



Acta de Correcciones al Proyecto de Grado Ingeniería Electrónica

Fecha:

Autores:

Juan Esteban Torres Tamayo
Janner Arley Rosero Mora

Nombre del Proyecto de Grado:

Clasificación automática de residuos aprovechables y no aprovechables en la Pontificia Universidad Javeriana Cali usando Deep Learning.

Director: Hernán Darío Vargas Cardona

Como indica el artículo 2.27 de las Directrices de Trabajo de Grado, he verificado que los estudiantes indicados arriba han implementado todas las correcciones que los Jurados del Proyecto de Grado definieron que se efectuaran, como consta en el Acta de Calificación correspondiente.

Firma de Director(a) del Proyecto de Grado

Nota de Aceptación

Aprobado por el Comité de Trabajo de Grado en cumplimiento de los requisitos exigidos por la Pontificia Universidad Javeriana para optar el título de Ingeniero Electrónico.

Camilo Rocha

Dr. Hernán Camilo Rocha Niño
Decano de la Facultad de Ingeniería

[Handwritten signature]

Dr. LUIS EDUARDO TOBON LLANO
Director Carrera Ingeniería Electrónica.

[Handwritten signature]

Dr. Hernán Darío Vargas Cardona
Director(a) Trabajo

Hernan Dario Benitez Restrepo

Dr. Hernán Darío Benítez Restrepo
Jurado 1

Alexander Martinez A.

Dr. Alexander Martínez Álvarez
Jurado 2



Pontificia Universidad
JAVERIANA
Cali

**Facultad de Ingeniería
y Ciencias**
Ingeniería Electrónica

MONOGRAFÍA DE TRABAJO DE GRADO

Clasificación automática de residuos aprovechables y no
aprovechables en la Pontificia Universidad Javeriana
Cali usando Deep Learning.

Juan Esteban Torres Tamayo
Janner Arley Rosero Mora

Director

Dr. Hernán Darío Vargas Cardona

24 de febrero de 2023

Santiago de Cali, 24 de febrero de 2023

Señores
Pontificia Universidad Javeriana – Cali
Dr. Hernán Camilo Rocha Niño
Decano
Facultad de Ingeniería y Ciencias
Ciudad

Cordial Saludo.


Por medio de la presente nos permitimos presentarle el Trabajo de Grado titulado “Clasificación automática de residuos aprovechables y no aprovechables en la Pontificia Universidad Javeriana Cali usando Deep Learning.”.

Esperamos que este trabajo reúna todos los requisitos académicos, cumpla el propósito para el cual fue creado y sirva de apoyo para futuros proyectos relacionados con la materia.

Atentamente,



Juan Esteban Torres Tamayo



Janner Arley Rosero Mora

Santiago de Cali, 24 de febrero de 2023

Señores

Pontificia Universidad Javeriana – Cali

Dr. Hernán Camilo Rocha Niño

Decano

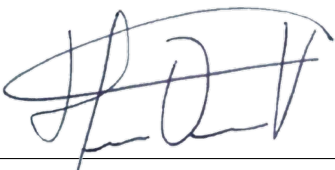
Facultad de Ingeniería y Ciencias

Ciudad

Cordial Saludo.

Certifico que el presente Trabajo de Grado titulado “Clasificación automática de residuos aprovechables y no aprovechables en la Pontificia Universidad Javeriana Cali usando Deep Learning.”, realizado por Juan Esteban Torres Tamayo y Janner Arley Rosero Mora, estudiantes de Ingeniería Electrónica, se encuentra terminado y puede ser presentado para su sustentación.

Atentamente,



Dr. Hernán Darío Vargas Cardona
Director Trabajo de Grado

Agradecimientos

Queremos agradecer en primer lugar al doctor Hernán Darío Vargas Cardona quien fue nuestro director a lo largo de este proceso, le agradecemos por su tiempo y consejos que fueron de vital importancia para la culminación de este proyecto. Queremos darle las gracias a todos los docentes que nos acompañaron en nuestra formación académica brindándonos sus conocimientos rigurosos y precisos además de hacerlo de una manera muy profesional siempre con dedicación y respeto. Queremos también agradecer a nuestros familiares y amigos que estuvieron apoyando y dando ánimos para que no desfalleciéramos a mitad de camino y lográramos cumplir nuestro objetivo. Finalmente, un especial agradecimiento a la Pontificia Universidad Javeriana Cali que nos brindó formación profesional buscando siempre que seamos los mejores para el mundo no solo desde lo académico sino también desde lo humano, con valores claros y compromiso con la sociedad.

Glosario

Acrónimos y Abreviaturas

<i>AUC</i>	Area Under the Curve
<i>CNN</i>	Convolutional Neural Network
<i>DL</i>	Deep Learning
<i>DNP</i>	Departamento Nacional de Planeación
<i>IA</i>	Inteligencia Artificial
<i>KNN</i>	K-Nearest Neighbors
<i>MCC</i>	Matthews Correlation Coefficient
<i>ML</i>	Machine Learning
<i>ODS</i>	Objetivos de Desarrollo Sostenible
<i>PGIR</i>	Plan de Gestión Integral de Residuos
<i>PLN</i>	Procesamiento de Lenguaje Natural
<i>PUJC</i>	Pontificia Universidad Javeriana Cali
<i>ROC</i>	Receiver Operating Characteristic
<i>UCA</i>	Unidad Central de Almacenamiento
<i>SVM</i>	Support Vector Machines
<i>VA</i>	Visión Artificial

Términos

<i>Transfer Learning</i>	Método de aprendizaje automático que permite transferir el aprendizaje a otro modelo.
<i>Dataset</i>	Conjunto de datos usado para el entrenamiento de los modelos.
<i>Métrica</i>	Dato numérico o gráfico que permite analizar el rendimiento de determinado modelo.

Resumen

El procesamiento de los residuos sólidos es un problema que viene perjudicando a la humanidad desde hace ya varios años, dando por resultado contaminación y acumulación excesiva de desperdicios en rellenos sanitarios. Todo este panorama ha traído consigo la aplicación de normativas para la clasificación de los residuos para su posterior procesamiento, donde en Colombia la actual normativa dicta tres tipos de residuos: Aprovechables, No Aprovechables y Orgánicos. Sin embargo, aún con la existencia de normativas y campañas educativas sobre el manejo de los residuos sólidos urbanos, la comunidad no realiza adecuadamente la separación de dichos materiales y esto trae consigo un aumento energético laboral en las instalaciones dedicadas al procesamiento de desperdicios que buscan darles un correcto tratamiento a estos.

Este trabajo propone la implementación de una herramienta tecnológica que permita realizar una clasificación automática de los residuos orgánicos enfocándose en las instalaciones del campus de la Pontificia Universidad Javeriana Cali. Para ello, se partió de la visión computacional para el reconocimiento de imágenes de residuos los cuales son procesados y clasificados a partir de un algoritmo de Deep Learning que tiene por objetivo identificar y clasificar los residuos entre aprovechables y no aprovechables. Después de un proceso de benchmarking entre modelos implementados con Transfer Learning el modelo escogido alcanza métricas de 0.93 en Accuracy.

Palabras Clave: Deep Learning, Visión Computacional, Residuos aprovechables, Residuos no aprovechables, Redes Neuronales Convolucionales, Clasificador automático, Transfer Learning.

Abstract

The processing of solid waste is a problem that has been harming humanity for several years, resulting in pollution and excessive accumulation of waste in landfills. This whole scenario has brought about the application of regulations for the classification of waste for further processing, where in Colombia the current regulations dictate three types of waste: Usable, Non-usable and Organic. However, even with the existence of regulations and educational campaigns on the management of urban solid waste, the community does not adequately separate these materials and this brings with it an increase in labor energy in the facilities dedicated to the processing of waste that seek to give them a correct treatment.

This work proposes the implementation of a technological tool that allows the automatic classification of organic waste focusing on the facilities of the campus of the Pontificia Universidad Javeriana Cali. For this purpose, computer vision was used for the recognition of waste images which are processed and classified from a Deep Learning algorithm that aims to identify and classify waste between usable and non-usable. After a benchmarking process between models implemented with Transfer Learning, the chosen model reaches 0.93 metrics in Accuracy.

Keywords: Deep Learning, Computational Vision, Usable waste, Non-usable waste, Convolutional Neural Networks, Automatic Classifier, Transfer Learning.

