

DESAROLLO DE UNA APLICACIÓN WEB PARA LA CLASIFICACIÓN DE RESIDUOS A TRAVÉS DE UN MODELO DE MACHINE LEARNING

Autor

Juan Camilo Fandiño Orjuela

Director

Diana Paola Figueroa Hernández



Universidad EAN

Facultad de Ingeniería

Proyecto de Grado

Bogotá, Colombia

2022

TABLA DE CONTENIDO

1. RESUMEN EJECUTIVO.....	6
2. INTRODUCCIÓN.....	7
3. OBJETIVOS.....	8
3.1. Objetivo General	8
3.2. Objetivos Específicos.....	8
4. PROBLEMA DE INVESTIGACIÓN	9
5. JUSTIFICACIÓN	11
6. MARCO TEÓRICO	12
6.1. Antecedentes	12
6.1.1. Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network	12
6.1.2. Waste Management System Using IoT Based Machine Learning in University	12
6.2. Inteligencia Artificial	13
6.2.1. Machine Learning	13
6.2.2. Tareas de clasificación	15
6.3. Redes Neuronales Artificiales	16
6.3.1. Redes Neuronales Concurrentes.....	17
6.3.2. Redes Neuronales Convolucionales	17
6.3.3. Métricas de rendimiento	18
6.4. Residuos sólidos urbanos.....	19
7. MARCO LEGAL	21
7.1. Resolución 2184 de 2019	21
7.2. Resolución 1407 de 2018	21
7.3. IEEE 1074: Estándar para desarrollar un proceso del ciclo de vida de un proyecto de software	22
8. ANÁLISIS DE REQUIRIMIENTOS.....	23
8.1. Requisitos Funcionales.....	23

8.2. Requisitos No Funcionales.....	26
9. ANÁLISIS DE RESTRICCIONES	28
9.1. Económicas	28
9.2. Legales	28
9.3. Ciberseguridad	28
9.4. Socioculturales	29
9.5. Éticas	29
10. METODOLOGÍA PARA LA SELECCIÓN Y DESARROLLO DE LA SOLUCIÓN	30
10.1. Selección del enfoque y “Brainstorming”	30
10.2. Revisión de antecedentes	31
10.3. Tecnologías propuestas	31
10.4. Interfaz de usuario (UI) y Experiencia de usuario (UX)	33
11. ANÁLISIS DE COSTOS	35
11.1. Costos directos	35
11.2. Costos fijos	35
11.3. Gastos generales	36
11.4. Costos totales	36
12. CONCLUSIONES.....	38
13. REFERENCIAS	40

LISTA DE FIGURAS

Figura 1 Neurona biológica en comparación con una red neuronal artificial.....	16
Figura 2 Red neuronal recurrente simple.....	17
Figura 3 Procedimiento de una CNN bidimensional	18
Figura 4 Matriz de Confusión	19
Figura 5 Composición de la basura.....	20
Figura 6 Landing page	33
Figura 7 Pagina de inicia de sesión y registro.....	34

LISTA DE TABLAS

Tabla 1. Ideas consideradas.....	31
Tabla 2. Tech Stack.....	32
Tabla 3. Costos directos	35
Tabla 4. Costos fijos.....	36
Tabla 5. Gastos generales.....	36
Tabla 6. Costos totales	36

1. RESUMEN EJECUTIVO

El presente proyecto tiene como objetivo el diseño e implementación de una aplicación web para la clasificación de desechos sólidos a través del uso de un modelo de machine learning. Esto con el propósito de contribuir desde el área de las ciencias de la computación a problemáticas ambientales entre las que se encuentran la acumulación de desechos, la sobreexplotación de los recursos naturales y la contaminación de fuentes hídricas.

La principal herramienta tecnológica utilizada es la biblioteca de aprendizaje automático “Tensorflow” la cual permite el entrenamiento de redes neuronales convolucionales, tipo de red neuronal que cuenta con un excelente desempeño en problemas de aprendizaje automático y especialmente en tareas de clasificación de imágenes (Albawi et al., 2018).

Este aplicativo web está pensado para ser utilizado por el público en general dado que no requiere un nivel de conocimiento técnico especializado por lo que su único requisito es ser ejecutado por un dispositivo móvil reciente que cuente con conexión a internet y cámara.

El presente trabajo comprende el diseño de la página web, el desarrollo del modelo de machine learning y la descripción del procedimiento para la publicación del proyecto en un alojamiento web.

2. INTRODUCCIÓN

La clasificación de residuos es un paso fundamental dentro del proceso del reciclaje pues permite distinguir entre los distintos tipos de desechos cuales son susceptibles de ser reciclados y cuáles no. Ahora bien, aunque el reciclaje es fundamental para combatir con una de las principales problemáticas de la sociedad moderna, la cual es la generación de grandes cantidades de residuos sólidos (Ciuta et al., 2015). En Colombia los ciudadanos poseen hábitos inadecuados en materia ambiental, un ejemplo de ello es que las personas arrojan residuos sólidos a espacios públicos, sin tener en cuenta sus implicaciones ambientales y sanitarias. Así mismo, de acuerdo con (Ramírez Hernández, 2015) en Colombia no existe una "cultura del reciclaje", lo que impide que se haga una separación en la fuente y, por lo tanto, un aprovechamiento de los residuos.

Por tal razón, desde el área de la ingeniería de sistemas se plantea el diseño e implementación de una herramienta que permita facilitar y promover el reciclaje, específicamente en la etapa de clasificación de residuos. Para tal efecto, se hará uso de machine learning, el cual comprende una serie de algoritmos computacionales diseñados para emular la inteligencia humana aprendiendo del entorno circundante (el Naqa & Murphy, 2015). De esta manera, se entrenará al algoritmo para que aprenda a diferenciar entre distintos tipos de desechos y de esta forma, a través de una interfaz gráfica alojada en un aplicativo web, permita ayudar a los usuarios en la clasificación correcta de los residuos.

Cabe destacar que el modelo de inteligencia artificial recibirá como argumento de entrada la imagen en tiempo real del tipo del desecho que buscará ser clasificado y le proporcionará al usuario la retroalimentación necesaria para que conozca en donde depositar dicho residuo, esto teniendo en cuenta la normativa colombiana vigente la cual ha establecido un código de colores para la separación de los residuos en la fuente, estableciendo el color verde para residuos orgánicos, el blanco para aquellos que son susceptibles de ser reciclados y el negro para los que no pueden ser aprovechados (Ministerio de Ambiente y Desarrollo Sostenible, 2019).

Finalmente, esta investigación comprenderá desde la teoría necesaria para el procesamiento de la imagen, la inteligencia artificial y redes neuronales hasta el diseño del aplicativo web que alojará la herramienta. No obstante, las pruebas acerca de la eficacia de la herramienta no serán abarcadas en esta primera instancia de la investigación dadas las limitaciones temporales.

3. OBJETIVOS

3.1. Objetivo General

Desarrollar un aplicativo web para la clasificación de residuos sólidos a través de un modelo de machine learning.

3.2. Objetivos Específicos

- Identificar los requerimientos funcionales y no funcionales necesarios para el desarrollo del aplicativo web.
- Entrenar un modelo de machine learning que permita clasificar ocho tipos distintos de residuos sólidos.
- Implementar una interfaz gráfica sencilla e intuitiva que les permita a los usuarios interactuar con el aplicativo de forma eficaz.
- Publicar el aplicativo web en un servicio de hosting de forma que sea accesible para el público a través de internet.

4. PROBLEMA DE INVESTIGACIÓN

En la actualidad la acumulación de residuos tanto a nivel nacional como internacional es una problemática que se está presentando con bastante frecuencia a raíz del crecimiento desaforado de la población. Ahora bien, examinando de manera específica a Colombia se encuentra que la cantidad de basuras y residuos sólidos pasó de un total de 20,31 millones de toneladas en 2012 a 26,25 millones en 2020 (DANE, 2022) lo cual es una evidencia tangible de la situación descrita.

