

UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN



**Sistema inteligente utilizando deep learning y gamificación para la
clasificación de residuos sólidos del programa institucional integrador
CISUSAT**

**TESIS PARA OPTAR EL TÍTULO DE
INGENIERO DE SISTEMAS Y COMPUTACIÓN**

AUTOR

Jordan Oxalc Vasquez Fernandez

ASESOR

Ricardo David Iman Espinoza

<https://orcid.org/0000-0003-0409-8773>

Chiclayo, 2024

**Sistema inteligente utilizando deep learning y gamificación para la
clasificación de residuos sólidos del programa institucional
integrador CISUSAT**

PRESENTADA POR

Jordan Oxalc Vasquez Fernandez

A la Facultad de Ingeniería de la
Universidad Católica Santo Toribio de Mogrovejo
para optar el título de

INGENIERO DE SISTEMAS Y COMPUTACIÓN

APROBADA POR

Maria Ysabel Aranguri Garcia

PRESIDENTE

Mariana Chavarry Chancay

SECRETARIO

Ricardo David Iman Espinoza

VOCAL

Dedicatoria

A Dios, fuente de inspiración y guía en este camino.


A mis padres y hermanos, por su amor incondicional y apoyo constante.

Agradecimientos

Agradezco a mi asesor, el Ing. Ricardo Iman, por su valiosa orientación y apoyo durante todo el proceso de esta investigación. También quiero expresar mi gratitud al Programa Institucional CISUSAT y a todas las personas involucradas en él, por proporcionar el marco y los recursos necesarios para llevar a cabo este proyecto. Mis sinceros agradecimientos a mis compañeros y amigos que colaboraron con sus ideas y esfuerzo, contribuyendo significativamente al éxito de esta tesis. Su apoyo fue fundamental en este viaje académico.

Artículo 100%

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	tesis.usat.edu.pe Fuente de Internet	2%
2	hdl.handle.net Fuente de Internet	2%
3	renati.sunedu.gob.pe Fuente de Internet	1%
4	repositorio.ucv.edu.pe Fuente de Internet	1%
5	www.researchgate.net Fuente de Internet	1%
6	repositorio.usil.edu.pe Fuente de Internet	<1%
7	eprints.uanl.mx Fuente de Internet	<1%
8	irep.ntu.ac.uk Fuente de Internet	<1%
9	www.usat.edu.pe Fuente de Internet	<1%

Índice

Resumen	6
Abstract	7
Introducción	8
Revisión de literatura	9
Materiales y métodos	17
Resultados y discusión	18
Conclusiones	31
Recomendaciones.....	32
Referencias	33
Anexos.....	38

Resumen

La investigación se centró en el desarrollo de un sistema inteligente para abordar el desafío de la clasificación de residuos sólidos en la localidad de Luis Alberto Sánchez, dentro del marco del Programa Institucional de Ciudad Sustentable, Saludable, Ambiental y Territorial (CISUSAT) en Chiclayo, Perú. Actualmente, la mayoría de los pobladores entregan sus residuos de manera inadecuada, a menudo mezclados con desechos no reciclables. Esta situación ha convertido el proceso de clasificación y separación en una tarea manual tediosa para la asociación de recicladores de la zona, compuesta por 10 miembros de los cuales solo están 5 activos, además en su mayoría personas de la tercera edad. En este contexto, se construyó un sistema que aprovechó la potencia del aprendizaje profundo, en particular, las redes neuronales convolucionales (CNN), para identificar y separar diversos tipos de residuos utilizando imágenes como entrada. La implementación se materializó en forma de una aplicación móvil nativa para dispositivos Android. La metodología SCRUM guió el proceso de desarrollo, complementada por la metodología de ciencia de datos de IBM, para la creación del modelo de deep learning. En cuanto a la tecnología, se utilizaron los lenguajes de programación Kotlin para la aplicación móvil y Python para el modelo y la API de comunicación. Los resultados obtenidos mostraron una alta precisión del 96.89% en la clasificación de residuos sólidos. Además, se agregaron elementos de gamificación, lo que podría resultar en una mayor participación y conciencia ambiental por parte de los usuarios.

Palabra clave: sistema inteligente, aprendizaje profundo, redes neuronales convolucionales (CNN), clasificación, residuos sólidos, gamificación

Abstract

The study aimed to create an intelligent system to tackle the problem of inappropriate waste segregation in the community of Luis Alberto Sánchez as part of the Institutional Program for Sustainable, Healthy, Environmental, and Territorial City (CISUSAT) in Chiclayo, Peru. At present, the populace tends to intermix their waste with non-recyclable materials. This scenario has transformed the process of sorting and segregating into a laborious manual task for the community of local recyclers, consisting of ten members of whom only five are currently active, and many of whom are elderly. Consequently, a solution was developed that employed the capacity of deep learning, specifically Convolutional Neural Networks (CNN), to classify and segregate various types of waste utilizing images as input. This was implemented through a native mobile app for Android devices. The development process was guided by the SCRUM methodology with IBM's data science methodology complementing the creation of the deep learning model. Kotlin was used for the mobile application, while Python was utilized for the model and communication API. The accuracy achieved in solid waste classification was high with a precise percentage of 96.89%. Furthermore, gamification features were included to encourage user participation and promote environmental awareness.

Keywords: intelligent system, deep learning, Convolutional Neural Networks (CNN), classification, solid waste, gamification

Introducción

En la era actual, los modelos tradicionales de producción y consumo, caracterizados por una economía lineal, han demostrado ser insostenibles y cada vez más inconsistentes [1]. Este enfoque, que se basa en producir, consumir y eliminar productos, ha carecido de una visión ambiental integral, asumiendo erróneamente la disponibilidad infinita de recursos y la capacidad del medio ambiente para absorber residuos sin límites [2]. Este paradigma lineal plantea desafíos significativos, con proyecciones que indican un aumento drástico en la demanda de recursos y alimentos, así como una presión creciente sobre el agua y la energía para el año 2050 [3]. La economía circular, presentada por la Fundación Ellen MacArthur [4], surge como una alternativa viable a este modelo lineal. La economía circular busca establecer un sistema restaurativo y regenerativo, priorizando la gestión sostenible de los residuos mediante prácticas de reutilización que conserven el valor y la utilidad de los productos antes de su eliminación. El reciclaje se posiciona como una estrategia esencial dentro de esta transición hacia la economía circular, ya que contribuye significativamente a la reducción de la generación de residuos sólidos y, por lo tanto, a un uso más eficiente de los recursos [5]. Sin embargo, el proceso de reciclaje se enfrenta a desafíos y problemas a nivel mundial. Estos incluyen la falta de una adecuada clasificación y separación de residuos, así como la limitada conciencia y participación de las partes interesadas [6][7]. A nivel global, las tasas de reciclaje son notoriamente bajas, como lo demuestran las estadísticas que revelan que solo una fracción mínima de los desechos plásticos se recicla de manera efectiva [8]. Incluso en países con programas ambientales avanzados, como Estados Unidos, la tasa de reciclaje no alcanza su máximo potencial [10]. La región de América Latina y el Caribe también enfrenta un panorama desafiante en cuanto al reciclaje. A pesar de que se generan grandes cantidades de residuos, la tasa de reciclaje en la región es notablemente baja [11]. Esta problemática se refleja en la realidad local, como se evidencia en la experiencia de la localidad Luis Alberto Sánchez, parte del Programa Institucional de Ciudad Sustentable, Saludable, Ambiental y Territorial (CISUSAT) [12]. A pesar de los esfuerzos para promover la clasificación de residuos, se han observado limitaciones en la práctica del reciclaje [13]. De los 10 recicladores en la asociación, solo 5 están actualmente activos, y 3 se han unido recientemente. Anteriormente, se llevaron a cabo aproximadamente diez capacitaciones específicas sobre la clasificación de los residuos sólidos, lo que inicialmente resultó en que los residentes entregaran sus desechos debidamente clasificados. Sin embargo, debido a la pandemia, estas prácticas se interrumpieron, y en la actualidad, la mayoría de los residentes entregan sus residuos sólidos de manera inadecuada, a menudo mezclados con otros desechos. Como resultado, el proceso de clasificación, separación

y selección de residuos se realiza manualmente por parte de los recicladores. Esta laboriosa tarea está sujeta a la variabilidad en la frecuencia y el volumen de los materiales recolectados, lo que puede demandar un tiempo significativo, desde 2 a 3 horas en días de recolección únicos hasta un extenso período de hasta 3 días de trabajo en jornadas de 2 a 3 horas diarias en casos de recolecciones extendidas. La presidenta de la asociación resalta que, desde su perspectiva, la etapa más desafiante de su labor radica en la separación de los residuos, incluso más que en la recolección en sí. Este artículo se centra en abordar esta problemática local, teniendo como objetivo general de desarrollar un sistema inteligente basado en deep learning y gamificación para la clasificación de residuos sólidos del programa institucional CISUSAT, del cual se desglosan los siguientes objetivos específicos: determinar el tipo de red neuronal artificial adecuado para el reconocimiento de patrones en imágenes de diferentes tipos de residuos sólidos; construir un modelo de deep learning para la clasificación de residuos sólidos en base a imágenes propias de la situación problemática; comprobar la confiabilidad del modelo de deep learning desarrollado mediante la obtención de sus grados de precisión, exactitud y exhaustividad; desplegar el modelo de deep learning desarrollado en un aplicativo móvil para la integración del sistema inteligente y validar el sistema inteligente con respecto a los criterios de usabilidad y utilidad percibida por los usuario. La investigación no solo aborda las características tecnológicas, sino que también tiene un fuerte enfoque en la conciencia ambiental y la participación comunitaria. Además, busca establecer un antecedente valioso para futuros proyectos que se enfrenten a problemáticas y objetivos similares. El desarrollo de esta solución involucró la implementación de diversas tecnologías, incluyendo Python, Kotlin y PostgreSQL, junto con metodologías como SCRUM y la metodología fundamental para la ciencia de datos de IBM. El sistema inteligente propuesto no solo tiene el potencial de aliviar la carga de trabajo de los recicladores locales, sino que también contribuirá al compromiso ambiental y la conciencia de la comunidad, promoviendo prácticas ecológicas en consonancia con los principios de la economía circular. En última instancia, la adecuada clasificación de residuos sólidos facilita su reciclaje y reutilización, lo que tiene importantes beneficios ambientales [7].

Revisión de literatura

Para el desarrollo de esta investigación se revisó diferentes fuentes de información a nivel internacional, nacional y local, las cuales sustentan y afianzan la solución propuesta.