Índice general

1. Introducción	1
1.1. Planteamiento del problema	2
1.1.1. Formulación	4
1.1.2. Sistematización	4
1.2. Objetivos	4
1.2.1. Objetivo General	4
1.2.2. Objetivos Específicos	4
1.3. Justificación	4
1.4. Limitaciones y alcances	6
2. Marco de Referencia	7
2.1. Áreas Temáticas	7
2.2. Marco Teórico	7
2.3. Trabajos Relacionados	11
3. Materiales y Métodos	13
3.1. Materiales	13
3.1.1. Ambiente con luminosidad controlada	13
3.1.2. Base de datos (Dataset)	15
3.1.3. Cámara	16
3.1.4. Google Colab	16
3.1.5. Jupyter NoteBook	17
3.1.6. Tensorflow	17
3.1.7. Keras	18
3.1.8. Sklearn	18
3.1.9. Matplotlib	19
3.1.10. Python	19
3.2. Métodos	19
3.2.1. Elección de modelos	19
3.2.2. Métricas	23
3.2.3. Entrenamiento y validación	25
4. Resultados y Discusión	27
4.1. Resultados	27
4.1.1. Hiperparámetros	27
4.1.2. Métricas obtenidas	28
4.2. Discusión	32

4.2.1. Análisis del error	35
4.2.2. Rendimiento del modelo elegido utilizando aumento de datos	37
5. Conclusiones	41
6. Trabajos futuros	42
7. Anexos	43
Bibliografía	54

Índice de figuras

2.1. Arquitectura de una CNN. Tomado de [15].	9
3.1. Plano del ambiente controlado. Diseño propio.	13
3.2. Ambiente de luminosidad controlada (cerrado). Fotografía propia.	14
3.3. Ambiente de luminosidad controlada (abierto). Fotografía propia.	14
3.4. Fotografía de residuos aprovechable. Fotografía propia.	15
3.5. Fotografía de residuos no aprovechable. Fotografía propia.	15
3.6. Logo - Google Colab.	17
3.7. Logo - Jupyter Notebook. Tomado de [31].	17
3.8. Logo - Tensorflow. Tomado de [32].	18
3.9. Logo - Keras. Tomado de [33].	18
3.10. Logo - ScikitLearn. Tomado de [34]	18
3.11. Logo - Matplotlib. Tomado de [36].	19
3.12. Logo - Python. Tomado de [37].	19
3.13. Representación gráfica del modelo InceptionV1. Tomado de [39]	20
3.14. Representación gráfica del modelo ResNet50V2. Tomado de [41]	21
3.15. Capas que componen el modelo MobileNetV3. Tomado de [42]	22
3.16. Representación gráfica del modelo MobileNet + SVM. Tomado de [29]	22
3.17. Representación gráfica del modelo VGG19. Tomado de [45]	23
4.1. Diagrama de caja y bigote - Accuracy.	28
4.2. Diagrama de caja y bigote - AUC.	28
4.3. Diagrama de caja y bigote - Recall.	29
4.4. Diagrama de caja y bigote - Specificity.	29
4.5. Diagrama de caja y bigote - F1 Score.	29
4.6. Diagrama de caja y bigote - MCC.	30
4.7. Promedio en los resultados de cada modelo.	31
4.8. Desviación estándar de cada modelo por métrica.	31
4.9. Comportamiento de Accuracy del mejor modelo durante el entrenamiento.	33
4.10. Curva ROC - Mejor modelo.	33
4.11. Matriz de confusión del mejor modelo entrenado.	34
4.12. Mosaico de imágenes mal clasificadas.	36
4.13. Comportamiento de Accuracy del modelo con datos aumentados durante el entrenamiento.	38
4.14. Curva ROC - Modelo con datos aumentados.	39
4.15. Matriz de confusión del modelo entrenado con datos aumentados.	39

7.1. Bolsa de residuos aprovechables.	44
7.2. Contenido de la bolsa de residuos aprovechables.	44
7.3. Bodega de botellas PET.	45
7.4. Bodega de cartón retal (no atable).	45
7.5. Bodega de cartón (atable).	46
7.6. Bodega de papel.	46
7.7. Bodega de residuos no aprovechables.	47
7.8. Componentes electrónicos.	47
7.9. Cables varios.	48
7.10. Marcadores.	48
7.11. Baterías.	49
7.12. Mezcla de líquidos sobrantes y tapas de botellas plásticas destinadas a fundación de niños con cáncer.	50
7.13. Bandeja de reclasificación junto al contenido de una bolsa de residuos aprovechables y residuos no aprovechables.	50

Índice de tablas

3.1. Características del sensor de la cámara posterior del Samsung Galaxy J8 - Tomado de [46]	16
3.2. Características de la imagen de la cámara posterior del Samsung Galaxy J8 - Tomado de [46]	16
3.3. Características del objetivo de la cámara posterior del Samsung Galaxy J8 - Tomado de [46]	16
3.4. Matriz de confusión.	23
4.1. Tabla de hiperparámetros utilizados en los modelos híbridos.	27
4.2. Media y desviación estándar de las métricas obtenidas	30
4.3. Mejores resultados obtenidos	35
4.4. Resultados con aumento de datos.	40

Introducción

El procesamiento de los residuos sólidos urbanos representa una gran problemática para todas las instalaciones y localidades del mundo debido a las consecuencias perjudiciales para el medio ambiente ocasionadas por un manejo de residuos erróneo. Para ello cada país adopta una reglamentación ecológica la cual dicta las instrucciones a seguir para la administración de los residuos. En Colombia, la resolución 2184 de 2019 es la última norma instaurada por el gobierno para el tratamiento de los residuos, en ella se postulan tres clasificaciones, cada clasificación viene acompañada de un código de colores, estas son: Aprovechables (Blanco) los cuales son plásticos, cartón, vidrio, papel y metales; No aprovechables (Negro), estos son papeles metalizados, servilletas, papeles y cartones contaminados con comida y papel higiénico; Y por último, Organicos aprovechables (Verde), los cuales corresponden a restos de comida y desechos agrícolas [1]. La Pontificia Universidad Javeriana Cali (PUJC) con la intención de adoptar los lineamientos de esta resolución ha actualizado su Plan de Gestión Integral de Residuos (PGIR), en él plasma sus estrategias, procesos y análisis del procesamiento de las basuras generadas dentro del campus de la universidad por parte de la comunidad universitaria. Sin embargo, al indagar con el personal encargado de dicha tarea es posible percatarse de falencias en este proceso que perjudican los resultados de esta labor.

La causa principal identificada es el desconocimiento de las normas y clasificaciones de residuos por parte de la comunidad universitaria, por lo tanto, se optó por investigar el procesamiento de residuos en el campus. Como resultado de ello, se logró identificar una evidente ausencia de clasificación por parte de las personas en los puntos ecológicos. Dicho problema genera una carga laboral elevada al obligar a los funcionarios de la Unidad Central de Almacenamiento (UCA) a tener que reclasificar todas las bolsas con residuos que se producen dentro de las instalaciones de la universidad.

Esta problemática no es exclusiva de la PUJC, pues en todo Colombia se presenta este tipo de inconvenientes que intervienen con el correcto procesamiento y por tanto el desperdicio de toda la materia prima que puede ser recuperada de estos residuos. Según [2], en Colombia se podría aprovechar el 40 % de los residuos producidos anualmente, pero dados estos percances solo se logra aprovechar cerca el 17 %.

Con el fin de contrarrestar dicho inconveniente se realizó una investigación dentro del área de la ingeniería con el objetivo de encontrar soluciones tecnológicas enfocadas en esta área. De esta revisión se logra caracterizar que la unión de técnicas de Deep Learning (DL) y Visión Artificial (VA) son factibles para la identificación automática de objetos, los cuales pueden ser clasificados posteriormente. Este proceso consiste en la adquisición de información de fotografías por medio de VA y el procesamiento de esta en un modelo de DL previamente entrenado con una base de datos de imágenes, para de esta manera identificar qué tipo de residuo es.

En este trabajo se presenta el desarrollo de la implementación de técnicas de DL y VA junto a la conformación de una base de datos formada de imágenes de residuos las cuales en conjunto permitirán la identificación automática y posterior clasificación de residuos sólidos urbanos generados dentro de las instalaciones del campus de la PUJC.