En virtud de esto, el reciclaje, el cual es el proceso de recolectar y procesar materiales que de otro modo serían desechados como basura y convertirlos en nuevos productos (US EPA, 2021), se ha alzado como una de las herramientas más importantes para combatir la acumulación de residuos. Sin embargo, aunque esta parecería ser la repuesta definitiva, cuando se evalúa el porcentaje de desechos que podrían ser reciclados se encuentra que Colombia solo recicla el 16,5 % de las más de 12 millones de toneladas de residuos sólidos que produce anualmente (Cámara de Comercio de Bogotá, 2020). Por otro lado, al inspeccionar de manera más concreta materiales tales como el plástico, se encontró que, aunque en 2019 Colombia consumió 1,4 millones de toneladas, solo recicló el 20% (Semana, 2021).

Ahora bien, cuando se indaga acerca de los factores que provocan ese bajo porcentaje de reciclaje en el país se encuentra que el principal motivo es que las personas no saben cómo hacerlo correctamente, por ejemplo, desconocen el código de colores para la separación de los residuos (Caicedo, 2022). De igual modo, John Alexander Chalarca Zapata, Magíster en sostenibilidad, comenta que siempre ha habido confusión con respecto a qué residuos desechar en cada recipiente. Teniendo en cuenta en los argumentos anteriores y estudios que revelan una tasa de reciclaje muy baja de menos de 1 tonelada per cápita (Alfonso et al., 2014) se hace evidente que Colombia debe implementar estrategias de reciclaje, específicamente en aspectos tan sencillos como la clasificación de desechos.

De acuerdo con lo anteriormente expuesto surge la necesidad de cuestionarse sobre métodos pedagógicos que instruyan a los colombianos sobre las normas básicas del reaprovechamiento de los residuos, ya que se tiene evidencia que la enseñanza de los procedimientos básicos del reciclaje y la incorporación de herramientas visuales cerca a los lugares donde se realiza la

disposición de los residuos generan un cambio a largo plazo en la actitud de las personas frente al reciclaje (Lee & Manfredi, 2021). Por tal motivo, se plantea la siguiente pregunta.

¿Cómo fomentar y facilitar el proceso de clasificación de residuos en Colombia a través de herramientas innovadoras con el fin de aumentar la cantidad de desechos que son reciclados?

5. JUSTIFICACIÓN

Desarrollar un aplicativo web para la clasificación de residuos sólidos a través de un modelo de machine learning es útil y relevante desde el punto de vista ambiental y social. En primer lugar, se facilitará y fomentará el proceso del reciclaje permitiendo que la cantidad de desechos que terminan en vertederos disminuya, lo cual provocaría una reducción en la cantidad de insectos tales como moscas, mosquitos, etc., los cuales son un vector importante en la propagación de enfermedades. De igual modo, se reduciría el riesgo de contaminar el suelo y el agua que son los recursos más susceptibles de ser afectados a raíz de la acumulación de los residuos en vertederos y del tratamiento inadecuado de los desechos.

Por otro lado, se evidencia la necesidad de esta herramienta de forma tecnológica pues diversos estudios han determinado que poner a disposición del público información específica sobre qué elementos son reciclables y cuales no lo son, además de indicar cuales son los contenedores de reciclaje correspondientes a cada desecho promueve el reciclaje (Oke & Kruijsen, 2016).

Por otra parte, en cuanto al aspecto social, se fomentaría el reciclaje contribuyendo así a la implementación de la economía circular en el país, el cual es un paradigma sostenible que consiste en un sistema regenerativo en el que la entrada y el desperdicio de recursos, las emisiones y las fugas de energía se minimizan al ralentizar, cerrar y estrechar los ciclos de materiales y energía. Esto se puede lograr mediante un diseño duradero, mantenimiento, reparación, reutilización, refabricación, restauración y reciclaje (Geissdoerfer et al., 2017).

Por otro lado, utilizar la herramienta en entornos académicos o laborales en Colombia permitirá que las entidades cumplan con la normativa colombiana vigente, específicamente la Resolución 1407, en donde se reglamenta la gestión ambiental de los residuos de envases y empaques de papel, cartón, plástico, vidrio, metal y se toman otras determinaciones (Ministerio de Ambiente y Desarrollo Sostenible, 2018a).

6. MARCO TEÓRICO

El presente marco teórico presenta una recopilación de antecedentes y consideraciones conceptuales en las que se sustenta la presente investigación. Los conceptos aquí abordados serán claves para la comprensión de los procesos realizados y permitirá la validación de los resultados obtenidos.

6.1. Antecedentes

6.1.1. Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network

Estudio realizado en Sudáfrica el cual propone un sistema inteligente de clasificación de materiales de desecho, este fue desarrollado utilizando una red neuronal convolucional de 50 capas entrenada previamente (ResNet-50). Ahora bien, cabe destacar que una red neuronal es una herramienta de aprendizaje automático, que en este caso fue utilizada para clasificar los desechos en diferentes grupos/tipos, como vidrio, metal, papel y plástico, etc. El sistema se puso a prueba con el conjunto de datos de imágenes de basura desarrollado por Gary Thung y Mindy Yang y fue capaz de lograr una precisión del 87% con dicho conjunto de datos. El objetivo de esta investigación fue lograr un proceso de separación de residuos en la fuente más rápido e inteligente reduciendo e incluso evitando la necesidad de la participación humana (Adedeji & Wang, 2019).

Ahora bien, es importante mencionar que, aunque el mecanismo de funcionamiento detrás de esta investigación consiste en una red neuronal y un modelo de aprendizaje automático, este estudio no incluyó ninguna interfaz gráfica ni método mediante el cual esta herramienta pudiese ser visitada que no fuera a través de un intérprete del lenguaje de programación Python.

6.1.2. Waste Management System Using IoT Based Machine Learning in University

En este artículo se propone un método para la gestión eficiente de residuos al calcular la probabilidad del nivel de desechos en contenedores de basura haciendo uso del aprendizaje automático y la teoría de grafos, esto con el fin de optimizar la recolección de desechos con el camino más corto. Igualmente, este estudio presentó los resultados de la implementación

de dicho método en el campus de la Universidad Ton Duc Thang (Vietnam) donde se evaluó el desempeño y factibilidad de la implementación del sistema. Así mismo, se demostraron las ventajas del sistema propuesto, el cual fue implementado a través de un circuito simple diseñado con bajo costo, fácil uso y capacidad de reemplazo. Finalmente, se encontró que el sistema logró ahorrar tiempo al encontrar la mejor ruta en la gestión de la recogida de residuos (Anh Khoa et al., 2020).

En cuanto al sistema propuesto, si bien este hace uso de teorías similares a la investigación propuesta en el presente documento, este estudio cuenta además con un sistema de hardware, específicamente haciendo uso de dispositivos IoT.

6.2. Inteligencia Artificial

La inteligencia artificial comprende cualquier técnica que permita a las computadoras imitar el comportamiento humano y reproducir o superar su habilidad para la toma de decisiones con el fin de resolver tareas complejas de forma independiente o con una intervención humana mínima. Así mismo, se ocupa de una variedad de problemas centrales, que incluyen la representación del conocimiento, el razonamiento, el aprendizaje, la clasificación, la percepción y la comunicación, y se refiere a una variedad de herramientas y métodos (Janiesch et al., 2021).

6.2.1. Machine Learning

El aprendizaje automático, o también conocido en inglés como “Machine Learning”, tiene como objetivo automatizar la tarea de construcción de modelos analíticos para realizar tareas cognitivas como la detección de objetos o la traducción de lenguaje natural. Esto se logra mediante la aplicación de algoritmos que aprenden iterativamente de los datos de entrenamiento específicos del problema, lo que permite a las computadoras encontrar información oculta y patrones complejos sin estar programados explícitamente (Bishop, 2006). El aprendizaje automático es especialmente útil en tareas como la clasificación, regresión y agrupación, donde ha demostrado ser una excelente herramienta. Por otro lado, al aprender de cálculos previos y extraer regularidades de bases de datos masivas, puede ayudar a producir decisiones confiables y repetibles. Por esta razón, los algoritmos de aprendizaje automático se han aplicado con éxito en muchas áreas, como la detección de fraudes, la calificación crediticia, el análisis de la siguiente mejor oferta, el reconocimiento de voz e imágenes o el procesamiento del lenguaje natural (Janiesch et al., 2021).