Antecedentes

Esta investigación ha tomado en cuenta los siguientes antecedentes:

Antecedentes internacionales

Huang et al. [21], desarrollan una infraestructura de contabilidad ecológica basada en dispositivos móviles denominada “CIRC4LIFE”, la cual es una aplicación que busca incentivar y mejorar la conciencia ambiental de los consumidores, aplica elementos de gamificación mediante monedas a las cuales llaman eco-créditos, en el desarrollo de su solución implementan algoritmos de cifrado, soporte a la API de Google Maps, conexión a web services además utilizan Android Studio con el lenguaje java para la programación de la aplicación. Peng et al. [22] abordaron la problemática relacionada con la gestión inadecuada de residuos en la Unión Europea. Su investigación se centró en la falta de compromiso por parte de los consumidores para reciclar y la carencia de contenedores inteligentes en esta región. Para abordar esta cuestión, los autores desarrollaron un sistema basado en Tecnologías de la Información y Comunicación (TIC) que promoviera tanto el reciclaje como las compras ecológicas implementaron su solución en la ciudad de Getxo, España. En el proceso de desarrollo, utilizaron lenguajes de programación como PHP para la conexión web, JavaScript y MySQL para la gestión de la base de datos. Los resultados de su investigación reflejaron el éxito en el desarrollo del sistema y destacaron una mejora significativa en la conciencia ambiental de los consumidores. Las dos soluciones mencionadas anteriormente abarcan en cierto modo la problemática de la investigación, no obstante, existen investigaciones que se centran específicamente en la clasificación de residuos sólidos, Delnevo et al. [25] desarrollan “ScanBage”, esta aplicación web aborda la problemática de separar los residuos sólidos y utiliza algoritmos de aprendizaje automático, incluyendo redes neuronales profundas y Máquinas de Soporte Vectorial (SVM), para clasificar automáticamente los residuos por categoría. Además, incorpora elementos de gamificación para motivar la participación de los usuarios, el modelo de clasificación se entrenó con un conjunto de datos llamado "Trashnet," que contiene imágenes de 6 tipos de residuos, como resultado obtuvieron una precisión del 98.6%. Otra solución es la desarrollada por Vo et al.[26], enfocada en la problemática de la inadecuada clasificación de residuos sólidos en Asia, para ello proponen un framework para la clasificación de residuos utilizando redes neuronales profundas, el al cual denominan “DNN-TC”, el entrenamiento lo hicieron mediante “VN-Trash” un conjunto de 5904 imágenes de residuos sólidos de Vietnam, mientras que el desarrollo se utilizó Python y su librería de deep learning Pytorch como

resultado su modelo logra tener una precisión de 98%. Para finalizar Mao et al. [27] desarrollan un modelo de clasificación de residuos de reciclaje, para abordar la problemática de la inadecuada clasificación de los mismos, desarrollan una CNN y algoritmos genéticos para la optimización de la red neuronal. Para el desarrollo del modelo se utilizó Python y sus librerías keras, también menciona el uso de C# en el desarrollo de una aplicación de escritorio para pruebas del modelo, con respecto a sus resultados el modelo obtiene una precisión del 99.6%.

Antecedentes nacionales

En nuestro país, se puede encontrar la investigación de Valderrama [23], el cual desarrolla un aplicativo móvil para la automatización del reciclaje en la urbanización la Capullana en Surco – Lima, el cual denomina “3R”, esta investigación tiene como problemática el poco porcentaje de reciclaje existente en la residencia además de la poca difusión que tiene esta práctica. La solución la cual propone para hacer frente a esa problemática se centra en la compraventa de material reciclable entre residentes y empresas recicladores, para su implementación utiliza Android Studio como entorno de desarrollo, los lenguajes de programación JavaScript y PHP para las conexiones web además de MySQL como base de datos.

Castro y Gonzales en [24], se centran en la problemática de la gestión de residuos sólidos en la localidad de Huarín, Huánuco, y aborda la falta de eficiencia en la recolección de residuos en la zona. El estudio se propone el desarrollo de un Sistema de Información Geográfica (SIG) para optimizar las rutas de recolección de residuos sólidos en la localidad. Esta herramienta realiza un análisis espacial y diseñar rutas eficientes para la recolección de residuos sólidos, abordando así la problemática existente. Los resultados obtenidos sirvieron como base para que las autoridades competentes tomen medidas concretas para abordar la falta de un plan de manejo de residuos sólidos en la zona y para mejorar la eficiencia en la recolección de residuos.

Para finalizar con los antecedentes nacionales, Chumbe, Nilson y Seudere [25], desarrollan una solución tecnológica para la optimización del programa de recolección de residuos sólidos reciclables en el Sector 1 de la Municipalidad de San Borja. Este programa enfrenta desafíos en términos de eficiencia y volumen de recolección, representando solo el 4.5% de los residuos sólidos recogidos en 2019. Utilizan la metodología basada en el modelo analítico de formulación estratégica de Fred David en conjunto con el mapa estratégico funcional (FSM) de Pérez-Franco para vincular las

estrategias con objetivos y actividades específicas. Esta investigación logró mejorar la gestión de residuos sólidos en la zona.

Antecedentes locales

Localmente, existe la solución propuesta por Torres [26], donde desarrolla una multiplataforma informática que busca apoyar a la gestión integral de residuos sólidos de distintas localidades pertenecientes a un proyecto universitario de la Universidad Católica Santo Toribio de Mogrovejo, la problemática en la cual se centra es la recolección empírica de residuos sólidos por parte de los recicladores, la falta de conocimiento para la separación de residuos sólidos y la falta de motivación para realizar actividades de reciclaje que tienen los pobladores. La multiplataforma que desarrolla se centra en la aplicación de algoritmos de optimización de rutas para agilizar la labor de recojo de los recicladores de la zona, así como la implementación de algunos elementos de gamificación como las recompensa por premios y puntos al usuario. Las tecnologías que utiliza para su desarrollo son el framework Ionic para el desarrollo de la aplicación, el lenguaje de programación PHP para la API REST y el gestor de base de datos MySQL. Los resultados que logran son la determinación del mejor algoritmo para la realidad problemática además de una validación positiva de los elementos gamificación y la usabilidad de su solución.

Vilcamango [27], describe la situación en el distrito de Santa Rosa, que enfrenta problemas relacionados con la disposición de residuos sólidos en un botadero sin las condiciones adecuadas. Se mencionan problemas de salud, impacto ambiental y la presencia de recicladores informales en el lugar. El proyecto de investigación diseña una infraestructura para el tratamiento y disposición final de los residuos sólidos en el distrito de Santa Rosa.

Finalizando con los antecedentes locales, Irigoín [28], aborda la problemática de la gestión inadecuada de los residuos sólidos urbanos en el distrito de Pucallá. El problema se caracteriza por la carencia de tecnología e infraestructura adecuada para el tratamiento y disposición final de estos residuos, lo que ha dado lugar a la existencia de vertederos a cielo abierto sin la debida supervisión. El objetivo fundamental de este estudio fue proponer un diseño de infraestructura que permita una gestión apropiada y una disposición final efectiva de los residuos sólidos en el mencionado distrito. Para lograr este propósito, se realizaron diversas actividades, como la inspección visual del vertedero de basura existente, la evaluación de terrenos para posibles ubicaciones

alternativas y el diseño de la infraestructura en áreas específicas, incluyendo un relleno sanitario, una zona de compostaje y un área de reciclaje. Como resultado; la investigación contribuyó a mitigar los impactos negativos en la salud pública y el medio ambiente de la comunidad.

Bases teórico-científicas

Inteligencia artificial

En el marco de esta investigación, que se centra en la clasificación de residuos sólidos, es fundamental comprender cómo la tecnología puede desempeñar un papel crucial en la resolución de desafíos ambientales. Desde que el informático John McCarthy acuñó por primera vez el término "IA" en 1956 [32], ha habido múltiples definiciones en constante evolución. Una de las definiciones más completas la proporciona [33], quien describe la IA como la disciplina científica que busca dotar a un sistema con la capacidad de actuar y razonar como lo haría un ser humano. En otras palabras, la IA se enfoca en desarrollar sistemas y algoritmos que pueden realizar tareas que, típicamente, requerirían inteligencia humana, como el aprendizaje, la toma de decisiones y la resolución de problemas. En este contexto, la IA es una herramienta prometedora para abordar eficazmente los desafíos de la clasificación de residuos sólidos y mejorar la gestión ambiental.

Sistema inteligente

Para abordar eficientemente y con precisión la clasificación de residuos sólidos es esencial contar con una solución que posea las habilidades cognitivas necesarias, como percepción, razonamiento y uso del lenguaje. En este contexto, un sistema inteligente se define como aquel que sigue principios de comportamiento basados en la racionalidad y tiene la capacidad de adaptarse mediante el aprendizaje [34].

Deep learning

En la investigación, fue necesario desarrollar un modelo de clasificación de residuos sólidos, y para lograr esto, se recurrió al Deep Learning, también conocido como aprendizaje profundo. El Deep Learning se basa en el aprendizaje a través de múltiples capas de datos y utiliza un modelo de redes neuronales artificiales [35]. Con esta tecnología, se pudo diseñar un modelo capaz de identificar y separar eficientemente los

diferentes tipos de residuos sólidos en función de sus características y composición, lo que resulta fundamental para abordar la problemática de la clasificación de residuos.

Redes neuronales artificiales

Para el desarrollo del modelo mencionado anteriormente, se utilizó la técnica de redes neuronales artificiales, que se inspira en el funcionamiento de las redes neuronales biológicas del ser humano [36]. Una red neuronal está compuesta y constituida por diferentes capas, las cuales replican la estructura jerárquica del cerebro humano [37]. Existen diferentes tipos de redes neuronales entre las principales tenemos a red neuronal prealimentada (FNN), redes neuronales recurrentes (RNN) y redes convolucionales (CNN), estas últimas utilizadas en el reconocimiento de patrones, segmentación de imágenes y detección de objetos [38], lo que las hace ideales para analizar y clasificar las imágenes de residuos sólidos en el Programa Institucional Integrador CISUSAT. Gracias a su capacidad para identificar patrones visuales en las imágenes, las CNN desempeñan un papel esencial en la automatización y precisión de la clasificación de residuos sólidos. En el contexto de esta investigación, se implementaron varias capas en la arquitectura de la red neuronal convolucional (CNN). Se incluyeron capas de regularización Dropout para evitar el sobreajuste, una capa de GlobalAveragePooling2D para reducir la complejidad del modelo, una capa de normalización de lotes para estabilizar el entrenamiento, capas densas para transformar las características y dos capas adicionales de Dropout. La última capa densa tiene un número de unidades igual al número de clases en el conjunto de datos y utiliza una función softmax para clasificar las imágenes según las probabilidades de pertenencia a cada clase. Estas capas se diseñaron para mejorar la capacidad de la red en la tarea de clasificación de residuos sólidos en imágenes.