Este documento se organiza de la siguiente manera: El capítulo 1 condensa el planteamiento del problema, exponiendo sus causas y efectos, los objetivos del proyecto, la justificación de este y establece sus limitaciones y alcances. El capítulo 2 expone el estado del arte y detalla los conceptos usados para este trabajo. El capítulo 3 presenta los materiales y los métodos usados para el desarrollo de este proyecto. El capítulo 4 expone los resultados obtenidos y la discusión sobre los mismos. El capítulo 5 presenta las conclusiones a las que se ha llegado después de todo el proceso. El capítulo 6 exhibe las recomendaciones, alternativas y sugerencias para el desarrollo de trabajos futuros, y finalmente, en el capítulo 7 se podrán encontrar anexos relevantes que complementan la presentación de este proyecto.

1.1. Planteamiento del problema

En el año 2019, Colombia generaba aproximadamente 11.6 millones de toneladas de residuos sólidos al año. De estos, cerca de 40 % podrían aprovecharse, pero según la Misión de Crecimiento Verde del Departamento Nacional de Planeación (DNP), solamente se recicla alrededor de 17 %, lo que ha llevado a la sobresaturación de los depósitos sanitarios del país. Debido al mal tratamiento de estos residuos sólidos se están presentando asentamientos de basuras en el mar lo que converge en la generación de islas de desperdicios y efectos nocivos sobre la fauna y flora global [2]. Desde el año 2016, el DNP anunció que 321 depósitos sanitarios del país colapsarían en cinco años [3], es decir que desde el año 2021 estos ya no dan abasto para las cantidades de toneladas de basura que reciben diariamente. Este dato es alarmante dado que en estos espacios se realizan entierros de basura para mantener a las personas fuera de los peligros que puede generar la descomposición de estos desechos, sin embargo, la falta de separación de los residuos perjudica los procesos de reciclaje y esto genera que materiales contaminantes o de lenta degradación sean enterrados en suelos, contaminando el medio ambiente [4]. Para atenuar estas consecuencias se han organizado proyectos de reciclaje como Reciclatón, el cual, según el Pacto Global Red Colombia, en el año 2021, logró recolectar 3.6 toneladas de desperdicios [5]. Partiendo de estos proyectos impulsados por el gobierno nacional y empresas del sector privado se ha logrado incrementar la capacidad de reciclaje del país con el fin de acatar los Objetivos de Desarrollo Sostenible (ODS): 13 (Acción por el clima), 14 (Vida submarina) y 15 (Vida de ecosistemas terrestres) [6]. Una problemática que se presenta en los espacios públicos a la hora de la clasificación de residuos subyace en el depósito de los desechos dado que la comunidad no hace buen uso de los contenedores de basura. Haciendo énfasis en el plástico, según un estudio realizado por Hi-Cone, el 68 % de las personas encuestadas no recicla tanto plástico como debería, además de que el 79 % cree que menos de la mitad del plástico que separa se recicla, lo que desemboca en un evidente desinterés por la separación de los residuos sólidos [7]. Este desinterés conlleva comportamientos nocivos para el proceso de reciclaje, específicamente el depósito erróneo de los residuos en los contenedores. Los residuos pueden ser clasificados de acuerdo

con el sector que los genera, donde según el ICONTEC en su norma GTC 24, se encuentra el sector doméstico y el industrial [8]. El sector doméstico también presenta su propia clasificación, en el año 2019, el gobierno colombiano dictó la resolución 2184 donde se especifica el uso racional y la correcta separación de los residuos domésticos según su tipo, además de una distribución de colores para distinguirlos. Dentro de esta clasificación se presentan los residuos aprovechables (plástico, cartón, vidrio, papel y metales) con color blanco, los residuos no aprovechables (papel higiénico, servilletas, papeles y cartones contaminados con comida y papeles metalizados) con color negro y los residuos orgánicos aprovechables (restos de comida y desechos agrícolas) con color verde [1]. Esta distribución y norma se ha ampliado hasta los contenedores de basura en espacios públicos tales como centros comerciales, universidades, supermercados, entre otros. En cuanto a los desafíos para la ingeniería dentro del campo planteado se puede encontrar que uno de los principales retos es la correcta identificación de los objetos por medio de la visión artificial, dado que un fallo en esta identificación puede resultar en una mala caracterización del objeto, lo que puede desfavorecer los datos de entrenamiento del clasificador y con ello conllevar a un aumento de falsos positivos y falsos negativos dentro del proceso de separación. Para contrarrestar este tipo de inconvenientes es necesario aplicar técnicas que permitan extraer de manera adecuada la información de los objetos captados en cámara y así evitar este tipo de problemas. Por el lado del clasificador, es necesario refinar su arquitectura hasta obtener el modelo que permita cumplir con las métricas de clasificación deseadas mientras que no se haga un uso excesivo de recursos, es decir, implementar una arquitectura que cumpla con los requerimientos sin que su arquitectura sea más robusta de lo que debería. Para esto se puede partir de trabajos relacionados con DL y así tomar un punto de partida con el fin de seleccionar las principales características de la red neuronal, tal y como son las cantidades de capas, neuronas y tipos de funciones de activación. Centrándose en la ubicación objetivo, la PUJC cuenta con un plan de gestión para los residuos que generan los estudiantes, concesionarios y personal. Este plan propone la recolección y separación de los residuos con base en las normativas expedidas por el gobierno colombiano. El proceso de recolección se realiza manualmente por operarios que recorren el campus de la universidad extrayendo las bolsas de basura de cada uno de los 95 puntos ecológicos ubicados a lo largo de las instalaciones, estas bolsas son trasladadas por medio de practiwagos, que son contenedores plásticos equipados con ruedas para el fácil transporte de los residuos. Una vez se realiza la recolección de estos se procede a llevarlos a la Unidad Central de Almacenamiento (UCA), en este punto se realiza una reclasificación, en muchos casos, de todos los residuos que llegan a la instalación, obligando a tener una persona encargada durante todo el día de esta labor, pues los residuos aprovechables son separados, pesados y vendidos a empresas externas. Por el lado de los residuos no aprovechables y orgánicos, estos son almacenados hasta ser recogidos por la empresa local de desechos y posteriormente son depositados en rellenos sanitarios [9]. Tras una visita técnica y una charla con los empleados encargados del correcto funcionamiento del UCA, se afirmó por su parte que la conciencia ambiental dentro del campus de la PUJC en cuanto a la clasificación de residuos deja mucho que desear, pues en ocasiones las bolsas de residuos aprovechables y no aprovechables son indistinguibles en cuanto a su contenido y por ello es necesaria una completa reclasificación haciendo necesario que el encargado de esta tarea tarde una jornada laboral completa.

1.1.1. Formulación

¿Cómo realizar la clasificación de residuos en la PUJC empleando técnicas de Deep Learning y visión artificial?

1.1.2. Sistematización

- ¿Cómo obtener un conjunto de datos de entrenamiento y validación para el clasificador que se desea implementar?
- ¿Cómo dotar de poder decisional al clasificador que se desea implementar?
- ¿Cómo determinar el rendimiento del clasificador?

1.2. Objetivos

1.2.1. Objetivo General

Implementar técnicas de Deep Learning y visión artificial para la clasificación de residuos aprovechables y no aprovechables en la PUJC.

1.2.2. Objetivos Específicos

- Conformar una base de datos adecuada compuesta por imágenes digitales para el entrenamiento de las técnicas de DL.
- Implementar técnicas de DL que permitan la identificación automática de residuos aprovechables y no aprovechables.
- Evaluar la eficiencia de las técnicas de identificación automática empleando métricas de clasificación.

1.3. Justificación

Dentro del Plan de Gestión Integral de Residuos (PGIR) de la PUJC se describe el correcto manejo que se le debe dar a los residuos sólidos generados, producto de las diversas actividades que se realizan dentro del campus como lo pueden ser prácticas de laboratorio, mantenimiento del campus, preparación de alimentos, gestión administrativa, entre otras.

Dentro del diseño de este plan se gira entorno a dos pilares fundamentales:

1.3.0.1. Reducción en el origen:

La cual implica acciones orientadas a promover cambios en el consumo de bienes y servicios para reducir la cantidad de residuos generados por parte de los usuarios. Incluye el desarrollo de acciones que promuevan la compra de bienes y servicios que faciliten su reutilización o aprovechamiento, la optimización de los procesos productivos, el desarrollo de programas y proyectos de sensibilización, educación y capacitación [9].

1.3.0.2. Aprovechamiento:

Implica el desarrollo de proyectos de aprovechamiento de residuos para su incorporación en el ciclo productivo con viabilidad social, económica y financiera que garanticen su sostenibilidad en el tiempo y evaluables a través del establecimiento de metas por parte del municipio o distrito [9].

