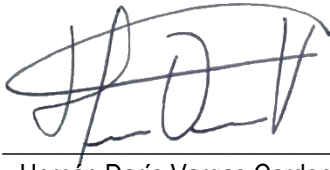


## SISTEMA EMPRESARIAL INTELIGENTE PARA LA CLASIFICACIÓN DE RESIDUOS

**Autores:** Elkin Leonardo Cantor, Santiago Morales Cadavid y Leidy Johana Correa

Nota de Aceptación

Certificamos que el presente Trabajo de Grado Satisface, en alcances y calidad, todos los requisitos que demanda un Trabajo de Grado de Maestría.



Hernan Darío Vargas Cardona

Director



Julián Gil  
Jurado 1



Eugenio Tamura  
Jurado 2

Aprobado en cumplimiento de los requisitos exigidos por la Pontificia Universidad Javeriana Cali, para optar el título de Magister en Ciencia de Datos.



HERNÁN CAMILO ROCHA NIÑO Ph. D.  
Decano Facultad de Ingeniería y Ciencias



JUAN CARLOS MARTÍNEZ ARIAS  
Director Posgrados de Ingeniería y Ciencias



**Acta de Correcciones al Documento de Trabajo de Grado**

**Santiago de Cali, 28 de junio de 2023**

**Autores: Elkin Leonardo Cantor, Santiago Morales Cadavid y Leidy Johana Correa**

**Título del Trabajo de Grado: “Sistema empresarial inteligente para la clasificación de residuos”**

**Director: Hernán Darío Vargas Cardona**

Como indica el artículo 2.13 de las Directrices para Trabajo de Grado de Maestría, he verificado que los estudiantes indicados arriba han implementado todas las correcciones que los Jurados del Proyecto de Trabajo de Grado definieron que se efectuaran, como consta en el Acta de Evaluación correspondiente.

\_\_\_\_\_  
Firma del Director del Trabajo de Grado

Santiago de Cali, 28 de mayo del 2023

Doctora

**Gloría Inés Alvarez V.**

Directora Maestría en Ciencia de Datos

Facultad de Ingeniería y Ciencias

Pontificia Universidad Javeriana de Cali

**Asunto:** Presentación para evaluación del proyecto aplicado

Cordial saludo,

Con el fin de cumplir con los requisitos exigidos por la Universidad para optar por el título de Magíster en Ciencia de Datos, nos permitimos presentar a su consideración el proyecto denominado "Sistema empresarial inteligente para la clasificación de residuos", el cual fue realizado por los estudiantes Elkin Leonardo Cantor, Santiago Morales Cadavid y Leidy Johana Correa con códigos 8972109, 8972741y 8972748 pertenecientes a la Maestría en Ciencia de Datos, bajo la dirección de Hernán Darío Vargas Cardona y codirección de Cristian Alejandro Torres Valencia.

El suscrito director del Proyecto Aplicado autoriza para que se proceda a hacer la evaluación de este proyecto, toda vez que ha revisado cuidadosamente el documento y avala que ya se encuentra listo para ser presentado y sustentado oficialmente.

Atentamente,

Elkin Leonardo Cantor Huérfano  
C.C. 1.022.333.702 de Bogotá  
Estudiante Maestría

Santiago Morales Cadavid  
C.C. 1.035.875.567 de Girardota  
Estudiante Maestría

Cristian Alejandro Torres Valencia  
C.C. 1.094.903.993  
Codirector Proyecto

Leidy Johana Correa Gómez  
C.C. 1.015.430.165 de Bogotá  
Estudiante Maestría

Hernán Darío Vargas Cardona  
C.C. 1.097.721.437 de Montenegro  
Director Proyecto

**Documentación anexa:**

Resumen del Proyecto Aplicado en formato digital (máximo 1 página).

Una copia digital (PDF) del documento del proyecto aplicado

## FICHA RESUMEN

**TÍTULO:** Sistema empresarial inteligente para la clasificación de residuos.

1. **ÁREA DE TRABAJO:** Área Ambiental.
2. **TIPO DE PROYECTO (Aplicado, Innovación, Investigación):** Aplicación e Innovación.
3. **ESTUDIANTE(S):** Elkin Leonardo Cantor, Santiago Morales Cadavid y Leidy Johana Correa.
4. **CORREO ELECTRÓNICO:** elcantorh@javerianacali.edu.co, santiagomorales9701@javerianacali.edu.co, ljcorreag@javerianacali.edu.co
5. **DIRECCIÓN Y TELEFONO:** 3003688104, 3046401893 y 3195097637.
6. **DIRECTOR:** Hernán Darío Vargas Cardona.
7. **VINCULACIÓN DEL DIRECTOR:** Profesor de planta.
8. **CORREO ELECTRÓNICO DEL DIRECTOR:** hernan.vargas@javerianacali.edu.co
9. **CODIRECTOR (Si aplica):** Cristian Alejandro Torres Valencia
10. **GRUPO O EMPRESA QUE LO AVALA (Si aplica):** No Aplica.
11. **OTROS GRUPOS O EMPRESAS:** No Aplica.
12. **PALABRAS CLAVE (al menos 5):** Reciclaje, Deep Learning, impacto ambiental, consciencia ambiental, modelo de clasificación.
13. **FECHA DE INICIO:** 01 de junio de 2022.
14. **DURACIÓN ESTIMADA (En meses):** 10 meses.
15. **RESUMEN:** Existe evidencia de que en Colombia se producen 24,8 millones de toneladas de residuos al año, de los cuales el 47% provienen de los hogares con una generación per cápita de 515 kilogramos y a su vez la tasa de reciclaje, que se refiere a la proporción de material reciclado sobre la generación total de residuos sólidos, es cercana al 12% en el año 2019, siendo esta una cifra muy baja comparada con la de otros países como Alemania donde llega al 68%. Por medio de este proyecto se buscó realizar un modelo de aprendizaje automático que a través del reconocimiento de imágenes permitiera en el ámbito empresarial realizar una correcta clasificación de residuos en las diferentes canecas del punto ecológico, así como la recolección de información que permita calcular diversos indicadores a nivel individual y de empresa, proporcionando información clave para el desarrollo de futuras campañas de impacto ambiental y buscando diversos mecanismos y estrategias que promuevan el uso de esta herramienta y nos convierta en un aliado estratégico del medio ambiente. Asimismo, por medio del desarrollo de este proyecto, se obtuvo un dataset que permitió crear algoritmos robustos que contribuyen al correcto entrenamiento del modelo de clasificación de residuos, este modelo se desarrolló en lenguaje Python, empleando algoritmos de Deep Learning, especialmente haciendo uso de redes neuronales convolucionales que permitieron la construcción de un prototipo o diseño (mockup) de una aplicación móvil donde a futuro se podrá desplegar el modelo realizado.



Pontificia Universidad  
**JAVERIANA**  
Cali

## **SISTEMA EMPRESARIAL INTELIGENTE PARA LA CLASIFICACIÓN DE RESIDUOS**

*Elkin Leonardo Cantor Huérfano*

*Código 8972109*

*Leidy Johana Correa Gómez*

*Código 8972748*

*Santiago Morales Cadavid*

*Código 8972741*

*Proyecto Aplicado para optar al título de  
Magister en Ciencia de Datos*

Director

Hernán Darío Vargas Cardona

Codirector

Cristian Alejandro Torres Valencia

FACULTAD DE INGENIERÍA Y CIENCIAS  
MAESTRÍA EN CIENCIA DE DATOS  
SANTIAGO DE CALI, JUNIO 1 DE 2023

## TABLA DE CONTENIDO

INTRODUCCIÓN .....	8
1. DEFINICIÓN DEL PROBLEMA .....	9
1.3. PLANTEAMIENTO DEL PROBLEMA.....	9
1.4. FORMULACIÓN DEL PROBLEMA.....	10
2. OBJETIVOS DEL PROYECTO .....	12
2.1. OBJETIVO GENERAL .....	12
2.2. OBJETIVOS ESPECÍFICOS .....	12
3. MARCO TEÓRICO Y ANTECEDENTES.....	13
3.1. MARCO TEÓRICO .....	13
3.1.1. Herramientas para el procesamiento de imágenes .....	14
3.1.2. ¿Qué es Deep Learning?.....	14
3.1.3. ¿Que son las redes neuronales? .....	14
3.1.4. Python y sus principales librerías para procesamiento de imágenes .....	15
3.1.5. Conceptos básicos de reciclaje.....	16
3.1.6. Normatividad de referencia .....	18
3.2. ANTECEDENTES.....	19
3.2.1. Procesamiento de imágenes de residuos.....	19
3.2.2. Conciencia del impacto ambiental desde el consumo de productos.....	21
4. PREPARACIÓN Y RECOPIACIÓN DEL DATASET DE IMÁGENES DE RESIDUOS .....	23
4.1. CLASIFICACIÓN BINARIA .....	23
4.2. CLASIFICACIÓN MULTICLASE .....	24
5. METODOLOGIA DE DEEP LEARNING .....	26
5.1. TÉCNICAS DE INTELIGENCIA ARTIFICIAL PARA EL PROCESAMIENTO DE IMÁGENES .....	26
5.1.1. Lógica difusa .....	26
5.1.2. Inteligencia de enjambre.....	26
5.1.3. Redes neuronales artificiales .....	27
5.2. SELECCIÓN DE HERRAMIENTA COMPUTACIONAL .....	31
5.3. CONSTRUCCIÓN, ENTRENAMIENTO, ELECCIÓN Y PRUEBAS DEL MODELO.....	32
5.3.1. Arquitecturas de redes convolucionales utilizadas .....	32

5.3.2.	Entrenamiento y elección de la arquitectura a implementar .....	36
5.3.3.	Unificación del modelo y pruebas de clasificación .....	44
6.	INDICADORES AMBIENTALES.....	47
6.1.	ENTREVISTA A PROFESIONAL AMBIENTAL.....	47
6.2.	ENTREVISTA A REPRESENTANTE DE EMPRESA PRIVADA .....	48
6.3.	ALGUNOS PRINCIPALES INDICADORES AMBIENTALES.....	49
6.3.1.	Indicadores ambientales medibles desde el sistema empresarial inteligente para la clasificación de residuos.....	51
6.4.	ESTRUCTURA DE ALMACENAMIENTO DE INFORMACIÓN DEL MODELO .....	53
7.	PROTOTIPO APP MÓVIL.....	56
8.	CONCLUSIONES .....	61
9.	REFERENCIAS BIBLIOGRÁFICAS .....	62

## LISTA DE ILUSTRACIONES

Ilustración 1 Redes neuronales .....	15
Ilustración 2 Código de colores residuos aprovechables .....	17
Ilustración 3 Código de colores residuos orgánicos .....	17
Ilustración 4 Código de colores residuos no aprovechables .....	18
Ilustración 5 Abecé para medir la sostenibilidad corporativa .....	19
Ilustración 6 Residuo no aprovechable .....	23
Ilustración 7 Residuo aprovechable .....	24
Ilustración 8 Residuo aprovechable - vidrio .....	24
Ilustración 9 Residuo aprovechable - metal .....	25
Ilustración 10 Residuo aprovechable – plástico .....	25
Ilustración 11 Residuo aprovechable - papel, cartón .....	25
Ilustración 12 Inteligencia de enjambre .....	27
Ilustración 13 Modelo de redes neuronales.....	28
Ilustración 14 Funcionamiento redes neuronales.....	30
Ilustración 15 Funcionamiento redes neuronales matricial.....	30
Ilustración 16 Herramienta tecnológica .....	31
Ilustración 17 Arquitectura Modelo ResNet.....	33
Ilustración 18 Arquitectura red propia .....	36
Ilustración 19 Loss y accuracy binario modelo propio .....	37
Ilustración 20 Loss y accuracy multiclase modelo propio .....	37
Ilustración 21 Loss y accuracy binario modelo AlexNet .....	37
Ilustración 22 Loss y accuracy multiclase modelo AlexNet .....	38
Ilustración 23 Loss y accuracy binario modelo ResNet .....	38
Ilustración 24 Loss y accuracy multiclase modelo ResNet .....	38
Ilustración 19 Indicadores modelo binario.....	41
Ilustración 20 LevenTest redes binarias en R-Studio.....	41
Ilustración 21 Kruskal-Wallis redes binarias en R-Studio .....	41
Ilustración 22 Pairwise test en R-Studio.....	42
Ilustración 23 Matriz de confusión clasificación binaria .....	43
Ilustración 24 Indicadores modelo multiclase .....	43
Ilustración 25 LevenTest redes multiclase en R-Studio .....	43
Ilustración 26 Kruskal-Wallis redes multiclase en R-Studio .....	44
Ilustración 27 Matriz de confusión clasificación multiclase .....	44
Ilustración 28 Compilación de los modelos.....	45
Ilustración 29 Prueba de ejecución de los modelos.....	46
Ilustración 30 Captura de información .....	54
Ilustración 31 Almacenamiento JSON .....	55
Ilustración 32 Prototipo envío correo electrónico .....	55
Ilustración 33 Prototipo App Movil - Opción Home .....	56
Ilustración 34 Prototipo App Móvil - Opción perfil .....	56
Ilustración 35 Prototipo App Móvil - Opción escaneo modelo ML.....	57

Ilustración 36 Prototipo App Móvil - Opción indicadores .....	58
Ilustración 37 Prototipo App Móvil - Opción ¿Quiénes somos? .....	58
Ilustración 38 Prototipo App Móvil - Opción calendario.....	59
Ilustración 39 Prototipo App Móvil - Opción chat y usuarios .....	59
Ilustración 40 Prototipo App Móvil - Opción nuestra comunidad .....	60

## LISTA DE TABLAS

Tabla 1 Indicadores de evaluación modelo binario.....	39
Tabla 2 Indicadores de evaluación modelo multiclase.....	39
Tabla 3 Formulación de indicadores de desempeño .....	40

## LISTA DE ECUACIONES

Ecuación 1 Cantidad de residuos clasificados (CRC) .....	51
Ecuación 2 Cantidad de residuos aprovechables (CRA) .....	51
Ecuación 3 Cantidad de residuos no aprovechables (CRNA).....	51
Ecuación 4 Indicador de generación de residuos aprovechables (IGRA) .....	52
Ecuación 5 Tasa de aprovechamiento de vidrio (TAV).....	52
Ecuación 6 Tasa de aprovechamiento de papel y/o cartón (TAPC) .....	52
Ecuación 7 Tasa de aprovechamiento de plástico (TAP) .....	52
Ecuación 8 Tasa de aprovechamiento de metales (TAM).....	53

## INTRODUCCIÓN

Durante los últimos años las cifras mundiales de generación de basuras han presentado grandes incrementos y en Colombia, particularmente, solo el 12% del material producido ha sido reciclado [1], esta situación puso en evidencia la falta de real conciencia, pues como sociedad no se está dando una solución a este problema, es por esto que en este proyecto se desarrolló una herramienta útil que aporta a la generación de conciencia ambiental y apoya a las personas a reciclar adecuadamente desde su cotidianidad, por ejemplo, desde sus lugares de trabajo, auxiliados por algunas métricas estratégicas que incrementan el nivel de percepción del impacto que generan las basuras en el medio ambiente y tal vez, cómo estas podrían llegar a afectar nuestra calidad de vida, la de nuestras familias y amigos cercanos.

Con este proyecto se obtuvo un modelo de clasificación de imágenes que tiene la capacidad de reconocer los diferentes residuos que se generan diariamente y así permitir desechar la basura en los lugares adecuados y dispuestos para tal fin, innovando en la obtención de diferentes datos que aportan a realizar mediciones de impacto ambiental a nivel individual y grupal, proporcionando información clave para el desarrollo de futuras campañas de impacto ambiental y buscando diversos mecanismos y estrategias que promuevan el uso de esta herramienta y convierta a las personas en un aliado estratégico del medio ambiente con la tecnología como aliada.

## **1. DEFINICIÓN DEL PROBLEMA**

### **1.3. PLANTEAMIENTO DEL PROBLEMA**

Colombia presenta retos importantes en materia de gestión de residuos, se tienen objetivos de transición hacia ciudades circulares, lo que significa un mayor aprovechamiento de desechos sólidos para volver a ser utilizados en la producción de bienes. De acuerdo con el DANE, en Colombia se producen 24,8 millones de toneladas de residuos al año, de los cuales el 47% provienen de los hogares y se tiene una generación per cápita de 515 kilogramos [1]. A su vez la tasa de reciclaje, que se refiere a la proporción de material reciclado sobre la generación total de residuos sólidos, es cercana al 11,82% en el año 2019 [1]. Siendo esta una cifra muy baja comparada con la de otros países como Alemania donde llega al 68%.

En el país, además, se consumen 24 kilos de plástico por persona al año y de esa cifra el 56% es de un solo uso, es decir, pitillos, cubiertos, platos, tapas y envases, entre otros utensilios [2]. El bajo nivel de reciclaje desde la fuente de generación (casas y fábricas) genera una crisis en crecimiento en los rellenos sanitarios, dado que cada vez más se pierde capacidad de almacenamiento. El problema tiende a empeorar en los próximos años, pues se estima que 321 rellenos del país cumplirán su vida útil [2]. La Organización de las Naciones Unidas (ONU) ha comunicado que, si no se cambian las pautas de consumo y prácticas de gestión de desechos, se contribuirá a que en 2050 haya unos 12.000 millones de toneladas de basura plástica en vertederos y el medio ambiente en todo el mundo [3].