Gamificación

Es esencial que el sistema inteligente sea capaz de motivar y guiar a los usuarios para que participen activamente en la clasificación de residuos. En este escenario, es necesario el uso de gamificación, el cual es el proceso de involucrar a usuarios a resolver problemas mediante el uso mecánicas y técnicas de juegos, es aplicable a cualquier problema que se pueda abordar mediante la influencia en la motivación y el comportamiento humano [39].

Elementos de gamificación

La implementación de elementos de gamificación en el sistema tiene como objetivo influir en la motivación y el comportamiento de las personas, incentivándolas a colaborar de manera efectiva en el proceso de clasificación de residuos y a utilizar la plataforma de manera activa. Zichermann y Cunningham [39] determinan tres componentes esenciales de la gamificación, las mecánicas de juego que son las herramientas utilizadas para crear juegos, las dinámicas de juego; la forma en la que los jugadores interactúan y la estética; el sentimiento del jugador durante la interacción. Por otra parte, nos mencionan siete elementos que pueden ser utilizados como mecánicas en un sistema basado en gamificación, los cuales son; puntos, niveles, tablas de clasificación, insignias, desafíos, incorporación y bucles de participación. La investigación se centra en la forma en que los usuarios interactúan con el sistema y en la utilización de puntos como elemento de gamificación para la clasificación de residuos sólidos.

Aplicación móvil

Para que los usuarios puedan interactuar con el sistema inteligente a través de sus dispositivos móviles, se optó por desarrollar una aplicación móvil. Una aplicación móvil es un software informático que ha sido desarrollado para ser ejecutado en dispositivos móviles [40].

Residuos sólidos

Los residuos sólidos son todas las sustancias o materiales que se encuentran en estado sólido, los cuales no tienen una utilidad directa y generalmente se tiene la intención de deshacerse de ellos [41]. En este sentido, los residuos sólidos se refieren a los materiales o sustancias en estado sólido que se generan en el programa institucional integrador CISUSAT y que necesitan ser clasificados de manera adecuada para su posterior gestión y disposición final.

Tipo de residuos

Existen diferentes tipos de residuos, los cuales son divididos por diversos factores, algunos de los más comunes son los descritos por [7]; los cuales son papel, cartón, plástico, residuos alimentarios, metal, vidrio y electrónicos. Se refieren por lo cual a las categorías en las que se clasifican los materiales sólidos generados en el programa institucional integrador CISUSA

Reciclaje

El reciclaje es el proceso recolección y procesamiento de residuos sólidos los cuales en un inicio iban a ser desechados, con el objetivo de reutilizarlos como nuevos productos, este proceso ayuda en la reducción de costos del desecho de residuos, así como reducir los impactos ambientales [7]. En este contexto, el reciclaje se refiere al proceso de recolección y procesamiento de residuos sólidos generados por los pueblos jóvenes participantes programa institucional integrador CISUSAT que inicialmente serían desechados. El objetivo del reciclaje es reutilizar estos materiales para la creación de nuevos productos, lo que contribuye a la reducción de costos de eliminación de residuos y a la disminución de los impactos ambientales asociados con su disposición.

Metodología de desarrollo de software

Para llevar a cabo el desarrollo del sistema inteligente, es esencial seguir una guía o conjunto de prácticas que orienten el proceso de creación y definan las tareas, fases, artefactos y sus relaciones. Una metodología de desarrollo de software es definida como la forma de trabajo que se sigue en el proceso de desarrollo de software esta especificará las tareas y fases a realizar, los artefactos a generar y la relaciones que tengan entre ellos [42].

SCRUM

Dado que esta investigación implica el desarrollo de un sistema inteligente con diferentes componentes para la clasificación de residuos sólidos, se eligió SCRUM como la metodología de desarrollo porque es eficaz en proyectos con requisitos cambiantes, lo que es relevante en este contexto en el que se aborda una solución tecnológica con múltiples componentes y características que pueden evolucionar a medida que se avanza en el proyecto. SCRUM es un marco que permite desarrollar, entregar y mantener productos complejos [43], como tal SCRUM no solo está ligado solo al software, sino que trabaja con cualquier tipo de proyecto. SCRUM trabaja en base a un conjunto de patrones en el proceso del software los cuales son eficaces para proyectos con requerimientos cambiantes [44], esta metodología será la utilizada para el desarrollo de la solución propuesta por lo que aspectos como sus fases serán descritas en el apartado de metodología de desarrollo.

Materiales y métodos

Tipo de investigación

La investigación aplicada consiste en desarrollar una idea en base a la profundización de conocimientos para la solución de un problema práctico específico [41], a partir de ello y puesto que la presente investigación implementó un sistema inteligente basado en deep learning y gamificación que apoye al proceso de clasificación de residuos, esta investigación es de tipo aplicada.

Métodos de investigación

La presente investigación empleará los métodos analítico y deductivo descritos por [42] además de los métodos de implementación y análisis de literatura [43], estos se describen y sustentan en la siguiente tabla:

TABLA I
MÉTODOS DE INVESTIGACIÓN

Método	Sustento por el cual será empleado en la investigación
Analítico	Se analizó la situación problemática correspondiente a la clasificación de residuos sólidos del programa institucional CIUSAT.
Análisis de literatura	Recopilación selectiva de antecedentes y fundamentos teóricos para contextualizar la formulación de la solución en relación al problema de investigación.
Deductivo	Para abordar la situación problemática se revisó estadística a nivel histórico mundial correspondiente a las prácticas del reciclaje, se inició dando un contexto mundial, luego se trabajó a nivel de región, nivel nacional finalizando en un contexto local.
Implementación	Se implementó el sistema inteligente basado en deep learning y gamificación.

Técnicas e instrumentos de recolección de datos

En la tabla siguiente se presentan las técnicas e instrumentos que resultaron efectivos en la recopilación de datos.

TABLA II
TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Técnica	Instrumento	Dirigido a	Sustento por el cual se empleará
Entrevista	Guía de entrevista y grabador de audio	Miembros de la asociación de recicladores	Recoger información acerca de los procesos y actores involucrados en la situación problemática.
Encuesta	Cuestionario	Vecinos y recicladores	Para verificar la usabilidad y utilidad

del sistema a
implementar.

Procedimientos

Metodología de desarrollo

El proyecto de desarrollo de un sistema inteligente de clasificación de residuos sólidos se basó en la metodología SCRUM, que permitió una adaptación ágil a las necesidades cambiantes y el aumento de la probabilidad de éxito. Las cinco fases de SCRUM [44], desde la visión inicial hasta el lanzamiento, se llevaron a cabo de manera efectiva. Se realizaron pruebas exhaustivas y se identificaron lecciones aprendidas. Para el desarrollo del modelo de Deep Learning, se siguió la Metodología Fundamental para la Ciencia de Datos de IBM [45], que consta de 10 etapas. Estas etapas se integraron en las fases de SCRUM, abarcando desde la comprensión del negocio hasta la implementación del modelo, con un enfoque en la mejora continua a través de la retroalimentación.

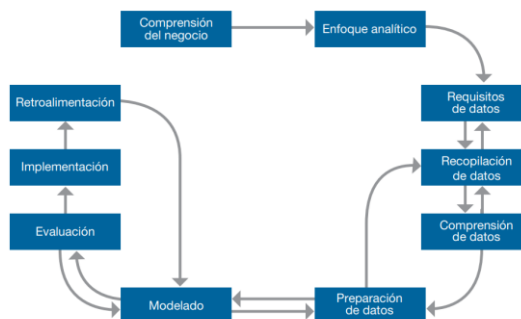


Fig. 1. Metodología Fundamental para la Ciencia de Datos – IBM [45]

Resultados y discusión

Para el desarrollo del modelo de Deep Learning se tuvo como base la Metodología Fundamental para la Ciencia de Datos propuesto por IBM [1], la cual consta de 10 etapas. Las cuáles serán detalladas a continuación:

Etapas 1: Comprensión del negocio

En la primera etapa de la Metodología Fundamental para la Ciencia de Datos de IBM, se abordó la comprensión del negocio y se establecieron los objetivos y requisitos del

proyecto. El problema identificado se relacionaba con la falta de compromiso de los pobladores, la falta de capacitación en educación ambiental y la escasez de recicladores activos en el pueblo Luis Alberto Sánchez, parte del programa CISUSAT. El objetivo principal del proyecto fue desarrollar un sistema inteligente basado en Deep Learning y gamificación para la clasificación de residuos sólidos en el programa CISUSAT, con el propósito de promover la participación de los pobladores y fortalecer el trabajo de los recicladores.

Etapa 2: Enfoque Analítico

Se definió el enfoque para abordar el problema de gestión de residuos sólidos en el programa CISUSAT. Se estableció que el problema se abordaría utilizando técnicas estadísticas y de aprendizaje profundo. Para clasificar los residuos sólidos en diferentes categorías, se llevó a cabo la selección de una red neuronal adecuada. Se presentó una tabla comparativa (Tabla IV) que analizó diferentes tipos de redes neuronales en función de varios criterios, como el número de capas, el optimizador utilizado, el número de épocas/iteraciones de entrenamiento, el nivel de rendimiento de predicción y el tipo de datos para los que son adecuados. Después de un análisis detallado de la tabla, se concluyó que la Red Neuronal Convolutiva (CNN) era la opción más adecuada para este proyecto. La elección se basó en el número variable de capas, el optimizador Adam, la cantidad de épocas/iteraciones necesarias, el alto rendimiento en predicción y su idoneidad para datos de imagen.

Tipo de red neuronal	Número de capas	Optimizador	Número de épocas	Nivel de predicción	Tipo de dato
Red neuronal convolutiva (CNN)	Varía según modelo	Adam	50-100	Alto	Datos de imagen
Red neuronal recurrente (RNN)	Varía según modelo	RMSprop	50-100	Medio	Datos de secuencia
Red neuronal convolutiva +	Varía según modelo	Adadelta	50-100	Alto	

recurrente (CRNN)					
Red neuronal de propagación hacia atrás (Backpropagation)	Varía según modelo	SGD	100-200	Bajo	Datos tabulares, datos de texto
Red neuronal de retroalimentación (Feedback)	Varía según modelo	Adagrad	100-200	Medio	Datos tabulares, datos de texto

Etapas 3: Requisitos de datos

Se definieron los requisitos de datos necesarios en función del enfoque analítico seleccionado para la clasificación de residuos sólidos en el modelo de Deep Learning. Estos requisitos de datos incluyeron:

- **Tipo de dato:** Se utilizaron imágenes como datos no estructurados.
- **Conjunto de datos etiquetados:** Se adquirió un conjunto de imágenes de residuos sólidos con etiquetas correspondientes que representaban las categorías de clasificación, que en este caso eran **7, incluyendo Aluminio, Cartón, Papel, Plástico, Residuos Orgánicos, Vidrio y No residuos sólidos.**
- **Datos de entrenamiento y validación:** Se realizó una partición adecuada del conjunto de datos en conjuntos de entrenamiento y validación para entrenar el modelo y evaluar su rendimiento durante el proceso de ajuste de parámetros.
- **Datos de prueba:** Se separó un conjunto independiente de datos de prueba para la evaluación final del modelo después de completar su entrenamiento.
- **Formato de imágenes:** Las imágenes se ajustaron a un formato específico, incluyendo una resolución de 256x256 píxeles y formatos compatibles como 'jpeg', 'jpg', 'bmp' y 'png', con un canal de color RGB (rojo, verde, azul).