Ahora, centrándonos en el tema de interés que es puntualmente la clasificación de residuos dentro del campus de la Pontificia Universidad Javeriana Cali, se encontró que los encargados de esta labor al cabo del último año se toparon con alrededor de 50t de residuos que debieron pasar por la UCA antes de ser entregados a los entes pertinentes y cabe resaltar que toda esta labor se lleva a cabo de manera manual [9]. Durante el proceso de reclasificación necesario para la venta de residuos aprovechables, según los encargados de esta labor dentro de la UCA, se ha manifestado que no se está llevando a cabo el correcto depósito de residuos en los puntos ecológicos distribuidos a lo largo de todo el campus y esto ocasiona que el proceso de reclasificación se vuelva más complejo y largo de lo que debería ya que bajo su criterio existen ocasiones en el que el contenido de las bolsas de residuos aprovechables llega de manera similar al de la bolsa de residuos no aprovechable.

Lo mencionado anteriormente da cabida a resaltar que actualmente dentro de la comunidad que hace uso del campus no existe gran compromiso con seguir la pautas de clasificación de residuos aprovechables y no aprovechables adoptadas por la Universidad.

Dicho todo lo anterior, se puede llegar a la conjetura de que existe la necesidad de implementar una solución que pueda ayudar tanto al personal de gestión de residuos como a la población que hace mal uso de los puntos ecológicos (Puntos de depósito de residuos) que están distribuidos a lo largo del campus.

Por las razones expuestas hasta el momento es que en este trabajo se busca la realización de un algoritmo que hace uso de Deep learning para caracterizar residuos y distinguir si sus características son propias de un residuos aprovechable o no, justo antes de que se haga el depósito de este en un recipiente. Esto yendo en lineamiento con los objetivos de diseño planteados para el PGIR mencionados anteriormente, así como buscando aportar al objetivo de desarrollo sostenible número 12 en cuanto a la gestión de residuos (Meta 12.4).

Para finalizar, la visión que se tiene es que este trabajo sirva como base para una futura implementación de un sistema mecatrónico autónomo de clasificación de residuos que pueda instalarse en cada uno de los puntos ecológicos y ayude a garantizar en la medida de lo posible la correcta categorización de residuos mientras que a la par ofrece retroalimentación al usuario sobre la naturaleza


del residuo depositado y su respectivo recipiente y color.

1.4. Limitaciones y alcances

1. Se implementaron técnicas de DL y visión artificial para la clasificación automática de desechos, limitándose al entrenamiento y validación de modelos de redes neuronales, dejando de lado implementaciones físicas.
2. El entrenamiento y validación del modelo de aprendizaje de máquina se realizaron con un dataset de fotografías tomadas bajo un ambiente controlado.
3. El modelo de aprendizaje de máquina seleccionado cuenta con las capacidades de ser implementado físicamente en las instalaciones de la PUJC.
4. El modelo de aprendizaje de máquina es capaz de clasificar desechos en dos clases: Aprovechables y No Aprovechables. Esto siguiendo la resolución 2184 de 2019 y las consideraciones prácticas del manejo de residuos de la PUJC.
5. El desarrollo de este proyecto se realizó basándose en metodologías existentes para el reconocimiento de imágenes mediante técnicas de DL.

Marco de Referencia

2.1. Áreas Temáticas

Áreas temáticas del proyecto para las áreas propias de la disciplina utilizando la taxonomía del  IEEE.

- Computational and artificial intelligence - Artificial intelligence.
- Computational and artificial intelligence - Machine learning - Deep learning.
- Computational and artificial intelligence - Machine learning - Transfer learning.

2.2. Marco Teórico

2.2.0.1. Clasificación de residuos

Los residuos sólidos urbanos son todos aquellos empaques, recipientes, cubiertas, entre muchos otros desperdicios que son generados en el sector doméstico [7]. Estos presentan distintos marcos de clasificación de acuerdo a su ubicación y su posibilidad de reaprovechamiento. En Colombia se cuenta con la resolución 2184 de 2019 la cual instauro la norma de tres tipos de residuos [8]:

- Residuos aprovechables: Estos residuos son todos aquellos que por sus características de materiales pueden ser procesados para posteriormente reintroducirlos a la cadena productiva [10]. Entre ellos se encuentran plástico, cartón, papel, vidrio, metales [8].
- Residuos no aprovechables: Estos residuos son aquellos que dadas las características físicas de sus materiales no cuentan con la capacidad de ser aprovechados de nuevo [10]. Entre ellos se encuentran papel higiénico, servilletas, papeles contaminados con comida o papeles metalizados [8].
- Residuos Orgánicos: Estos residuos son todos aquellos restos de alimentos, estos suelen ser usados para el uso de compostaje.

2.2.0.2. Aprendizaje de máquina

El aprendizaje de máquina (ML) consiste en algoritmos capaces de reconocer patrones en los datos suministrados y con base a ellos genera modelos de predicción y toma de decisiones. Estas decisiones están basadas puramente en el campo matemático, consiguiendo así un criterio completamente objetivo a diferencia de las decisiones humanas [11].

2.2.0.3. Deep Learning

Se reconoce al Deep learning como un subcampo del aprendizaje de máquina que busca emular el aprendizaje humano con el fin de dar poder decisional a una máquina. Una de las características que lo hace tan versátil es que a diferencia del aprendizaje de máquina no se requiere de reglas previamente programadas pues el propio sistema en sí es capaz de “Aprender” tras una sesión de entrenamiento. Otra característica relevante dentro de este método es que se compone de redes neuronales entrelazadas que procesan la información para retornar una salida [12]. Dentro de los algoritmos que componen a un sistema de Deep learning se pueden distinguir principalmente tres capas neuronales:

- Capa de entrada : Asimilan datos de entrada como imágenes o tablas de datos.
- Capa oculta: Procesa la información y hace los cálculos necesarios. A medida que crece el número de neuronas presentes, la complejidad de los cálculos aumenta.
- Capa de salida: Toma una decisión o realiza una conclusión aportando datos de salida.

La unidad básica de procesamiento que utilizan las redes neuronales son denominadas ‘Neuronas’ a las cuales se les asocia un ‘Peso’, el cual define la relevancia que tiene una neurona dentro del sistema. Para que el proceso de aprendizaje del Deep Learning se diferencie del Aprendizaje de máquina se debe garantizar que la función de activación de las neuronas sea no lineal pues el que sean lineales implicaría que el resultado final se puede calcular sin necesidad de utilizar neuronas, haciendo que el proceso sea un sinsentido, pues conceptualmente las neuronas actúan como un procesamiento de un resultado para aumentar la fiabilidad de la decisión final y sería de esperarse que un sistema de más neuronas entregue resultados más afines a la realidad [12].

2.2.0.4. Transfer Learning

El aprendizaje por transferencia es un método de aprendizaje automático en el que un modelo desarrollado para una tarea se reutiliza como punto de partida para un modelo en una segunda tarea.

Es un enfoque popular en el aprendizaje profundo, en el que se utilizan modelos preentrenados como punto de partida en tareas de visión por ordenador y procesamiento del lenguaje natural, dados los enormes recursos de computación y tiempo necesarios para desarrollar modelos de redes neuronales en estos problemas y por los enormes saltos de habilidad que proporcionan en problemas relacionados. [13]

De este método se puede resaltar las siguientes dos aproximaciones:

- Feature extraction: Este proceso consiste en usar una red ya entrenada como extractor de características, seguido a que estas son adquiridas se procede a realizar la clasificación/regresión de los objetos analizados.

- Fine-Tuning: Este proceso consta de tomar una red ya entrenada y acoplarla a otra para posteriormente ser entrenadas, pero con la excepción de que esta red acoplada es “congelada”, es decir, no entrena nuevamente sino que se hace uso de sus pesos ya entrenados para realizar la clasificación/regresión.

2.2.0.5. CNN (Redes neuronales artificiales convolucionales)

Las CNN son potentes sistemas de procesamiento de imágenes e inteligencia artificial (IA) que utilizan el aprendizaje profundo para llevar a cabo tareas tanto generativas como descriptivas, a menudo utilizando la visión de máquina que incluye el reconocimiento de imágenes y vídeos, junto con los sistemas de recomendación y el procesamiento del lenguaje natural (PLN) [14].




Figura 2.1: Arquitectura de una CNN. Tomado de [15].

