automatizado de clasificación de residuos.

9.4.1. Fase 1: revisión de literatura

El objetivo de esta fase es recopilar y analizar estudios previos y teorías relacionadas con el reconocimiento de imágenes, el aprendizaje profundo, y la gestión automatizada de residuos. Durante esta fase, se realizará una búsqueda de artículos científicos y documentos técnicos que sustenten el marco teórico del proyecto. Se prestará atención a la identificación de tecnologías similares, metodologías empleadas en estudios anteriores, y resultados obtenidos en la automatización de procesos de clasificación de residuos.

9.4.2. Fase 2: diseño del prototipo

Se desarrollará el sistema de clasificación de residuos utilizando Amazon Rekognition. El proceso comenzará con el diseño conceptual del prototipo, donde se definirán las especificaciones técnicas y los componentes necesarios para su construcción. Se seleccionará el hardware adecuado, incluyendo una Raspberry Pi versión 4 y una cámara de alta resolución, que serán integrados para capturar y procesar imágenes de residuos. Asimismo, se programará el software que gestionará el reconocimiento de imágenes y la clasificación de los residuos, asegurando la correcta integración de Amazon Rekognition con los componentes físicos del prototipo. Esta fase finalizará con la validación del diseño y la preparación para las pruebas experimentales.

9.4.3. Fase 3: gestión y recolección de la información

Esta fase se enfocará en la implementación del prototipo en un entorno controlado y en la recolección de datos sobre su rendimiento. Se procederá a capturar imágenes de diferentes tipos de residuos, que serán procesadas en tiempo real por el sistema. Durante esta fase, se registrarán los resultados de la clasificación, midiendo la precisión con la que el prototipo identifica los materiales reciclables, así como el tiempo de respuesta desde la captura de la imagen hasta la clasificación final. Los datos recolectados se almacenarán de manera estructurada para su posterior análisis, asegurando que se pueda realizar un seguimiento detallado del rendimiento del sistema bajo diversas condiciones.

9.4.4. Fase 4: análisis de la información

En esta fase, se realizará un análisis estadístico de los datos recolectados durante las pruebas. Se evaluará el rendimiento del prototipo en términos de precisión, tiempo de respuesta y eficiencia general. El análisis permitirá identificar patrones o problemas recurrentes en la clasificación de residuos, proporcionando una comprensión más profunda de cómo el prototipo maneja diferentes escenarios. Además, se compararán los resultados con los obtenidos en estudios previos y con la clasificación manual, lo que permitirá evaluar la efectividad del sistema y hacer recomendaciones para futuras mejoras.

9.4.5. Fase 5: interpretación de resultados e información

La última fase se centrará en la interpretación de los resultados obtenidos durante el análisis. Se extraerán conclusiones sobre la viabilidad y

efectividad del prototipo en la gestión de residuos, evaluando en qué medida la solución técnica propuesta resuelve el problema planteado. Se presentarán recomendaciones basadas en los hallazgos del estudio, incluyendo posibles mejoras en el diseño del prototipo y consideraciones para su implementación en entornos reales. Esta fase también incluirá la elaboración de un informe final que documente el proceso completo, los resultados obtenidos y las conclusiones derivadas del estudio.

9.5. Resultados esperados

Se espera que el prototipo desarrollado sea capaz de clasificar los residuos con una alta precisión y eficiencia, demostrando la viabilidad del uso de tecnologías avanzadas de reconocimiento de imágenes en la gestión automatizada de residuos. Los resultados obtenidos deberán evidenciar en qué medida el prototipo resuelve el problema planteado y qué mejoras podrían implementarse para su aplicación en entornos reales.

10. TÉCNICAS DE ANÁLISIS DE INFORMACIÓN

Para el análisis de la información obtenida del prototipo de clasificación automatizada de residuos, se utilizarán técnicas cuantitativas que permitirán evaluar las variables clave: precisión, tiempo de respuesta y eficiencia del sistema. El objetivo es interpretar los datos obtenidos de las pruebas experimentales de manera que se pueda optimizar el rendimiento del prototipo.

10.1. Análisis de precisión

En cuanto a la precisión, se llevará a cabo un análisis detallado sobre el porcentaje de residuos correctamente clasificados por el sistema en comparación con la clasificación manual de los mismos residuos. La precisión se medirá como la proporción de aciertos en relación con el número total de residuos clasificados. Para analizar esta variable, se emplearán técnicas estadísticas descriptivas, tales como la media y mediana, que permitirán conocer el rendimiento promedio del sistema en la clasificación de los diferentes tipos de residuos. Además, se calculará la desviación estándar para evaluar la consistencia de la precisión del prototipo bajo distintas condiciones, como variaciones en la iluminación y ángulos de captura.