Ante este panorama alarmante, el gobierno de Colombia ha trabajado en reglamentar e incentivar políticas de reciclaje como el Decreto Único Reglamentario 1077 del 2015. En ese sentido, el decreto define la separación en la fuente como la clasificación de los residuos sólidos en aprovechables y no aprovechables por parte de los usuarios en el sitio donde se generan. En 2018 se publicó la Resolución 1407, con la cual el Gobierno reglamenta la gestión ambiental y establece el compromiso que tienen las empresas de recoger los empaques y envases de papel, cartón, plástico, vidrio y metal que ponen en el mercado, excluyendo los usados en el sector farmacéutico en medicamentos primarios o peligrosos.

Dichas medidas sin duda alguna generaran un cambio en la forma que se impacta el medio ambiente, pero no en la medida en la que se necesita, si no se involucra de una forma activa al principal actor en la contaminación del planeta, nosotros mismos como consumidores. Todos pueden vivir de forma más sostenible y ayudar a construir un mundo mejor para todos. Pero esto

no se va a lograr sí no se tiene conciencia de como los estilos de vida y las decisiones cotidianas impactan al medio ambiente; es apremiante generar conciencia en las personas de que al momento de comprar productos es importante considerar su durabilidad, sustentabilidad y facilidad de reciclaje.

Ante esta necesidad no cubierta aun de forma efectiva, se planteó el uso de la ciencia de datos para desarrollar un sistema de clasificación de imágenes de desechos con el fin de indicarle al usuario cual es la disposición adecuada del residuo para un adecuado reciclaje, pero que también mediante la recopilación del histórico del comportamiento del reciclaje se den señales del impacto ambiental al usar determinados productos; indicadores tales como tasa de reciclaje y huella de carbono son indicadores que tradicionalmente se llevan a la industria pero que a veces se dificulta su entendimiento para las personas del común, pero cuando se llevan a métricas desde nuestro consumo se puede generar más conciencia ambiental. Todos llevamos un celular capaz de tomar fotos, con lo cual tenemos una herramienta para educar y concientizar a muchas personas. Se planteó llevar esta solución a una aplicación móvil con la cual se puede incentivar su uso en los entornos corporativos como medida de trabajo hacia un mundo más sostenible.

En el estado del arte se puede encontrar desarrollos de procesamiento de imágenes de residuos enfocados inicialmente a la comparación de eficiencias en las técnicas de procesamiento de imágenes y en la automatización de procesos de reciclaje; así mismo, es posible evidenciar algunos inconvenientes con el procesamiento de imágenes, debido a que residuos como el papel y el cartón quedan mezclados en los desechos ocasionando su deterioro en algunos casos, lo que dificulta la aplicación de las tecnologías desarrolladas para apoyar al correcto depósito y aprovechamiento de los residuos [4], [5] y [6].

La aplicación de procesamiento de imágenes de residuos estuvo direccionada a unos de las áreas de impacto que tiene la ciencia de datos; cambiar la forma como se entiende los negocios y se interactúa con los clientes [4].

#### **1.4. FORMULACIÓN DEL PROBLEMA**

A partir de la recolección de imágenes de desechos de cada persona se plantea la siguiente pregunta: ¿Como desde la recopilación de información de imágenes de residuos y su clasificación automática podemos generar conciencia del impacto ambiental?

Las preguntas de sistematización del problema serían las siguientes:

- ¿Cuál es la mejor herramienta de inteligencia artificial que se puede utilizar para clasificar desechos sólidos?
- ¿Cuáles serán las características de las imágenes que permiten entrenar adecuadamente el sistema de clasificación?
- ¿Cuál es la infraestructura tecnológica necesaria para desarrollar el sistema de clasificación de imágenes y disponerlo para la enseñanza de las personas sobre un consumo sostenible?
- ¿Cómo se debe estructurar el sistema de clasificación de residuos para que sea útil en un entorno empresarial?

## **2. OBJETIVOS DEL PROYECTO**

### **2.1. OBJETIVO GENERAL**

Desarrollar una herramienta que permita clasificar imágenes de residuos de acuerdo con sus características y que permita conocer diversas métricas que aporten a la generación de conciencia ambiental.

### **2.2. OBJETIVOS ESPECÍFICOS**

- Preparar y depurar las imágenes de residuos para el entrenamiento, prueba y evaluación del modelo.
- Establecer el modelo de clasificación de imágenes con la técnica de inteligencia artificial más adecuada.
- Seleccionar los indicadores de impacto ambiental adecuados para el modelo y el problema a solucionar.
- Diseñar prototipo de aplicación móvil donde se desplegaría el modelo.

### **3. MARCO TEÓRICO Y ANTECEDENTES**

#### **3.1. MARCO TEÓRICO**

Contribuir a un mundo sostenible donde la ciencia de datos permita generar acciones desde lo individual, es una de las premisas de este trabajo al igual que crear conciencia ambiental en un entorno empresarial, por lo tanto, para el desarrollo del mismo a nivel técnico se propuso realizar un prototipo de aplicación de software encargada de hacer una clasificación de imágenes de residuos en tiempo real y recopilación de información histórica del reciclaje de cada usuario que permita la generación de indicadores, usando redes neuronales convolucionales y abarcando una de las áreas del Machine Learning que es el Deep Learning.

Antes de entrar a detallar los conceptos técnicos de este proyecto, es importante precisar que el reciclaje es de suma importancia, ya que el mismo supone la reutilización de elementos y objetos de distinto tipo que de otro modo serían desechados, contribuyendo a formar más cantidad de basura y, en última instancia, dañando de manera continua al planeta [7].

Es por esto, por lo que el prototipo de la aplicación para la clasificación de residuos hace más simple la correcta clasificación en los puntos ecológicos, estos puntos son zonas demarcadas y señalizadas que sirven para manejar correctamente los desechos. Un punto fijo de recolección con contenedores o canecas, identificadas con colores para almacenar cada tipo de residuos, que puede corresponder a conjuntos residenciales, instituciones educativas, hospitales, centros comerciales o culturales o en el caso de este proyecto, el sector empresarial [8].

Por otro lado la Organización Internacional de Normalización (ISO) publicó en el año 1996 la ISO 14001 donde se dan los lineamientos técnicos acerca de la gestión ambiental, por lo que antes del año mencionado se presentaba una falencia en políticas ambientales en el sector empresarial, y es que aunque el grado de concientización frente a estas problemáticas ha aumentado con el paso de los años como consecuencia de los fenómenos naturales que se han vivido y donde el impacto del ser humano hacia la naturaleza, gracias a su intervención y a su usufructo, ha generado repercusiones nocivas; aun hace falta crear mayor conciencia y hacer un llamado a las compañías para que enfoquen la adopción de comportamientos amigables con el medio ambiente como parte de su labor diaria, pues dicha conciencia no basta solo en la proceso de producción de las compañías, sino también en la capacitación de las personas que componen la organización.

Como lo indica la Universidad ESAN en su artículo de “¿Por qué incentivar la conciencia

medioambiental en el sector empresarial?” uno de los cambios urgentes de las empresas es analizar la cadena de valor para convertirla en una cadena de suministros sostenibles, garantizando una adecuada gestión de las materias primas, asegurando que estas no sean depredadas, si no por el contrario sean aprovechadas mediante la práctica de las 3 R’s (reduciendo, reciclando y reutilizando), de igual manera y es donde se enfocó el proyecto, se pretende promover un consumo responsable en los colaboradores de la empresa [9].

Ante esta situación identificada, se hace necesario abordar un poco el marco conceptual en tema de programación y de medio ambiente, para tener mayor entendimiento de los tecnicismos que a lo largo de este trabajo se pueden utilizar.

### **3.1.1. Herramientas para el procesamiento de imágenes**


Para poder lograr lo anterior y como se indicó inicialmente, este proyecto se fundamenta en el Machine Learning, refiriéndose a este como el aprendizaje automático, que permite que las maquinas aprendan sin ser expresamente programadas para ello. Una habilidad indispensable para hacer sistemas capaces de identificar patrones, toda vez que en este caso se abordarán patrones para el reconocimiento y procesamiento de imágenes [10].

### **3.1.2. ¿Qué es Deep Learning?**

El Deep Learning es un subcampo del Machine Learning en el cual se utilizan distintas redes neuronales para lograr el aprendizaje de sucesivas capas de representaciones cada vez más significativas de los datos, en general se suelen utilizar decenas o cientos de capas las cuales aprenden automáticamente a medida que un modelo es entrenado con los datos [11].

### **3.1.3. ¿Que son las redes neuronales?**

Las redes neuronales simulan el comportamiento del cerebro humano, permitiendo así a diferentes programas computacionales el reconocimiento de patrones y la resolución de problemas comunes en temas de Machine Learning.



*Ilustración 1 Redes neuronales [12]*

Como se observa en la *Ilustración 1*, estas redes neuronales están compuestas por capas de nodos, que contienen una capa de entrada, una o más capas ocultas, y una capa de salida. Cada nodo, o neurona artificial, se conecta a otro y tiene un peso y un umbral asociado. Si la salida de cualquier nodo individual está por encima del valor del umbral especificado, dicho nodo se activa, enviando datos a la siguiente capa de la red, de lo contrario, no se pasan datos a la siguiente capa [12].

#### 3.1.4. Python y sus principales librerías para procesamiento de imágenes

Python es un lenguaje de programación de alto nivel y multiparadigma soportando la orientación a objetos, programación imperativa y programación funcional. A diferencia de otros lenguajes de programación orientada a objetos, este es interpretado, es decir que no necesita compilarse para ejecutar su código. Se caracteriza por usar tipado dinámico, es open source y es multiplataforma. El Framework Tensorflow y la librería de alto nivel Keras, utilizados para el entrenamiento de redes neuronales, son APIs que pueden ser integradas en Python, siendo esta la razón de la elección para la utilización en este proyecto [13].

- **Librería TensorFlow:** Es una biblioteca de Python para computación numérica rápida, creada y lanzada por Google. Según su página web oficial, TensorFlow facilita la creación de modelos de aprendizaje automático, ofreciendo una colección de flujos de trabajo para entrenar y desarrollar modelos mediante Python, se puede implementar con facilidad en la nube, en el navegador de forma local o en el dispositivo que se use [14].
- **Librería Keras:** Es una biblioteca de código abierto utilizada para crear redes neuronales, está escrita en Python y su objetivo es acelerar la creación de redes

neuronales, funciona como API que permite acceder a varios frameworks de aprendizajes automáticos y desarrollarlos [15].

### 3.1.5. Conceptos básicos de reciclaje

Es importante resaltar que el tratamiento de reciclaje puede llevarse a cabo de manera total o parcial, según esto, con el uso de algunos materiales, es posible obtener una materia prima, mientras que con otros se pueden generar nuevos productos, a continuación, se presentaran dos conceptos claves en este tema:

- **Definición de las 3R:** Estas 'R' hacen referencia a reducir, reutilizar y reciclar, una propuesta fomentada inicialmente por la organización GreenPeace que promueve tres pasos básicos para disminuir la producción de residuos y contribuir a la conservación del medio ambiente, cambiando hábitos de consumo, haciéndolos responsables y sostenibles [1] . A continuación, se muestran algunos ejemplos:
  - **Reducir:**
    - Comprar menos.
    - Sustituir bolsas de plástico.
    - Escoger productos cuyo proceso de embalaje este fabricado con materiales que puedan ser reciclados fácilmente.
  - **Reutilizar:**
    - Reutilizar el agua que se utiliza para lavar verduras y frutas, para regar plantas o lavar el suelo.
    - Reutilizar el agua procedente de los desagües de lavadoras o bañeras, para el uso de cisternas.
  - **Reciclar:**
    - Seleccionar y separar desechos que se generan en el hogar, utilizando bolsas de basura de diferentes colores y varias canecas para depositar los residuos generados.
- **Clasificación de canecas:** El manejo adecuado de las basuras es un tema al que cada vez se le presta mayor atención debido a la masiva producción de desechos, por lo tanto, se dispone de la caneca blanca para los residuos aprovechables, la caneca verde para los residuos orgánicos aprovechables y la

caneca gris para el material contaminado. A continuación, se presentan en las ilustraciones 1, 2 y 3 el tipo de residuo que debe ir en cada caneca según su origen y especificación:



Ilustración 2 Código de colores residuos aprovechables [1]



Ilustración 3 Código de colores residuos orgánicos [1]



*Ilustración 4 Código de colores residuos no aprovechables [1]*

### 3.1.6. Normatividad de referencia

La norma de Sistemas de Gestión Ambiental (SGA), llamada también ISO 14001, logra que las empresas puedan demostrar su responsabilidad ambiental y que se encuentran comprometidas con la sostenibilidad ambiental y la gestión de riesgos medioambientales que son inherentes al desarrollo de la actividad empresarial. Esta norma aporta a las organizaciones la posibilidad de alinear sus procesos con la buena imagen corporativa, la sostenibilidad y respeto por el medio ambiente y el posible incremento de sus ventas a futuro de acuerdo con la ilustración 5; toda vez que hoy en día el impacto que tiene el buen manejo del medio ambiente dentro de una compañía puede generar valorización de estas y dicho aumento afecta positivamente la imagen corporativa, debiendo ser reconocida en las Normas Internacionales de Información Financiera (NIIF)[16].

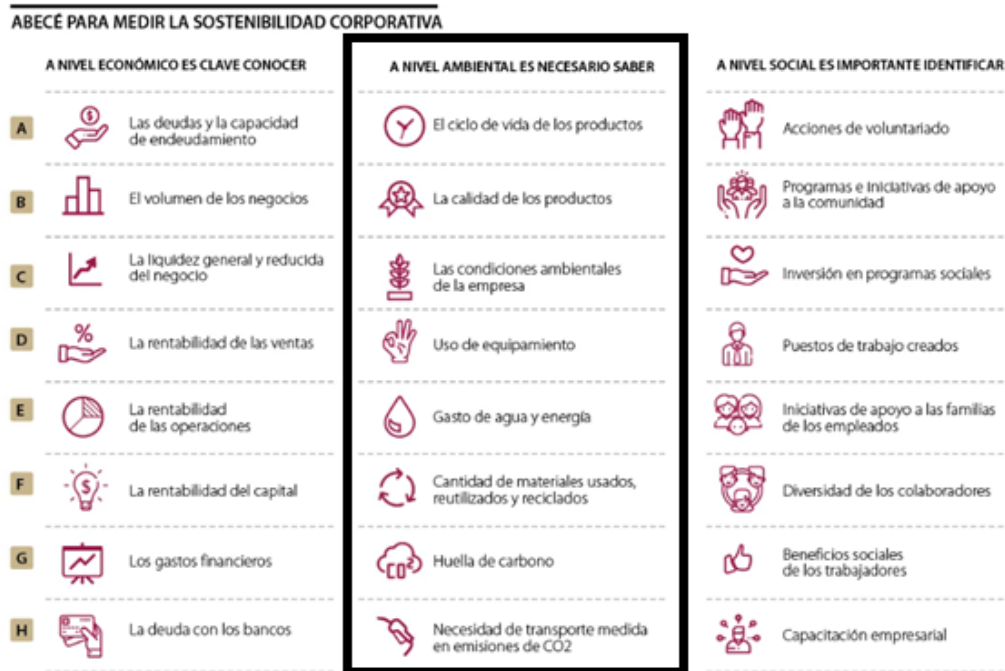


Ilustración 5 Abecé para medir la sostenibilidad corporativa [17][16]

## 3.2. ANTECEDENTES

Se realizó una revisión de trabajos desarrollados en relación con la clasificación de residuos con procesamiento de imágenes, trabajos en donde se resaltan aplicaciones en las cuales un robot clasifica los residuos y permite una clasificación óptima; igualmente, se identifican desarrollos en procesamiento de imágenes de drones para identificar zonas contaminadas con plástico. Otros trabajos se centran en el desarrollo técnico de clasificación de imágenes y comparación de métricas de rendimiento de diferentes técnicas. Adicionalmente, de lo investigado se evidencia que no existen aplicaciones en las que el procesamiento de imágenes lleve métricas de usuarios y cómo estas permitirían a las empresas obtener información para definir políticas de sensibilización sobre el impacto del consumo y del reciclaje. A continuación, se presentan los trabajos desarrollados en relación a la clasificación de residuos y generación de conciencia ambiental en las organizaciones por medio de apoyos tecnológicos.

### 3.2.1. Procesamiento de imágenes de residuos

- **Aprendizaje automático aplicado al procesamiento de imágenes para la clasificación de objetos reciclables:** El presente proyecto se basa en la utilización de técnicas de Deep

Learning, específicamente se realizó el modelado de redes neuronales convolucionales (CNN), capaces de clasificar distintas imágenes de objetos reciclables. Estos modelos fueron probados con una clasificación binaria (reciclable y no reciclable) y una clasificación multiclase (plástico, vidrio, metal, papel, cartón, orgánico y no reciclable). Además, se realizaron pruebas con modelos pre entrenados, utilizando aprendizaje por transferencia (Transfer Learning) para comparar resultados. Estos modelos fueron implementados utilizando como lenguaje de programación Python, apoyándose en el Framework de backend TensorFlow y la librería de alto nivel Keras. El modelo final se probó en una aplicación (beta) implementada también en Python sobre un minicomputador Raspberry Pi y un módulo de cámara (picam) en donde se toman fotos y se aplica el modelo para realizar una clasificación en tiempo real[4].