La figura 6.1 presenta un ejemplar de la arquitectura de una CNN en la cual se puede observar los componentes básicos de toda red de este tipo. Primero se cuenta con una entrada que ingresa a una primera capa llamada Input Layer, seguido de una serie de capas llamadas Hidden Layers y finalmente la capa Output Layer. La arquitectura de una CNN siempre cuenta con estos tres tipos de capas, más sin embargo las capas ocultas pueden variar en la cantidad de ellas dependiendo del problema, así mismo varían la cantidad de neuronas por cada capa.

2.2.0.6. Visión computacional

La visión computacional es un asunto relativamente nuevo y totalmente conectado con el aprendizaje de las máquinas (Machine Learning). Concepto conocido también como visión por computador, es el área de la ciencia que desarrolla teorías y métodos hacia la extracción automática de información útil contenida en imágenes. El objetivo de esta ciencia es crear y transmitir esa información a las máquinas de forma comprensible [16].

2.2.0.7. Datasets

Un conjunto de datos o dataset corresponde a los contenidos de una única tabla de base de datos o una única matriz de datos de estadística, donde cada columna de la tabla representa una variable en particular, y cada fila representa a un miembro determinado del conjunto de datos que se está

tratando [17]. Estos conjuntos de datos pueden ser hallados en plataformas dedicadas como Kaggle, Google Datasets Search, páginas gubernamentales o creados por los mismos investigadores.

2.2.0.8. Clasificación

Clasificación hace referencia a un proceso donde el objetivo es asignar la etiqueta correcta a una serie de datos según los criterios de clasificación programados [18]. Este proceso puede abarcar problemas binarios o de múltiples variables.

2.2.0.9. Métricas

Las métricas son indicadores numéricos que representan el rendimiento de un algoritmo de clasificación, en otras palabras, que tan acertado es el resultado de una clasificación con respecto a la solución real. Existen varias métricas usadas en el ámbito del aprendizaje de máquina, algunas de las más conocidas son:

- Accuracy: Esta métrica consiste en la relación entre el número de muestras clasificadas correctamente y el número total de muestras, donde esta relación aplica tanto para clasificaciones binarias como para ejemplares multiclases. Sin embargo, esta métrica no puede ser considerada adecuada cuando el dataset en uso está desbalanceado, es decir, el número de muestras de una clase es mucho mayor al número de muestras de otra clase, en estos casos debe considerarse otra métrica [18].
- MCC (Matthews Correlation Coefficient): Una métrica que ha tomado gran acogida y permite una solución a los problemas de clases desbalanceadas es el Coeficiente de Correlación de Matthews. Esta métrica se considerará de las más fiables, pero es importante reconocer que existen casos extremos donde presenta fluctuaciones que perjudican la calidad de la medida, no obstante existen soluciones matemáticas que permiten solucionar estos problemas [18].
- F1 score: Esta métrica es usualmente usada tanto en problemas binarios como multiclases. En los casos multiclases es posible implementar un procedimiento de promediación macro/micro y así adquirir la característica de invariabilidad en casos multiclase al intercambiar clases [18].
- Matriz de confusión: Las matrices de confusión son la forma más usual y estándar de informar sobre la exactitud temática de productos derivados de la clasificación de datos procedentes de imágenes [19].
- Curva ROC: La curva ROC es una gráfica que presenta el rendimiento de un algoritmo de clasificación en todos los umbrales [20]. La curva presenta dos parámetros:
 - Tasa de verdaderos positivos (True positive rate TPR).
 - Tasa de falsos positivos (False positive rate FPR).
- Área bajo la curva ROC (AUC): El AUC mide el área bidimensional bajo la curva ROC tomando valores entre 0 y 1, donde 0 se interpreta como un clasificador con predicciones 100 % incorrectas y 1 como un clasificador con predicciones 100 % correctas [21].

2.2.0.10. Validación

La validación corresponde a uno de los pilares dentro del desarrollo de algoritmos, específicamente en DL se debe probar que el algoritmo cuenta con la capacidad de extraer correctamente las características de las muestras y realizar una correcta clasificación asignando correctamente las clases. Para la validación de un algoritmo como este se puede partir de un mismo dataset, dicho arreglo de datos puede ser dividido en un arreglo de entrenamiento y el restante en un arreglo destinado a pruebas de modo que no se llegue a realizar overfit del algoritmo. Esta separación es de carácter porcentual y su distribución suele variar dependiendo del investigador.

2.3. Trabajos Relacionados

- **Punto ecológico automatizado para separación y clasificación de residuos a través de una neurona artificial.** Este trabajo consiste en la implementación de un punto ecológico inteligente en la Universidad de Córdoba, esta estación de reciclaje captura fotografías de los residuos y automáticamente usando un modelo de clasificación KNN (K-Nearest Neighbors) realiza la apertura del contenedor indicado. La clasificación de los residuos contempla la Resolución 2184 de 2019 sobre el código de colores para residuos en Colombia. Para mayor detalle sobre el trabajo puede verse [22].
- **Método de aprendizaje profundo híbrido multicapa para la clasificación y el reciclaje de residuos.** En este trabajo se propone un sistema híbrido multicapas con Deep Learning para la clasificación de residuos en zonas públicas, para ello se basan en un sistema CNN para adquirir las características de las fotografías de los residuos y un método de perceptrones multicapa para consolidar dichas características y clasificarlas. El sistema fue probado en dos escenarios distintos con artículos etiquetados manualmente consiguiendo una precisión de más del 90 % [23].
- **Un novedoso marco de trabajo para la clasificación de la basura utilizando Aprendizaje profundo de transferencia.** Este trabajo presenta una propuesta de sistema de clasificación de basura automática a partir de fotografías de basura, clasificando los desechos en tres clases: orgánicos, inorgánicos y médicos de Vietnam. Para ello se presenta un modelo de red neuronal profundo denominado DNN-TC, el cual es una mejora del modelo ResNext, para el entrenamiento y validación del modelo se hace uso de los datasets de fotografías de basuras VN-trash y Trashnet [24].
- **Clasificador inteligente de basura basado en aprendizaje profundo para una gestión efectiva de basura.** Este trabajo propone un sistema de clasificación de residuos en las ciudades metropolitanas de India, donde se producen cerca de 10 millones de toneladas de basura. Para su clasificación se hace uso de un conjunto de imágenes etiquetadas de cuatro clases: plástico, cartón, papel y metal, las cuales son procesadas por una red neuronal convolucional (CNN). En la etapa de validación se alcanza una precisión del 76 %. Para mayor información se puede consultar [25].

- **Aplicación de clasificación de basura mediante técnicas de aprendizaje profundo.** En este trabajo se presenta una aplicación de técnicas de aprendizaje profundo para la automatización de la clasificación de los desechos humanos generados por la población de India, todo con el fin de reducir la interacción humana en este proceso, además de impactar económicamente en este proceso al reducir costos. Para este proyecto se realizaron pruebas con tres arquitecturas de CNN's distintas: una simple o genérica, ResNet50 y VGG16. Donde estas dos últimas fueron desarrolladas específicamente para el reconocimiento de imágenes. En cuanto al dataset de entrenamiento se usaron varios, entre ellos TACO y GINI los cuales están compuestos de imágenes de basura en ambientes naturales [26].
- **Diseño de una red neuronal convolucional basada en un sistema inteligente de eliminación de residuos.** El presente proyecto presenta el diseño de un sistema de clasificación de residuos en diez categorías enfocado en la localización de Bangladesh apoyados en redes neuronales convolucionales. Este sistema consiste en la construcción de una variable de cajero automático enfocado en identificar el desecho y luego recibirlo, para el reconocimiento hacen usos de técnicas de aprendizaje profundo donde han decidido estudiar los resultados usando la arquitectura AlexNet enfocada en reconocimiento de imágenes, con ella han alcanzado una métrica de accuracy en 96 % [27].
- **Segregación de residuos sólidos con CNN.** En este trabajo se presentan los resultados de una comparación de identificación de imágenes de residuos sólidos para posterior clasificación partiendo de distintas arquitecturas de redes neuronales convolucionales. Las arquitecturas probadas fueron: VGG-16, ResNet-50, MobileNet V2 y DenseNet-121. La base de datos usada consta de 9.200 imágenes de residuos en la población de Tailandia. Esta comparación dio por vencedor a la arquitectura ResNet-50 con un accuracy de 94.86 % [28].
- **Clasificación de residuos reciclables mediante visión por ordenador y aprendizaje profundo.** Este trabajo presenta los resultados del diseño y entrenamiento de un clasificador automático de residuos reciclables a partir de técnicas de Machine Learning (ML) y Deep Learning (DL). Este sistema consiste en una CNN entrenada para identificar los residuos, seguido de un clasificador de ML el cual finalmente clasifica los residuos entre cinco categorías: plástico, metal, papel, cartón y vidrio. Para la CNN han analizado doce arquitecturas existentes enfocadas en la identificación de imágenes, entre ellas están: Xception, VGG16, VGG19, MobileNet, entre otras. Para el clasificador de ML han analizado Support Vector Machine (SVM), Sigmoid y SoftMax. Como resultado del estudio han encontrado que la unión entre VGG-19 y el clasificador SoftMax es su mejor solución para este caso de estudio con una métrica de accuracy de alrededor de 88 % [29].