- **Equilibrio de clases:** Se aseguró que cada categoría contara con al menos 300 imágenes para garantizar un equilibrio en la cantidad de datos por clase.
- **Etiquetado de imágenes:** Se realizó una revisión para verificar que las etiquetas de las imágenes fueran precisas y estuvieran correctamente asignadas a las categorías correspondientes (Aluminio, Cartón, Papel, Plástico, Residuos Orgánicos, Vidrio y No residuos sólidos).

Etapa 4: Recopilación de datos

Se utilizaron dos fuentes de información:

Fuente interna: Se recolectaron imágenes de manera personal y mediante colaboradores, principalmente residentes de las ciudades de Chiclayo y Lambayeque. Se creó un grupo de WhatsApp donde los colaboradores capturaron imágenes de las diferentes categorías de residuos sólidos requeridas para el modelo.

Fuente externa: Se extrajeron imágenes de Internet, combinando descargas de repositorios libres de derechos de autor y del conjunto de datos "Trashnet". Este último conjunto de datos contiene 2527 imágenes en diversas categorías, incluyendo vidrio, papel, cartón, plástico, metal y basura. Estos datos se adaptaron y clasificaron de acuerdo a las categorías específicas mencionadas en la etapa anterior, asegurando que fueran relevantes para la problemática en cuestión. En conjunto, se unificaron todas las imágenes recopiladas, tanto de fuentes internas como externas, en un único dataset que contenía un total de 4802 imágenes.

Etapa 5: Comprensión de datos

Se verificó la extensión de los archivos de cada etiqueta de imágenes para asegurarse de que fueran compatibles con el modelo. Además, se inspeccionaron las etiquetas o clases de datos en las carpetas correspondientes. Se verificó que la mayoría de las imágenes en cada categoría fueran del formato 'jpg', lo cual es necesario para el modelo. Finalmente, en esta etapa se identificaron imágenes con formatos incompatibles o dañados que no serían aceptados por el modelo. Estas imágenes se eliminaron como parte del proceso de preparación de datos, que se detallará en la siguiente etapa.

Etapa 6: Preparación de datos

Se realizaron diversas actividades para asegurar que los datos estuvieran listos antes del modelado:

Eliminación de imágenes dañadas o con formato incorrecto: Se identificaron imágenes que no estaban en formato válido o que estaban dañadas, y se procedió a

eliminarlas del conjunto de datos, lo que resultó en una reducción del conjunto de imágenes del 0.52%, pasando de 4,802 imágenes iniciales a 4,779 imágenes válidas.

```

for etiqueta in os.listdir(DIR): #Recorre la carpeta data
    for img in os.listdir(os.path.join(DIR,etiqueta)): #Recorre por etiquetas
        image_path = os.path.join(DIR,etiqueta,img) #Extrae la ruta de la imagen
        try:
            img = cv.imread(image_path) #Lee la imagen
            tip = imgndr.what(image_path) #Extrae el tipo
            if tip not in img_extension:
                print('Extensión de imagen no esta en lista {}'.format(image_path))
                os.remove(image_path)
        except:
            print('Problema con la imagen {}'.format(image_path))

```

Fig 10. Eliminación de imágenes dañadas.

Preprocesamiento de datos con aumento de datos: Se aplicó una técnica de aumento de datos para generar más imágenes a partir del conjunto de datos existente. Esta técnica ayudó a diversificar el conjunto de datos y mejorar la capacidad del modelo para generalizar.

Separación de datos: Se dividieron las imágenes en dos conjuntos principales:

Imágenes de entrenamiento: El 90% de las imágenes se utilizaron para el entrenamiento del modelo, con un tamaño de lote de 128 imágenes y un formato de 256x256 píxeles. Se utilizaron un total de 4,302 imágenes para el entrenamiento, abarcando las 7 categorías. La razón detrás de esta división es garantizar que el modelo se entrene en una gran cantidad de datos, lo que le permite aprender patrones y características relevantes.

Imágenes de validación: El 10% de las imágenes se reservaron para la validación del modelo. Se emplearon 477 imágenes en este conjunto, que también abarcaba las 7 categorías.

Etapas 7: Modelado

En la etapa de modelado, se implementó una arquitectura de red neuronal convolucional (CNN) utilizando MobileNetV3 Large como modelo base. Esta elección se basó en la eficiencia computacional y la precisión de la red. A este modelo se le añadieron las siguientes las capas del modelo:

- Capa base pre-entrenada: Se utilizó MobileNetV3 Large como base pre-entrenada.
- Capa de regularización: Se aplicó una capa de regularización de Dropout para reducir el sobreajuste.
- Capa para compresión: Se empleó una capa de GlobalAveragePooling2D para comprimir características y reducir el número de parámetros.

- Capa de normalización: Se incluyó una capa de normalización de lotes (BatchNormalization) para estabilizar el entrenamiento.
- Capa densa: Se añadió una capa densa con una función de activación Exponential Linear Unit (ELU).
- Capa adicional de regularización: Se implementaron dos capas de regularización de Dropout adicionales.
- Capa densa final: La última capa produce las probabilidades de pertenencia a cada clase para la clasificación.

```

Agregando capas convolucionales
last_output = baseModel.layers[-1].output #obtiene la última capa de la base del modelo
x = tf.keras.layers.Dropout(0.45)(last_output) # capa de regularización de dropout
x = tf.keras.layers.GlobalAveragePooling2D()(x) # comprimir aún más las características y reducir aún más el número de parámetros del modelo.
x = tf.keras.layers.BatchNormalization()(x) # Normalización
x = tf.keras.layers.Dense(256,
    activation=tf.keras.activations.elu,
    kernel_regularizer=tf.keras.regularizers.l1(0.045),
    activity_regularizer=tf.keras.regularizers.l1(0.045),
    kernel_initializer='he_normal')(x) #inicializa pesos con he_normal
x = tf.keras.layers.Dropout(0.45)(x) #otra capa de regularización para reducir el sobre ajuste
x = tf.keras.layers.Dense(numClasses, activation='softmax')(x) # Activador softmax para obtener las probabilidades de cada clase

```

Fig 16. Construcción de las capas del modelo.

El modelo se compila con el optimizador Adam y una función de pérdida de entropía cruzada categórica escasa. El entrenamiento se llevó a cabo durante 50 épocas/iteraciones, con ajustes en la tasa de aprendizaje a lo largo del proceso. Se proporcionan los resultados obtenidos durante el entrenamiento en términos de pérdida y exactitud para el conjunto de entrenamiento y validación. El modelo demostró un progreso constante y una mejora en su capacidad de clasificación a medida que avanzaba el entrenamiento.

TABLA V. Resultados obtenidos durante el entrenamiento.

Época	Pérdida de entrenamiento	Exactitud de entrenamiento	Pérdida de validación	Exactitud de validación
1	252.5249	0.5765	112.9063	0.8155
2	53.2256	0.8133	14.5021	0.7883
3	7.4204	0.7306	4.4895	0.6730
4	4.0565	0.6506	3.8654	0.5430
5	3.8450	0.6013	3.8101	0.5891
6	3.8158	0.6123	3.7602	0.5618
7	3.7870	0.6083	3.7034	0.4864
8	3.7438	0.6225	3.6325	0.5933
9	3.6810	0.6483	3.5448	0.6205

10	3.6247	0.6897	3.4984	0.6855
...
49	2.6346	0.9528	2.6483	0.9371
50	2.6321	0.9542	2.6121	0.9392

Etapa 8: Evaluación

Se realizaron las pruebas correspondientes al modelo, primeramente, se presenta el siguiente gráfico que muestra la evolución de la precisión del modelo, se presenta la evaluación en base las métricas de evaluación.

Métricas de evaluación

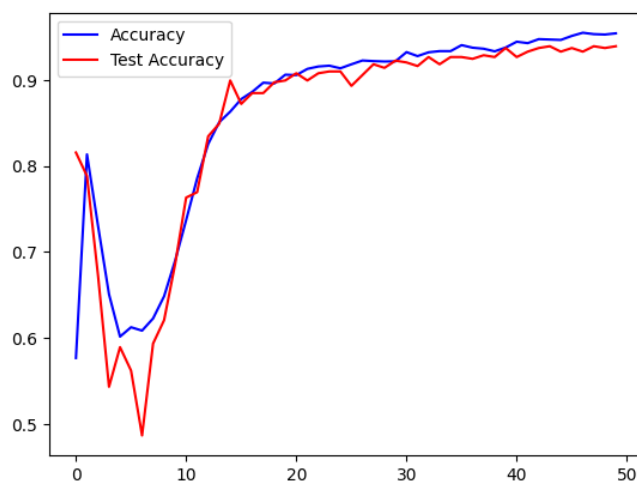


Fig 19. Evolución de la exactitud del modelo.