10.2. Análisis del tiempo de respuesta

El tiempo de respuesta del sistema se analizará midiendo el intervalo de tiempo que transcurre desde la captura de la imagen hasta la obtención de la clasificación del residuo. Esta variable será evaluada utilizando la media aritmética del tiempo de procesamiento por imagen y se complementará con

el cálculo de la desviación estándar, para identificar la variabilidad en los tiempos de respuesta bajo diferentes condiciones de prueba. La eficiencia del sistema en términos de tiempo de procesamiento será crucial, ya que el prototipo deberá operar en tiempo real para poder ser implementado en un entorno práctico.

10.3. Análisis de eficiencia

En relación con la eficiencia del sistema, se analizará la relación entre el uso de recursos (tiempo de procesamiento, consumo energético, capacidad de procesamiento) y el nivel de precisión alcanzado. Para ello, se realizará un análisis comparativo de los resultados obtenidos bajo diversas condiciones experimentales, evaluando la relación entre la cantidad de imágenes procesadas y la precisión general del sistema. El análisis estadístico de esta variable permitirá determinar si el prototipo mantiene un equilibrio adecuado entre precisión y tiempo de respuesta.

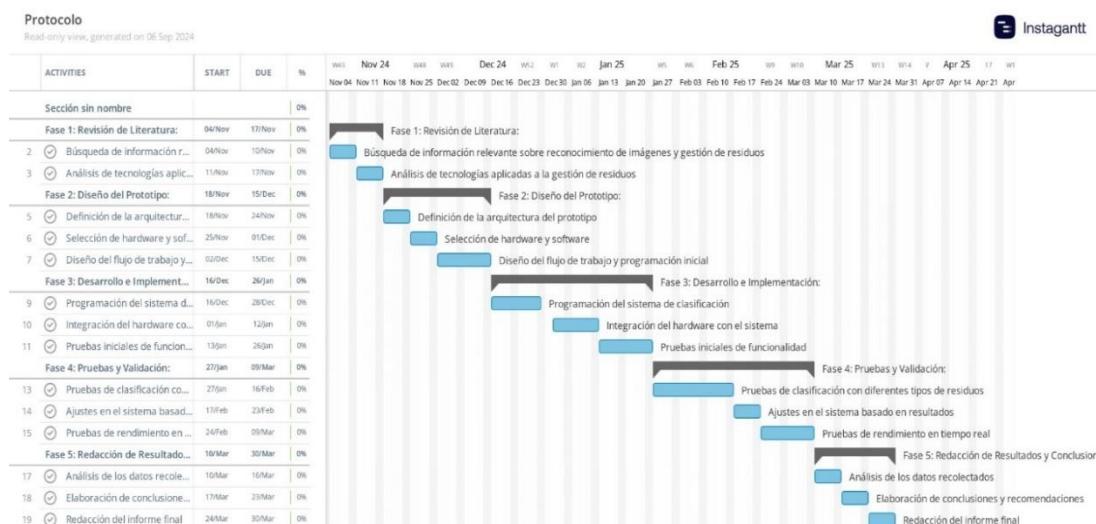
10.4. Comparación y optimización

Finalmente, los resultados obtenidos del análisis de las tres variables (precisión, tiempo de respuesta, y eficiencia) se compararán con estudios previos en el área de la clasificación de residuos y se presentarán recomendaciones para mejorar el rendimiento del prototipo en futuras iteraciones. Este análisis permitirá identificar las fortalezas y limitaciones del sistema, proporcionando una base sólida para la optimización y el ajuste de los parámetros del prototipo.

11. CRONOGRAMA

En la Figura 7 se muestra el cronograma del desarrollo de la solución propuesta.

Figura 7.
Cronograma



Nota. Cronograma por fases de la investigación. Elaboración propia, realizado con Instagantt.

12. ANÁLISIS DE FACTIBILIDAD

El análisis de factibilidad tiene como objetivo evaluar las condiciones bajo las cuales el desarrollo del prototipo es viable, considerando las dimensiones operativas, técnicas y económicas.