- **Trash and Recycled Material Identification using Convolutional Neural Networks (CNN):** El objetivo de esta investigación fue mejorar la recolección de basura utilizando algoritmos de procesamiento de imágenes y aprendizaje profundo y tecnologías para la detección de basura en espacios públicos. Esta investigación ayuda a mejorar los sistemas de gestión de basura y a crear una ciudad inteligente. Dos redes neuronales convolucionales (CNN), ambas basadas en la Arquitectura de red AlexNet, fueron desarrollados para buscar basura en una imagen y separar los elementos reciclables del vertedero de basura, respectivamente. El sistema CNN de dos etapas fue el primero entrenado y probado en el conjunto de datos de imágenes interiores TrashNet de referencia y logró un gran rendimiento para probar el concepto, así que el sistema fue entrenado y probado en imágenes al aire libre tomadas por los autores en el entorno de uso previsto. Usando el conjunto de datos de imágenes al aire libre, la primera CNN logró una precisión preliminar del 93,6%. Luego se entrenó a CNN para distinguir la basura que irá a un vertedero de los artículos reciclables con una precisión que va del 89,7% al 93,4% y en general 92%. Un objetivo futuro es integrar este procesamiento de imágenes de identificación de basura basado en un robot inteligente de basura con un cámara para tomar fotos en tiempo real que pueden detectar y recoger los residuos que estén a su alrededor [5].
- **Sistema EGREEN. Patentada en España por Environmental Green Engineering:** Sistema basado en visión artificial multispectral y tecnologías complementarias, para la separación de residuos sólidos urbanos, por medio de sensores ópticos e implementados en plantas de tratamiento de residuos. Esta técnica de visión artificial multispectral, promete ser una solución viable para el reciclaje, en la que se disponen sensores ópticos, bajo la gestión de inteligencia artificial [6].

- **Drones para el cuidado del medio ambiente:** Investigadores del Instituto Tecnológico de Boca del Río, que pertenece al Tecnológico Nacional de México, trabajaron monitoreando playas a través de drones y el escaneo de imágenes mediante un software, para conocer la cantidad de plásticos desechados. Este proyecto busca principalmente medir la cantidad de desechos y realizar una clasificación, por cuadrantes, donde inicialmente hacen una caracterización de residuos, luego a través del uso de drones, se realiza la captura de imágenes, en las que se identifican los residuos, particularmente PET. El reconocimiento de imágenes se realiza mediante el uso del software Matlab y algoritmos de reconocimiento e integración con redes neuronales [7].

### 3.2.2. Conciencia del impacto ambiental desde el consumo de productos

Se realizó la búsqueda referente al desarrollo de generación de conciencia ambiental, utilizando métodos modernos e innovadores que aportaran al fortalecimiento del conocimiento de las personas respecto a la correcta clasificación de los residuos, y los impactos y beneficios que esto trae al planeta y a nuestras vidas.

- **Reduce, Reuse, Recycle (3Rs) Awareness App:** En un trabajo realizado por integrantes de la Universidad Utara en Malasia, fue posible el desarrollo de una App que facilitara por medio del aprendizaje didáctico, el conocimiento a un segmento específico de la población. Por medio de una estructura simple de aprendizaje, la App aportaba al conocimiento por medio del método ADDIE por sus siglas en inglés, lo cual significa analizar, diseñar, desarrollar, implementar y evaluar, y los usuarios, por medio de un juego de preguntas, lograban adquirir información relevante e importante acerca de la importancia del reciclaje e invitaba a este mismo segmento poblacional a reciclar conscientemente [16].

De acuerdo con lo anterior, es posible evidenciar que han existido esfuerzos para aportar conocimientos a las personas, sin embargo, el trabajo indicado anteriormente se focalizó en los niños de una escuela en Malasia y esta propuesta se alinea a la generación de conciencia ambiental pero enfocado en el sector empresarial, ya que tiene como línea de trabajo aportar al recurso humano de las compañías una herramienta que apoye el reciclaje y que estimule la participación de estas personas en el cuidado del planeta.

- **Mobile Augmented Reality for Environmental Awareness:** Por medio de la realidad aumentada los desarrolladores de este proyecto buscan generar conciencia ambiental a los usuarios, simulando las tareas del día a día de las personas, observan el comportamiento de los individuos respecto a la generación de basuras y su posterior clasificación. De acuerdo con los datos observados durante la simulación virtual, la App recolecta información importante para el análisis de comportamientos de los individuos y la posterior generación de planes de acción de acuerdo con indicadores que promuevan y aporten la disminución de su huella ecológica [18][16].

En general, este proyecto promueve el aprendizaje en las personas en temas medioambientales con el objetivo de contribuir a la disminución de su huella ecológica. Este estudio fue desarrollado con personas escogidas aleatoriamente y como se ha mencionado anteriormente, se busca brindar conocimientos a personas del sector empresarial que a su vez podrían trasladar el conocimiento a sus familiares y personas cercanas.

## 4. PREPARACIÓN Y RECOPIACIÓN DEL DATASET DE IMÁGENES DE RESIDUOS

El proceso de adquisición de datos se realizó con algunas fotos tomadas con dispositivos móviles y de repositorios abiertos tales como: Kaggle, Taco y TrashNet , estas imágenes se encuentran en entornos controlados o semicontrolados y fueron cargadas en Google Fotos con el fin de facilitar la conexión con el código desarrollado en Colab. Se buscó que el fondo en el que se tomaran fuera de color blanco o en su defecto un color uniforme, evitando fotos en entornos altamente variantes. Esta decisión se tomó teniendo en cuenta que el propósito es la detección del residuo y su respectiva clasificación, no siendo de interés el entorno en el que se encuentra el residuo.

Para poder robustecer el data set inicial se procedió a usar la técnica de Data Augmentacion para aumentar tanto el tamaño como la diversidad de los datos de entrenamiento, mejorando así la precisión y controlando un posible overfitting a través del argumento `rotation_range` donde de manera aleatoria la imagen se rotó en el sentido de las agujas del reloj dentro de un rango determinado de 0 a 360 grados.

Posteriormente, Se implementaron dos sets de datos, el primero con dos categorías (aprovechable y no aprovechable) y el segundo (aprovechables) con 4 categorías (papel – cartón, plástico, metal y vidrio). A continuación, se detalla cada uno de ellos:

### 4.1. CLASIFICACIÓN BINARIA

En este caso los datos fueron divididos en 2 categorías (aprovechables y no aprovechables), la cantidad total de imágenes de este set es de 14.649 imágenes balanceadas en ambas clases, es decir, para la categoría aprovechables 7.749 imágenes y para no aprovechables 6.900 imágenes; a su vez, se dividieron los datos en dos partes separando el 20% de las imágenes para la validación y el 80% de las imágenes utilizadas para el entrenamiento del modelo. Antes de ser usadas en la construcción del modelo como entradas, se realizó un ajuste del tamaño de las fotos por medio de código llevándolas a un tamaño de 250 x 250 píxeles. A continuación, un ejemplo de las fotos utilizadas:



*Ilustración 6 Residuo no aprovechable*



*Ilustración 7 Residuo aprovechable*

## 4.2. CLASIFICACIÓN MULTICLASE

En este caso los datos fueron divididos en 4 categorías (papel - cartón, metales, vidrio y plástico), la cantidad total de imágenes de este set es de 10.400 imágenes balanceadas en todas las clases, es decir, cada una de las cuatro clasificaciones tienen 2.600 imágenes; a su vez, se dividieron los datos en dos partes separando el 20% de las imágenes para la validación y el 80% de las imágenes utilizadas para el entrenamiento del modelo. A continuación, un ejemplo de las fotos utilizadas:



*Ilustración 8 Residuo aprovechable - vidrio*



*Ilustración 9 Residuo aprovechable - metal*



*Ilustración 10 Residuo aprovechable – plástico*



*Ilustración 11 Residuo aprovechable - papel, cartón*

## **5. METODOLOGIA DE DEEP LEARNING**

### **5.1. TÉCNICAS DE INTELIGENCIA ARTIFICIAL PARA EL PROCESAMIENTO DE IMÁGENES**

A continuación, se presentan las técnicas de inteligencia artificial más usadas en el procesamiento digital de imágenes:

#### **5.1.1. Lógica difusa**

La lógica difusa es una técnica de inteligencia computacional que permite trabajar con información de alto grado de imprecisión, es una lógica multivaluada que permite valores intermedios para poder definir evaluaciones entre si/no, verdadero/falso, negro/blanco, etc. Este concepto fue concebido por el profesor de la universidad de California en Berkeley, Lofti A. Zaded, quien disconforme con la teoría de los conjuntos clásicos que solo permiten dos opciones, la pertenencia o no de un elemento a dicho conjunto, presentó la idea como una forma de procesar información permitiendo pertenencias parciales a unos conjuntos, que en contraposición a los clásicos denominó conjuntos difusos [19].

En el tema de procesamiento de imágenes mediante lógica difusa, se tiene que esta es una técnica informática, que permite manipular imágenes en formato digital a través de conjuntos difusos. Este procesamiento incluye tres etapas principales: fusificación de imagen, modificación de una función de pertenencia y una defusificación de imagen si es necesario. La mayor parte del proceso depende de la modificación de los valores de pertenencia. El procesamiento de las imágenes no sigue un solo procedimiento, sino que se siguen diferentes enfoques, debido a que la lógica difusa permite aplicar una gran variedad de reglas a una misma situación, por lo tanto, la condición más famosa que se utiliza en las imágenes es el color o el tamaño de los objetos [20].


#### **5.1.2. Inteligencia de enjambre**

Este sistema corresponde a un grupo de técnicas que están basadas en el estudio del comportamiento colectivo de sistemas autoorganizados y distribuidos, inspirados en grupos de animales que realizan acciones conjuntas para cumplir con una tarea específica. Muchos modelos se han implementado con base al funcionamiento de grupo de trabajo colectivo entre los que se encuentra las colonias de hormigas, abejas, crecimiento bacteriano, grupo de aves, y peces [21].

La segmentación de imágenes es el proceso en el cual se divide una imagen en múltiples segmentos de píxeles, el modelo FABC creado por Ankita Bose y Kalyani Mali, es una combinación entre una colonia de abejas con funciones de pertenencia difusas, aquí el algoritmo de trabajo se basa en la colonia de abejas buscando en la imagen los diferentes grupos de intensidad con base a estos los valores de las funciones de pertenencia del conjunto difuso se van modificando. Una vez el algoritmo deje de detectar cambios de intensidad, los píxeles de la foto serán asociados al grupo más cercano [22].

La siguiente gráfica muestra el resultado de una segmentación a color y otra con escala de grises. Se puede observar como el algoritmo desarrollado (FABC) puede diferenciar más regiones tanto en color como en escala de grises, en comparación a los métodos de optimización por enjambre de partículas PSO, algoritmos genéticos GA y expectativa de maximización EM.


Donde: (a) Imagen original, segmentación por (b) FABC, (c) PSO, (d) GA y (e) EM.



*Ilustración 12 Inteligencia de enjambre [23]*

### 5.1.3. Redes neuronales artificiales

Este proyecto se enfoca en este tipo de técnica para poder realizar el procesamiento de imágenes adecuadas a las necesidades y requerimientos, y es que las redes neuronales como se nombró anteriormente, es un modelo simplificado de inteligencia artificial que enseña a las computadoras a procesar datos emulando el modo en el que el cerebro humano procesa la información. Las unidades de procesamiento se organizan en capas, estas redes se organizan de la siguiente manera [24]:



*Ilustración 13 Modelo de redes neuronales [25]*

- **Capa de entrada** con unidades que representan los campos de entrada. Aquí la información del mundo exterior entra a la red neuronal artificial y los nodos de entrada procesan los datos, analizan o clasifican y los pasan a la siguiente capa.
- **Capas ocultas** (puede ser una o varias). Se toma la información de la capa de entrada y cada capa oculta analiza la salida de la capa anterior, hace un procesamiento más detallado y la pasa a la siguiente capa.
- **Capas de salida** con una o unas unidades que representan los campos destino. Esta capa de salida proporciona el resultado final de todo el procesamiento de datos que realiza la red neuronal artificial. Cuenta con uno o varios nodos, ej. si se tiene un problema de clasificación binaria (Si/No), la capa de salida tendrá un nodo de salida que dará como resultado un 1 o 0 [26].

Aquí los datos de entrada se presentan en la primera capa, donde los valores se propagan desde cada neurona hasta cada neurona de la capa siguiente, al final se envía un resultado desde la capa de salida [24].

Este tipo de machine learning llamado aprendizaje profundo o Deep learning, crea un sistema adaptable que las computadoras utilizan para aprender de sus errores y mejorar continuamente, de esta forma las redes neuronales artificiales intentan resolver problemas complicados como la realización de documentos y reconocimiento de imágenes con mayor precisión, estas redes pueden ayudar a tomar decisiones inteligentes con poca asistencia humana, esto es posible gracias a que aprenden y modelan relaciones entre datos de

entrada y salida que no son lineales y que pueden llegar a ser complejos [26].

### 5.1.3.1. Tipos de redes neuronales

- **Redes neuronales prealimentadas:**

Este tipo de redes procesan los datos en una sola dirección, desde el nodo de entrada al nodo de salida, todos los nodos de una capa están conectados a todos los nodos de capa siguiente. Una red prealimentada utiliza el proceso de retroalimentación para mejorar sus predicciones a largo tiempo [27].

- **Perceptrón:**

Esta es la red neuronal en su forma original y la más sencilla debido a que es una red de una sola neurona que se modifica mediante ponderaciones y según el valor de su umbral [27].

- **Redes neuronales convolucionales:**

Las capas ocultas de las redes convolucionales realizan funciones matemáticas específicas, como la síntesis o el filtrado (denominado convoluciones), son muy útiles para la clasificación de imágenes porque tienen la propiedad de extraer características relevantes de la imagen que son útiles para el reconocimiento y la clasificación. Cada capa oculta extrae y procesa diferentes características de la imagen, como los bordes, el color y la profundidad [26].

**Características:**

- La red se estructura en capas de convolución y capas de agrupación, a cada una de estas capas le corresponde un tipo de neurona diferente, las convoluciones se encargan de extraer patrones de los datos de entrada y las agrupaciones se encargan de crear invariancia traslacional en esos patrones. Cada una de esas capas se compone a su vez de un cierto número de mapas de características [28].

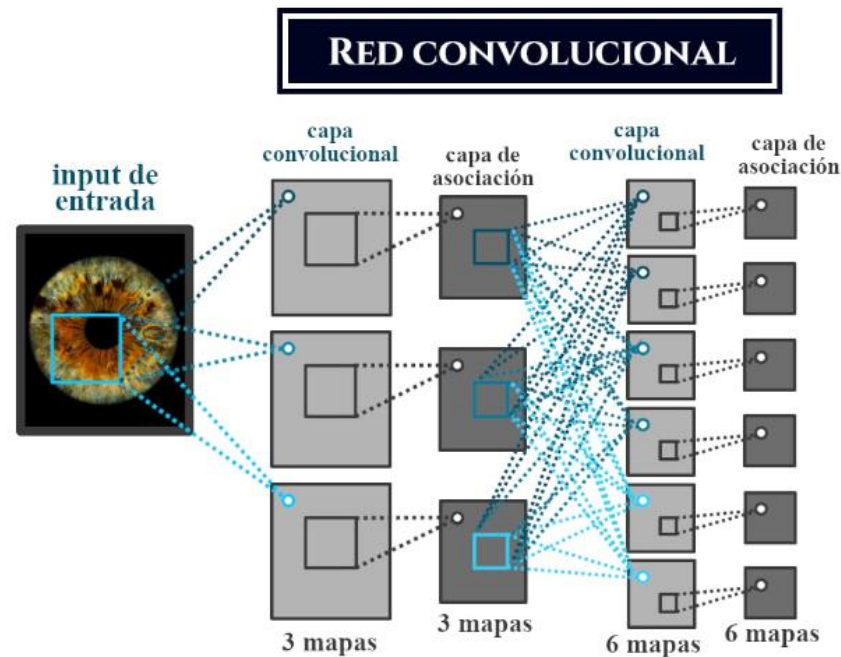


Ilustración 14 Funcionamiento redes neuronales [28].

- Las neuronas de ambos tipos de capas tienen un campo excitatorio, que constituye un subconjunto de los datos de entrada. En los sistemas de reconocimiento visual, este campo suele ser una región rectangular de  $n \times m$  píxeles. El conjunto de células de cada mapa cubre el campo visual de la entrada al completo, como se ve en el siguiente gráfico una de las neuronas de un mapa de segmentación de  $4 \times 4$  recibe su input de 9 neuronas pertenecientes a un campo excitatorio de  $3 \times 3$  que es una sección de un mapa de segmentación de la capa previa [28].

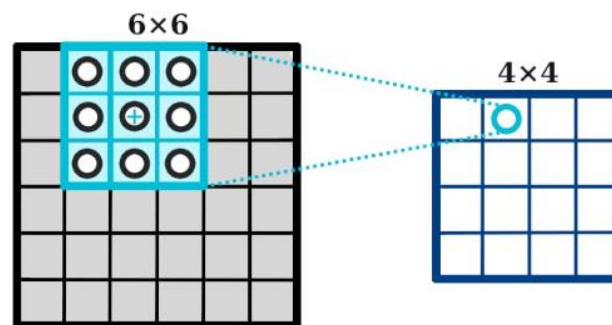


Ilustración 15 Funcionamiento redes neuronales matricial.