Se observa que en un inicio la precisión era baja, pero a partir de la época 10 a 20, sube exponencialmente, de la 20 hacia la 50 incrementa de una manera más constante.

```
[ ] from sklearn.metrics import accuracy_score, f1_score, precision_score, recall_score, confusion_matrix

# Obtén las etiquetas verdaderas (y_true) y las predicciones (y_pred) del conjunto de validación
y_true = []
y_pred = []
class_names = val_dataset.class_names
for images, labels in val_dataset:
    y_true.extend(labels.numpy())
    preds = model.predict(images)
    y_pred.extend(np.argmax(preds, axis=1))

# Calcular las métricas
# Calcula exactitud
accuracy = accuracy_score(y_true, y_pred)
misclass_accuracy = 1 - accuracy

# Calcula precision
precision = precision_score(y_true, y_pred, average='weighted')
misclass_precision = 1 - precision

# Calcula recall
recall = recall_score(y_true, y_pred, average='weighted')
misclass_recall = 1 - recall

# Imprimir las métricas
print("Exactitud: {:.2%} Pérdida: {:.2%}".format(accuracy, misclass_accuracy))
print("Precisión: {:.2%} Pérdida: {:.2%}".format(precision, misclass_precision))
print("Recall: {:.2%} Pérdida: {:.2%}".format(recall, misclass_recall))

4/4 [=====] - 0s 66ms/step
4/4 [=====] - 0s 52ms/step
4/4 [=====] - 0s 49ms/step
4/4 [=====] - 0s 44ms/step
4/4 [=====] - 0s 44ms/step
4/4 [=====] - 0s 43ms/step
4/4 [=====] - 0s 43ms/step
4/4 [=====] - 0s 44ms/step
4/4 [=====] - 0s 42ms/step
4/4 [=====] - 0s 43ms/step
1/1 [=====] - 0s 35ms/step
Exactitud: 96.79% Pérdida: 3.21%
Precisión: 96.89% Pérdida: 3.11%
Recall: 96.79% Pérdida: 3.21%
```

Fig 17. Evaluación del modelo en base a métricas.

En este código, se utiliza el conjunto de validación para evaluar el modelo después de entrenarlo. Se obtienen las etiquetas verdaderas y las predicciones correspondientes utilizando el modelo entrenado. Luego, se calculan tres métricas comunes para evaluar el desempeño del modelo: exactitud, precisión y recall.

La exactitud, es la proporción de predicciones correctas respecto al total de predicciones. Se muestra tanto la exactitud como su complemento, que es la pérdida de exactitud (`misclass_accuracy`), en este caso se obtuvo un valor de **96.79%** y **3.21%** correspondientemente.

La precisión, es la proporción de instancias clasificadas correctamente como positivas (verdaderos positivos) respecto al total de instancias clasificadas como positivas (verdaderos positivos + falsos positivos). Se muestra tanto la precisión como su complemento, que es la pérdida de precisión (`misclass_precision`), en este caso se obtuvo un valor de **96.89%** y **3.11%** correspondientemente.

El recall, es la proporción de instancias clasificadas correctamente como positivas (verdaderos positivos) respecto al total de instancias que realmente son positivas (verdaderos positivos + falsos negativos). Se muestra tanto el recall como su complemento, que es la pérdida de recall (`misclass_recall`), en este caso se obtuvo un valor de **96.79%** y **3.21%** correspondientemente.

Matriz de confusión

En base a los datos de entrenamiento con respecto a la clase "Aluminio", se clasificaron 223 correctamente mientras que 3 fueron clasificadas como "Papel", 10 como "Plástico" y 5 como "Vidrio"; de la clase cartón 183 se clasificaron correctamente mientras que 2 fueron clasificadas como "Papel" y 2 como "Plástico"; de la clase "No residuos sólidos" todos fueron correctamente clasificados; de la clase "Papel" 287 fueron correctamente clasificadas mientras que 2 fueron tomadas como "Plástico" y 1 una como "Papel"; de la clase residuos orgánicos todas fueron correctamente clasificadas, con respecto a "Vidrio" se clasificaron 235 correctamente, 2 se clasificó como "Aluminio", 1 como "Cartón", 1 como "Papel" y 11 como "Plástico".




Fig 20. Matriz de confusión del modelo

Según los datos proporcionados, podemos concluir que el modelo de clasificación ha tenido un buen desempeño en general. Sin embargo, se observan algunos errores de clasificación en ciertas clases. En particular, el modelo ha logrado clasificar correctamente la mayoría de las instancias en las clases "No residuos sólidos" y "Residuos orgánicos", lo cual es alentador. En cuanto a las clases "Aluminio", "Papel", "Plástico" y "Vidrio", se observan algunos errores de clasificación. Por ejemplo, se han clasificado incorrectamente algunas instancias de aluminio como papel, plástico y vidrio, y también se han cometido errores similares en las otras clases mencionadas. Estos errores podrían deberse a similitudes en las características visuales o estructurales entre algunas de las clases. Para mejorar el rendimiento del modelo, podría ser útil recopilar más datos de entrenamiento específicos para estas clases y realizar ajustes adicionales en el proceso de entrenamiento, como el uso de técnicas de aumento de datos.

Etapa 9: Implementación

En la etapa de Implementación, se llevaron a cabo dos componentes clave: la exportación del modelo y la creación de una API para la predicción de residuos sólidos. Primero, se exportó el modelo entrenado en un archivo denominado "modeloDRSV3.h5," que contiene tanto los pesos como la configuración del modelo. Luego, se creó una API utilizando Flask, que permite realizar predicciones sobre residuos sólidos. Esta API se integra con el modelo previamente exportado y proporciona resultados de clasificación en forma de las tres clases con mayor probabilidad. Esto se logra a través de una llamada POST a la API, como se muestra en la *figura 22*. La implementación de esta API es fundamental para que la aplicación móvil, que se desarrollará en la siguiente etapa, pueda interactuar con el modelo y realizar predicciones en tiempo real.

```

1 @app.route('/predict', methods=['POST'])
2 def success():
3     error = ''
4     target_img = os.path.join(os.getcwd(), 'static/images')
5     if (request.files):
6         print('ENTRO')
7         file = request.files['file']
8         print(file.filename)
9         if file and allowed_file(file.filename):
10            file.save(os.path.join(target_img, file.filename))
11            img_path = os.path.join(target_img, file.filename)
12            img = file.filename
13            class_result, prob_result = predict(img_path, model)
14            if class_result[0] == 'No residuo solido':
15                predictions = {
16                    "class1": "No se trata de un residuo solido",
17                    "class2": "",
18                    "class3": "",
19                    "prob1": prob_result[0],
20                    "prob2": 0,
21                    "prob3": 0,
22                }
23            else :
24                predictions = {
25                    "class1": class_result[0],
26                    "class2": class_result[1],
27                    "class3": class_result[2],
28                    "prob1": prob_result[0],

```

Fig 22. API de predicción del modelo.

Etapa 10: Retroalimentación

Se pretende una vez implementado en un ambiente real, los datos serán reajustados según la retroalimentación de los usuarios.

SCRUM

En el proceso de investigación, si bien se adoptó la metodología de IBM para la Ciencia de Datos como base para el desarrollo del modelo de deep learning, se reconoció la importancia de complementar esta metodología con el enfoque ágil de SCRUM para la definición de las necesidades de la aplicación móvil que integra dicho modelo. SCRUM permitió una gestión efectiva de los requerimientos y funcionalidades esenciales, y además facilitó la adaptación continua a las necesidades cambiantes del proyecto.

Desarrollo de Épicas

Las épicas representan las necesidades o requerimientos de alto nivel que el producto debe cumplir para lograr los objetivos del proyecto. Estas se derivaron de entrevistas realizadas y se pueden encontrar en los Anexos N°1 y N°2. A partir de esta información, se definieron los siguientes requerimientos funcionales y no funcionales:

Requerimientos Funcionales

- Se requería una interfaz atractiva y amigable para proporcionar una experiencia de usuario agradable.
- Era fundamental permitir el registro e inicio de sesión de recicladores y vecinos, lo que les proporcionaría acceso a sus funcionalidades respectivas.
- Los usuarios debían tener la capacidad de actualizar su información de perfil, incluyendo su nombre, dirección y preferencias de reciclaje.
- El sistema debía contar con la capacidad de detectar residuos sólidos, ya sea a través de la cámara del dispositivo o mediante la selección de imágenes desde el gestor de archivos.
- Las funcionalidades para la gestión de rutas de recolección de recicladores debían estar presentes, permitiéndoles planificar y organizar eficazmente su trabajo.
- Se requería que los vecinos pudieran verificar las rutas activas de recolección para poder preparar adecuadamente sus residuos y esperar al reciclador.
- Los recicladores debían tener la capacidad de entregar ecocoins como recompensa a los vecinos por su participación en el programa de reciclaje.
- Un componente esencial era la inclusión de una billetera digital que permitiera a los recicladores y vecinos gestionar sus ecocoins y realizar transacciones relacionadas con el programa de reciclaje.

Requerimientos No Funcionales

La arquitectura lógica del sistema involucraba el uso de un servidor de base de datos, la conexión a internet para operaciones específicas, un servidor web que servía como puente entre la base de datos y el sistema inteligente, una red neuronal para la clasificación de residuos sólidos y una API para la clasificación de residuos sólidos implementada en Python.

La infraestructura tecnológica del sistema se basó en una serie de lenguajes de programación, como Python, Flask y Kotlin, junto con herramientas de desarrollo, incluyendo Android Studio, Visual Studio Code y Google Colaboratory. Además, se aprovechó un servidor en la nube para alojar servicios web, APIs y la base de datos del sistema inteligente.

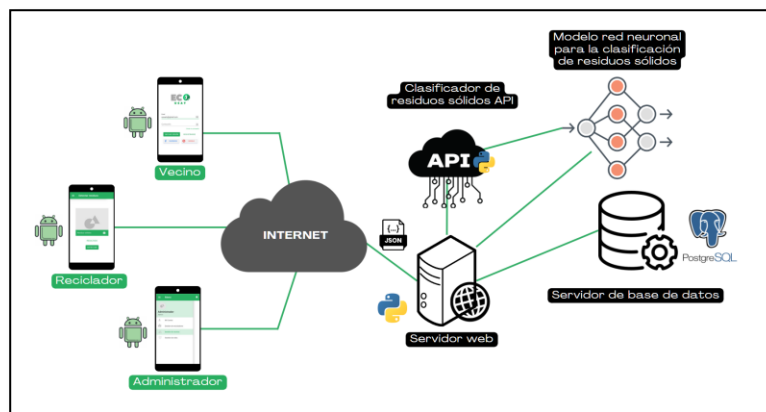


Fig 24. Arquitectura lógica del sistema inteligente

Discusión

En la investigación de Delnevo et al. [25], se destaca la aplicación web "ScanBage" como un enfoque eficaz para abordar la separación de residuos sólidos con elementos de gamificación, una estrategia similar a la aplicada en esta tesis. Sin embargo, es preciso resaltar las diferencias significativas. Esta tesis se centró en la utilización de algoritmos de aprendizaje profundo, específicamente las redes neuronales convolucionales (CNN), en contraste con las Máquinas de Soporte Vectorial (SVM) y otras técnicas empleadas en el estudio previo. Además, el modelo de clasificación de la presente tesis se entrenó con un conjunto de datos diverso, combinando el conjunto "Trashnet" con datos locales específicos relacionados con la problemática de los residuos sólidos en la localidad. Por otro lado, es crucial considerar se abordó la clasificación de siete categorías de residuos sólidos en comparación con las seis categorías del trabajo anterior.