12.1. Factibilidad operativa

La factibilidad operativa se basa en que el prototipo será desarrollado e implementado por una sola persona con conocimientos en desarrollo de software, machine learning, y hardware. Este enfoque reduce la complejidad operativa, ya que no será necesario coordinar equipos de trabajo. El entorno de desarrollo será mayormente digital, utilizando servicios en la nube como Amazon Rekognition para la clasificación de imágenes y una Raspberry Pi v4 para el procesamiento y captura de imágenes.

El proceso operativo incluye la integración de componentes de hardware y software:

- Cámaras de alta resolución conectadas a la Raspberry Pi para capturar imágenes de los residuos.
- Amazon Rekognition para el procesamiento y análisis de las imágenes en la nube.
- Desarrollo de scripts y software para manejar la interacción entre los dispositivos y los servicios en la nube.

12.2. Factibilidad técnica

La Raspberry Pi es un dispositivo robusto y adecuado para proyectos individuales, con suficiente capacidad para manejar el procesamiento de imágenes básico y enviar datos a la nube. Amazon Rekognition ofrece una API amigable, lo que facilita su integración con los scripts desarrollados para este prototipo.

Los componentes técnicos incluyen:

- Cámara de alta resolución, adecuada para capturar imágenes de los residuos.
- Raspberry Pi 4 Modelo B, con capacidad suficiente para gestionar la captura de imágenes y la comunicación con los servidores de Amazon.
- Amazon Rekognition, que permitirá procesar las imágenes de residuos y devolver la clasificación automáticamente.
- Conexión a internet, fundamental para el envío de imágenes y la recepción de resultados desde la nube.

El riesgo principal a nivel técnico puede estar en la calidad de la imagen capturada bajo distintas condiciones (iluminación, ángulos), que podría afectar la precisión de la clasificación. Esto se mitigará utilizando cámaras adecuadas y ajustando los parámetros del sistema durante las fases de prueba.

12.3. Factibilidad económica

Siendo un proyecto desarrollado por una sola persona, los costos estarán más enfocados en la adquisición del hardware y los servicios en la

nube. A continuación, se presentan los costos aproximados de los componentes y servicios necesarios para el prototipo:

Tabla 2.

Costos del prototipo

Concepto	Costo estimado (USD)
Cámara de alta resolución	\$150
Raspberry Pi y periféricos	\$200
Amazon Rekognition	\$1 por cada 1,000 imágenes procesadas
Servidor AWS EC2 (opcional para pruebas extendidas)	\$10 mensuales (plan básico)
Materiales adicionales (cables, adaptadores, entre otros.)	\$50
Total estimado inicial	\$400 - \$500

Nota. Costos asociados a la realización del prototipo. Elaboración propia, realizado con Word.

12.3.1. Costos operativos

- Amazon Rekognition: el servicio tiene un costo aproximado de \$1 por cada 1,000 imágenes procesadas. Para las pruebas iniciales, este costo será bastante bajo y escalable a medida que se necesite procesar más imágenes.

- AWS EC2 (opcional): un servidor EC2 para manejar tareas adicionales o pruebas de integración costaría unos \$10 mensuales en el plan más básico.

El proyecto, por lo tanto, tiene una factibilidad económica alta, ya que los costos iniciales son relativamente bajos y los servicios en la nube permiten escalar el procesamiento sin necesidad de una gran inversión inicial. Con un presupuesto de entre \$400 a \$500 para la fase inicial, se puede implementar el prototipo con los componentes necesarios y servicios básicos en la nube.