Finalmente, es importante mencionar que según el tipo de algoritmo y proceso aplicado durante el “Machine Learning” este se puede subdividir en las siguientes categorías.

6.2.1.1. Aprendizaje Supervisado

El aprendizaje supervisado se refiere a cualquier proceso de aprendizaje automático que aprende una función de cualquier tipo de entrada a un tipo de salida utilizando datos que comprenden ejemplos que tienen valores de entrada y salida. Dos ejemplos típicos de aprendizaje supervisado son el aprendizaje de clasificación y la regresión. En estos casos, los tipos de salida son respectivamente categóricos (clases) y numéricos (Sammut & Webb, 2017).

6.2.1.2. Aprendizaje No-supervisado

El aprendizaje no supervisado tiene lugar cuando se supone que el sistema de aprendizaje detecta patrones sin etiquetas o especificaciones preexistentes. Por lo tanto, los datos de entrenamiento solo consisten en variables x con el objetivo de encontrar información estructural de interés, como grupos de elementos que comparten propiedades comunes (Bishop, 2006).

Ahora bien, aunque la experiencia humana es la que suele encargarse de convertir datos "en bruto" en características útiles (Feature extraction), es el aprendizaje no-supervisado el que se propone como alternativa cuando se ve involucrado un gran volumen de datos o se encuentran inmersas propiedades de difícil comprensión. Por otro lado, es importante resaltar que son las "unidades ocultas" de las redes neuronales artificiales las que calculan representaciones internas análogas a las características detectadas (Guyon & Elisseeff, 2006).

6.2.1.3. Aprendizaje Por Refuerzo

En un sistema de aprendizaje por refuerzo, en lugar de proporcionar pares de entrada y salida, se describe el estado actual del sistema, se especifica un objetivo, y se proporciona una lista de acciones permitidas para sus resultados, dejando así que el modelo de aprendizaje automático experimente el proceso de lograr el objetivo utilizando el principio de prueba y error para maximizar una recompensa. Los modelos de aprendizaje por refuerzo

se han aplicado con gran éxito en entornos de mundo cerrado como los juegos (Janiesch et al., 2021).

6.2.2. Tareas de clasificación

Una de las tareas más comunes de los modelos de aprendizaje automático es la clasificación de datos. Ahora bien, es específicamente el aprendizaje supervisado en donde se pueden obtener las etiquetas usadas para categorizar los datos de datos durante las etapas de entrenamiento y prueba del algoritmo. No obstante, existen distintos tipos de clasificación los cuales dependen en su mayoría del conjunto de datos utilizado y las categorías subyacentes.

6.2.2.1. Binario

La entrada debe clasificarse en una, y solo una, de dos clases que no se superponen. La clasificación binaria es la tarea de clasificación más popular. Las categorías asignadas pueden ser objetivas, independientes de la evaluación manual o subjetivas, dependientes de la evaluación manual (Sokolova & Lapalme, 2009).

6.2.2.2. Multiclase

La clasificación es una tarea de clasificación con más de dos resultados posibles. Por ejemplo, cuando el desempeño académico de los estudiantes como excelente o bueno o regular o pobre. La entrada se clasificará en una, y sólo una, de varias clases que no se superponen. Al igual que en la clasificación binaria, la categorización multiclase puede ser objetiva o subjetiva, bien definida o ambigua (Sen et al., 2020).

6.2.2.3. Multietiquetado

La entrada se clasificar en varios clases no superpuestas. Los ejemplos incluyen la identificación de escenas a partir de datos de imágenes o la alineación de bases de datos de texto y alineación de palabras en máquina. Cuando la tarea de aprendizaje es la clasificación de temas de documentos, el etiquetado múltiple a menudo se denomina clasificación de temas múltiple (Sokolova & Lapalme, 2009).


6.2.2.4. Jerárquico

La entrada debe clasificarse en una sola clase que se divide en subclases o se agrupan en superclases. La jerarquía está definida y no se puede cambiar durante la clasificación. La clasificación de textos y la bioinformática brindan muchos ejemplos, por ejemplo, la predicción de la función de proteínas (Sokolova & Lapalme, 2009).

6.3. Redes Neuronales Artificiales

Una red neuronal artificial o también conocida por sus siglas en inglés como ANN, Artificial Neural Network, se refiere a los sistemas informáticos cuyo funcionamiento es análogo al de las redes neuronales biológicas. Una ANN consta de una gran cantidad de procesadores simples vinculados por conexiones ponderadas cuyo valor es llamado "Fuerza de la conexión" o "Peso" e indica hasta qué punto una señal se amplifica o se reduce por la conexión. Por analogía, los nodos de procesamiento se denominan "neuronas" y su salida depende solo de la información que está disponible localmente en el nodo, ya sea almacenada internamente o la que llega a través de las conexiones ponderadas. Cada unidad recibe entradas de muchos otros nodos y transmite su salida a otros nodos. Ahora bien, un solo elemento de procesamiento genera una salida escalar con valor numérico único, que es una función no lineal simple de sus entradas. El poder del sistema emerge de la unión de varios nodos interconectados (Dongare et al., 2008).

Figura 1 Neurona biológica en comparación con una red neuronal artificial




Nota: El grafico representa (a) neurona humana; (b) neurona artificial; (c) sinapsis biológica; y (d) sinapsis ANN. Tomado de *Using a data driven approach to predict waves generated by gravity driven mass flows* (Meng et al., 2020).

6.3.1. Redes Neuronales Concurrentes

Una red neuronal recurrente (RNN) es una red neuronal que consta de un estado oculto, una salida opcional y que opera en una secuencia de longitud variable. Por otro lado, las RNN se caracterizan por utilizar funciones de activación no lineales, tales como funciones sigmoideas de elementos o unidades de memoria a corto plazo (LSTM). Ahora bien, una RNN puede aprender una distribución de probabilidad sobre una secuencia entrenándose para predecir el siguiente símbolo en una secuencia (Cho et al., 2014).

Figura 2 Red neuronal recurrente simple



Nota: El grafico representa la estructura básica de una red neuronal recurrente. Tomado de *Learning phrase representations using RNN encoder-decoder for statistical machine translation* (Cho et al., 2014).

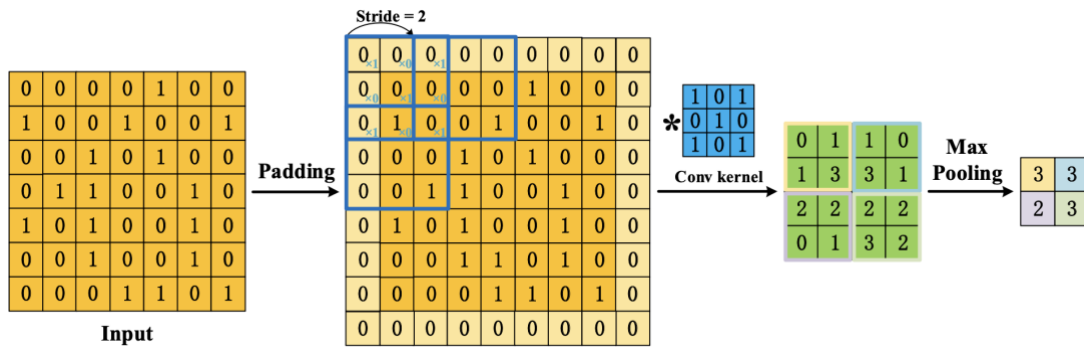
Ahora bien, las RNN mantienen un vector de activaciones para cada paso de tiempo, lo que hace que las RNN sean extremadamente profundas. Su profundidad, a su vez, las hace difíciles de entrenar debido al problema del desvanecimiento del gradiente (Jozefowicz et al., 2015).