En comparación con los enfoques de Vo et al. [26] y Mao et al. [27], que se centraron en la clasificación de residuos sólidos utilizando redes neuronales profundas específicas para la problemática de Asia y utilizaron conjuntos de datos y herramientas específicas como Pytorch, esta tesis presenta diferencias fundamentales en su planteamiento y diseño. Una distinción clave radica en la arquitectura del modelo neural implementado. En lugar de utilizar un enfoque de modelo base, como lo hicieron Vo et al. [26] y Mao

et al. [27], esta tesis desarrolla un modelo que incorpora varias capas específicas para optimizar su rendimiento. En primer lugar, se aplica una capa de regularización de Dropout con un valor del 45% para reducir el sobreajuste al desactivar aleatoriamente conexiones durante el entrenamiento. Posteriormente, se introduce una capa de GlobalAveragePooling2D para comprimir y simplificar las características, disminuyendo el número de parámetros del modelo al calcular el promedio de las características en cada mapa de características. La estabilización del proceso de entrenamiento se logra mediante la incorporación de una capa de normalización de lotes (BatchNormalization) que ajusta y normaliza las activaciones de la capa anterior. A continuación, se agrega una capa densa con 256 unidades y función de activación ELU, lo que permite una transformación lineal seguida de una activación no lineal en las características. Para mitigar aún más el riesgo de sobreajuste, se incluyen dos capas adicionales de regularización de Dropout. Finalmente, se incorpora una capa densa final con un número de unidades igual al número de clases en el conjunto de datos, y se aplica la función de activación softmax. Esto permite que el modelo genere las probabilidades de pertenencia a cada clase, lo que facilita su capacidad de clasificación. Además, es importante destacar que esta tesis no solo se limita a la evaluación del modelo desarrollado, sino que también se enfoca en su implementación práctica. Mientras que los otros estudios se centran en la evaluación de sus modelos, esta investigación va más allá al desplegar exitosamente el modelo desarrollado en un entorno real, el sistema inteligente como tal. Adicionalmente, en la construcción de este modelo, se aplicó una metodología específica que sigue los principios fundamentales de la ciencia de datos de IBM. Esta metodología proporciona un marco estructurado y eficaz para la creación y validación del modelo, asegurando que los pasos se realicen de manera sistemática y respaldando la fiabilidad y robustez de los resultados obtenidos.

Para finalizar, Torres [26] también tiene el objetivo de mejorar la gestión de residuos sólidos a nivel local. No obstante, se aborda la problemática de manera distinta. Mientras que el proyecto mencionado se centra en la recolección de residuos sólidos por parte de los recicladores y la falta de conocimiento sobre la separación de residuos en la comunidad, la presente tesis se enfoca en la clasificación precisa de los residuos sólidos a través de la inteligencia artificial. Principalmente la diferencia radica en la tecnología utilizada. La investigación en cuestión se vale de algoritmos de optimización de rutas para agilizar la labor de los recicladores. Por otro lado, esta tesis opta por el uso de redes neuronales convolucionales (CNN) como núcleo del sistema, lo que permite una

identificación precisa de los residuos sólidos a partir de imágenes. Además, en el proceso de desarrollo, se ha adoptado una metodología ágil como SCRUM en lugar de RUP, lo que agrega un enfoque más dinámico y adaptable a la gestión de proyectos. `

Conclusiones

1. Se logró determinar el tipo de red neuronal artificial más adecuado para el reconocimiento de patrones en imágenes de diversos tipos de residuos sólidos. A través del análisis de las características de los datos y una evaluación de diferentes modelos de redes neuronales, se ha identificado que la Convolutional Neural Network (CNN) se destaca como la opción óptima. Con relación a la matriz de confusión del modelo, se obtuvieron resultados sobresalientes en términos de verdaderos positivos. Cabe destacar que se lograron identificar correctamente el 100% de los casos en las categorías "No residuos sólidos" y "Residuos orgánicos". Asimismo, se obtuvieron altas tasas de verdaderos positivos en categorías como "Papel" (96.83%), "Cartón" (98.38%), "Aluminio" (98.58%), y "Vidrio" (95.49%).
2. Se construyó el modelo de clasificación, basado en una red neuronal convolucional y entrenado con imágenes representativas de los residuos locales. Se empleó MobileNetV3 como base y se adaptaron sus capas con 6 adiciones específicas para construir el modelo (2 de regularización, comprensión, normalización, 2 densas). Luego, se aplicó la tecnología de compresión, normalización y regularización para mejorar la eficacia. El proceso de entrenamiento se desarrolló durante 50 épocas/iteraciones, ajustando la tasa de aprendizaje. Los resultados reflejaron una mejora constante en la pérdida y la precisión en el conjunto de entrenamiento, con el modelo logrando una adecuada generalización en el conjunto de validación.
3. Se comprobó la confiabilidad del modelo desarrollado mediante la obtención de sus grados de precisión, exactitud y exhaustividad. Los resultados reflejan un alto desempeño del modelo, con una exactitud del 96.79%, una precisión del 96.89% y una exhaustividad del 96.79%. Estos porcentajes indican que el modelo tiene una alta capacidad de realizar clasificaciones precisas, minimizando tanto los falsos positivos como los falsos negativos. Estos resultados respaldan la robustez y eficacia del modelo en la clasificación de residuos sólidos basada en imágenes. `

4. El modelo de deep learning se desplegó de manera exitosa al ser exportado y alojado en una API desarrollada en Flask. Esta API se integró con una aplicación Android desarrollada en Kotlin, lo que culminó en la creación de un sistema inteligente completamente funcional e integrado listo para su uso por parte de los usuarios.
5. Finalmente, se evaluó la usabilidad del sistema inteligente, se obtuvo una alta utilidad percibida, destacando su capacidad para mejorar la participación en el programa de reciclaje y promover la conciencia ambiental. Además, se percibió como una herramienta motivadora para la participación activa en el programa.

Recomendaciones

1. Se recomienda explorar la posibilidad de desarrollar un módulo de aprendizaje específico para abordar la clasificación de nuevos tipos de residuos que puedan surgir en el futuro. Este proyecto se plantea como la base para futuras expansiones que agreguen funcionalidades adicionales a través de módulos específicos.
2. Para futuros proyectos de investigación, se sugiere explorar en mayor profundidad el potencial de la inteligencia artificial y el aprendizaje profundo en la clasificación de residuos sólidos, considerando el uso de arquitecturas de redes neuronales más avanzadas, como redes recurrentes o modelos de atención, para abordar desafíos específicos y mejorar la precisión en la clasificación de residuos.
3. Considerando la accesibilidad y la conveniencia para un público más amplio, se podría desarrollar una versión híbrida de la aplicación móvil. Esto permitiría que usuarios con dispositivos iOS y otros sistemas operativos también participen en la clasificación de residuos sólidos y contribuyan al éxito del programa CISUSAT.
4. Finalmente, para asegurar que los datos recopilados y las predicciones generadas sean utilizados eficazmente en la toma de decisiones ambientales, se propone la implementación de un sistema de reportes y seguimiento dedicado. Este sistema permitirá la recopilación, análisis y presentación regular de los datos relacionados con la clasificación de residuos sólidos y los patrones de comportamiento de los usuarios. A través de estos informes, las autoridades ambientales y los responsables de la gestión de residuos podrán evaluar de manera continua el impacto del sistema inteligente en la comunidad y tomar decisiones informadas.

Referencias

- [1] Y. Guillermina, "Impulsando la economía circular", *AENOR: Revista de la normalización y la certificación*, vol. 1, n.º 1, p. 29, 2016. [En línea]. Disponible: <https://www.aenorperu.com/revistaperu/Revista%20AENOR%20Perú%20nº1.pdf>
- [2] L. Jiménez, "Economía circular-espiral. opciones estratégicas desde el reciclaje al cambio sistémico", *Economía sin Fronteras*, vol. 1, n.º 1, p. 9, 2020.
- [3] F. María, "De una economía lineal a una circular, en el siglo XXI. análisis realizado en la sociedad mendocina, 2019.", Universidad Nacional de Cuyo, Mendoza, 2019. [En línea]. Disponible: https://bdigital.uncuyo.edu.ar/objetos_digitales/14316/falappa-fce.pdf
- [4] ELLEN MACARTHUR FOUNDATION, "From linear to circular Accelerating a proven concept", *Towards the Circular Economy*, pp. 22–35, 2013. [En línea]. Disponible: <https://unfccc.int/sites/default/files/resource/Circular%20economy%202.pdf>
- [5] A. H. Vo, L. Hoang Son, M. T. Vo and T. Le, "A Novel Framework for Trash Classification Using Deep Transfer Learning," en *IEEE Access*, vol. 7, pp. 178631-178639, 2019, doi: 10.1109/ACCESS.2019.2959033.
- [6] Cheema, S.M.; Hannan, A.; Pires, I.M. Smart Waste Management and Classification Systems Using Cutting Edge Approach. *Sustainability* 2022, 14, 10226. <https://doi.org/10.3390/su141610226>
- [7] Agencia de Protección Ambiental de los Estados Unidos, "Mejores prácticas para la gestión de los residuos sólidos: Una Guía para los responsables de la toma de decisiones en los países en vías de desarrollo", Oficina de Conservación y Recuperación de Recursos, 2020.
- [8] UNEP - UN Environment Programme. "Visual feature | beat plastic pollution". UNEP - UN Environment Programme. <https://www.unep.org/interactives/beat-plastic-pollution/> (accedido el 16 de septiembre de 2022).
- [9] Organisation for Economic Co-operation and Development. "Plastic pollution is growing relentlessly as waste management and recycling fall short, says OECD". OECD.org. <https://www.oecd.org/newsroom/plastic-pollution-is-growing-relentlessly-as-waste-management-and-recycling-fall-short.htm> (accedido el 23 de septiembre de 2022).
- [10] EPA - United States Environmental Protection Agency. "National overview: Facts and figures on materials, wastes and recycling | US EPA". US