13. PROPUESTA DE ÍNDICE DE CONTENIDOS

ÍNDICE GENERAL

ÍNDICE DE ILUSTRACIONES

LISTA DE SÍMBOLOS

GLOSARIO

RESUMEN

PLANTEAMIENTO DEL PROBLEMA Y PREGUNTAS DE INVESTIGACIÓN

OBJETIVOS

MARCO METODOLÓGICO

INTRODUCCIÓN

1. ANTECEDENTES

2. JUSTIFICACIÓN

3. ALCANCES

4. MARCO TEÓRICO

4.1. Tecnologías IoT en la Gestión de Residuos

4.1.1. Definición y Componentes Básicos del IoT

4.1.2. Arquitectura del IoT: Dispositivos, Gateways y Plataformas

4.1.3. Protocolos de Comunicación en IoT

4.1.4. Dispositivos y Hardware IoT

4.2. Inteligencia Artificial en la Gestión de Residuos

4.2.1. Introducción a la Inteligencia Artificial (IA)

4.2.2. Aplicaciones de la IA en la Gestión de Residuos

- 4.2.2.1. Técnicas de IA Utilizadas en la Gestión de Residuos
 - 4.2.2.2. Sistemas de Clasificación Basados en IA
 - 4.2.3. Fundamentos Teóricos de la Inteligencia Artificial
- 4.3. Reconocimiento de Imágenes para la Gestión de Residuos
- 4.3.1. Capacidades Técnicas de Amazon Rekognition
 - 4.3.1.1. Aprendizaje por Transferencia (Transfer Learning)
 - 4.3.1.2. Deep Learning y Modelos Avanzados
 - 4.3.1.3. Procesamiento de Imágenes y Reducción de Dimensionalidad
 - 4.3.1.4. Desafíos y Limitaciones Técnicas

5. PRESENTACIÓN DE RESULTADOS

- 5.1. Pruebas de Clasificación Automatizada
 - 5.1.1. Análisis de Precisión
 - 5.1.2. Análisis del Tiempo de Respuesta
 - 5.1.3. Análisis de la Eficiencia del Sistema
- 5.2. Resultados Cuantitativos
 - 5.2.1. Gráficas y Tablas de Resultados
 - 5.2.2. Interpretación de Datos Estadísticos

6. DISCUSIÓN DE LOS RESULTADOS

- 6.1. Fortalezas del Prototipo
- 6.2. Limitaciones Identificadas
- 6.3. Oportunidades de Mejora

CONCLUSIONES

RECOMENDACIONES

REFERENCIAS

ANEXOS

14. REFERENCIAS

- Adedeji, O. & Wang, Z. (2019). Intelligent waste classification system using deep learning convolutional neural network [Sistema inteligente de clasificación de residuos mediante redes neuronales convolucionales de aprendizaje profundo]. *Procedia Manufacturing*, 35, 607-612.
<https://www.sciencedirect.com/science/article/pii/S2351978919307231/pdf?md5=ca3fd6406f928cc6a1a2938b690c00e9&pid=1-s2.0-S2351978919307231-main.pdf>
- Anagnostopoulos, T., Zaslavsky, A., Kolomvatsos, K., Medvedev, A., Amirian, P., Morley, J., & Hadjileftymiades, S. (2017). Challenges and opportunities of waste management in IoT-enabled smart cities: a survey [Desafíos y oportunidades de la gestión de residuos en ciudades inteligentes basadas en IoT: una encuesta]. *IEEE Transactions on Sustainable Computing*, 2(3), 275-289.
<https://drive.google.com/file/d/1m3ON8nlnxeQ5vULMOWeFqpNIHPW-Oom/view>
- Ansari, D., Rehman, A., & Ali, R. (2018). Internet of things (iot) protocols: a brief exploration of mqtt and coap [Protocolos de Internet de las cosas (IoT): una breve exploración de MQTT y COAP]. *International Journal of Computer Applications*, 179(27), 9-14.
<https://www.academia.edu/download/75180943/ijca2018916438.pdf>
- Azis, F., Suhaimi, H., & Abas, E. (2020). Waste classification using convolutional neural network [Clasificación de residuos mediante

redes neuronales convolucionales]. In *Proceedings of the 2020 2nd international conference on information technology and computer communications*, AMC Digital Library, 9-13.
<https://dl.acm.org/doi/abs/10.1145/3417473.3417474>

Esmaeilian, B., Wang, B., Lewis, K., Duarte, F., Ratti, C., & Behdad, S. (2018). The future of waste management in smart and sustainable cities: A review and concept paper [El futuro de la gestión de residuos en ciudades inteligentes y sostenibles: una revisión y un documento conceptual]. *Waste management*, 81, 177-195.
<https://www.sciencedirect.com/science/article/abs/pii/S0956053X18305865>

Hasan, B., Yeazdani, A., Istiaque, L., & Chowdhury, R. (2017). Smart waste management system using IoT [Sistema de gestión inteligente de residuos mediante IoT]. *Doctoral dissertation, BRAC University*.
https://dspace.bracu.ac.bd/xmlui/bitstream/handle/10361/8718/12321065.13101215.16141003.16341020_CSE.pdf?sequence=1&isAllowed=y

Indla, R. (2021). *An overview on amazon rekognition technology* [Una descripción general de la tecnología de reconocimiento de Amazon]. California State University San Bernardino, CSUSB ScholarWorks.
<https://scholarworks.lib.csusb.edu/cgi/viewcontent.cgi?article=2396&context=etd>