6.3.2. Redes Neuronales Convolucionales

Las redes neuronales convolucionales o también conocidas por sus siglas en inglés como CNN, Convolutional Neural Networks, son tipos de redes neuronales artificiales que están compuestas por neuronas que se auto optimizan a través del aprendizaje. Cada neurona aún recibe una entrada y realiza una operación (un producto escalar seguido de una función no lineal). Ahora bien, desde los vectores de imagen sin procesar de entrada hasta la salida final de la puntuación de la clase, toda la red seguirá expresando una única función de

puntuación perceptiva (el peso). La última capa contendrá funciones de pérdida asociadas con las clases.

Figura 3 Procedimiento de una CNN bidimensional



Nota: Tomado de *A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects* (Li et al., 2020)

La principal diferencia entre las redes neuronales convolucionales y las redes neuronales artificiales recae en su campo de aplicación, esto debido a que las CNN se utilizan específicamente para reconocer patrones dentro de las imágenes. Por tal razón, se pueden codificar características concretas de la imagen en la arquitectura de la red, al tiempo que reducen aún más los parámetros necesarios para la configuración del modelo (O’Shea & Nash, 2015).

6.3.3. Métricas de rendimiento

6.3.3.1. Precisión (Accuracy)

La precisión es una métrica para evaluar los modelos de clasificación, definida como la fracción de predicciones que el modelo acertó. Ahora bien, de manera matemática tenemos que la fórmula (Ecuación 1) que representaría la precisión es:

$$\text{Precisión} = \frac{\text{Número de predicciones correcta}}{\text{Número total de predicciones}} \quad (1)$$

6.3.3.2. *Perdida*

En el aprendizaje supervisado, un algoritmo de aprendizaje automático construye un modelo examinando muchos ejemplos e intentando encontrar un modelo que minimice la pérdida. La pérdida es la pena por una mala predicción. Es decir, la pérdida es un número que indica qué tan mala fue la predicción del modelo en un solo ejemplo. Si la predicción del modelo es perfecta, la pérdida es cero; de lo contrario, la pérdida es mayor. El objetivo de entrenar un modelo es encontrar un conjunto de ponderaciones y sesgos que tengan una pérdida baja, en promedio, en todos los ejemplos (Google Developers, 2022).

6.3.3.3. *Matriz de confusión*

Una matriz de confusión, o también llamada “Tabla de contingencia” es una herramienta que permite medir el desempeño de un clasificador basado en un conjunto de instancias (el conjunto de prueba). Ahora bien, de manera más específica, dado un clasificador y una instancia, hay cuatro posibles resultados. Si la instancia es positiva y se clasifica como positiva, se cuenta como un verdadero positivo; si está clasificada como negativa, se cuenta como un falso negativo. Si la instancia es negativa y se clasifica como negativa, se cuenta como un verdadero negativo; si se clasifica como positivo, se cuenta como un falso positivo (Fawcett, 2006).

Figura 4 Matriz de Confusión

		<u>True class</u>	
		p	n
<u>Hypothesized class</u>	Y	True Positives	False Positives
	N	False Negatives	True Negatives


Nota: Esquema sobre cómo está conformada una matriz de confusión. Tomado de *An introduction to ROC análisis* (Fawcett, 2006).

6.4. Residuos sólidos urbanos

Conocidos por sus siglas en inglés como “MSW” (Municipal Solid Waste) o en español como “RSU”, están definidos como materiales que se han descartado de fuentes residenciales

y comerciales o como materiales que han dejado de tener valor para el titular. A pesar de la variedad de significados dado a los residuos, su presencia y proliferación son indiscutibles (Vergara & Tchobanoglous, 2012).

Figura 5 Composición de la basura



Nota: El grafico representa el porcentaje de plástico, metal, vidrio, papel y desechos orgánicos en los residuos de 20 ciudades distintas. Tomado de *Municipal solid waste and the environment: A global perspective*. (Vergara & Tchobanoglous, 2012).

7. MARCO LEGAL

7.1. Resolución 2184 de 2019

Normativa Colombiana titulada “Por la cual se modifica la resolución 668 de 2016 sobre el uso racional de bolsas plásticas y se adoptan otras disposiciones”. Esta normativa tiene como propósito modificar los indicadores sobre los cuales se determina el porcentaje de reducción de bolsas vendidas. Así mismo, la norma ordena a los distribuidores de bolsas plásticas incorporar dichos indicadores en el reporte anual de cantidad de bolsas vendidas (Ministerio de Ambiente y Desarrollo Sostenible, 2019).

Adicionalmente, la resolución exige la adopción de un código de colores para la separación de residuos sólidos desde la fuente en todo el territorio nacional. Este código de colores funciona de la siguiente manera:

- Verde: Residuos orgánicos.
- Blanco: Residuos como plásticos, vidrio, metales, papel o el cartón.
- Negro: Residuos que no son susceptibles de ser aprovechados.

7.2. Resolución 1407 de 2018

Normativa Colombiana titulada “Por la cual se reglamenta la gestión ambiental de los residuos de envases y empaques de papel, cartón, plástico, vidrio, metal y se toman otras determinaciones”. Esta norma tiene como propósito optimizar el uso de material en los envases y empaques, por tal motivo, la industria debe crear un plan orientado a fomentar el aprovechamiento y reutilización de estos. Así mismo, este plan debe incluir procesos en los cuales se recuperen materiales a través del reciclaje, reutilización o cualquier método con el fin de incorporarlos al ciclo económico o productivo de la empresa (Ministerio de Ambiente y Desarrollo Sostenible, 2018b). Ahora bien, según esta resolución los planes formulados por las empresas han de tener:

- Identificación
- Recursos administrativos y técnicos
- Aspectos técnicos y metas
- Descripciones técnicas, operativas y logísticas

7.3. IEEE 1074: Estándar para desarrollar un proceso del ciclo de vida de un proyecto de software

Norma de ingeniería dictaminada por el Instituto de Ingenieros Eléctricos y Electrónicos (IEEE) la cual proporciona una serie de directrices para crear y seleccionar un proceso de ciclo de vida para un proyecto de software (SPLCP). Así mismo, describe el conjunto de actividades obligatorias para el desarrollo y mantenimiento de software. Ahora bien, cabe destacar que el “Ciclo de Vida” determina el orden en que se realizaran cada una de las tareas dentro de un proyecto. Así mismo, un modelo de ciclo de vida es la descripción de las distintas formas de desarrollo de un proyecto (IEEE, 1996). A continuación se encuentran desglosados los principales procedimientos dictaminados por la normativa:

- A. Modelamiento del Ciclo de Vida
 - a. Selección de un ciclo de vida
- B. Administración del Proyecto
 - a. Iniciación del Proyecto
 - b. Monitoreo y Control del Proyecto
 - c. Administración de la calidad del SW
- C. Pre-desarrollo
 - a. Exploración del concepto
 - b. Asignación de Recursos
- D. Desarrollo
 - a. Requerimientos
 - b. Diseño
 - c. Implementación
- E. Post-desarrollo
 - a. Instalación
 - b. Operación y Soporte
 - c. Mantenimiento
 - d. Retiro
- F. Procesos Integrales
 - a. Verificación y Validación
 - b. Administración de la configuración
 - c. Documentación
 - d. Entrenamiento

8. ANÁLISIS DE REQUERIMIENTOS

8.1. Requisitos Funcionales

Los requisitos funcionales son características o funciones que se deben implementar, desde el punto de vista de desarrollo de software, para permitir que los usuarios puedan realizar las tareas previstas por la aplicación. Dentro de los requisitos funcionales encontramos:

Número de requerimiento	RF001
Nombre de requerimiento	Herramienta para la clasificación de residuos
Tipo	Requisito
Fuente del requerimiento	Usuario
Proceso	La aplicación ayuda en la clasificación de residuos sólidos urbanos a partir del registro del residuo a través de la cámara del dispositivo.
Prioridad del requerimiento	Esencial

Número de requerimiento	RF002
Nombre de requerimiento	Registro de usuarios
Tipo	Requisito
Fuente del requerimiento	Usuarios
Proceso	La aplicación permite la creación de cuentas de usuarios a través de un portal de registro.
Prioridad del requerimiento	Esencial