- EPA. <https://www.epa.gov/facts-and-figures-about-materials-waste-and-recycling/national-overview-facts-and-figures-materials#recycling> (accedido el 16 de septiembre de 2022).
- [11] C. de Miguel, K. Martínez, M. Pereira y M. Kohout, "Economía circular en América Latina y el Caribe: Oportunidad para una recuperación transformadora", Comisión Económica para América Latina y el Caribe (CEPAL), Santiago, Documentos de Proyectos (LC/TS.2021/120), 2021. [En línea]. Disponible: https://repositorio.cepal.org/bitstream/handle/11362/47309/1/S2100423_es.pdf
- [12] J. Vadillo. "Reciclar: La palabra clave". Diario Oficial El Peruano | El Peruano. <https://elperuano.pe/noticia/106181-reciclar-la-palabra-clave#:~:text=Las%20cifras%20que%20maneja%20la,el%20país%20dejaron%20la%20recolección.> (accedido el 16 de septiembre de 2022).
- [13] Ministerio del Ambiente - MINAM. "Lambayeque: Estadísticas ambientales, Diciembre 2021". SINIA | Sistema Nacional de Información Ambiental. <https://sinia.minam.gob.pe/documentos/lambayeque-reporte-estadistico-departamental-diciembre-2021> (accedido el 16 de septiembre de 2022).
- [14] "Mejora de limpieza y recolección de residuos sólidos se debe al incremento de la flota vehicular". Munichiclayo.gob.pe. <https://www.munichiclayo.gob.pe/portalcix/Noticia/MEJORA-DE-LIMPIEZA-Y-RECOLECCION-DE-RESIDUOS-SOLIDOS-SE-DEBE-AL-INCREMENTO-DE-LA-FLOTA-VEHICULAR/M3JyME9XQWZqVHBLK0U5bGEwQ29iQT09/> (accedido el 3 de octubre de 2022).
- [15] A. Melo, "Problemática ambiental por mal manejo de residuos sólidos domésticos en el municipio de Galapa". [En línea]. Disponible: <https://www.aidisnet.org/wp-content/uploads/2019/07/463-Colombia-oral.pdf>
- [16] S. Patrick, "Promoting a just transition to an inclusive circular economy", *Chatham House*, p. 16, 2020.
- [17] «Gestión del Conocimiento», Recíclame. <https://reciclame.org/gestion-del-conocimiento/> (accedido 2 de junio de 2022).
- [18] FOVIDA, "SEGREGACIÓN DE RESIDUOS SÓLIDOS y CAMBIO CLIMÁTICO", Fovida, p. 12, 2018.

- [19] ACNUR Comité Español. "¿Cuáles son las consecuencias de no reciclar? - ACNUR". ACNUR. https://eacnur.org/blog/cuales-las-consecuencias-no-reciclar-tc_alt45664n_o_pstn_o_pst/ (accedido el 20 de septiembre de 2022).
- [20] "A circular economy approach for lifecycles of products and services". CIRC4Life. <https://www.circ4life.eu/> (accedido el 18 de septiembre de 2022).
- [21] Huang, H.; Su, D.; Peng, W.; Wu, Y. Development of a mobile application system for eco-accounting. *Sustainability* 2020, 12, 9675.
- [22] Peng W. Y Su. D. Novel ICT System for Recycling and Eco-Shopping 2022, 14,7687
- [23] L. Valderrama, "Implementación de un aplicativo móvil sobre compraventa para automatizar el reciclaje en la urbanización La Capullana – Surco", Universidad San Ignacio de Loyola, 2018.
- [24] L. Castro y D. Gonzales, "Optimización de rutas para recolección de los residuos sólidos domiciliarios utilizando herramienta SIG en la localidad de Huarín, 2022.", Universidad San Ignacio Loyola, Lima, 2022.
- [25] J. Chumbe, O. Nilson y J. Seudere, "Propuesta para optimizar la gestión de residuos sólidos reciclables de la municipalidad de San Borja", Universidad Del Pacífico, Lima, 2022.
- [26] A. Torres, "Implementación de multiplataforma informática aplicada a la gestión integral de residuos sólidos del programa PROGRESO de responsabilidad social universitaria USAT", Universidad Católica Santo Toribio De Mogrovejo, Chiclayo, 2022.
- [27] S. Vilcamango, "Diseño de la infraestructura de disposición final de residuos sólidos del distrito de Santa Rosa, Chiclayo- Lambayeque-2020", Universidad Católica Santo Toribio De Mogrovejo, Chiclayo, 2022.
- [28] J. Irigoín, "Diseño de infraestructura para el manejo y disposición final de residuos sólidos para el distrito de Pucalá-Chiclayo-Lambayeque", Universidad Católica Santo Toribio De Mogrovejo, Chiclayo, 2022.
- [29] G. Delnevo, G. Aguzzi, S. Letizi, M. Luffarelli, A. Petreti, y S. Mirri, «Encouraging users in waste sorting using deep neural networks and gamification», *Proceedings of the Conference on Information Technology for Social Good*. ACM, 2021. doi: 10.1145/3462203.3477056.
- [30] A. H. Vo, L. Hoang Son, M. T. Vo and T. Le, «A Novel Framework for Trash Classification Using Deep Transfer Learning», in *IEEE Access*, vol. 7, pp. 178631-178639, 2019, doi: 10.1109/ACCESS.2019.2959033.

- [31] W.-L. Mao, W.-C. Chen, C.-T. Wang, y Y.-H. Lin, «Recycling waste classification using optimized convolutional neural network», *Resources, Conservation and Recycling*, vol. 164. Elsevier BV, p. 105132, 2021. Doi: [10.1016/j.resconrec.2020.105132](https://doi.org/10.1016/j.resconrec.2020.105132).
- [32] M. McHugh, «Artificial Intelligence, » de *Encyclopedia of Nursing Research*, New York, Springer Publishing Compan, 2006, pp. 22-24.
- [33] S. Russell y P. Norvig, *Artificial Intelligence A Modern Approach*, 4th ed., Hoboken: Pearson Education, 2021, pp. 31-37.
- [34] M. Molina, "What is an intelligent system?", Dept. of Artificial Intelligence, Universidad Politécnica de Madrid, pp. 1–7, 2022. Doi: <https://doi.org/10.48550/arXiv.2009.09083>
- [35] F. Chollet, *Deep Learning With Python*. Manning Publications, 2017.
- [36] X. Basogain, *Redes Neuronales Artificiales Y Sus Aplicaciones*. Bilbao: Dpto. Ingeniería de Sistemas y Automática.
- [37] P. Larrañaga, I. Inza y A. Moujahid, "Tema 8. Redes Neuronales". Bilbao: Departamento de Ciencias de la Computación e Inteligencia Artificial, pp. 1–4.
- [38] J. Schmidhuber, "Deep Learning in Neural Networks: An Overview", Technical Report IDSIA, 2014. Doi: <https://arxiv.org/pdf/1404.7828.pdf>
- [39] G. Zichermann y C. Cunningham, *Gamification by design: Implementing game mechanics in web and mobile apps*. Sebastopol, Calif: O'Reilly Media, 2011.
- [40] Open-Xchange GmbH, *Guía a la galaxia de aplicaciones móviles*, 17a ed. Olpe: Olper Hütte 5f, 2017.
- [41] Instituto Nacional de Estadística e Informática, "Acceso a los servicios básicos en el Perú, 2013 - 2019", 2020, Lima, Perú. [En línea]. Disponible: https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1756/
- [42] G. Pantaleo y L. Rinaudo, *Ingeniería de software*. Buenos Aires: Alfaomega Grupo Editor, 2015.
- [43] K. Schwaber y J. Sutherland, *La Guía Definitiva de Scrum: Las Reglas del Juego*. 2020. [En línea]. Disponible: <https://scrumguides.org/docs/scrumguide/v2020/2020-Scrum-Guide-Spanish-Latin-South-American.pdf>
- [44] R. S. Pressman, *Ingeniería del Software - Un Enfoque Práctico 5b: Edición*. McGraw-Hill Companies, 2002.
- [45] *Manual de Frascati 2015*. OECD, 2018. Accedido el 21 de octubre de 2022. [En línea]. Disponible: <https://doi.org/10.1787/9789264310681-es>

- [46] C. Bernal, Metodología de la investigación: administración, economía, humanidades y ciencias sociales - 3. edición. Pearson Education, 2010.
- [47] M. Berndtsson, J. Hansson, B. Olsson y B. Lundell, Thesis projects: A guide for students in computer science and information systems, 2a ed. London: Springer, 2008.
- [48] SCRUMstudy. "Scrum Phases and Processes". SCRUMstudy. <https://www.scrumstudy.com/whyscrum/scrum-phases-and-processes>.
- [49] J. Rollins, Metodología Fundamental para la Ciencia de Datos. New York: IBM Analytics, 2015. [En línea]. Disponible: <https://www.ibm.com/downloads/cas/WKK9DX51>
- [50] Palletsprojects. "Flask". Pallets. [En línea]. Disponible: <https://palletsprojects.com/p/flask/>

Anexos

ANEXO N° 1 GUÍA DE ENTREVISTA

	Cód_Doc	GE_01
Fecha	01/10/2022	Diseñado por:
de		Jordan Vásquez Fernández
diseño:		
Nombre	del	Guía de entrevista para levantamiento de información
documento:		
Objetivo:		Proporcionar un conjunto estructurado de preguntas y temas a abordar durante una entrevista con la asociación de recicladores que colaboró con el proyecto de investigación CISUSAT. Esta guía tiene como finalidad recopilar información valiosa sobre las experiencias, desafíos, procesos y necesidades de la asociación de recicladores, lo que permitirá comprender su perspectiva y mejorar el diseño y la implementación del sistema inteligente
Organización		Asociación de recicladores
Participantes:		
Nombre		Blanca Cueva Martínez
Cargo	del	Presidenta de la asociación de recicladores
participante		
Nombre		Juventino Llacsahuanga Calderón
Cargo	del	Miembro de la asociación de recicladores
participante		
Preguntas	Respuestas	
1. Situación actual		Asociación de recicladores con 10 miembros, de los cuales solo 5 están activos y 3 se han unido recientemente. La pandemia interrumpió las capacitaciones sobre la clasificación de residuos sólidos y provocó que los residentes entreguen sus desechos de manera inadecuada, incluso mezclados con otros desechos. Como resultado, el proceso de clasificación, separación y selección se realiza manualmente por los recicladores, siendo una tarea laboriosa condicionada por la frecuencia y el volumen de los materiales recolectados. La presidenta de la asociación enfatiza que la etapa más ardua es la separación de residuos, y la