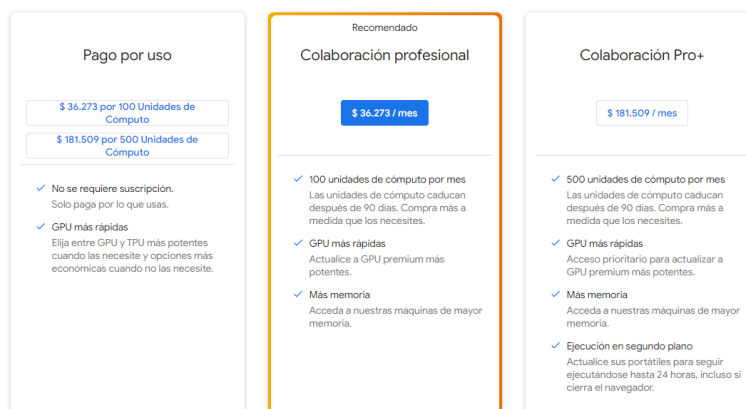
- Todas las neuronas convolucionales de un mismo mapa de características poseen el mismo número de conexiones y el mismo conjunto de pesos sinápticos, este conjunto común recibe el nombre de Kernel [28].

## 5.2. SELECCIÓN DE HERRAMIENTA COMPUTACIONAL

Después de validar varias herramientas como Kaggle, Visual Studio Code, Anaconda, Pycharm, se decidió hacer uso de Google Colab Pro para implementar toda la arquitectura de las redes neuronales que se realizaron, ya que esta herramienta es un servicio en la nube producto de Google Research, que permite a cualquier usuario escribir y ejecutar código de Python en el navegador, esta adecuado para tareas de aprendizaje automático y análisis de datos. Colab es un cuaderno que provee de una Jupyter Notebook que no requiere configuración ya que el código se ejecuta en una máquina virtual asociada a la cuenta. Tiene grandes ventajas [29]:

- Posibilidad de activar una GPU.
- Posibilidad de compartir el código fácilmente.
- Tiene preinstaladas librerías comunes usadas en datascience y la posibilidad de instalar las que se requieran usar.
- Permite enlazar la cuenta de Google Drive, lo que facilita la lectura de los dataset para la construcción de las redes neuronales.
- Se integra fácilmente con Github.
- Debido a que Colab está basado en la nube, se tiene un control de versión automático.

Por lo tanto, aunque se tiene la opción de trabajar en un ambiente de desarrollo local, se tomó la decisión de programar y trabajar en la nube por temas de practicidad y eficiencia, debido a que se puede tener el ambiente listo en pocos segundos gracias a las máquinas virtuales que ofrece Google sin necesidad de instalar, ejecutar o actualizar el hardware de la computadora, y teniendo acceso a los beneficios de infraestructura informática como almacenamiento, memoria, capacidad de procesamiento, unidades de procesamiento gráfico (GPU) y unidades de procesamiento de tensor (TPU). Siendo una excelente opción para trabajos de codificación colaborativa grupal como este y a un precio accesible siguiendo los recursos financieros estipulados inicialmente para la ejecución de este proyecto.



The image shows three pricing options for Google Colab:

- Pago por uso:** \$ 36.273 por 100 Unidades de Cómputo and \$ 181.509 por 500 Unidades de Cómputo. Features include no subscription required and faster GPUs.
- Recomendado Colaboración profesional:** \$ 36.273 / mes. Features include 100 units of compute per month, faster GPUs, and access to higher memory machines.
- Colaboración Pro+:** \$ 181.509 / mes. Features include 500 units of compute per month, faster GPUs, access to higher memory machines, and execution in the second plane.

*Ilustración 16 Herramienta tecnológica*

### **5.3. CONSTRUCCIÓN, ENTRENAMIENTO, ELECCIÓN Y PRUEBAS DEL MODELO**

A continuación, se detalla todo el proceso realizado para la selección de las arquitecturas utilizadas para la realización del modelo, métricas obtenidas, entrenamiento y pruebas de este.

#### **5.3.1. Arquitecturas de redes convolucionales utilizadas**

##### **5.3.1.1. ResNet**

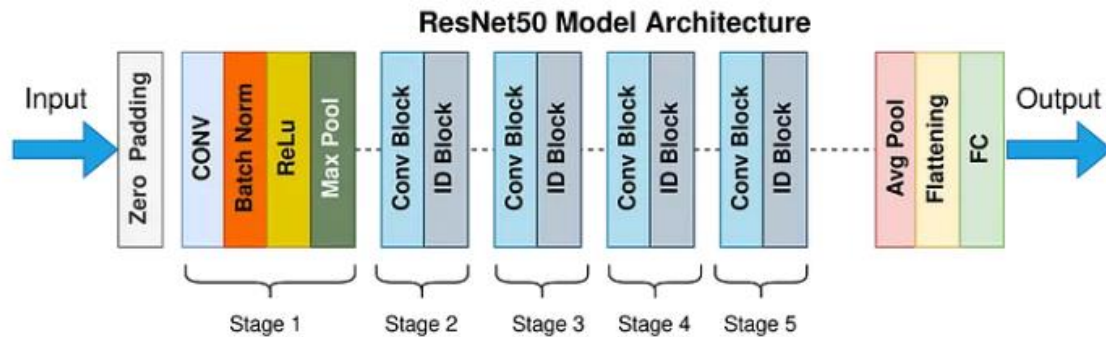
La red neuronal residual también conocida como ResNet fue propuesta en el año 2015 por investigadores de Microsoft Research, la diferencia de esta arquitectura a las otras propuestas es que se pretende resolver el problema de gradiente<sup>1</sup> de desaparición/explosión, el cual se fundamenta que al aumentar la cantidad de capas dentro de la red la tasa de error de entrenamiento y prueba también [30].

Para resolver este problema del gradiente que desaparece o explota, la arquitectura de ResNet introdujo el concepto llamado Bloques Residuales, en donde se utiliza una técnica para saltar conexiones permitiendo así generar conexiones de activación de una capa con otra omitiendo capas intermedias formando los bloques residuales. Estas redes generan atajos para saltar dos o tres capas para hacer el proceso más rápido, haciendo que el atajo cambie la forma en que se calcula los gradientes de cada capa, esto hace simplificar las cosas ya que se pasa la entrada por la salida evitando que algunas capas cambien los valores del gradiente, lo que significa que se puede saltar el procedimiento de aprendizaje para algunas capas específicas y así, cuando se está entrenando la red, el modelo capta el concepto de retener las capas útiles y no hacer uso de las que no ayudan [31].

En temas de arquitectura, se puede indicar que esta red ha sido de gran utilidad para aumentar el rendimiento de las redes neuronales con múltiples capas, en su núcleo las ResNet son como varias redes con pequeñas modificaciones, esta es una arquitectura de red simple de 50 capas inspirada en el diseño de la VGG-19 en la que luego se agrega la conexión de acceso directo. Estas conexiones de acceso directo luego convierten la arquitectura en una red residual [30].

---

<sup>1</sup> Se entiende por gradiente al cálculo que nos permite saber cómo ajustar los parámetros de la red de tal forma que se minimice su desviación a la salida[33].



*Ilustración 17 Arquitectura Modelo ResNet [32]*

Para su implementación se usó la Api de Tensorflow y Keras .A continuación se describe el detalle técnico del modelo implementado tanto para la red binaria como para la red multiclase. El primer bloque de código usado crea un bloque de identidad con una conexión atajo sobre tres capas y una activación ReLu, posteriormente se procede a hacer la creación del modelo con las siguientes características:

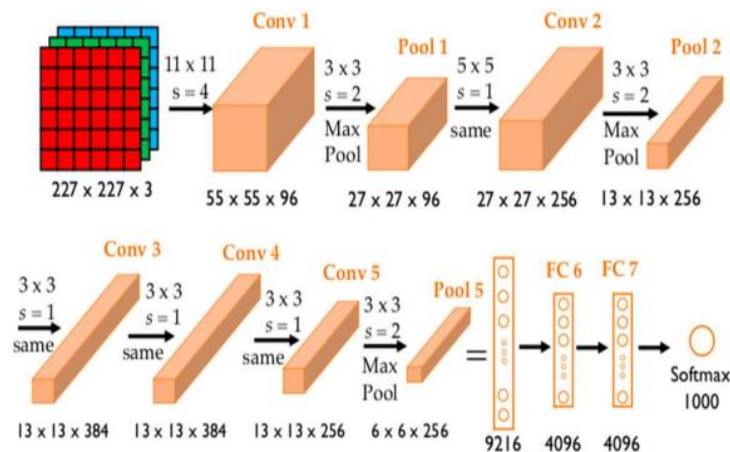
- Zero-padding rellena la entrada con un pad de (3, 3).
- Etapa 1:
  - La Convolution 2D tiene 64 filtros de dimensiones (7, 7) y usa un stride de (2, 2).
  - BatchNorm es aplicado al eje de los canales de la imagen de entrada.
  - MaxPooling usa una ventana de (3, 3) y un stride de (2, 2).
- Etapa 2:
  - El bloque convolucional usa tres conjuntos de filtros de tamaño (64, 64, 256), "f" es 3, "s" es 1.
  - Los 2 bloques identidad usan tres conjuntos de filtros de tamaño (64, 64, 256), "f" es 3.
- Etapa 3:
  - El bloque convolucional usa tres conjuntos de filtros de tamaño (128, 128, 512), "f" es 3, "s" es 1.
  - Los 3 bloques identidad usan tres conjuntos de filtros de tamaño (128, 128, 512), "f" es 3 y "s" es 2.
- Etapa 4:
  - El bloque convolucional usa tres conjuntos de filtros de tamaño (256, 256, 1024), "f" es 3, "s" es 1.
  - Los 5 bloques identidad usan tres conjuntos de filtros de tamaño (256, 256, 1024), "f" es 3 y "s" es 2.
- Etapa 5:
  - El bloque convolucional usa tres conjuntos de filtros de tamaño (512, 512, 2048), "f" es 3, "s" es 1.
  - Los 5 bloques identidad usan tres conjuntos de filtros de tamaño (512, 512, 2048), "f" es 3 y "s" es 2.

- La capa Average Pooling 2D usa una ventana de dimensiones de (2, 2).
- La capa de aplanamiento no tiene ningún hiperparámetro.
- La capa Fully Connected reduce la entrada al número de clases utilizando una activación "softmax".

### 5.3.1.2. AlexNet

Hoy en día, las redes neuronales convolucionales se consideran uno de los algoritmos de inteligencia artificial más importantes para el procesamiento de imágenes.

El modelo AlexNet está considerado entre los modelos más famosos de redes convolucionales. Este modelo fue desarrollado por el investigador Alex Krizhevsky, ganador del concurso de la ImageNet Large Scale Visual, desafío de reconocimiento (ILSVRC) en 2012. En la siguiente figura se ilustra la arquitectura de esta red.



*Ilustración 18 Arquitectura ALEXNET [34]*

Cuatro operaciones en las que se basa el modelo AlexNet son [34]:

1. Convolución o filtrado: utilizado para extracción de características
2. No linealidad (usando la función ReLU): usado para cambiar los valores negativos a cero.
3. Pooling o sub-sampling: utilizado para reducir las dimensiones
4. Capa totalmente conectada: Características finales introducidas en el clasificador

El clasificador se compone de 5 capas convolucionales y 3 totalmente conectadas. En primer lugar, el algoritmo de normalización por lotes se aplica a las capas convolucionales para acelerar

la convergencia de la red profunda. En segundo lugar, cada capa convolucional normalizada es seguida por capas ReLU para mejorar la eficiencia de cálculo y capas de agrupación máxima para evitar el sobreajuste. En tercer lugar, el método de abandono se aplicó aún más a la capa totalmente conectada para reducir el sobreajuste, y la función Log\_softmax se aplicó para lograr los resultados finales de la clasificación.

### **5.3.1.3. Modelo propio**

El modelo propio desarrollado para ser evaluado en su desempeño, junto con las dos metodologías expuestas anteriormente se encuentra fundamentado en las redes convolucionales para la clasificación de imágenes, detección de objetos, búsqueda de imágenes, segmentación y combinación de características entre diferentes imágenes.

Las CNN es una red neuronal profunda, la cual cuenta entre sus capas con la capacidad de operar la convolución que realiza matrices de la imagen evaluada y otra matriz llamada kernel, utilizada para obtener las condiciones o características del borde y enfoque. En general, la estructura de la CNN se compone por los siguientes elementos: entrada, convolución, pooling, ReLU, capa conectada y capa de salida. En esta estructura las capas de convolución y reducción pueden repetirse las veces que sean necesarias dependiendo del modelo y son utilizadas para extraer las características más relevantes de cada una de las imágenes utilizadas para modelar, probar y evaluar el modelo de clasificación de residuos.

Finalmente, la capa de salida evidencia la probabilidad de que la imagen que se añadió a la entrada corresponda a un residuo aprovechable o no aprovechable en el caso del modelo propio binario realizado y para el modelo multiclase si es papel\_carton, plástico, vidrio o metal. Es importante aclarar que para el modelo binario se utilizó la función “sigmoid” y para el multiclase la función “softmax”.

A continuación, se refleja un ejemplo de cómo se podría ver gráficamente el funcionamiento de la red propia desarrollada. En la red binaria se contó con cinco capas convolucionales cada una acompañada por su capa pooling y ReLU, posteriormente una capa flatten la cuál convierte las imágenes de tamaño 250x250 utilizadas en un array de una dimensión del mismo tamaño, una capa dense que se encuentran totalmente conectadas a nuestra función de activación ReLU y una capa dropout que ayuda a reducir el overfitting desactivando aleatoriamente neuronas durante el entrenamiento. En la red multiclase se contó con tres capas convolucionales acompañadas por su capa pooling y ReLU, una capa flatten, una capa dense y una capa dropout.




Ilustración 18 Arquitectura red propia [32]

### 5.3.2. Entrenamiento y elección de la arquitectura a implementar

Es importante recordar que el sistema empresarial inteligente para la clasificación de residuos está compuesto por dos modelos que tienen como objetivo clasificar la imagen de un residuo en aprovechable o no aprovechable, es por esto, por lo que se desarrolló un modelo binario que realiza esta clasificación inicial y posteriormente por medio de un modelo multiclase se clasifica en papel – cartón, vidrio, plástico o metal.

Nuestro modelo con redes neuronales convolucionales se realizó desde cero, es decir, no hubo uso de técnicas como transfer-learning o fine-tuning, lo que significó un mayor reto para el desarrollo de este proyecto, sin embargo, permitió tener una comprensión más profunda de los detalles y el funcionamiento interno de las CNN, para esto se efectuó una preparación de datos para el entrenamiento de la red neuronal. Posteriormente, se implementó las dos arquitecturas seleccionadas (ResNet y AlexNet), donde se definió de manera individual por cada arquitectura el número y tipo de capas que se iban a utilizar, como capas convolucionales, capas pooling y capas completamente conectadas, también se determinaron los tamaños de los filtros, las funciones de activación y otros parámetros relacionados.

Luego se hizo el entrenamiento, durante este proceso el modelo ajustó de manera automática los pesos de las conexiones entre las neuronas para minimizar la función de pérdida o error a través del uso de la función de retro propagación del error y la función de optimización “Adam”. Después de esto, se procede a evaluar el rendimiento, por medio del cálculo de métricas relevantes que permiten determinar que tan bien se está desempeñando el modelo y de forma posterior realizar los ajustes pertinentes a cada una de las redes hasta encontrar el equilibrio deseado para tener un buen resultado del mismo.

A continuación, presentamos las curvas de desempeño para cada modelo, siendo estas una herramienta de diagnóstico ampliamente utilizada en el aprendizaje automático en algoritmos que aprenden de un conjunto de datos de entrenamiento de forma incremental, como lo son las redes neuronales convolucionales.

La revisión de las curvas de aprendizaje de los modelos durante el entrenamiento se usó para identificar problemas con el aprendizaje en los diferentes modelos evaluados, permitiendo visualizar sobreajuste (overfitting) o el sub ajuste (underfitting), donde el modelo no generaliza bien los datos. Al monitorear estas curvas se puede ajustar los hiperparámetros, como la tasa de aprendizaje o la regularización, para mejorar el rendimiento del modelo.

De acuerdo con lo anterior, fue posible evidenciar que una vez entrenados los modelos y posterior a la realización de varios experimentos donde se modificaban los hiperparámetros, se logró un nivel adecuado de pérdidas y de accuracy; así mismo, logramos visualizar que los resultados de cada uno de los modelos no se encontraban afectados por el overfitting.