Kiran, S., & Sriramoju, S. (2018). A Study on the Applications of IOT [Un estudio sobre las aplicaciones de la IoT]. *Indian Journal of Public Health Research & Development*, 9(11), 1173-1175.

https://www.academia.edu/download/59324740/10.A_Study_on_the_Applications_of_IOT_20190520-79027-1xy91js.pdf

Malik, M., Sharma, S., Uddin, M., Chen, C., Wu, C., Soni, P., & Chaudhary, S. (2022). Waste classification for sustainable development using image recognition with deep learning neural network models [Clasificación de residuos para el desarrollo sostenible mediante reconocimiento de imágenes con modelos de redes neuronales de aprendizaje profundo]. *Sustainability*, 14(12), 7222. <https://www.mdpi.com/2071-1050/14/12/7222>

Masroor, H. (2020). *IoT Enabled Efficient Waste Collection System* [Sistema de recolección de residuos eficiente basado en IoT]. United International University. <http://103.109.52.4/bitstream/handle/52243/1895/Md.%20Hasan%20Masroor%20Khan%20-%20012161003%20-%20revise.pdf?sequence=1&isAllowed=y>

Mao, W., Chen, W., Wang, C., & Lin, Y. (2021). Recycling waste classification using optimized convolutional neural network [Clasificación de residuos de reciclaje mediante redes neuronales convolucionales optimizadas]. *Resources, Conservation and Recycling*, 164, 105132. <https://www.sciencedirect.com/science/article/abs/pii/S0921344920304493>

Poudel, S., & Poudyal, P. (2022). Classification of waste materials using CNN based on transfer learning [Clasificación de materiales de desecho mediante CNN basada en aprendizaje por transferencia]. In *Proceedings of the 14th Annual Meeting of the Forum for Information*

Retrieval Evaluation, AMC Digital Library, 29-33.
<https://dl.acm.org/doi/pdf/10.1145/3574318.3574345>

Sami, K., Amin, Z., & Hassan, R. (2020). Waste management using machine learning and deep learning algorithms [Gestión de residuos mediante algoritmos de aprendizaje automático y aprendizaje profundo]. *International Journal on Perceptive and Cognitive Computing*, 6(2), 97-106.

<https://journals.iium.edu.my/kict/index.php/IJPCC/article/download/165/120>

Sinthiya, N., Chowdhury, T., & Haque, A. (2022). Artificial intelligence based Smart Waste Management—a systematic review [Gestión inteligente de residuos basada en inteligencia artificial: una revisión sistemática]. *Computational Intelligence Techniques for Green Smart Cities, Springer Nature*, 67-92.

https://lutpub.lut.fi/bitstream/handle/10024/164859/sinthiya_et_al_artificial_intelligence_am.pdf?sequence=1&isAllowed=y

Torrey, L., & Shavlik, J. (2010). *Transfer learning*. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* [Aprendizaje por transferencia. En Manual de investigación sobre aplicaciones y tendencias del aprendizaje automático: algoritmos, métodos y técnicas], IGI global, Information Science Reference. <https://ftp.cs.wisc.edu/machine-learning/shavlik-group/torrey.handbook09.pdf>

Sivakumar, M. & Gurumekala, T. (2022). *Design and development of smart Internet of Things-based solid waste management system using*

computer vision [Diseño y desarrollo de un sistema inteligente de gestión de residuos sólidos basado en Internet de las cosas mediante visión artificial]. *IGI globa*, Springer Nature.
<https://link.springer.com/article/10.1007/s11356-022-20428-2>

Yankova, T., & Grigorova, I. (2020). *Automated waste collection systems—Possibilities, trends and application* [Sistemas automatizados de recogida de residuos: posibilidades, tendencias y aplicaciones]. Proceedings of the 20th International Multidisciplinary Scientific Geoconference SGEM, University of Mining and Geology St. Ivan Rilski.
https://www.researchgate.net/profile/Irena-Grigorova/publication/347778578_AUTOMATED_WASTE_COLLECTION_SYSTEMS-_POSSIBILITIES_TRENDS_AND_APPLICATION/links/6571e0746610947889a71eeb/AUTOMATED-WASTE-COLLECTION-SYSTEMS-POSSIBILITIES-TRENDS-AND-APPLICATION.pdf