Materiales y Métodos

3.1. Materiales

Los materiales utilizados para el desarrollo de este proyecto han sido tanto físicos como digitales, por ello se hace la siguiente descripción de los materiales y recursos utilizados:

3.1.1. Ambiente con luminosidad controlada

Para la construcción del dataset de fotografías usado en el desarrollo de este proyecto se consideró que la luminosidad del ambiente tiene un impacto considerable en el resultado de las fotografías finales. Dadas las circunstancias anteriormente contempladas, se realizó la construcción de un ambiente con luminosidad controlada el cual permitiese la toma de fotografías de los residuos de manera que el resultado final no se vea afectado por factores ambientales externos.

Este ambiente controlado consiste en una caja rectangular de 50x30x30 cm hecha en acrílico transparente cortado a laser, esta cuenta con una de sus caras abatible para poder ingresar los elementos a fotografiar, así como un agujero circular pequeño de 2 cm de diámetro para poder ubicar la cámara del teléfono con el que se tomaron las fotografías. La figura 3.1 presenta un plano con las medidas y partes de la caja que fue usada como ambiente controlado.




Figura 3.1: Plano del ambiente controlado. Diseño propio.

Para mantener una luminosidad uniforme a la hora de tomar las fotografías, la caja fue forrada en su totalidad de papel Contac blanco, esto con el objetivo de no permitir el ingreso de luz natural y además mantener la luminosidad interna del contenedor; Para la iluminación de este se realizó la instalación de una cinta led de color blanco. Las siguientes figuras presentan el resultado final de esta construcción.



Figura 3.2: Ambiente de luminosidad controlada (cerrado). Fotografía propia.




Figura 3.3: Ambiente de luminosidad controlada (abierto). Fotografía propia.

3.1.2. Base de datos (Dataset)

La base de datos usada para el entrenamiento y validación de las arquitecturas implementadas fue desarrollada a partir de la captura de fotografías de residuos aprovechables y no aprovechables generados en las instalaciones del campus de la PUJC. Para la toma de estas fotografías se hizo uso del ambiente controlado mencionado en la sección 3.1.1, asimismo, para garantizar la correcta caracterización de los residuos de la PUJC, las fotografías fueron tomadas en su mayoría dentro del recinto de la UCA. Para la clasificación de las fotografías se partió de la tabla 9.1.1.1 del PGIR de la PUJC. Con el fin de ampliar dicha clasificación, en la sección de anexos se presenta una tabla con la información del tipo de residuos, su fotografía (propia del dataset) y su clasificación.

Al concluir con la conformación de la base de datos se cuenta con un total de 2015 fotografías, 1015 de residuos aprovechables y 1000 correspondientes a residuos no aprovechables. A continuación, se presentan un ejemplar fotográfico de cada tipo de residuo en las figuras 3.3 y 3.4, dichos ejemplares sirven de ilustración para clarificar de qué se compone la base de datos.



Figura 3.4: Fotografía de residuos aprovechable. Fotografía propia.



Figura 3.5: Fotografía de residuos no aprovechable. Fotografía propia.

3.1.3. Cámara

Respecto a la cámara usada para la toma de las fotografías que conforman la base de datos se hizo uso de la cámara trasera del smartphone Samsung Galaxy J8. Las características específicas de esta son mostradas en las siguientes tablas:

Sensor			
Tamaño físico	Tipo de sensor	Tamaño de píxel	Área del sensor
5.0x3.8mm	1/27"	1.1 μ	18.8mm ²

Tabla 3.1: Características del sensor de la cámara posterior del Samsung Galaxy J8 - Tomado de [46]

Imagen		
Resolución máxima	Megapíxeles	Formato
4608x3456	15.9	JPEG

Tabla 3.2: Características de la imagen de la cámara posterior del Samsung Galaxy J8 - Tomado de [46]

Objetivo	
Longitud focal (35mm)	28.3mm
Longitud focal	3.9mm
Campo de visión horizontal	65°
Campo de visión vertical	51.1°
Factor de zoom	1x

Tabla 3.3: Características del objetivo de la cámara posterior del Samsung Galaxy J8 - Tomado de [46]

3.1.4. Google Colab

Colab es un producto de Google Research en el que un desarrollador de programas de Python puede usar este cuaderno para escribir y ejecutar códigos aleatorios de programas de Python simplemente usando un navegador web. Para usar Colab, no se necesita instalar y ejecutar ni actualizar el hardware de una computadora para cumplir con los requisitos intensivos de carga de trabajo de CPU/GPU de Python. Además, Colab le brinda acceso gratuito a la infraestructura informática como almacenamiento, memoria, capacidad de procesamiento, unidades de procesamiento de gráficos (GPU) y unidades de procesamiento de tensor (TPU). En resumen, provee al usuario de un cuaderno de código con todos los componentes necesarios para mostrar el paso a paso un aprendizaje automático completo o ciencia de los datos, pues Colab puede contener códigos ejecutables, códigos



Figura 3.6: Logo - Google Colab.

de Python en vivo, HTML, LaTeX, imágenes, visualizaciones de datos, cuadros, gráficos, tablas y más [30].

3.1.5. Jupyter Notebook



Figura 3.7: Logo - Jupyter Notebook. Tomado de [31].

Jupyter Notebook es un proyecto sin fines de lucro de código abierto, nacido del Proyecto IPython en 2014. Evolucionó para admitir la ciencia interactiva de datos y la computación científica en todos los lenguajes de programación [31]. Igual que Google, Colab provee al usuario de un cuaderno de código en el que mostrar los resultados de ejecución de código con la diferencia que lo hace de una forma local haciendo usos de los propios recursos de computador en el que se ejecuta por ello es importante tener conocimientos del hardware con el que se posee pues la falta de recursos computacionales puede llevar a que haya interrupciones inesperadas en el proceso de ejecución de código.

3.1.6. Tensorflow

Se concibe a Tensorflow como un ecosistema completo para ayudarte a resolver problemas complejos del mundo real con aprendizaje automático. Pues se ha constituido como uno de los Frameworks más importantes en cuanto al aprendizaje automático, este framework es mantenido por Google y ofrece gran cantidad de herramientas y modelos de utilidad para la ciencia de datos y el aprendizaje de máquina[32].



Figura 3.8: Logo - Tensorflow. Tomado de [32].

3.1.7. Keras



Figura 3.9: Logo - Keras. Tomado de [33].

Keras es un conjunto de modelos y herramientas para experimentación en aprendizaje profundo, esta API sigue las mejores prácticas para reducir la carga cognitiva: ofrece APIs consistentes y simples, minimiza la cantidad de acciones del usuario requeridas para casos de uso comunes y proporciona mensajes de error claros y accionables. También tiene una extensa documentación y guías para desarrolladores [33]. La importancia para este proyecto se fundamenta en que puede correr sobre Tensorflow complementado así el entorno de desarrollo.

3.1.8. Sklearn



Figura 3.10: Logo - ScikitLearn. Tomado de [34]

Es un proyecto se inició en 2007 como un proyecto Google Summer of Code de David Cournapeau. Más tarde ese año, Matthieu Brucher comenzó a trabajar en este proyecto como parte de su tesis. En 2010, Fabian Pedregosa, Gael Varoquaux, Alexandre Gramfort y Vincent Michel de INRIA asumieron el liderazgo del proyecto e hicieron el primer lanzamiento público el 1 de febrero de 2010. Desde entonces, han aparecido varios lanzamientos después de un ciclo de 3 meses y una próspera comunidad internacional ha estado liderando el desarrollo [34]. Sklearn demuestra su valor al ser una librería gratuita para Python que cuenta con algoritmos de clasificación, regresión, clustering y reducción de dimensionalidad, presentando además compatibilidad con otras librerías de Python como NumPy, SciPy y Matplotlib. Su gran variedad de algoritmos y utilidades la convierten en una herramienta básica para empezar a estructurar sistemas de análisis de datos y modelado estadístico

así como para generar soluciones de aprendizaje de máquina y se considera una de las librerías más robustas en su campo [35].