Número de requerimiento	RF003
Nombre de requerimiento	Autenticación de usuarios
Tipo	Requisito
Fuente del requerimiento	Usuario
Proceso	La aplicación permite validar las credenciales del usuario a través de una pantalla de inicio de sesión.
Prioridad del requerimiento	Esencial

Número de requerimiento	RF004
Nombre de requerimiento	Información sobre reciclaje
Tipo	Requisito
Fuente del requerimiento	Usuario
Proceso	La aplicación permite a los usuarios informarse sobre la ley Resolución No. 2184 de 2019, que establece el código de colores para los contenedores de basura, canecas de reciclaje y bolsas que se utilicen en la separación de residuos en la fuente.
Prioridad del requerimiento	Esencial

Número de requerimiento	RF005
Nombre de requerimiento	Historial de reciclaje
Tipo	Requisito
Fuente del requerimiento	Usuario
Proceso	La aplicación permite a los usuarios obtener información sobre su historial de residuos siempre y cuando se hayan registrado antes de utilizar la herramienta para la clasificación de residuos
Prioridad del requerimiento	Esencial

Número de requerimiento	RF006
Nombre de requerimiento	Prohibir duplicados
Tipo	Restricción
Fuente del requerimiento	Administrador
Proceso	La aplicación impide la creación de usuarios con el mismo con el mismo correo
Prioridad del requerimiento	Esencial

Número de requerimiento	RF007
Nombre de requerimiento	Garantizar Integridad
Tipo	Restricción
Fuente del requerimiento	Administrador
Proceso	La aplicación impide la modificación de la información de los usuarios por parte de terceros sin autorización.
Prioridad del requerimiento	Esencial

8.2. Requisitos No Funcionales

Los requisitos no-funcionales definen atributos del sistema como seguridad, confiabilidad, rendimiento, mantenibilidad, escalabilidad y facilidad de uso. Sirven como restricciones o restricciones en el diseño del sistema. Entre los definidos para esta aplicación se encuentran:

Número de requerimiento	RNF001
Nombre de requerimiento	Cifrado de claves
Tipo	Requisito
Fuente del requerimiento	Administrador
Proceso	La contraseña se almacena cifrada en la base de datos, esto con el fin de que ninguna persona a parte del usuario la conozca.
Prioridad del requerimiento	Esencial

Número de requerimiento	RNF002
Nombre de requerimiento	UI/UX
Tipo	Requisito
Fuente del requerimiento	Usuario
Proceso	La aplicación cuenta con una interfaz de usuario intuitiva y fácil de usar.
Prioridad del requerimiento	Deseada

Número de requerimiento	RNF003
Nombre de requerimiento	Almacenamiento de información
Tipo	Requisito

Fuente del requerimiento	Administrador
Proceso	Los datos de la aplicación serán administrados mediante un sistema de gestión de bases de datos relacionales.
Prioridad del requerimiento	Esencial

Número de requerimiento	RNF004
Nombre de requerimiento	Alojamiento de la aplicación
Tipo	Requisito
Fuente del requerimiento	Administrador
Proceso	La aplicación esta alojada en un servicio de hosting online, estando disponible para los usuarios a través de la web.
Prioridad del requerimiento	Esencial

Número de requerimiento	RNF005
Nombre de requerimiento	Diseño responsivo
Tipo	Requisito
Fuente del requerimiento	Usuario
Proceso	El diseño de la aplicación permite que esta sea ejecutado desde dispositivos móviles conservando una interfaz de usuario apropiada para pantallas de menor tamaño.
Prioridad del requerimiento	Esencial

9. ANÁLISIS DE RESTRICCIONES

Las restricciones son una serie de aspectos a considerar en el desarrollo de la investigación. Su identificación temprana permite que se acoten y delimiten correctamente los alcances e incluso las características con las que deberá y podrá contar el proyecto. A continuación, se encuentran explicadas según su área de pertinencia.

9.1. Económicas

Si bien, la herramienta va a ser de uso gratuito se deben tener en cuenta los costos implicados en el mantenimiento de la plataforma, en los que se ven incluidos la renovación del dominio web, costo de operación de los servidores, salario del profesional encargando, entre otros. Por tal motivo, se debe considerar un método de monetización, siendo la publicidad el más probable, que permita el mantenimiento de la plataforma.

9.2. Legales

Teniendo en cuenta que este es un proyecto de software, es necesario revisar cuidadosamente las licencias de las librerías usadas en su desarrollo, esto con el fin de evitar cualquier uso no permitido de las mismas que impida su uso en proyectos de código abierto (Open Source), tal como lo es el presente aplicativo web. Ahora bien, cuando se desarrolla un proyecto de esta índole se deben seguir los siguientes principios:

- a) Libre distribución
- b) Permite trabajos derivados
- c) No discrimina grupo de personas
- d) No discrimina áreas de uso

Así mismo, de manera explícita se espera que el código fuente esté disponible de manera gratuita al público (Open Source Initiative, 2007).

9.3. Ciberseguridad

Tomando en consideración que el aplicativo web recopilará información de los usuarios entre la que se encuentra su dirección de correo electrónico y contraseña, se deberán usar métodos de autenticación seguros para el acceso a la base de datos y métodos de cifrados

información de los usuarios y cumplir con las regulaciones vigentes tales como la GDPR General Data Protection Regulation o, en español, Reglamento General de Protección de Datos, la cual, es una ley creada por la Unión Europea para garantizar la protección y privacidad de datos de los usuarios (IBM, 2019).

Por otro lado, Colombia en el artículo 15 de su constitución (también conocido como Habeas Data) expresa el derecho que tienen las personas de conocer, actualizar y rectificar las informaciones que se hayan recogido sobre ellas en los bancos de datos y en archivos de entidades públicas y privadas (Constitución Política de Colombia, 1991), por lo que es necesario incluir un método para que los usuarios puedan solicitar que su información sea eliminada del sistema,

9.4. Socioculturales

Según lo expuesto anteriormente, se ha podido corroborar que en Colombia la cultura del reciclaje es casi inexistente (Ramírez Hernández, 2015), por lo que es posible que la adopción de esta herramienta de clasificación por parte de los usuarios colombianos sea bastante lenta. Por tal motivo, se debe reforzar la experiencia de usuario dentro de la aplicación para que esta sea intuitiva y fácil de usar, fomentando así su adopción y uso. Así mismo, se deberán implementar estrategias para promocionar el aplicativo a través de plataformas de alcance masivo como redes sociales.

9.5. Éticas

Dado que los modelos de inteligencia artificial siempre cuentan con un margen de exactitud e inexactitud durante las tareas de clasificación (Cai et al., 2008), es de vital importancia advertir a los usuarios sobre la fiabilidad de los resultados entregados por el aplicativo. Así mismo, es importante añadir una herramienta dentro del aplicativo que permita que los usuarios compartan si los resultados obtenidos fueron correctos.

10. METODOLOGÍA PARA LA SELECCIÓN Y DESARROLLO DE LA SOLUCIÓN

Luego de identificar la problemática y de determinar su pertinencia, es necesario llevar a cabo una serie de pasos que permitan ofrecer una solución óptima teniendo en cuenta el conocimiento que se puede brindar desde la academia, específicamente desde el área de estudio que en este caso es la ingeniería de sistemas en lo relacionado con ingeniería de software, inteligencia artificial, entre otras. Ahora bien, los procesos llevados a cabo fueron los siguientes:

10.1. Selección del enfoque y “Brainstorming”

Si bien el fomento de la cultura del reciclaje y la enseñanza sobre la clasificación de residuos se puede efectuar a través de la pedagogía tradicional, ya sea en forma de talleres o clases, nuevamente se reitera la necesidad de un aspecto diferenciador, pues se encontró que la incorporación de herramientas tecnológicas en los procesos de aprendizaje ha demostrado ser un vehículo eficaz en la generación de aprendizaje significativo (Essel et al., 2018).