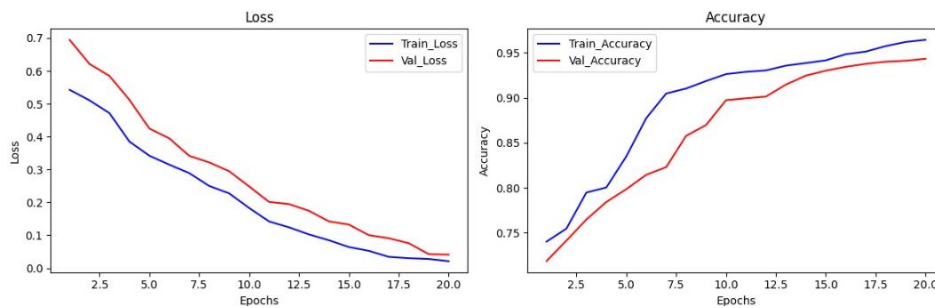


Ilustración 19 Loss y accuracy binario modelo propio

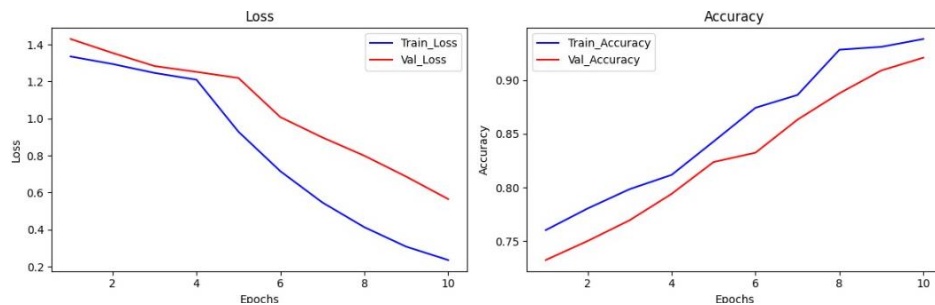


Ilustración 20 Loss y accuracy multiclase modelo propio

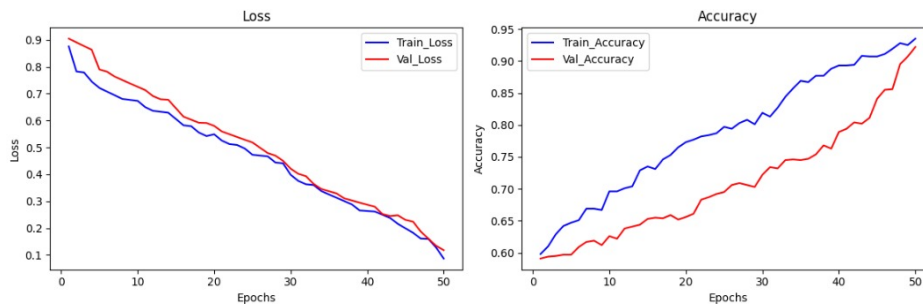
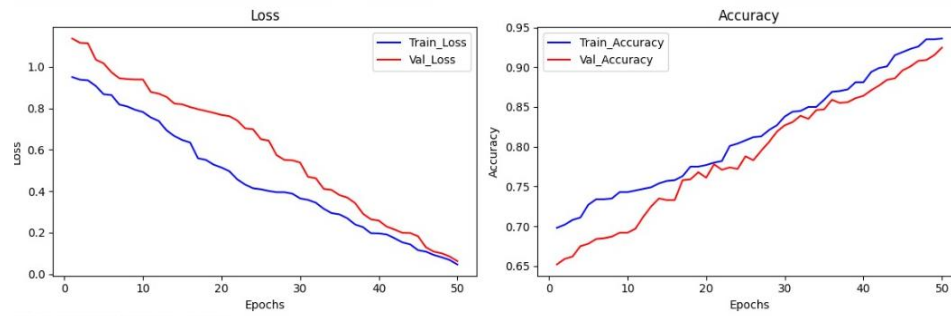
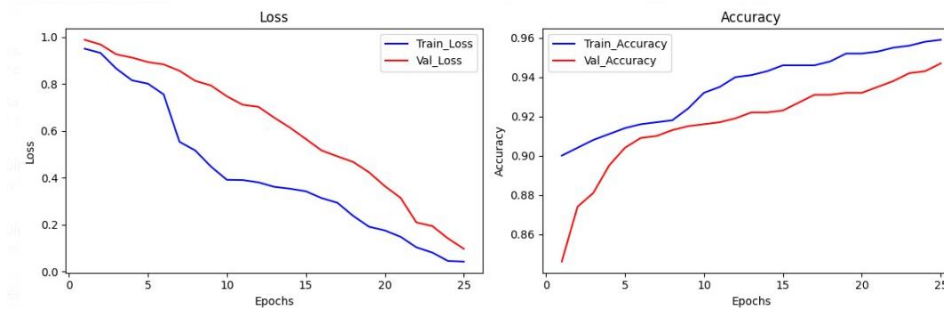


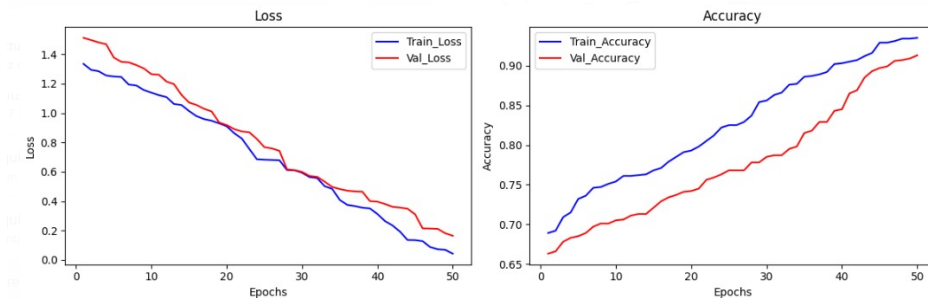
Ilustración 21 Loss y accuracy binario modelo AlexNet



*Ilustración 22 Loss y accuracy multiclase modelo AlexNet*



*Ilustración 23 Loss y accuracy binario modelo ResNet*



*Ilustración 24 Loss y accuracy multiclase modelo ResNet*

Durante el proceso de elección se realizó diez iteraciones por cada uno de los modelos desarrollados para dejar en evidencia la efectividad de estos y hacer la elección apoyados en datos y el test Kruskal-Wallis, para esto se consolidó la información de los indicadores obtenidos para cada iteración y modelo en las siguientes tablas:

Iteracion	Binario														
	Propia					AlexNet					ResNet				
	Epochs	Accuracy	Precision	Recall	f1-score	Epochs	Accuracy	Precision	Recall	f1-score	Epochs	Accuracy	Precision	Recall	f1-score
1	20	93.14%	92.53%	92.87%	92.70%	50	97.10%	96.76%	96.98%	96.87%	25	96.07%	95.85%	95.91%	95.88%
2	20	85.97%	89.00%	80.19%	84.37%	50	97.20%	97.42%	96.39%	96.90%	25	95.90%	97.71%	93.16%	95.38%
3	20	86.99%	86.79%	84.67%	85.72%	50	94.37%	95.49%	90.34%	92.84%	25	95.36%	95.55%	94.27%	94.91%
4	20	87.37%	89.02%	83.15%	85.98%	50	97.10%	95.25%	95.77%	95.51%	25	93.85%	93.75%	93.20%	93.47%
5	20	95.08%	95.65%	93.85%	94.74%	50	93.40%	93.71%	92.51%	93.11%	25	95.02%	97.01%	92.21%	94.55%
6	20	90.34%	97.59%	81.04%	88.55%	50	92.41%	93.56%	92.01%	92.78%	25	95.73%	96.14%	94.49%	95.31%
7	20	83.27%	96.04%	67.69%	79.41%	50	95.21%	95.66%	93.40%	94.52%	25	96.42%	97.40%	94.72%	96.04%
8	20	84.60%	84.94%	81.39%	83.13%	50	95.91%	95.89%	93.41%	94.63%	25	92.11%	90.62%	92.67%	91.63%
9	20	81.80%	88.76%	70.75%	78.74%	50	92.13%	92.79%	92.23%	92.51%	25	94.84%	95.75%	93.18%	94.45%
10	20	92.11%	94.37%	88.15%	91.15%	50	92.45%	92.41%	92.23%	92.32%	25	94.64%	95.14%	93.42%	94.27%
Promedio		88.07%	91.47%	82.38%	86.45%		94.73%	94.89%	93.53%	94.20%		94.99%	95.49%	93.72%	94.59%
Desviación		4.20%	4.12%	8.00%	5.09%		1.95%	1.60%	2.05%	1.67%		1.20%	1.96%	1.05%	1.23%

Tabla 1 Indicadores de evaluación modelo binario

Iteracion	Multiclase														
	Propia					AlexNet					ResNet				
	Epochs	Accuracy	Precision	Recall	f1-score	Epochs	Accuracy	Precision	Recall	f1-score	Epochs	Accuracy	Precision	Recall	f1-score
1	10	85.95%	86.73%	85.46%	86.09%	50	95.51%	95.65%	95.46%	95.55%	50	89.17%	89.50%	89.02%	89.26%
2	10	87.12%	88.28%	86.34%	87.30%	50	94.44%	94.61%	94.15%	94.38%	50	95.31%	95.35%	95.17%	95.26%
3	10	96.00%	96.78%	95.27%	96.02%	50	94.78%	94.91%	94.59%	94.75%	50	92.48%	92.78%	92.20%	92.49%
4	10	96.59%	97.09%	96.00%	96.54%	50	91.76%	92.27%	91.41%	91.84%	50	87.37%	87.57%	87.32%	87.44%
5	10	96.98%	97.57%	95.95%	96.75%	50	96.98%	97.07%	96.88%	96.97%	50	94.49%	94.58%	94.44%	94.51%
6	10	97.02%	97.44%	96.54%	96.99%	50	92.24%	92.36%	91.95%	92.15%	50	97.51%	97.56%	97.51%	97.53%
7	10	95.76%	96.30%	95.12%	95.71%	50	91.71%	92.01%	91.51%	91.76%	50	97.56%	97.61%	97.56%	97.58%
8	10	96.93%	97.30%	96.68%	96.99%	50	90.59%	91.46%	89.85%	90.65%	50	96.78%	96.83%	96.78%	96.80%
9	10	97.12%	98.07%	96.59%	97.32%	50	95.66%	95.85%	95.66%	95.75%	50	97.41%	97.46%	97.32%	97.39%
10	10	85.90%	87.71%	84.59%	86.12%	50	90.24%	90.27%	90.05%	90.16%	50	90.63%	90.79%	90.44%	90.61%
Promedio		93.54%	94.33%	92.85%	93.58%		93.39%	93.65%	93.15%	93.40%		93.87%	94.00%	93.78%	93.89%
Desviación		4.75%	4.46%	4.88%	4.67%		2.24%	2.13%	2.37%	2.25%		3.57%	3.48%	3.61%	3.54%

Tabla 2 Indicadores de evaluación modelo multiclase

Donde:

- 1. Iteración (epochs):** es la cantidad de veces en que se ejecutó la red neuronal.
- 2. Accuracy:** mide el porcentaje de casos que el modelo ha acertado por cada una de las clases de residuos.
- 3. Precision:** mide la calidad del modelo en su clasificación de residuos aprovechables de acuerdo con sus categorías o no aprovechable.
- 4. Recall:** mide la cantidad de residuos clasificados positivamente, es decir, identificados correctamente por el modelo entre todos los positivos reales.
- 5. F1 score:** combina la precision y el recall comparando el rendimiento general de clasificación de residuos del modelo.

A continuación, se explica la composición de cada uno de los indicadores y se presenta a modo de ejemplo como se lograría visualizar la matriz de confusión para un modelo multiclase respectivamente:

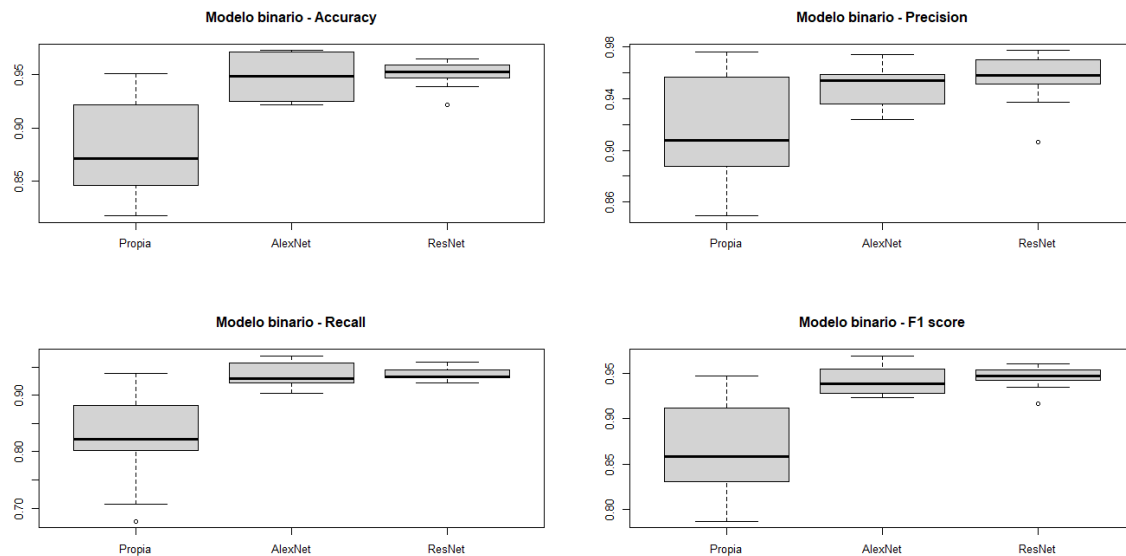
Parameters	Definition	Equation
Accuracy	This measure gives an overall rate of the model's efficiency in classifying images	$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$ <p> <b>TP</b> prediction and actual both are positive  <b>TN</b> prediction and actual both are negative  <b>FP</b> predicted-positive, actual-negative  <b>FN</b> predicted-negative, actual-positive         </p>
Precision	Out of all the positive predicted cases (what percentage is correct positive predicted)	$Precision = \frac{TP}{TP + FP}$
Recall	Out of all the truly positive cases (what percentage is correct positive predicted)	$Recall = \frac{TP}{TP + FN}$
F1-Score	Is derived from the precision and recall rate	$F1-Score = \frac{2TP}{2TP+FP+FN}$

Tabla 3 Formulación de indicadores de desempeño [35]

### 5.3.2.1. Clasificación binaria

Durante el desarrollo de los tres modelos binario y multiclase (propio, AlexNet y ResNet) realizados, se simularon o entrenaron durante diez veces cada uno de ellos con el fin de conocer los indicadores que nos apoyarían a determinar cuál sería el que podría presentar mejores resultados para este sistema empresarial inteligente para la clasificación de residuos.

Es así como haciendo uso de los gráficos de boxplot de la ilustración 19, comparamos el modelo con mayor efectividad y que de acuerdo con la imagen se resalta los buenos resultados presentados ResNet que están acompañados por una menor volatilidad en el accuracy, precisión, recall y f1-score. Los resultados de las otras dos redes también entregaron resultados aceptables, pero más volátiles y con menor exactitud en el poder de clasificación que la ResNet.



*Ilustración 25 Indicadores modelo binario*

Con el fin de evidenciar si existe homogeneidad de las varianzas del accuracy en los resultados de los tres modelos desarrollados, se realizó la prueba de Levene en R-Studio. Por lo anterior, se evidencia que las varianzas son heterogéneas y son significativamente diferentes entre sí.

```
> leveneTest(accuracy_kruska12 ~ condicion2, data = datos2, center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
  Df F value Pr(>F)
group 2 6.7151 0.004294 **
 27
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

*Ilustración 26 LevenTest redes binarias en R-Studio*

Finalmente, por medio del test Kruskal-Wallis se desea corroborar si existen diferencias relevantes estadísticamente entre el modelo propio, AlexNet y ResNet, esta prueba determina si las medianas de dos más grupos son diferentes y de esta forma se calcula el estadístico de prueba y se comparan.

```
> kruskal.test(accuracy_kruska12 ~ condicion2, data = datos2)

Kruskal-wallis rank sum test

data: accuracy_kruska12 by condicion2
kruskal-wallis chi-squared = 14.163, df = 2, p-value = 0.0008405
```

*Ilustración 27 Kruskal-Wallis redes binarias en R-Studio*

**Hipótesis nula:** Las muestras independientes tienen toda la misma tendencia central y por lo tanto provienen de la misma población.

**Hipótesis alternativa:** Al menos una de las muestras independientes no tiene la misma tendencia central que las otras muestras y, por lo tanto, se origina en una población diferente.

Resultado p-value de  $0.0008405 < 0.05$  por lo que se rechaza la hipótesis nula. Es decir, que hay diferencias estadísticamente significativas entre los tres modelos en su indicador de accuracy. Una vez evidenciado que existe diferencia entre los datos arrojados por los modelos, se realiza una prueba post hoc para determinar exactamente qué modelos de acuerdo con su resultado de accuracy son diferentes entre sí.