3.1.9. Matplotlib



Figura 3.11: Logo - Matplotlib. Tomado de [36].

Es una biblioteca para realizar gráficos 2D de matrices en Python, nace principalmente con el objetivo de emular los comandos de gráficos existentes en Matlab dado que en un principio Python no contaba con una biblioteca de comando que lograra realizar gráficos 2D de buena calidad. Dada esta problemática, su autor, John D. Hunter, se propuso desarrollar una que lograra emular las funcionalidades necesarias para aquel entonces, dando por resultado Matplotlib [36].

3.1.10. Python



Figura 3.12: Logo - Python. Tomado de [37].

Python es un lenguaje de programación usado en diversos campos, tales como aplicaciones web, desarrollo de software, ciencia de datos, seguridad informática, robótica, entre otros. Es altamente apetecido por los programadores por su eficiencia y facilidad de entendimiento. Fue creado en 1989 por Guido Van Rossum en un intento por mantenerse ocupado durante las vacaciones. Python es un lenguaje interpretado, orientado a objetos (aunque permite otros tipos de programación), y de alto nivel [38].

3.2. Métodos

3.2.1. Elección de modelos

Tras la revisión del estado del arte actual se hace un filtro sobre los modelos empleados en trabajos similares para afrontar problemas como el que se propone en este proyecto, y con ello se observó que los modelos con mejores resultados eran los siguientes:

3.2.1.1. InceptionV1

El modelo InceptionV1 también conocido como GoogleNet fue un exitoso modelo creado en los primeros años en las que se empezaba a trabajar con redes neuronales convolucionales. Google Inc, publicó el modelo en su artículo llamado “Going Deeper with Convolutions” y ganó ILSVRC-2014 con un amplio margen [39]. El éxito de InceptionV1 se fundamenta en los trucos inteligentes que hacen que el modelo sea más liviano y fácil de entrenar, siendo esta una red de 22 capas de profundidad. En la figura 3.13 se muestra la arquitectura del modelo en cuestión.

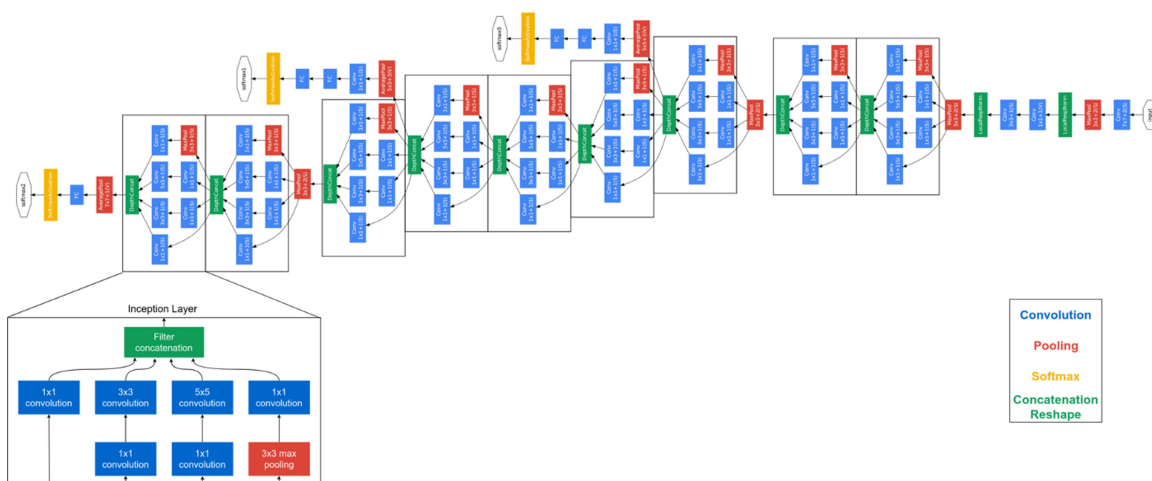


Figura 3.13: Representación gráfica del modelo InceptionV1. Tomado de [39]

3.2.1.2. ResNet50V2

ResNet50V2 es la segunda versión del modelo ResNet50, el cual fue presentado en el año 2015 en el documento “Deep Residual Learning for Image Recognition” por He Kaiming, Zhang Xiangyu, Ren Shaoqing, y Sun Jian. Este es un modelo de red neuronal convolucional (CNN) de 50 capas (48 convolucionales, una capa MaxPool y una capa AveragePool). Su nombre proviene de la cantidad de capas con las que está constituida, y el tipo de red que es, esto dado a que las CNN funcionan con apilamiento de bloques residuales [40].

La principal característica de este modelo es el uso de un diseño de cuello de botella para el bloque de construcción. Los bloques de construcción de cuellos de botella utilizan convoluciones de 1x1, lo que reduce el número de parámetros y multiplicaciones en la matriz permitiendo un entrenamiento mucho más rápido en cada capa [40].

A continuación, en la figura 3.14 se ilustra la arquitectura de este modelo.

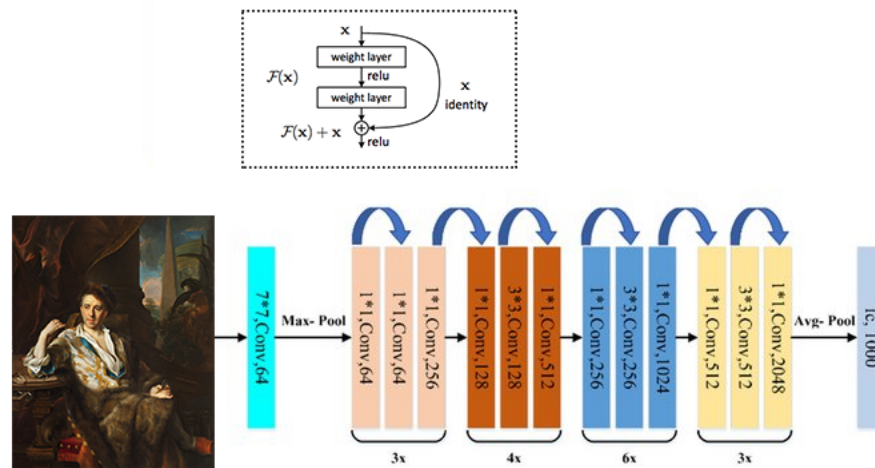


Figura 3.14: Representación gráfica del modelo ResNet50V2. Tomado de [41]

3.2.1.3. MobileNetV3

El modelo MobileNetV3 es la tercera versión del mismo, este está enfocado a las CPU de teléfonos móviles a través de una combinación de búsqueda de arquitectura de red (NAS) con reconocimiento de hardware, esto complementado con un algoritmo NetAdapt, que posteriormente es mejorado con avances de arquitecturas novedosas [42].

La figura 3.15 presenta la arquitectura de MobileNetV3.

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	-	RE	1
$112^2 \times 16$	bneck, 3x3	64	24	-	RE	2
$56^2 \times 24$	bneck, 3x3	72	24	-	RE	1
$56^2 \times 24$	bneck, 5x5	72	40	✓	RE	2
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 3x3	240	80	-	HS	2
$14^2 \times 80$	bneck, 3x3	200	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	480	112	✓	HS	1
$14^2 \times 112$	bneck, 3x3	672	112	✓	HS	1
$14^2 \times 112$	bneck, 5x5	672	160	✓	HS	2
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	conv2d, 1x1	-	960	-	HS	1
$7^2 \times 960$	pool, 7x7	-	-	-	-	1
$1^2 \times 960$	conv2d 1x1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1x1, NBN	-	k	-	-	1

Notes: Specification for MobileNetV3-Large. SE denotes whether there is a Squeeze-And-Excite in that block. NL denotes the type of nonlinearity used. Here, HS denotes h-swish and RE denotes ReLU. NBN denotes no batch normalization. s denotes stride.

Figura 3.15: Capas que componen el modelo MobileNetV3. Tomado de [42]

3.2.1.4. MobileNetV3 + SVM

Una manera de conseguir un modelo de clasificación disminuyendo los tiempos de entrenamiento es haciendo uso del transfer learning, para este caso puntual, se hace uso de la CNN MobileNetV3 como extractor de características modificando la arquitectura original y quitando las capas encargadas de hacer el proceso de clasificación en la CNN, seguido a esto se hace uso de un modelo ML que funge como nuevo clasificador haciendo uso de todas las características que previamente MobileNetV3 ha generado. El método de ML elegido para este fin fueron las Máquinas de Soporte Vectorial, dada su gran capacidad de adaptación a distintos tipos de problemas. La representación gráfica de este proceso se ilustra en la figura 3.16.