Ahora bien, dado que en el área tecnológica también existen muchas opciones para atacar el problema, se llevó a cabo una lluvia de ideas, conocida en inglés como “Brainstorming” y una posterior evaluación objetiva de las opciones propuestas por medio de una matriz de consistencia de forma que se pudiera elegir una alternativa adecuada e innovadora. En esta matriz de consistencia se otorga un valor de 1 a 5 en donde el valor más alto siempre indica que la idea es más favorable en ese aspecto, por ejemplo, puntuar 5 en la columna “competencia” significaría que hay una amplia oportunidad de incursión en el mercado dado que no existen alternativas similares.

Por otro lado, es importante mencionar que las calificaciones se asignan teniendo en cuenta la experiencia y recursos económicos propios, como también la demanda y competencia en el contexto colombiano, el cual es el público objetivo de la presente aplicación:

A continuación, se encuentran las ideas que se consideraron inicialmente, como también resaltada la que resulto exitosa:

Tabla 1*Matriz de Consistencia*

Idea	Conocimientos Propios	Recursos Financieros	Demanda	Competencia
Dispositivo IOT para la autoclasificación de residuos	3	3	5	3
Aplicativo web basado en machine learning para la clasificación de residuos	5	5	4	3
Videojuego móvil como elemento pedagógico para la enseñanza del reciclaje	4	4	3	5

Nota: Elaboración propia.

10.2. Revisión de antecedentes

A continuación, se realizó una consulta de material bibliográfico con el fin de conocer y documentar aproximaciones anteriores al problema estudiado. Así mismo, un objetivo secundario de esta actividad era el de determinar si ya existía un producto con características similares que pretendiera usarse con los mismos objetivos de la presente investigación.

Ahora bien, dentro de la información recopilada durante este proceso se encontró que si bien existían modelos de machine learning utilizados para la clasificación de residuos, ninguno había sido adecuado a la normativa colombiana vigente, ni mucho menos había sido puesto a disposición del público de manera gratuita en un aplicativo web como el descrito en el presente proyecto. No obstante, fueron utilizados como soporte teórico y documentados en el documento.

10.3. Tecnologías propuestas

Una vez determinadas las características globales de la solución, se hace necesario definir el conjunto de tecnologías que se utilizaran para crear la aplicación, lo cual se denomina “Tech Stack”. En la Tabla 2 se exponen los lenguajes de programación, frameworks, librerías, servidores, soluciones UI/UX, software y herramientas utilizadas para su desarrollo.

Tabla 2*Tech Stack*

Tipo de Tecnología	Selección	Motivo
Lenguaje de programación	Python	<ul style="list-style-type: none">• Versatilidad• Fácil implementación• Curva de aprendizaje baja• Lenguaje de mayor uso en el campo de la inteligencia artificial
Framework de Desarrollo	Flask	<ul style="list-style-type: none">• Escalabilidad• Flexibilidad• Soporte para pruebas unitarias• Depurador integrado• Rápida implementación
Sistema de gestión de bases de datos relacionales (RDBMS)	MySQL	<ul style="list-style-type: none">• Escalabilidad• Alto rendimiento• Alta disponibilidad• Soporte transaccional sólido
Sistema operativo del servidor	Linux (Ubuntu 22.04 LTS)	<ul style="list-style-type: none">• Desempeño• Escalabilidad• Seguridad• Estabilidad

Nota: Elaboración propia.

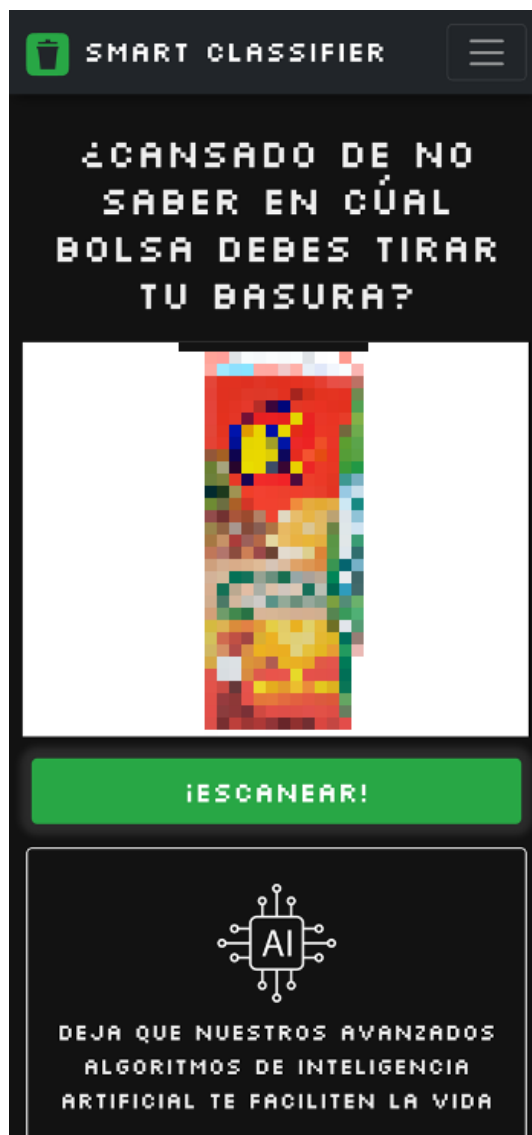
Por otro lado, en cuanto al conjunto de datos (dataset) utilizado para el entrenamiento del modelo de machine learning se optó por el conjunto Trashnet (Yang & Thung, 2016). Ahora bien, la decisión de utilizar un dataset ya existente obedeció principalmente a las restricciones temporales del proyecto y la complejidad técnica que involucra la captura de material nuevo.

10.4. Interfaz de usuario (UI) y Experiencia de usuario (UX)

Finalmente, luego de elegir el conjunto de tecnologías que harán parte del proyecto se procede con el diseño de la UI siguiendo como principio que la aplicación sea siempre intuitiva y fácil de usar, logrando así una UX favorable que facilite la adopción de la herramienta. Para este diseño se tomó como fuente de inspiración los colores institucionales de la Universidad EAN.

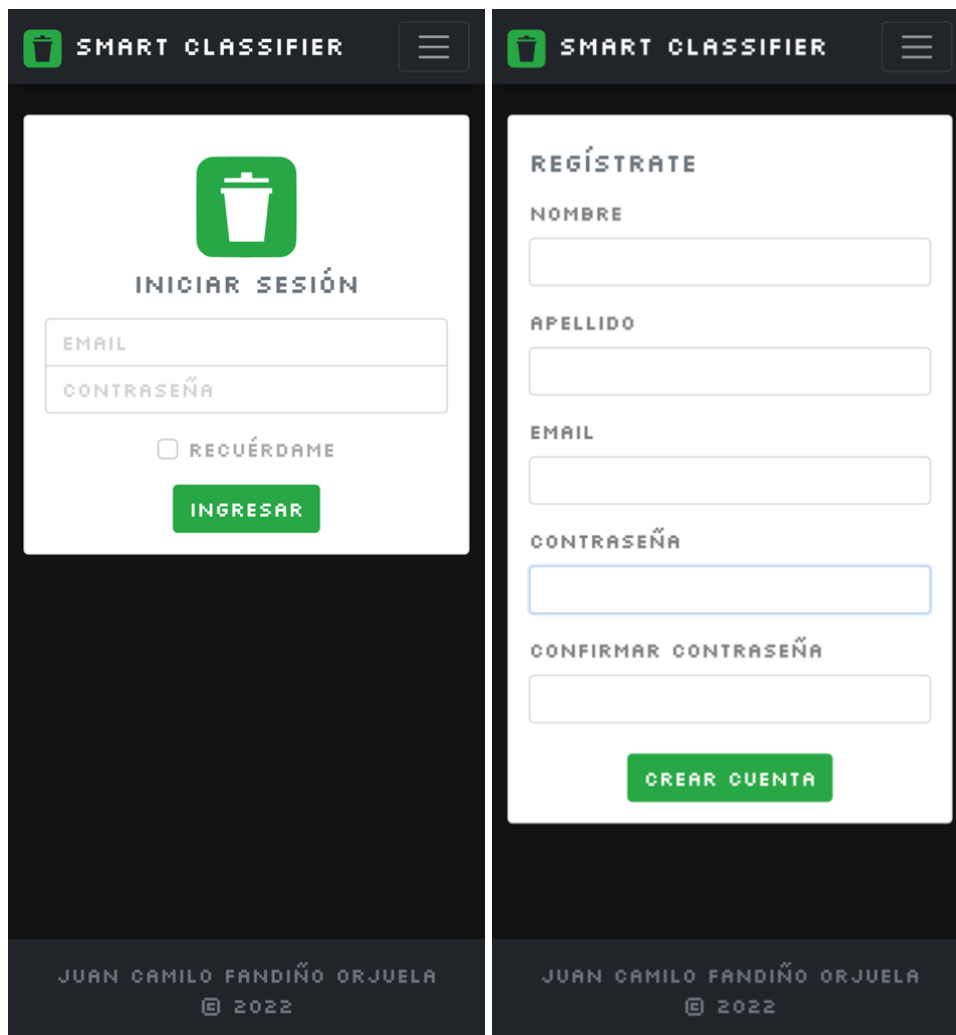
A continuación, se encuentra las diferentes pantallas a los que los usuarios podrán recurrir para interactuar con la aplicación:

Figura 6 Landing page



Nota: El lugar en donde se encuentra el envase del jugo corresponde al espacio en donde se le enseñara al usuario lo que la cámara esta capturando. Elaboración propia.

Figura 7 Pagina de inicio de sesión y registro



Nota: Elaboración propia

Las instrucciones para acceder y utilizar el aplicativo son las siguientes:

- a) Ingresar a <https://smart-classifier.com/>.
- b) Otorgar al aplicativo web permisos para utilizar la cámara del dispositivo
- c) Hacer clic en “Escanear” apuntando al residuo
- d) Se obtendrá el tipo de residuo escaneado y la bolsa de reciclaje correspondiente.

11. ANÁLISIS DE COSTOS

El análisis de costos consiste en identificar los recursos económicos necesarios para la ejecución del proyecto planteado. Así mismo, permite evaluar si el servicio brindado a través del aplicativo web será rentable o si por el contrario requiere algún modelo de ingresos para que la operación de la plataforma sea viable. Cabe destacar que estos costos fueron calculados para el año 2022 en Bogotá, Colombia y fueron obtenidos al realizar las cotizaciones en zonas residenciales, por lo que es importante tener en cuenta que podrían llegar a diferir de los costos en los que se podría incurrir en un contexto industrial o comercial. A continuación, se exponen los distintos tipos de costos involucrados:

11.1. Costos directos

Estos son los costos relacionados directamente con el desarrollo inicial del aplicativo, suponiendo así una inversión inicial para la ejecución del proyecto. Estos incluyen un periodo de tiempo de alrededor de seis meses e incluyen el pago de la nómina del desarrollador.

Tabla 3

Costos directos

Concepto	Proveedor	Unidad	Cantidad	P. Unitario	Precio Total
Computador	Apple	Única	1	\$ 5.300.000	\$ 5.300.000
Ingeniero de Sistemas (Python Full Stack)	N/A	Mensual / Medio tiempo	6	\$ 1.600.000	\$ 9.600.000
Servicio de Internet y telefonía	ETB	Mensual	6	\$ 90.000	\$ 540.000
Hosting	Linode	Mensual	6	\$ 47.859	\$ 287.154
				Total	\$ 15.727.154

Nota: Elaboración propia.

11.2. Costos fijos

Estos son los costos invariables a lo largo del tiempo pues son los necesarios para la operación y mantenimiento de la plataforma. A continuación, se encuentran desglosados para un periodo de tiempo de un año:

Tabla 4*Costos fijos*

Concepto	Proveedor	Unidad	Cant.	P. Unitario	Precio Total
Servicio de Internet y telefonía	ETB	Mensual	12	\$ 90.000	\$ 1.080.000
Ingeniero de Sistemas (Python Full Stack)	N/A	Mensual / Medio tiempo	12	\$ 1.600.000	\$ 19.200.000
Dominio	GoDaddy	Anual	1	\$ 47.156	\$ 47.156
Hosting	Linode	Mensual	12	\$ 47.859	\$ 574.308
Total					\$ 20.901.464

Nota: Elaboración propia.

11.3. Gastos generales

Se consideran los costos en los que se incurre al manejar un proyecto de software, entre los que se incluye la administración del mismo.

Tabla 5*Gastos generales*

Concepto	Proveedor	Unidad	Cant.	P. Unitario	Precio Total
Administrador de Empresas / Gerente de proyectos	N/A	Mensual / Medio tiempo	12	\$ 1.000.000	\$ 12.000.000
Total					\$ 12.000.000

Nota: Elaboración propia.

11.4. Costos totales

Finalmente, los costos totales agruparían la inversión inicial necesaria para el desarrollo del proyecto junto con el costo de operación (mensual) de la plataforma. Dando así los siguientes resultados:

Tabla 6*Costos totales*

Concepto	Valor
Inversión Inicial	\$ 15.727.154
Costos fijos	\$ 1.741.000
Gastos Generales	\$ 1.000.000
Total	\$ 18.468.154

Nota: Elaboración propia.

Ahora bien, aunque la cantidad calculada representa una suma importante de fondos, es necesario tener en cuenta que este aplicativo web está diseñado como una herramienta de uso gratuito para la comunidad, por tal motivo, es necesario considerar alianzas estratégicas y financiación de ONGs, entidades públicas tales como MINCIENCIAS o MINTIC, u organizaciones sostenibles dispuestas a fomentar el reciclaje en Colombia. Así mismo, se deberá incluir publicidad dentro de la página con el fin de ayudar a solventar los gastos en los que se incurre mensualmente.

12. CONCLUSIONES

Se desarrollo un aplicativo web utilizando Python como lenguaje de programación y Flask como marco de desarrollo web, dicho aplicativo fue alojado en un servidor Linux y publicado en internet bajo el dominio: <https://smart-classifier.com/>.

Para la clasificación de residuos sólidos se entrenó una red neuronal convolucional a través de la librería TensorFlow utilizando un optimizador “Adam” el cual usa el método estocástico del descenso del gradiente, lo que permitió la clasificación de ocho tipos de residuos distintos entre los que se encuentran: aluminio, cartón, envases plásticos, desechos orgánicos, papel, plásticos de un solo uso, envases Tetra Pak y vidrio. Ahora bien, cabe destacar que este modelo de Machine Learning tuvo una precisión de alrededor del 90% según los resultados del entrenamiento. Así mismo, la matriz de confusión permitió determinar qué el modelo tuvo un mayor éxito en la clasificación de papel, aluminio y vidrio, mientras que no fue tan eficaz en la clasificación de desechos orgánicos, lo cual se debe al número de imágenes que pertenecían a esta categoría dentro del conjunto de datos utilizado.

Ahora bien, en cuanto a la eficacia del modelo si bien el entrenamiento otorgó los resultados anteriormente expuestos, se propone la implementación de pruebas de campo como recomendaciones para futuros proyectos, esto con el fin de evaluar con usuarios reales el comportamiento de la aplicación y el desempeño del modelo, para este motivo la aplicación ya cuenta con un apartado para que los usuarios puedan ingresar la retroalimentación con respecto a la predicción dada.

En cuanto al algoritmo usado para el entrenamiento del modelo de inteligencia artificial, se propone para futuras investigaciones la comparación de diferentes algoritmos de optimización con el fin de determinar cuál de ellos otorga resultados más favorables en cuanto a la precisión del modelo.

Se considera que el desarrollo del aplicativo se realizó de manera exitosa por lo menos en lo que involucra la etapa del mínimo producto viable gracias al levantamiento oportuno de los requerimientos funcionales y no funcionales, los cuales se obtuvieron al consultar la literatura vigente en desarrollo de software, como también, al evaluar los antecedentes de proyectos similares.