```
> pairwise.wilcox.test(x = datos2$accuracy_kruska12, g = datos2$condicion2, p.adjust.method = "holm")  
  
Pairwise comparisons using wilcoxon rank sum test with continuity correction  
data: datos2$accuracy_kruska12 and datos2$condicion2  
  
AlexNet Propia  
Propia 0.0034 -  
ResNet 0.9698 0.0034  
  
P value adjustment method:holm
```

*Ilustración 28 Pairwise test en R-Studio*

Las comparaciones por pares muestran que la diferencia entre los niveles de accuracy informados para AlexNet y ResNet no es estadísticamente significativa (valor  $p = 0.9698$ ) y la diferencia entre los niveles de accuracy informados para la red propia y ResNet es estadísticamente significativa (valor  $p = 0.0034$ ).

Estos resultados se alinean con lo que se observó en los diagramas de caja anteriormente, pues se evidenció que los resultados de AlexNet y ResNet eran parecidos en sus resultados de accuracy y eran notablemente mejores que el modelo propio; en cambio entre el modelo propio y los otros dos modelos la diferencia era más notoria, por lo anterior se hará uso para la clasificación binaria de la ResNet.

Adicionalmente, es posible observar en la ilustración 24 que las imágenes correspondientes a los residuos no aprovechables fueron las que más errores de clasificación obtuvieron, debido a que las imágenes de entrada presentan ruido por el tratamiento que se les da a este tipo de residuos como estar arrugados, húmedos o sucios. Sin embargo, se obtuvo resultados aceptables para el modelo de acuerdo con los indicadores mencionados anteriormente.

Matriz de confusión		
	Residuos aprovechables	Residuos no aprovechables
Residuos aprovechables	1471	90
Residuos no aprovechables	78	1290

Ilustración 29 Matriz de confusión clasificación binaria

### 5.3.2.2. Clasificación multiclase

Para la clasificación multiclase el modelo que presentó mejores resultados para la clasificación de residuos aprovechables (papel – cartón, vidrio, metal y plástico) es AlexNet, toda vez que dejó en evidencia resultados estadísticamente más estables durante todas las pruebas realizadas. Es importante resaltar que el modelo propio y ResNet presentaron resultados aceptables, sin embargo, para el modelo propio se presentaba mayor volatilidad en los indicadores, dejando muy pocos resultados altos por encima del 50% de las pruebas realizadas y para ResNet, también se evidenciaron resultados volátiles en la ilustración 23, que dejaban mayor exposición a una menor efectividad del modelo.

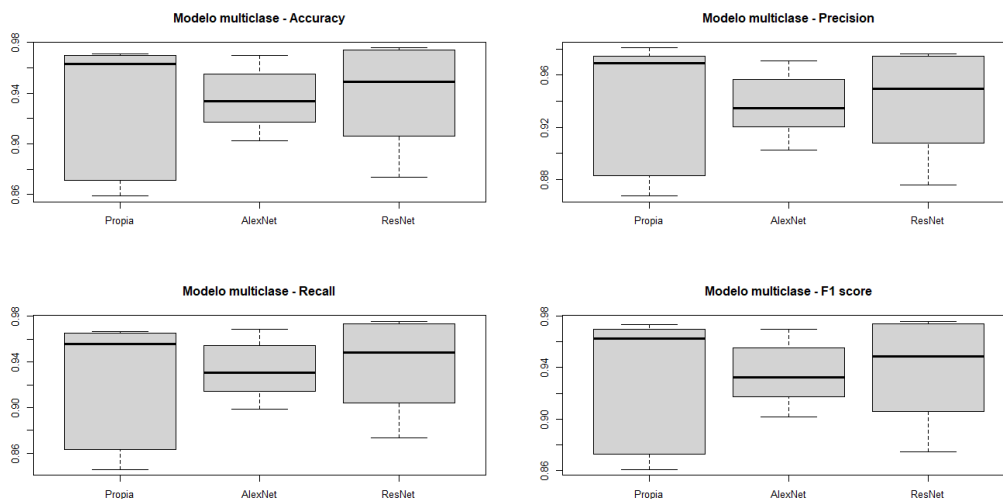


Ilustración 30 Indicadores modelo multiclase

```
> leveneTest(accuracy_kruskal ~ condicion, data = datos, center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
  Df F value Pr(>F)
group 2  0.5192 0.6008
  27
```

Ilustración 31 LevenTest redes multiclase en R-Studio

No hay evidencias en contra de la homogeneidad de varianzas. Ya que el p-value es  $>0.05$ , son homogéneas y no son significativamente diferentes entre sí.

```
> kruskal.test(accuracy_kruskal ~ condicion, data = datos)

kruskal-wallis rank sum test

data: accuracy_kruskal by condicion
kruskal-wallis chi-squared = 1.1635, df = 2, p-value = 0.5589
```

*Ilustración 32 Kruskal-Wallis redes multiclase en R-Studio*

**Hipótesis nula:** Las muestras independientes tienen toda la misma tendencia central y por lo tanto provienen de la misma población.

**Hipótesis alternativa:** Al menos una de las muestras independientes no tiene la misma tendencia central que las otras muestras y, por lo tanto, se origina en una población diferente.

Resultado p-value de  $0.5589 > 0.05$  por lo que se acepta la hipótesis nula. Es decir, que no hay diferencias estadísticamente significativas entre los tres modelos en su indicador de accuracy.

Adicionalmente, en la ilustración 27 se deja en evidencia que la categoría de metales es la que presenta mayores desviaciones en la clasificación multiclase, lo que podría dejar en evidencia que las imágenes de residuos metálicos posiblemente presentan ruido o distorsión, ya que este tipo de arquitectura de red neuronal son sensibles a este tipo de situaciones en las imágenes de entrada. Sin embargo, los resultados son satisfactorios de acuerdo con los indicadores e información analizada anteriormente.

Matriz de confusión				
	Metales	Papel_Carton	Plastico	Vidrio
Metales	508	7	3	9
Papel_Carton	16	487	10	4
Plastico	18	6	446	9
Vidrio	28	0	18	481

*Ilustración 33 Matriz de confusión clasificación multiclase*

### 5.3.3. Unificación del modelo y pruebas de clasificación

Después de la creación de las tres diferentes arquitecturas (ResNet, AlexNet y modelo propio) se procede a hacer la compilación de estos, para lo cual se hace uso de la función `loss='binary_crossentropy'` la cual es usada como función de pérdida para el modelo de

clasificación binaria. La función `binary_crossentropy` calcula la pérdida de entropía cruzada entre etiquetas verdaderas y etiquetas predichas. De igual manera se hace uso de la función `loss='categorical_crossentropy'` y se utiliza como una función de pérdida para el modelo de clasificación de clases múltiples (en este modelo se usan 4 etiquetas de salida). A la etiqueta de salida se le asigna un valor de codificación de categoría única en forma de 0 y 1. La etiqueta de salida, si está presente en forma de número entero, se convierte en codificación categórica mediante el método `keras.utils.to_categorical` [36].

Se usa el optimizador Adam (Adaptative Moment Optimization) tanto para red binaria como red multiclase, este optimizador combina la metodología de AdaGrad<sup>2</sup> y RMSProp<sup>3</sup> y hace el cálculo de una combinación lineal entre el gradiente y el incremento anterior y considera los gradientes recientemente aparecidos en las actualizaciones para mantener diferentes tasas de aprendizaje por variable[37].

```
model.compile(loss='binary_crossentropy', #binary_crossentropy si fuera binario
              optimizer=tf.keras.optimizers.Adam(learning_rate=0.001),
              metrics=[ 'accuracy', 'AUC', tf.keras.metrics.TruePositives(), tf.keras.metrics.TrueNegatives(), tf.keras.metrics.FalsePositives(),
                        tf.keras.metrics.FalseNegatives(), tf.keras.metrics.Precision(), tf.keras.metrics.Recall
```

*Ilustración 34 Compilación de los modelos*

De igual manera se hace el cálculo de las diferentes métricas nombradas anteriormente (Accuracy, AUC, TruePositives, TrueNegatives, FalsePositives, FalseNegatives, Precision y Recall) durante el entrenamiento de los modelos se hace uso de la `data_train`, se le indica las épocas definidas por cada arquitectura y se procede a hacer la validación con el `data_test`. Cuando se tiene el entrenamiento finalizado se procede a hacer el `model.evaluate(data_test)`.

Cuando la ResNet y la AlexNet están totalmente entrenados, se guardan en un formato h5 de manera individual y posteriormente se procede a hacer la unificación del modelo, de manera local se logró correr el modelo y hacer pruebas en tiempo real para esto dentro del código se define una función que me habilita la cámara en el Google Colab y hace la captura de la foto del residuo que se quiere clasificar, luego se le hace un `resize` a la foto tomada para que quede de 250x250 tal como se les indico a las dos arquitecturas durante su proceso de creación, después de hacer las configuraciones pertinente a la imagen se procede hacer inicialmente la predicción de la red binaria, para esto se hace uso de la función `model.predict` y se analiza el resultado dependiendo la clasificación que se realice sobre las etiquetas '0' para residuo aprovechable y '1' para residuo no aprovechable.

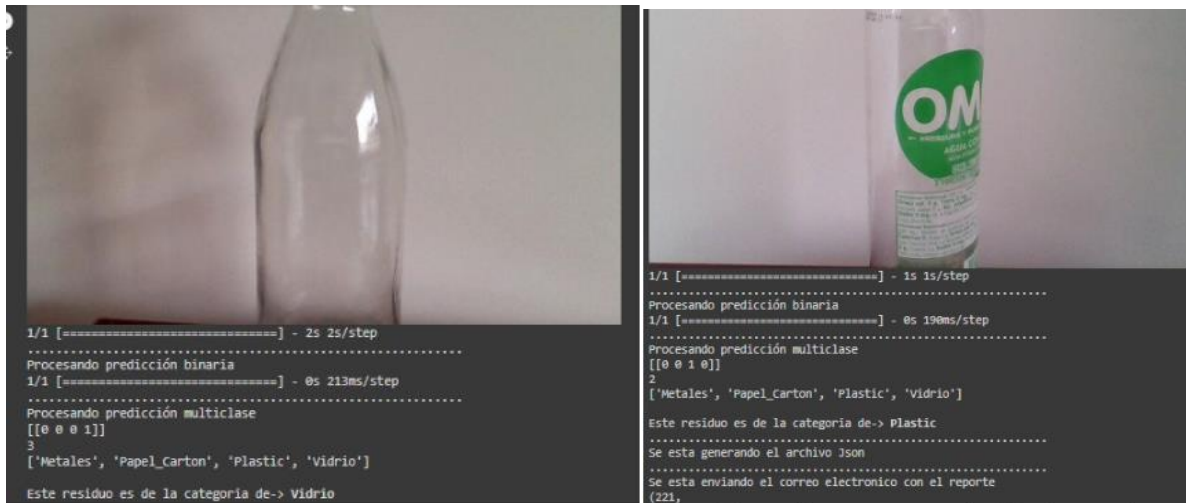
Si la predicción sobre la imagen obtiene como resultado un 0, pasa inmediatamente por un

---

<sup>2</sup> AdaGrad es un algoritmo que considera un valor uniforme para todos los pesos, se mantiene un factor de entrenamiento específico para cada uno de ellos. Y partiendo del factor de entrenamiento inicial, AdaGrad lo escala y adapta para cada dimensión con respecto al gradiente acumulado en cada iteración [37].

<sup>3</sup> RMSProp es un algoritmo que mantiene un factor de entrenamiento diferente para cada dimensión, pero en este caso el escalado del factor de entrenamiento se realiza dividiéndolo por la media del declive exponencial del cuadrado de los gradientes [37].

condicional que activa la predicción de la red multiclase y hace la clasificación según las etiquetas definidas ['Metales', 'Papel\_Carton', 'Plastic', 'Vidrio'], en caso de ser el resultado inicial de la binaria 1, no activa el condicional y arroja como resultado el residuo no aprovechable. Se hace la aclaración que para los dos casos de resultado de la red binaria una vez terminado la predicción se procede a almacenar la información en un JSON y hacer el envío de correo con la información capturada.



*Ilustración 35 Prueba de ejecución de los modelos*

Teniendo en cuenta lo anterior, es importante indicar que la red neuronal binaria tiene un peso alrededor de 271 MB, la multiclase 475 MB y ya unificadas como se explicó en el párrafo anterior junto con la identificación del usuario, el JSON y el envío automático del correo su peso es de 34 KB; después de realizadas varias pruebas que ayudan a evidenciar el correcto funcionamiento del proceso, se contabilizó un tiempo de ejecución de alrededor de 24 segundos desde Google Colab y con la cámara del celular conectada a esta plataforma para la clasificación del residuo, el guardado en el archivo JSON y el envío automático del mensaje al correo electrónico del usuario.

## 6. INDICADORES AMBIENTALES

### 6.1. ENTREVISTA A PROFESIONAL AMBIENTAL

Se realizó entrevista a Juan David Álzate Tamayo, Ingeniero Ambiental, experto en Manejo Integral de Residuos [38]. Tiene 25 años de experiencia en el diseño, implementación y monitoreo de proyectos que disminuyen el impacto ambiental, frente a la generación de residuos sólidos, la gestión integral del agua y el consumo energético, en especial de electricidad. Se ha desempeñado en Empresas Varias de Medellín, Universidad de Antioquia, Cervecería Unión S.A, Hospital Pablo Tobón Uribe, Secretaría del Medio Ambiente del Municipio de Medellín, Interconexión Eléctrica S.A. E.S.P. e ISA INTERCOLOMBIA S.A. E.S.P., resalta que es importante que la sociedad del común se debe informar de temas de impacto ambiental y como pueden contribuir individualmente a las metas de disminución de contaminación.

Nos indica que existen diferentes tipos de residuos que debemos trabajar para reducir su contaminación, entre ellos, sólidos, líquidos y gaseosos. Nuestro trabajo se concentró en los residuos sólidos. Es importante tener claro el concepto de residuo, para lo cual Juan David nos indica que es un material que cumplió su utilidad para las personas, sin embargo, se ha visto la necesidad de prologar esa utilidad, por lo tanto, el termino de residuo se ha resignificado. Un residuo entonces es algo que se puede reutilizar.

Los datos ambientales a nivel nacional indican que se están generando cada vez más residuos sólidos como también se ve la tendencia a incrementar el reciclaje, sin embargo, no a la misma tasa a la que crecen la generación de residuos. Lo cual demanda acciones importantes, resalta Juan David, que nuestra iniciativa es vital para contribuir al cierre de estas brechas. Según las últimas cifras que se tienen de referencia de Medellín es que en promedio cada persona genera 0.54 kg de residuos por día, con tendencia a incrementarse anualmente. Juan David resalta que nuestro proyecto contribuye a generar conciencia a las personas para que por lo menos esta tasa de generación se estabilice y en el mediano plazo logremos revertir las tasas (reducción de residuos y aumento de reciclaje).

Aprovechamos la experiencia de Juan David para preguntarle si un indicador que podríamos trabajar con la recolección de información de nuestro modelo sería el de huella de carbono que tanto se escucha en los medios. Nos indica que para la huella de carbono sería difícil su implementación, pues esta huella no solo la da el material sino toda la cadena productiva y de transporte que se da para tener un producto en nuestras manos, toda contaminación en cada una de estas etapas contribuye a la métrica de huella de carbono. Indica Juan David que no es lo mismo la huella de carbono de un producto fabricado en Colombia a uno fabricado en otro país, pues hay muchas variables que impactan en la diferenciación, por ejemplo, recursos, energía utilizada para la transformación del material, medios de transporte entre otros. Ante esta situación nos recomienda llevar otro tipo de métricas de impacto ambiental y de comportamientos ecológicos de las personas.

## **6.2. ENTREVISTA A REPRESENTANTE DE EMPRESA PRIVADA**

Con el fin de conocer algunas tendencias de sostenibilidad ambiental en el sector empresarial acerca de los proyectos, indicadores e inversiones proyectadas o ejecutadas que hoy en día son tendencia en algunas organizaciones, realizamos una entrevista por medio de la plataforma Teams a Victoria Cárdenas Álzate quien se desempeña como Coordinadora de Arquitectura Empresarial y Sostenibilidad del Fondo de Empleados del Grupo EPM, comentándonos que actualmente las empresas están trabajando en proyectos que impacten el medio ambiente y están innovando en sus procesos buscando la transformación de estos de forma responsable para generar el menor impacto posible en el medio ambiente y es por esto que desde las altas direcciones de las compañías se han destinado recursos financieros para apoyar estos cambios.

Adicionalmente, quisimos profundizar en la usabilidad que podría tener una herramienta tecnológica que ayudara a los empleados de una empresa a clasificar los residuos que generan en su día a día de forma responsable, eficiente y eficaz en las canecas de basura de residuos aprovechables y no aprovechables y que tipo de indicadores ambientales o usos podría esperarse de esta herramienta para ser utilizada dentro de una organización y que generara valor útil dentro de la misma; para lo cual nuestra invitada respondió que obtener indicadores sobre el consumo de los colaboradores que permitan identificar tendencias de consumo de ellos, por ejemplo, botellas de vidrio donde se pudiera evidenciar que un grupo de personas tienden a consumir más gaseosas que otras y si fuera posible saber que marcas de gaseosas, esto con un fin más comercial pensando a gran escala; también si consume productos que estén hechos con un alto grado de plástico, papel o cartón, ya que esto serviría para aproximar un resultado de la huella de carbono de cada empleado y generar campañas, cultura y estrategias que dentro de la organización mitiguen el consumo de ciertos productos que sean más contaminantes que otros o que sea reemplazados por empaques más sostenibles y amigables con el medio ambiente, esto también nos permitiría conocer los hábitos de vida de las personas en cuestiones de salud y serviría para estrategias del sistema de seguridad y salud en el trabajo.

La manera de visualizar la información también es importante, por medio de un dashboard poder interactuar con información por ciudades, sectores o áreas de la organización y que permita a su vez filtrar por variables cualitativas y cuantitativas como edad, genero, estrato, entre otras, con el fin de facilitar la estrategia y la toma de decisiones en cuestiones relativas a la sostenibilidad ambiental y empresarial.

Desde el punto de la sostenibilidad empresarial, sería importante entregar como organización por medio de indicadores, el seguimiento a la disminución de los diferentes impactos al medio ambiente que como empresa hemos dejado o logrado y así tener la posibilidad de dejar evidencia de estos hitos en el balance social de la compañía. Desde el punto de vista social del Fondo de Empleados del Grupo EPM, la retribución se observa desde el uso del presupuesto para incentivar la disminución de la huella de carbono de las personas o la generación de conciencia para el cuidado del medio ambiente por medio del reciclaje y de la calidad de vida de cada uno de nuestros colaboradores.

Finalmente, es importante recordar que el desarrollo y uso de todas estas ideas deben partir desde el principio de la responsabilidad y honestidad por medio de la correcta aplicación de la normatividad vigente en temas de protección de datos personales para recolección, tratamiento y transferencia de estos, los cuales serían recolectados de forma masiva [39].

### 6.3. ALGUNOS PRINCIPALES INDICADORES AMBIENTALES

Para el cálculo de los indicadores ambientales, la información resulta ser uno de los principales insumos para su formulación y es por esto que a veces existe una inapropiada selección de los mismos, por lo que podría dificultarse su comprensión, interpretación y uso que desencadenaría en decisiones o estrategias erróneas que podría degradar el medio ambiente o los recursos financieros de una organización por la mala toma de decisiones.

Actualmente existen algunos indicadores que son llamados “indicadores ambientales de primera generación”, estos fueron definidos a mediados del año 1980 y aún no han perdido su vigencia y tratan sobre la cobertura boscosa del territorio, la calidad del aire de una ciudad, la contaminación del agua por coliformes<sup>4</sup>, deforestación, desertificación o cambio de suelo [40].

Este primer grupo de indicadores están estrechamente asociados a actividades productivas de determinados sectores pero que han sido parte del desarrollo de la economía mundial y que estos a su vez, han sido posibles grandes partícipes de los principales inconvenientes ambientales que hoy en día evidenciamos [40].

Existen indicadores ambientales principales a los cuales se les realiza seguimiento a nivel mundial, algunos de estos son los siguientes [41]:

- **Indicador de bienestar económico sostenible (IBES):** Este indicador integra variables económicas, distributivas, sociales y ambientales las que reciben valores en escalas y ponderaciones únicas e intenta ser un indicador alternativo al producto interno bruto (PIB) como un indicador de bienestar social [40].
- **Indicador de sostenibilidad ambiental (ISA):** Es un indicador que mide el nivel de responsabilidad y satisfacción de las necesidades ambientales actuales de las comunidades, sin tener en cuenta las necesidades futuras de esa misma comunidad [40].

Así mismo, se centra en cinco puntos: estado de los sistemas medioambientales de cada comunidad, el éxito en la gestión de los planes de acción a desarrollar en temas ambientales, el progreso en la protección de los ciudadanos, capacidad social e

---

<sup>4</sup> La denominación genérica coliformes designa a un grupo de especies bacterianas que tienen ciertas características bioquímicas en común e importancia relevante como indicadores de contaminación del agua y los alimentos.

institucional y los recursos utilizados y el nivel administrativo del gobierno de cada país [40].

- **Huella ecológica (HE):** Este indicador mide el uso del espacio ambiental que es requerido para producir y sostener los niveles de vida existentes en las comunidades o sociedades en relación con el consumo; sirve también para dar una idea de la necesidad de absorción de los residuos generados por una persona de acuerdo con la proporción del planeta que corresponda [40].
- **Huella ecológica ajustada (HEA):** Este indicador ha surgido de forma tendencial recientemente, considerando variables como el crecimiento de los bosques, rendimientos por hectáreas, entre otras y suele interpretarse como el total de superficie productiva, visto desde la necesidad de producción para suplir el consumo de una comunidad específica [42].
- **Índice del planeta vivo (LPI):** Este indicador se enfoca en los cambios en la salud de los ecosistemas, haciendo seguimiento a las poblaciones de mamíferos, aves, peces, reptiles y anfibios del planeta y se construye con base en los datos de poblaciones silvestres que ocupan el mundo [43].
- **Huella de carbono (HC):** La huella de carbono mide la masa equivalente al impacto ambiental que generan los seres humanos a la emisión de gases de efecto invernadero, el uso de objetos del día a día como el despertador, el celular, los electrodomésticos en general, empaquetados, entre otros, contribuyen a que este indicador tenga variaciones [44].

Así como los indicadores mencionados anteriormente, se disponen de una diversidad de herramientas de seguimiento para evaluar el desempeño de sistemas de prevención y gestión de residuos con diferentes niveles de detalle, complejidad y escala, desde un nivel macro (mundial o nacional) hasta un nivel meso (urbano o empresarial).

Es por eso que una vez realizado este acercamiento con estos indicadores y para dar alcance a las necesidades que se podrían presentar en las organizaciones, es necesario la realización de algunos indicadores ambientales específicos para el seguimiento del consumo de las personas que hagan uso del sistema empresarial inteligente para la clasificación de residuos.

### 6.3.1. Indicadores ambientales medibles desde el sistema empresarial inteligente para la clasificación de residuos

Con el fin de dar a conocer resultados acerca del uso del sistema empresarial inteligente para la clasificación de residuos, este sistema permite recolectar la siguiente información clasificada por tercero y fecha:

- **Cantidad de residuos clasificados (CRC):** Mide la cantidad de residuos clasificados por el modelo por cada uno de los usuarios durante un tiempo determinado.

$$CRC = \sum_{i=1}^i r_i$$

Donde:  $r_i$  = Residuo clasificado

*Ecuación 1 Cantidad de residuos clasificados (CRC)*

- **Cantidad de residuos aprovechables (CRA):** Mide la cantidad de residuos aprovechables clasificados por el modelo por cada uno de los usuarios durante un tiempo determinado.

$$CRA = \sum_{i=1}^i ra_i$$

Donde:  $ra_i$  = Residuo aprovechable clasificado

*Ecuación 2 Cantidad de residuos aprovechables (CRA)*

- **Cantidad de residuos no aprovechables (CRNA):** Mide la cantidad de residuos no aprovechables clasificados por el modelo por cada uno de los usuarios durante un tiempo determinado.

$$CRNA = \sum_{i=1}^i rna_i$$

Donde:  $rna_i$  = Residuo no aprovechable clasificado

*Ecuación 3 Cantidad de residuos no aprovechables (CRNA)*

- **Indicador de generación de residuos aprovechables (IGRA):** Mide el porcentaje de residuos aprovechables generados por un usuario durante un tiempo determinado sobre el total de los residuos clasificados.

$$IGRA = \frac{\sum_{i=1}^i ra_i}{\sum_{i=1}^i r_i} * 100 = \frac{CRA}{CRC} * 100$$

*Ecuación 4 Indicador de generación de residuos aprovechables (IGRA)*

- **Tasa de aprovechamiento de vidrio (TAV):** Mide el porcentaje de residuos aprovechables y clasificados como vidrio generados por un usuario durante un tiempo determinado sobre el total de los residuos clasificados.

$$TAV = \frac{\sum_{i=1}^i rav_i}{\sum_{i=1}^i r_i} * 100 = \frac{\sum_{i=1}^i rav_i}{CRC} * 100$$

*Donde:  $rav_i$  = Residuos aprovechable de vidrio clasificado*

*Ecuación 5 Tasa de aprovechamiento de vidrio (TAV)*

- **Tasa de aprovechamiento de papel y/o cartón (TAPC):** Mide el porcentaje de residuos aprovechables y clasificados como papel y/o cartón generados por un usuario durante un tiempo determinado sobre el total de los residuos clasificados.

$$TAPC = \frac{\sum_{i=1}^i rapc_i}{\sum_{i=1}^i r_i} * 100 = \frac{\sum_{i=1}^i rapc_i}{CRC} * 100$$

*Donde:  $rav_i$  = Residuos aprovechable de papel o cartón clasificado*

*Ecuación 6 Tasa de aprovechamiento de papel y/o cartón (TAPC)*

- **Tasa de aprovechamiento de plástico (TAP):** Mide el porcentaje de residuos aprovechables y clasificados como plástico generados por un usuario durante un tiempo determinado sobre el total de los residuos clasificados.

$$TAP = \frac{\sum_{i=1}^i rap_i}{\sum_{i=1}^i r_i} * 100 = \frac{\sum_{i=1}^i rap_i}{CRC} * 100$$

*Donde:  $rav_i$  = Residuos aprovechable de plástico clasificado*

*Ecuación 7 Tasa de aprovechamiento de plástico (TAP)*

- **Tasa de aprovechamiento de metales (TAM):** Mide el porcentaje de residuos aprovechables y clasificados como metales generados por un usuario durante un tiempo determinado sobre el total de los residuos clasificados.

$$TAM = \frac{\sum_{i=1}^i ram_i}{\sum_{i=1}^i r_i} * 100 = \frac{\sum_{i=1}^i ram_i}{CRC} * 100$$

Donde:  $ram_i$  = Residuos aprovechable de metal clasificado

Ecuación 8 Tasa de aprovechamiento de metales (TAM)

Estos indicadores son sugeridos y le permitirán a la empresa conocer tendencias de consumo y de contaminación en los colaboradores o de una comunidad en general, por lo que aportaría a la realización de campañas estratégicas que buscarán la disminución de la cantidad de basura generada o del uso de empaques altamente contaminantes mediante los diferentes insumos que brindará el modelo por medio de la información que se obtiene desde la clasificación de los residuos.

#### 6.4. ESTRUCTURA DE ALMACENAMIENTO DE INFORMACIÓN DEL MODELO

Uno de los objetivos que se establecieron al inicio del proyecto fue la recopilación de información del uso del modelo para poder tener el insumo con el que calcular diferentes indicadores tanto empresariales como ambientales, es por esto que se utilizó un almacenamiento en un JSON ya que este formato permite estructurar datos en forma de texto y permite el intercambio de información entre aplicaciones de manera sencilla, liviana y rápida. La información aquí contenida se estructura por medio de una colección de pares clave-valor [45]. De igual manera la elección de este tipo de archivo se debe en parte a que como el modelo va enfocado a la parte empresarial no se quería encasillar la información a una determinada base de datos, por lo que el uso de JSON permite hacer interacciones con diferentes bases o bancos de datos y de esta manera poder hacer la estructura y consolidación de información para después ser procesada por la empresa en su cálculo de indicadores y métricas.

Como se comentó anteriormente, el almacenamiento de los datos se hace con unas capturas de información que se solicitan al iniciar la ejecución de la red por medio de unos input, donde se le solicita al usuario que por favor ingrese datos generales de la compañía como lo son su usuario de red, el área a la que pertenece, su número de documento, su nombre completo y la fecha en la que se hace uso del modelo como se muestra en la ilustración 28, esta información es almacenada dentro de variables y posteriormente es usada para el almacenamiento.