	<p>mayoría de los recicladores son personas de la tercera edad. Además, menciona que muchos vecinos no están empadronados y no siguen el cronograma de entrega, lo que agrega tiempo al proceso de recolección. También, se enfrenta al desafío de contar con un número limitado de recicladores formales en la zona.</p>
2. Impacto de la pandemia	<p>La pandemia interrumpió las capacitaciones sobre la clasificación de residuos sólidos y provocó que los residentes entreguen sus desechos de manera inadecuada, incluso mezclados con otros desechos. Esto afectó significativamente la práctica del reciclaje en la localidad.</p>
3. Frecuencia y volumen	<p>La frecuencia y el volumen de materiales recolectados varían según si la recolección se realiza en un solo día o durante un período de 3 a 4 días. En el primer caso, la tarea puede durar de 2 a 3 horas, mientras que en el segundo, puede extenderse hasta 3 días de trabajo con jornadas de 2 a 3 horas diarias.</p>
4. Proceso de separación	<p>El proceso de separación de residuos se realiza de forma manual por parte de los recicladores. Esta etapa es considerada la más ardua de su labor.</p>
5. Desafíos significativos	<p>Los desafíos más significativos incluyen la falta de capacitación durante la pandemia, la entrega inadecuada de residuos por parte de los residentes, la exposición potencial a enfermedades debido a la edad de los recicladores, la falta de empadronamiento de algunos vecinos y la limitada participación de recicladores formales en la zona.</p>
6. Impacto de la edad y salud	<p>La edad de la mayoría de los recicladores implica una exposición potencial a diversas enfermedades durante el proceso de separación de residuos, lo que pone en riesgo su salud.</p>
7. Estrategias de mejora	<p>Es necesario implementar estrategias que fomenten la incorporación de más personas a la asociación y la participación de voluntarios que puedan brindar apoyo tanto en las labores físicas como en la concienciación sobre la práctica del reciclaje.</p>



ANEXO N° 2 FICHA DE OBSERVACIÓN

	Cód_Doc	FO_01
Fecha de 2/10/2022	Diseñado por:	Jordan Vásquez Fernández
diseño:		
Fecha de la 3/10/2022	Hora de Inicio - Hora de 2 p.m. 5p.m.	
Observación	Finalización	
Nombre del Ficha de observación		
documento:		
Objetivo:	Registrar y documentar observaciones y datos relevantes relacionados con la participación y actividades de la Localidad Luis Alberto Sánchez en el Programa Institucional de Ciudad Sustentable, Saludable, Ambiental y Territorial (CISUSAT) en Chiclayo, Perú, durante el período de observación especificado.	
Lugar de la Localidad Luis Alberto Sánchez, participante del Programa Institucional de Ciudad		
Observación	Sustentable, Saludable, Ambiental y Territorial (CISUSAT) en Chiclayo, Perú	

Aspectos Observados	Descripción de la Observación
1. Recolección de Residuos	Durante la observación se pudo constatar que los recicladores realizan la recolección de residuos sólidos en la localidad. Se recolectaron diferentes tipos de residuos, incluyendo papel, cartón, plástico y vidrio.
2. Clasificación de Residuos	Los recicladores llevan a cabo la clasificación de los residuos sólidos de forma manual. Esto implica separar los materiales recogidos en diferentes categorías, como papel, cartón, plástico y vidrio. La separación se realiza en función de la naturaleza de los materiales y su posible valor para el reciclaje.
3. Participación de Residentes	Se observó que algunos residentes entregaron sus residuos de manera adecuada, separando los diferentes tipos de materiales. Sin embargo, también se observó que algunos entregaron sus desechos de forma inadecuada, mezclando diferentes tipos de materiales en una sola bolsa o contenedor.
4. Exposición de Recicladores	Se notó que la mayoría de los recicladores son personas de la tercera edad. Durante el proceso de separación de residuos, están expuestos

potencialmente a diversas enfermedades debido a su edad y la naturaleza del trabajo.

5. Empadronamiento de Vecinos Se pudo constatar que no todos los residentes de la localidad están empadronados en el programa de reciclaje. Esto sugiere que existe una falta de participación de algunos vecinos en las prácticas de reciclaje.

6. Número de Recicladores Formales Durante la observación, se confirmó que la zona cuenta con un número limitado de recicladores formales en la asociación.

Conclusiones de la Observación

Durante la observación, se observó que los recicladores realizan la recolección y clasificación de residuos sólidos en la localidad Luis Alberto Sánchez, como parte del Programa Institucional de Ciudad Sustentable, Saludable, Ambiental y Territorial (CISUSAT). Se notó una participación variada de los residentes, con algunos entregando sus residuos de manera adecuada y otros de forma inadecuada. La mayoría de los recicladores son personas de la tercera edad, lo que los expone a riesgos para su salud durante la separación de residuos. Además, se identificó una falta de empadronamiento de algunos vecinos en el programa de reciclaje y un número limitado de recicladores formales en la zona. Estos hallazgos respaldan la necesidad de implementar estrategias para mejorar la práctica del reciclaje en la localidad, fomentar la participación de más personas y concienciar sobre su importancia.

**ANEXO N° 3 ENCUESTA DE INVESTIGACIÓN: MODELO DE ACEPTACIÓN
TECNOLOÓGICA TAM**

Objetivo: Validar el sistema inteligente con respecto a los criterios de utilidad percibida por los usuarios.

Encuesta de Utilidad Percibida:

Leyenda para Utilidad Percibida:

Puntuación	Descripción
1	Muy baja utilidad percibida
2	Baja utilidad percibida
3	Utilidad percibida moderada
4	Alta utilidad percibida
5	Muy alta utilidad percibida

Cuestionario

Por favor marque con una [X] según corresponda.

Pregunta	Puntuación				
	1	2	3	4	5
1. ¿Consideras que la aplicación EcoUsat te ayuda a mejorar tu participación en el programa de reciclaje?					
2. ¿Crees que la aplicación EcoUsat te brinda beneficios significativos al utilizarla para clasificar tus residuos sólidos?					
3. ¿Piensas que la aplicación EcoUsat es una herramienta útil para promover la conciencia ambiental y la sostenibilidad?					
4. ¿Consideras que el uso de la aplicación EcoUsat te ayuda a tomar decisiones más informadas sobre la clasificación de residuos sólidos?					
5. ¿Sientes que la aplicación EcoUsat te motiva y te incentiva a seguir participando activamente en el programa de reciclaje?					

6. ¿Consideras que la función de detección de residuos sólidos de la aplicación EcoUsat es precisa y confiable?

Encuesta de Facilidad de Uso Percibida:

Objetivo: Validar el sistema inteligente con respecto a los criterios de usabilidad percibida por los usuarios.

Leyenda para Facilidad de Uso Percibida:

Puntuación	Descripción
1	Muy difícil de usar
2	Difícil de usar
3	Uso moderadamente fácil
4	Fácil de usar
5	Muy fácil de usar

Cuestionario

Por favor marque con una [X] según corresponda.

Pregunta	Puntuación				
	1	2	3	4	5
1. ¿Consideras que la aplicación EcoUsat es difícil de usar?					
2. ¿Encuentras que la aplicación EcoUsat requiere mucho esfuerzo y tiempo para aprender a utilizarla?					
3. ¿Crees que la interfaz de la aplicación EcoUsat es intuitiva y fácil de navegar?					
4. ¿Piensas que las funcionalidades y características de la aplicación EcoUsat son fáciles de entender y utilizar?					
5. ¿Consideras que la aplicación EcoUsat te permite realizar las tareas de clasificación de residuos sólidos de manera rápida y eficiente?					

6. ¿Sientes que la aplicación EcoUsat te proporciona suficiente ayuda y guía durante su uso?

ANEXO N° 4 PRESUPUESTO DEL PROYECTO DE TESIS***Presupuesto del producto acreditable***

TABLA III
PRESUPUESTO DEL PRODUCTO ACREDITABLE

PARTE PRESUP.	DESCRIPCIÓN	CANT.	UNIDAD DE MEDIDA	PRECIO UNITARIO (S/.)	PRECIO TOTAL (S/.)	SUBTOTAL (S/.)
2.3	BIENES Y SERVICIOS					2005.00
2.3.22	SERVICIOS BASICOS, COMUNICACIONES, PUBLICIDAD Y DIFUSION					
2.3.22.1	SERVICIOS DE ENERGIA ELECTRICA, AGUA Y GAS					840.00
2.33.22.1.1	Servicio de suministro de energía eléctrica	12	MENSUAL	50.00	600.00	
2.33.22.1.2	Servicio de agua	12	MENSUAL	20.00	240.00	
2.3.22.2	SERVICIOS DE TELEFONÍA E INTERNET					840.00
2.33.22.2.3	Servicio de internet	12	MENSUAL	70.00	840.00	
2.3.15	MATERIALES Y ÚTILES					325.00
2.3.15.1	DE OFICINA					
2.3.15.1.1	Papelera en general, útiles y materiales de oficina	1	GLOBAL	300.00	300.00	
2.13.15.5	OTROS					
2.13.15.5.1	Carta de presentación	1	UNIDAD	25.00	25.00	
2.3.21	VIAJES					200.0
2.3.21.2	VIAJES DOMÉSTICOS					
	Pasajes y gastos de transporte	1	GLOBAL	200.00	200.00	
TOTAL, PRESUPUESTO DEL PROUCTO ACREDITABLE						2205.00

Presupuesto tecnológico

TABLA V
PRESUPUESTO TECNOLÓGICO


PARTE PRESUP.	DESCRIPCIÓN	CANT.	UNIDAD DE MEDIDA	PRECIO UNITARIO (S/.)	PRECIO TOTAL (S/.)	SUBTOTAL (S/.)
2.6.32.3	ADQUISICION DE EQUIPOS INFORMATICOS Y DE COMUNICACIONES					3,200.00
2.6.32.3.1	Equipos computacionales y periféricos	1	UNIDAD	3,000.00	3,000.00	
2.6.32.3.3	Equipos de telecomunicaciones	1	GLOBAL	200.00	200.00	
2.6.61.3	ACTIVOS INTANGIBLES					1200.00
2.6.61.3.1	Patentes y marcas de fabrica	1	GLOBAL	1200.00	1200.00	
2.3.27.3	SERVICIO DE CAPACITACION Y PERFECCIONAMIENTO					50.00
2.3.27.3.1	Capacitación del uso del sistema inteligente	1	UNIDAD	50.00	50.00	
TOTAL, PRESUPUESTO TECNOLÓGICO						4450.00

Resumen presupuestalTABLA VI
RESUMEN PRESUPUESTAL

ITEM	DESCRIPCIÓN PRESUPUESTO	SUBTOTAL (S/.)
1	TOTAL PRESUPUESTO DEL PRODUCTO ACREDITABLE	2205.00
2	TOTAL PRESUPUESTO TECNOLÓGICO	4450.00
	TOTAL PRESUPUESTO	S/. 6655.00

ANEXO N° 5 DESCRIPCIÓN REALIDAD PROBLEMÁTICA

SITUACIÓN PROBLEMÁTICA



PUEBLOS JÓVENES PARTICIPANTES DEL PROGRAMA CISUSAT



ANEXO N° 06. MANUAL DE USUARIO

Link del manual:

[ECO USAT MANUAL \(CANVA.COM\)](#)