Adicionalmente, se evidencio mediante el uso del aplicativo que es necesario tener ciertas consideraciones al momento de realizar la captura del residuo con la cámara, algunas de estas son: tratar de aislar la imagen del residuo en un fondo blanco o sin muchos colores, utilizar residuos reales en lugar de imágenes generadas por computador y utilizar un dispositivo que entregue imágenes de alta resolución.

Finalmente, se espera que esta herramienta pueda ser utilizada por la población colombiana en general pues no necesita ningún conocimiento técnico especializado para su utilización. No obstante, se deberán realizar seguimientos al uso de la aplicación que permitan determinar su tasa de uso, como también, añadir una sección de sugerencias que permita conocer que características creen los usuarios que podrían permitir un mayor uso de la herramienta.

13. REFERENCIAS

- Adedeji, O., & Wang, Z. (2019). Intelligent waste classification system using deep learning convolutional neural network. *Procedia Manufacturing*, 35, 607–612. <https://doi.org/10.1016/J.PROMFG.2019.05.086>
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2018). Understanding of a convolutional neural network. *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017, 2018-January*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Alfonso, W. H., Piñiña, P., Inés, C., & Martínez, P. (2014). Urban material flow analysis: An approach for Bogotá, Colombia. *Ecological Indicators*, 42, 32–42. <https://doi.org/10.1016/j.ecolind.2013.10.035>
- Anh Khoa, T., Hoang Phuc, C., Duc Lam, P., Mai Bao Nhu, L., Minh Trong, N., Thi Hoang Phuong, N., van Dung, N., Tan-Y, N., Nam Nguyen, H., & Ngoc Minh Duc, D. (2020). *Waste Management System Using IoT-Based Machine Learning in University*. <https://doi.org/10.1155/2020/6138637>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*.
- Cai, Q., Zhang, C., Peng, C., & Zhang, J. (2008). *Analysis of classification margin for classification accuracy with applications*. <https://doi.org/10.1016/j.neucom.2008.03.015>
- Caicedo, E. (2022). Día del Reciclaje: a Colombia le va mal, pero así puede ayudar a cambiarlo. *El Tiempo*. <https://www.eltiempo.com/vida/medio-ambiente/dia-del-reciclaje-a-colombia-le-va-mal-pero-asi-puede-ayudar-a-cambiarlo-672818>
- Cámara de Comercio de Bogotá. (2020). *Así cambiará el reciclaje en Colombia tras entrada en vigencia de una norma*. <https://www.ccb.org.co/Clusters/Cluster-Impresion-y-Packaging/Noticias/2020/Noviembre-2020/Asi-cambiara-el-reciclaje-en-Colombia-tras-entrada-en-vigencia-de-una-norma>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1724–1734. <https://doi.org/10.3115/v1/d14-1179>

- Ciuta, S., Apostol, T., & Rusu, V. (2015). Urban and rural MSW stream characterization for separate collection improvement. *Sustainability (Switzerland)*, 7(1), 916–931. <https://doi.org/10.3390/su7010916>
- Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2008). Introduction to Artificial Neural Network. *Certified International Journal of Engineering and Innovative Technology (IJEIT)*, 9001(1), 2277–3754.
- el Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? *Machine Learning in Radiation Oncology*, 3–11. https://doi.org/10.1007/978-3-319-18305-3_1
- Essel, H. B., Bonsu, F. M., Ofori, E., Barton Essel, H., & Ma, M. (2018). USING DIGITAL TECHNOLOGIES AS A VEHICLE FOR ENHANCING LEARNING AT THE SUNYANI TECHNICAL UNIVERSITY. *Original Research Article Journal of Basic and Applied Research International*, 24(3), 96–103. <https://www.researchgate.net/publication/326300101>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 861–874. <https://doi.org/10.1016>
- Geissdoerfer, M., Savaget, P., And Bocken, N. M. P., & Hultink, E. J. (2017). *The circular economy a new sustainability paradigm?*, *Journal of cleaner production*. 143, 757–768. <https://doi.org/10.1016/j.jclepro.2016.12.048>
- Google Developers. (2022). *Descending into ML: Training and Loss*. https://developers.google.com/machine-learning/crash-course/descending-into-ml/training-and-loss?hl=es_419
- Guyon, I., & Elisseeff, A. (2006). An Introduction to Feature Extraction. In *Feature Extraction* (pp. 1–25). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-35488-8_1
- IBM. (2019). *Cumplimiento del reglamento GDPR - Colombia*. <https://www.ibm.com/co-es/analytics/use-cases/gdpr-personal-data-protection-consent>
- IEEE. (1996). IEEE Standard for Developing Software Life Cycle Processes. *IEEE Std 1074-1995*, 1–106. <https://doi.org/10.1109/IEEESTD.1996.79663>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/S12525-021-00475-2>
- Jozefowicz, R., Zaremba, W., & Sutskever, I. (2015). An empirical exploration of Recurrent Network architectures. *32nd International Conference on Machine Learning, ICML 2015*, 3, 2332–2340.

- Lee, S., & Manfredi, L. R. (2021). Promoting recycling, reducing and reusing in the School of Design: a step toward improving sustainability literacy. *International Journal of Sustainability in Higher Education*, 22(5), 1038–1054.
<https://doi.org/10.1108/IJSHE-11-2020-0443>
- Li, Z., Peng, S., & Liu, F. (2020). *A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects*. <https://www.researchgate.net/publication/340475800>
- Meng, Z., Hu, Y., & Ancey, C. (2020). Using a data driven approach to predict waves generated by gravity driven mass flows. *Water (Switzerland)*, 12(2).
<https://doi.org/10.3390/W12020600>
- Ministerio de Ambiente y Desarrollo Sostenible. (2018a). *Resolución 1407 de 2018*.
https://www.cancilleria.gov.co/sites/default/files/Normograma/docs/resolucion_min_ambienteds_1407_2018.htm
- Ministerio de Ambiente y Desarrollo Sostenible. (2018b). *Resolución 1407 de 2018*.
https://www.cancilleria.gov.co/sites/default/files/Normograma/docs/resolucion_min_ambienteds_1407_2018.htm
- Ministerio de Ambiente y Desarrollo Sostenible. (2019). *Resolución 2184 de 2019*.
<https://www.minambiente.gov.co/documento-entidad/resolucion-2184-de-2019/>
- Oke, A., & Kruijssen, J. (2016). The importance of specific recycling information in designing a waste management scheme. *Recycling*, 1(2).
<https://doi.org/10.3390/recycling1020271>
- Open Source Initiative. (2007). *The Open Source Definition*. <https://opensource.org/osd>
- O’Shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks*.
<http://arxiv.org/abs/1511.08458>
- Ramírez Hernández, O. (2015). Identificación de problemáticas ambientales en Colombia a partir de la percepción social de estudiantes universitarios localizados en diferentes zonas del país. *Revista Internacional de Contaminación Ambiental*, 293–310. https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-49992015000300009
- Sammut, C., & Webb, G. I. (2017). Encyclopedia of Machine Learning and Data Mining. In C. Sammut & G. I. Webb (Eds.), *Encyclopedia of Machine Learning and Data Mining*. Springer US. <https://doi.org/10.1007/978-1-4899-7687-1>
- Semana. (2021). *En Colombia se recicla menos del 17% de los residuos que se generan*. <https://www.semana.com/en-colombia-se-recicla-menos-del-17-de-los-residuos-que-se-generan/59739/>

- Sen, P. C., Hajra, M., & Ghosh, M. (2020). Supervised Classification Algorithms in Machine Learning: A Survey and Review. *Advances in Intelligent Systems and Computing*, 937, 99–111. https://doi.org/10.1007/978-981-13-7403-6_11/COVER
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45, 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- US EPA. (2021). *Recycling Basics*. <https://www.epa.gov/recycle/recycling-basics>
- Vergara, S. E., & Tchobanoglous, G. (2012). Municipal solid waste and the environment: A global perspective. In *Annual Review of Environment and Resources* (Vol. 37, pp. 277–309). <https://doi.org/10.1146/annurev-environ-050511-122532>
- Yang, M., & Thung, G. (2016). *Trashnet*. <https://github.com/garythung/trashnet>