```
Ingrese:
0 si es Administración y Recursos Humanos
1 si es Finanzas y Contabilidad
2 si es Gerencia
3 si es de Marketing y Ventas
4 si es de Producción
5 si es de Tecnología
6 si es de otra area: 3

Ingrese su usuario de red: ljcorrea

Ingrese su número de documento: 1015430165

Ingrese su nombre completo: Leidy Correa
User: ljcorrea
Area: Marketing y Ventas
Cedula: 1015430165
Nombre Completo: Leidy Correa
.....

¿Esta de acuerdo con los valores ingresados y/n y
2023-01-31 14:56:12.292028 Comienza el Proceso
Saved to photo.jpg
```

*Ilustración 36 Captura de información*

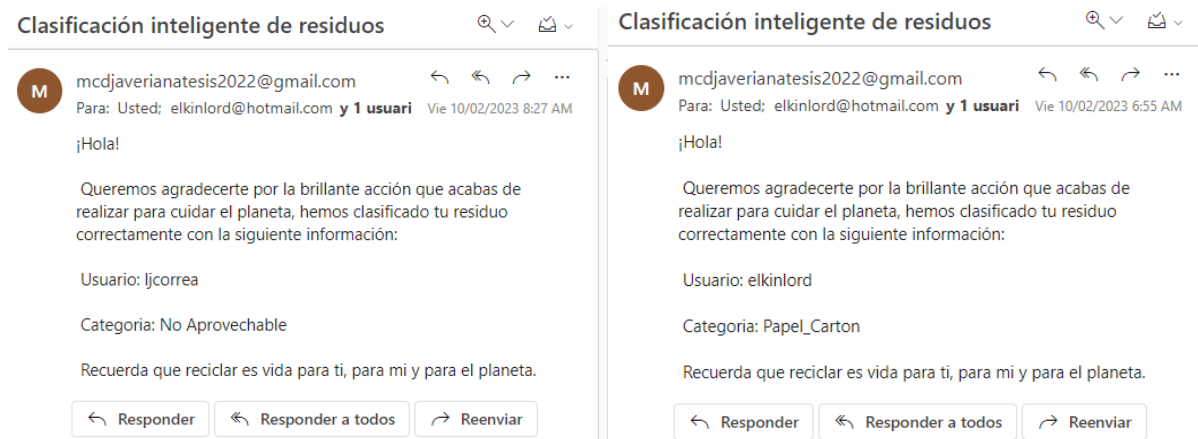
Para esto se realizó una parte de código que se ejecuta después de la predicción de la red, sea que termine en resultado no aprovechable o que ingrese al condicional que ejecuta la red multiclase para predecir la categoría del residuo aprovechable. Este código define una función en la cual valida si el archivo existe (en caso contrario lo crea en la ruta especificada) y procede a abrirlo y a incluir los datos almacenados anteriormente en variables sin modificar los datos ya existentes, lo que permite guardar un histórico y tener una trazabilidad del proceso, ejemplo:

```
{
  "Fecha": "2023-02-09 13:42:32.638549",
  "User": "ljcorrea",
  "Area": "Gerencia",
  "Cedula": 1015430165,
  "Nombre": "Leidy Correa",
  "Residuo_Clasificado": "Papel_Carton"
},
{
  "Fecha": "2023-02-09 13:44:25.902013",
  "User": "ljcorrea",
  "Area": "Finanzas y Contabilidad",
  "Cedula": 1015430165,
  "Nombre": "Leidy Correa",
  "Residuo_Clasificado": "No Aprovechable"
},
```

```
{
  "Fecha": "2023-02-10 13:27:12.313669",
  "User": "ljcorrea",
  "Area": "Marketing y Ventas",
  "Cedula": 1015430165,
  "Nombre": "Leidy Correa",
  "Residuo_Clasificado": "No Aprovechable"
},
{
  "Fecha": "2023-02-10 13:58:36.549192",
  "User": "elkinlord",
  "Area": "Produccion",
  "Cedula": 1022333802,
  "Nombre": "ELKIN LEONARDO CANTOR",
  "Residuo_Clasificado": "Vidrio"
},
}
```

*Ilustración 37 Almacenamiento JSON*

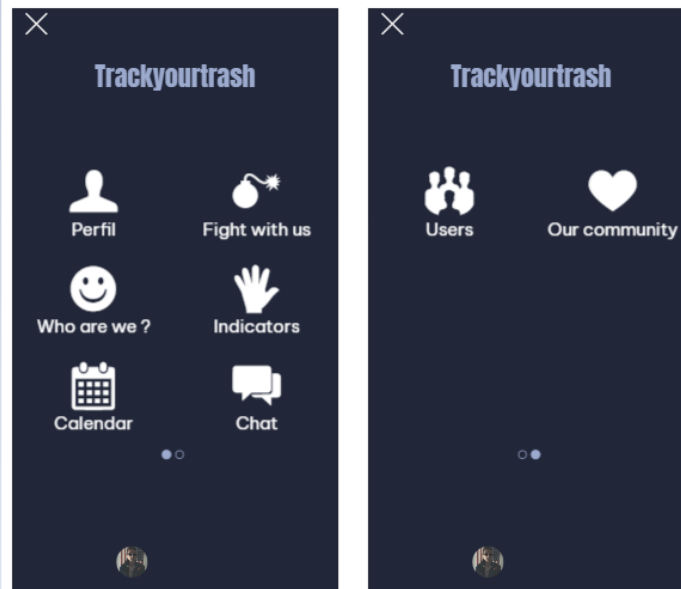
Posteriormente al almacenamiento JSON, se hace el envío del correo con la información básica capturada del modelo, para esto se usó el servicio de SMTP de Gmail que permite hacer el proceso de manera práctica y sencilla. El usuario que utiliza el modelo recibirá un correo con información básica del proceso de reciclaje que acaba de realizar siendo este un aliciente para que le dé continuidad a su buena acción y se convierta en una costumbre.



*Ilustración 38 Prototipo envío correo electrónico*

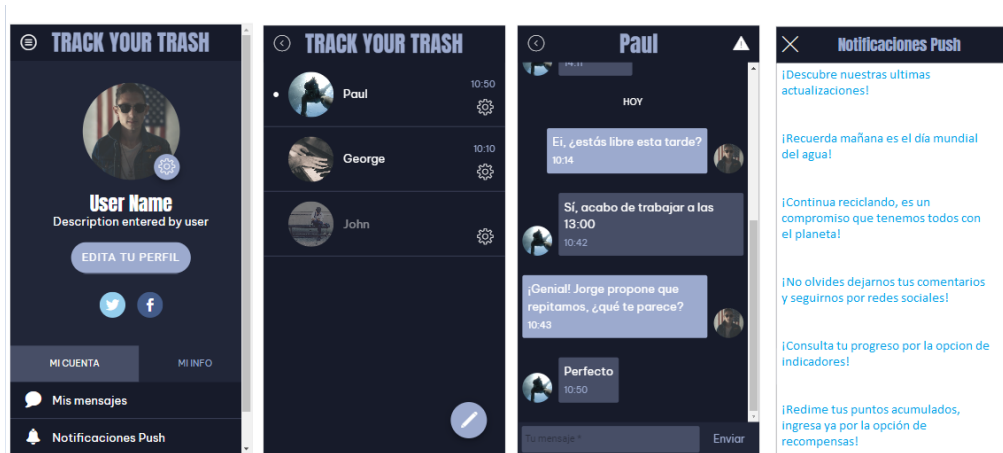
## 7. PROTOTIPO APP MÓVIL

Se realizó el diseño del prototipo de la App móvil TRACK YOUR TRASH, donde se aloja el modelo anteriormente descrito, para esto se pensó en una interfaz amigable y fácil de usar, que tiene principalmente las siguientes funcionalidades:



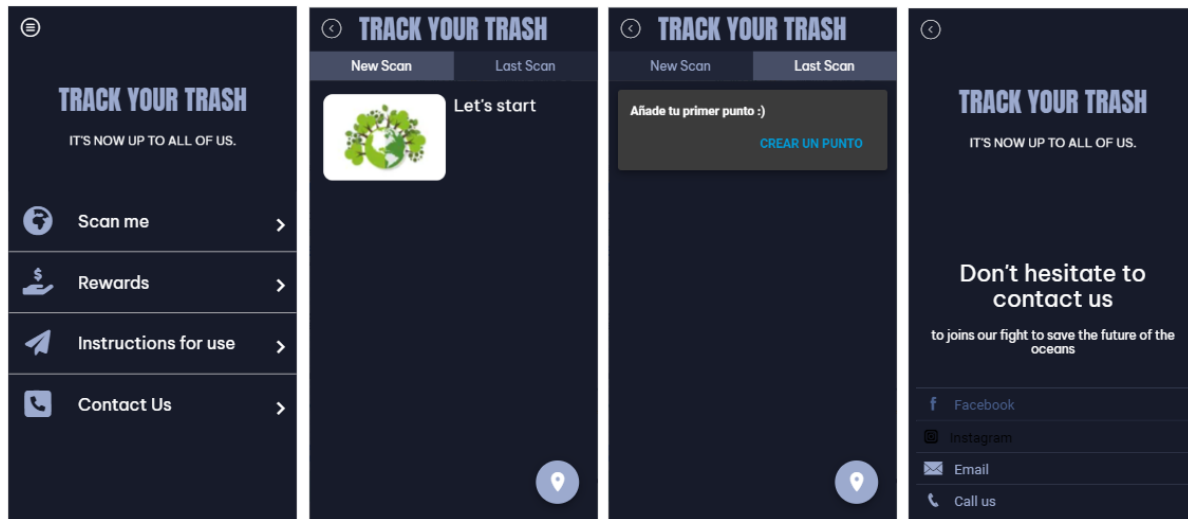
*Ilustración 39 Prototipo App Movil - Opción Home*

- **Perfil:** En esta opción el usuario puede modificar los datos básicos de su cuenta, cambiar la foto, validar los mensajes y notificaciones que ha recibido.



*Ilustración 40 Prototipo App Móvil - Opción perfil*

- **Lucha con nosotros:** Por esta opción se encuentra el modelo de ML anteriormente descrito, listo para escanear y clasificar el residuo de manera correcta, también se puede consultar el histórico de los escaneos realizados. Se quiso manejar una sección de recompensas y es allí donde se van a mostrar todos los puntos acumulados que lleva el usuario por hacer uso del modelo, también se encuentran las instrucciones de uso y la sección de contáctenos, en caso de que se presente alguna falla sobre el mismo.




*Ilustración 41 Prototipo App Móvil - Opción escaneo modelo ML*

- **Indicadores:** Por esta sección se presentan las principales métricas que se obtienen del uso del modelo por usuario y se le da una visión general de la contribución que se está haciendo al planeta con el uso del reciclaje. Se mide Cantidad de residuos clasificados (CRC), Cantidad de residuos aprovechables (CRA), Cantidad de residuos no aprovechables (CRNA), Tasa de aprovechamiento de vidrio (TAV), Tasa de aprovechamiento de papel y/o cartón (TAPC), Tasa de aprovechamiento de plástico (TAP), Tasa de aprovechamiento de metales (TAM), para mayor información sobre estos indicadores ir a la sección de principales indicadores ambientales.




*Ilustración 42 Prototipo App Móvil - Opción indicadores*

- **¿Quiénes somos?:** Por esta opción el usuario puede leer información acerca de nosotros y de nuestra filosofía, así como dejar sus comentarios.



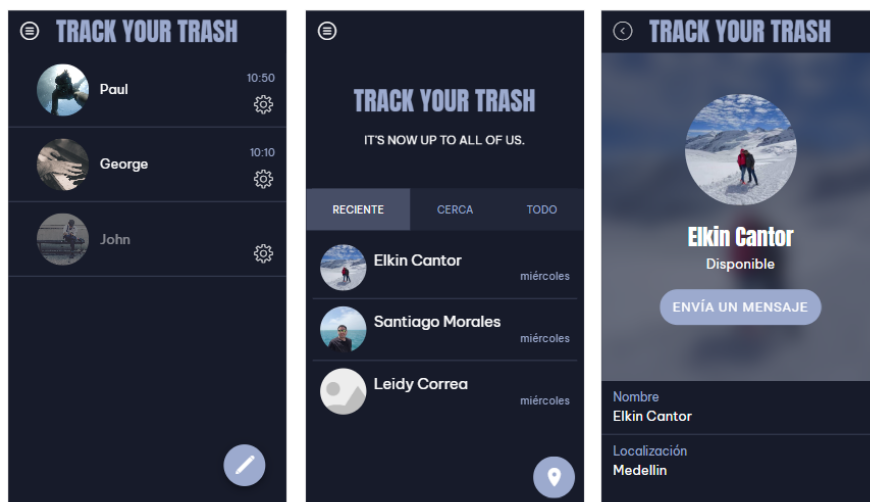
*Ilustración 43 Prototipo App Móvil - Opción ¿Quiénes somos?*

- **Calendario:** Por esta opción el usuario tendrá acceso a todas las fechas ambientales importantes tanto a nivel nacional como internacional.



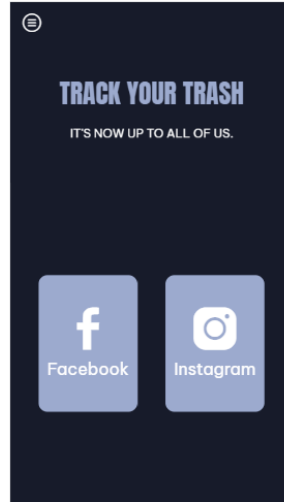
*Ilustración 44 Prototipo App Móvil - Opción calendario*

- **Chat y usuarios:** Por esta opción el usuario podrá ver que personas estan en línea y mensajear con sus compañeros de trabajo.



*Ilustración 45 Prototipo App Móvil - Opción chat y usuarios*

- **Nuestra comunidad:** Por esta opción el usuario podrá encontrarnos en redes sociales y hacer parte de una gran comunidad interesada por temas ambientales y cuidado del planeta.



*Ilustración 46 Prototipo App Móvil - Opción nuestra comunidad*

## 8. CONCLUSIONES

A lo largo de este trabajo desarrollamos diferentes arquitecturas y modelos que nos llevaron a evaluar los mejores resultados de cada uno de estos con el fin de seleccionar el más preciso, para esto exploramos redes como AlexNet, ResNet y un desarrollo propio que en conjunto se uniera para crear el modelo general de clasificación de residuos y que durante la fase de pruebas obtuvo un resultado de aproximadamente el 89% en su capacidad de predecir si el residuo era no aprovechable o aprovechable y a su vez, si se trataba de papel-cartón, plástico, vidrio o metal.

Así mismo, este modelo almacena la información de cada una de las clasificaciones que realiza con el fin de monitorear el comportamiento de reciclaje de los colaboradores de las organizaciones que podrían implementar esta tecnología dentro de sus programas de sostenibilidad empresarial, por medio de los diferentes indicadores que se facilitan calcular desde la recolección de información y, así mismo, se lograría conocer el posible impacto ambiental que se podría estar 'evitando' al no desechar un residuo de manera incorrecta en los basureros.

Finalmente, este trabajo busca incentivar el uso de la tecnología y el cuidado del medio ambiente en las personas, comunidades, organizaciones, entre otros; es por esto que se pensó en la recolección y almacenamiento de la información que se clasificaba para que con esto se facilitara la actividad de incentivar a los diferentes usuarios por medio de premios, puntos, regalos o bonos y que el cuidado del medio ambiente se vuelva una rutina permanente, apoyada por la tecnología y el consumo responsable.

## 9. REFERENCIAS BIBLIOGRÁFICAS

- [1] Departamento Nacional de Planeación (2022). Guía nacional para la adecuada separación de residuos sólidos [Online]. Disponible en: [https://colaboracion.dnp.gov.co/CDT/Vivienda%20Agua%20y%20Desarrollo%20Urbano/Guia\\_Residuos%20Solidos\\_Digital.pdf](https://colaboracion.dnp.gov.co/CDT/Vivienda%20Agua%20y%20Desarrollo%20Urbano/Guia_Residuos%20Solidos_Digital.pdf)
- [2] Departamento Nacional de Planeación (2016). Rellenos sanitarios de 321 municipios colapsarán en cinco años, advierte el DNP [Online]. Disponible en: <https://www.dnp.gov.co/Paginas/Rellenos-sanitarios-de-321-municipios-colapsar%C3%A1n-en-cinco-a%C3%B1os,-advierte-el-DNP--.aspx>
- [3] ONU noticias (2017). La ONU lucha por mantener los océanos limpios de plásticos [Online]. Disponible en: <https://news.un.org/es/story/2017/05/1378771>
- [4] S. Mauro, J. Cappelletti “Aprendizaje automático aplicado al procesamiento de imágenes para la clasificación de objetos reciclables”. Pertenece al libro: Memorias del Congreso Argentino en Ciencias de la Computación - CACIC 2021.
- [5] R. Sultana, R. D. Adams, Y. Yan, P. M. Yanik and M. L. Tanaka, *Trash and Recycled Material Identification using Convolutional Neural Networks (CNN)*, 2020 SoutheastCon, 2020, pp. 1-8, doi: 10.1109/SoutheastCon44009.2020.9249739.
- [6] Segui, P. (2014). Sistema para el tratamiento de residuos [Online]. Disponible: <https://patentados.com/2014/sistema-para-el-tratamiento-de-residuos.1>
- [7] M. Cobeñas, *Importancia del reciclado de los residuos sólidos urbanos*. 1ra ed. Madrid: Editorial Académica Española, 2012.
- [8] C. Martínez, F. Rentería, “Construcción de puntos ecológicos y disminución de residuos a través de la implementación del reciclaje”, UNAD, Florencia, 2018.
- [9] School of Business (2020). ¿Por qué incentivar la conciencia medioambiental en las empresas? [Online]. Disponible: <https://www.esan.edu.pe/conexion-esan/por-que-incentivar-la-conciencia-medioambiental-en-las-empresas#:~:text=Garantiza%20el%20equilibrio%20entre%20crecimiento,los%20dem%C3%A1s%20y%20a%20su%20destino.>
- [10] School of Business (2019). ¿Machine learning: ¿qué es y cómo funciona? [Online]. Disponible: <https://www.bbva.com/es/machine-learning-que-es-y-como-funciona/>
- [11] R. López (2017). Introducción al Deep Learning [Online]. Disponible: <https://relopezbriega.github.io/blog/2017/06/13/introduccion-al-deep-learning/>
- [12] IBM Cloud Education (2020). Redes neuronales [Online]. Disponible: <https://www.ibm.com/co-es/cloud/learn/neural-networks>
- [13] F. Chollet, *Deep Learning with Python*. 1ra ed. New York: Manning Publications, 2017.
- [14] H. Mrinal, *Aprendizaje tensorflow*. 1ra ed. US, 2020.
- [15] R. Valencia, *Aprendizaje keras*. 1ra ed. US, 2020.

- [16] M. Abdullan, M. Kavakli, "Mobile Augmented Reality for Environmental Awareness", M.S tesis, Tabuk University, Sydney, Australia, 2019.
- [17] F. Ortega. (2019, mayo 31). La sostenibilidad es tan importante como las utilidades para una empresa [Online]. Disponible: <https://www.larepublica.co/especiales/sostenibilidad-mayo-2019/la-sostenibilidad-es-tan-importante-como-las-utilidades-para-una-empresa-2869126#:~:text=En%20otras%20palabras%2C%20la%20sostenibilidad,trabajo%2C%20las%20empresas%20podr%C3%A1n%20desaparecer.>
- [18] M. Mohd, "Reduce, Reuse, Recycle (3Rs) Awareness App", M.S tesis, Ultra University, Kedah, Malasia, 2019.
- [19] Negri y E.L. Vito, "Introducción al razonamiento aproximado: lógica difusa", vol. 4, pp. 8 - 12, diciembre 2006.
- [20] A. Castañeda (2011). Análisis comparativo del procesamiento digital de imágenes médicas entre las técnicas convencionales vs técnicas difusas [Online]. Disponible: <https://tesis.ipn.mx/jspui/bitstream/123456789/9832/1/45.pdf>
- [21] M. Muñoz, J. López y E. Caicedo (2008). Inteligencia de enjambres: sociedades para la solución de problemas (una revisión) [Online]. Disponible: [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0120-56092008000200015](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-56092008000200015)
- [22] O. Reyes, M. Mejia y J. Useche (2019). Técnicas de inteligencia artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos [Online]. Disponible: <https://www.redalyc.org/journal/1492/149258931014/html/>
- [23] Bose, A. & Mali, K. (2016). Fuzzy-based artificial bee colony optimization for gray image segmentation. Signal, Image and Video Processing, 10, pp.1089–1096.
- [24] IBM (2021, agosto 17). El modelo de redes neuronales [Online]. Disponible: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- [25] IBM (2021, agosto 17). El modelo de redes neuronales [Online]. Disponible: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- [26] AWS (2022). ¿Qué es una red neuronal? [Online]. Disponible: <https://aws.amazon.com/es/what-is/neural-network/>
- [27] IONOS Digital Guide (2022). ¿Qué es una red neural network? [Online]. Disponible: <https://www.ionos.es/digitalguide/online-marketing/marketing-para-motores-de-busqueda/que-es-una-neural-network/>
- [28] J. Reinhold (2018, noviembre 29). ¿Cómo funcionan las Convolutional Neural Networks? Visión por Ordenador [Online]. Disponible: <https://www.aprendemachinelearning.com/como-funcionan-las-convolutional-neural-networks-vision-por-ordenador/>
- [29] Google Research (2022). Colaboratory [Online]. Disponible: [https://research.google.com/colaboratory/intl/es/faq.html#:~:text=Colaboratory,%20o%20"Colab"%20para,análisis%20de%20datos%20y%20educación.](https://research.google.com/colaboratory/intl/es/faq.html#:~:text=Colaboratory,%20o%20)

- [30] GeeksforGeeks. (2023) Residual networks (resnet) - deep learning [Online]. Disponible: <https://www.geeksforgeeks.org/residual-networks-resnet-deep-learning/>
- [31] Team, D.S. (2020) Redes Neuronales residuales - lo que necesitas saber (ResNet), DATA SCIENCE. [Online]. Disponible: <https://datascience.eu/es/aprendizaje-automatico/una-vision-general-de-resnet-y-sus-variantes/>
- [32] López, F. (2019). Clasificación de imágenes usando redes neuronales convolucionales. Disponible: <http://zaloamati.azc.uam.mx/handle/11191/6123>
- [33] UNIR. (2021). El algoritmo gradient descent para el entrenamiento de redes neuronales [Online]. Disponible: <https://www.unir.net/ingenieria/revista/gradient-descent/>
- [34] A. Boudiaf, K. Harrar, S. Benlahmidi, R. Zaghdoudi, S. Ziani and S. Taleb, "Automatic surface defect recognition for hot-rolled steel strip using AlexNet convolutional neural network," 2022 7th International Conference on Image and Signal Processing and their Applications (ISPA), Mostaganem, Algeria, 2022, pp. 1-5
- [35] Kubat, M., & Kubat, J. A. (2017). *An introduction to machine learning* (Vol. 2, pp. 321-329). Cham, Switzerland: Springer International Publishing.
- [36] Ajitesh Kumarl - Data Analytics. (2020) Keras - categorical cross entropy loss function [Online]. Disponible: [https://vitalflux.com/keras-categorical-cross-entropy-loss-function/#:~:text=categorical\\_crossentropy%3A%20Used%20as%20a%20loss,into%20categorical%20encoding%20using%20keras.](https://vitalflux.com/keras-categorical-cross-entropy-loss-function/#:~:text=categorical_crossentropy%3A%20Used%20as%20a%20loss,into%20categorical%20encoding%20using%20keras.)
- [37] Interactive Chaos. (2020). Adam [Online]. Disponible: <https://interactivechaos.com/es/manual/tutorial-de-machine-learning/adam>
- [38] J.D. Alzate. (comunicación privada), 2022.
- [39] V.E. Cárdenas (comunicación privada), 2022.
- [40] R. Quiroga. "Indicadores ambientales y de desarrollo: avances y perspectivas para América Latina y el Caribe". Santiago de Chile: Naciones Unidas, 2007.
- [41] A. Ivette (2021, abril 10). Indicador ambiental [Online]. Disponible en: <https://economipedia.com/definiciones/indicador-ambiental.html>
- [42] F. Coll (2020, junio 21). Huella ecológica [Online]. Disponible: <https://economipedia.com/definiciones/huella-ecologica.html>
- [43] M. Lambertini. "Informe planeta vivo 2020". Londres: WWF, 2020.
- [44] Greenpeace México (2020, diciembre 26). Huella de carbono: aprende a calcular tu impacto ambiental [Online]. Disponible: <https://www.greenpeace.org/mexico/blog/9386/huella-de-carbono/#:~:text=La%20huella%20de%20carbono%20se,del%20resto%20de%20los%20elementos.>

- [45] Dantas, K. and Donnini, F. (2021) Archivo Json: Descubre Qué es y para qué sirve, Rock Content [Online]. Disponible: <https://rockcontent.com/es/blog/archivo-json/#:~:text=El%20formato%20JSON%20se%20utiliza,manera%20sencilla%2C%20liviana%20y%20r%C3%A1pida.>