Figura 3.16: Representación gráfica del modelo MobileNet + SVM. Tomado de [29]

3.2.1.5. VGG19

El modelo VGG19 nació del interés de mejorar el rendimiento del modelo ConvNet, modelo campeón del ILSVRC de 2012, este interés llevo al anexo y modificación en las capas ocultas de ConvNet hasta alcanzar una arquitectura de 19 capas [43] la cual se popularizo en años pasados al ser la ganadora del ILSVRC 2014 con una precisión del 92.7% [44].

La figura figura 3.17 enseña la arquitectura con la que cuenta el modelo VGG19.




Figura 3.17: Representación gráfica del modelo VGG19. Tomado de [45]

3.2.1.6. VGG19 + SVM

Al igual que en el caso de MobileNetV3 + SVM, el proceso de este modelo híbrido se puede ilustrar con la figura 3.16 Este modelo hace uso de la CNN VGG19 mostrado anteriormente en la figura 3.17 pero quitando las capas del bloque 6, pues así el modelo sirve como extractor de características. Seguido a esto se añade el método de Máquinas de Soporte Vectorial para la clasificación en sí, por lo que el proceso de optimización de hiperparámetros se hace directamente sobre la máquina de soporte vectorial usando el método de búsqueda de malla proveniente de su nombre en inglés “Grid Search”.

3.2.2. Métricas

Con el fin de aclarar de donde provienen las métricas que son usadas para evaluar cada uno de los modelos se realiza una ilustración de la matriz de confusión, esto dado que es de ella de donde se extraen cada una de las métricas que se consideran en el presente proyecto. La tabla 3.4 presenta su estructura.

		Valores Reales	
		Positivos	Negativos
Valores predichos	Positivos	Verdaderos positivos (TP)	Falsos positivos (FP)
	Negativos	Falsos negativos (FN)	Verdaderos negativos (TN)

Tabla 3.4: Matriz de confusión.

Es considerando la matriz de confusión que las métricas de los modelos pueden ser obtenidas. Sus definiciones son presentadas a continuación:

- **Accuracy (ACC):**

$$Accuracy(ACC) = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.1)$$

- **Area Under the Curve (AUC):**

$$AreaUndertheCurve(AUC) = \int_0^1 TPR(FPR)dFPR \quad (3.2)$$

Siendo TPR (True Positive Rate) y FPR (False Positive Rate):

$$TPR = \frac{TP}{TP + FN} \quad (3.3)$$

$$FPR = \frac{FP}{FP + TN} \quad (3.4)$$

- **Recall:**

$$Recall = \frac{TP}{TP + FN} \quad (3.5)$$

Aquí cabe resaltar que Recall y TPR (True Positive Rate) corresponden a la misma variable.

- **Specificity:**

$$Specificity = \frac{TN}{TN + FP} \quad (3.6)$$

- **F1 Score:**

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (3.7)$$

- **Matthews Correlation Coefficient (MCC):**

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (3.8)$$

3.2.3. Entrenamiento y validación

Al momento de entrenar los modelos previamente expuestos se adoptó el método de validación Hold Out con una partición de 80 % para entrenamiento y 20 % para validación. Este método fue elegido dadas las características del dataset usado, puesto que la cantidad de muestras aún es considerable como baja, por lo tanto, este debería continuar su conformación y por ello es recomendable adaptarse a este método de validación.

Con respecto al plan de pruebas y entrenamiento de los modelos, a continuación, se presentan los pasos seguidos:

- **Carga y procesamiento de la base de datos:** Se realiza la carga de todo el dataset de fotografías, estas son procesadas ajustando su tamaño al de una imagen cuadrada con tamaño de 250x250 pixeles.
- **Partición del dataset:** Posterior al procesamiento de las fotografías se divide el dataset en dos secciones acorde con el método Hold Out: 1612 fotografías para entrenamiento (80 %) y 403 para validación (20 %). Esta división se realiza de manera pseudoaleatoria a partir de una semilla y una librería de Sklearn. Cabe recordar que esta partición incluye las etiquetas de cada fotografía, considerando 0 para las fotografías de residuos aprovechables y 1 para los residuos no aprovechables.
- **Entrenamiento:** Se procede con la importación de los modelos ya que en su totalidad todos hacen uso de técnicas de transfer learning. Una vez se cargan, se agregan capas que permitan clasificar correctamente las fotografías, estas capas serán modificadas y refinadas hasta obtener resultados que cumplan los objetivos del proyecto.
- **Análisis de rendimiento:** Finalizado el entrenamiento, se procede a analizar el rendimiento del modelo, para ello se toma base en las siguientes métricas: Accuracy, Recall, Specificity, AUC, F1 Score y MCC. De acuerdo con estos resultados se procede a determinar si es necesario modificar las capas del modelo.
- **Optimización de Hiperparámetros:** En esta sección se hace necesario destacar que se realizan dos procesos de optimización diferentes:
 1. Modelos Deep Learning (Fine Tuning): Dentro de los modelos que usan transfer learning con la metodología “fine tuning” sus arquitecturas constan de la red congelada para entrenamiento seguido a capas full-connected para procesar la clasificación de las imágenes. Dada la arquitectura en su mayoría está congelada, la optimización se enfoca en las últimas capas dedicadas en la clasificación, para ello plantea la experimentación con la cantidad de neuronas de las capas ocultas, así como de las funciones de activación tanto en las capas ocultas como en la capa de salida. Por último, dado que existe la posibilidad de llegar a un entrenamiento inestable o con conflictos de ajuste, se considera la adición de capas que contrarresten estos factores.

2. Modelos Híbrido: Debido a que este modelo hace uso de una CNN como extractor de características y un clasificador con máquinas de soporte vectorial, el enfoque hacia mejorar los resultados recae en el algoritmo de ML, por tal razón se hace uso de una herramienta que nos entrega la librería sklearn que permite hacer una búsqueda de malla o “Grid Search”, con dicha función es posible hacer combinaciones de variación con todos los hiperparámetros que se necesite alterar en el modelo y utiliza validación cruzada para emitir un resultado de cada conjunto de hiperparámetros.
- **Obtención de resultados:** Finalmente, para determinar los resultados definitivos de cada modelo se ejecuta cada uno un total de 10 veces, cambiando en cada ejecución la semilla de la función pseudoaleatoria usada en la partición del dataset. Se almacena la semilla y las métricas de cada ejecución y, finalmente, se obtiene un valor medio y una desviación estándar por cada métrica.

Resultados y Discusión

4.1. Resultados

Una vez culminado el proceso de entrenamiento y validación acorde con el plan de pruebas planteado anteriormente los resultados obtenidos son presentados a continuación.

4.1.1. Hiperparámetros

Acorde al plan de prueba se ejerció un proceso de optimización a los modelos con el fin de que logren un rendimiento aceptable frente a la problemática planteada. Finalizado este proceso se llegó a ciertos valores y métodos que en conjunto permiten que los modelos funcionen adecuadamente en este contexto. A continuación, se presentan dichos valores.

- Modelos Deep Learning (Fine Tuning):

Para los modelos que hacen uso de transfer learning con la metodología “fine tuning” se llegó a que la función de activación para las capas ocultas que mejor se adapta es *Relu*. Por su parte la función de activación para la capa de salida que presentó mejores resultados es *Sigmoid*.

- Modelos Híbridos:

Para el caso puntual de este proyecto se evidenció que el conjunto de hiperparámetros que se muestran en la tabla 4.1 son los que aportan mejores resultados.

Optimización de Hiperparámetros		
Hiperparámetro	VGG19 + SVM	MobileNetV3 + SVM
C	100	5
Gamma	scale	scale
Decision function shape	ovo	ovo
Class weight	balanced	balanced
Kernel	rbf	rbf

Tabla 4.1: Tabla de hiperparámetros utilizados en los modelos híbridos.

4.1.2. Métricas obtenidas

Tras optimizar cada modelo y ejecutar su respectivo entrenamiento y validación acorde al plan expuesto se prosigue a presentar los resultados obtenidos por cada uno de los modelos por medio de un gráfico de caja y bigote por cada métrica.




Figura 4.1: Diagrama de caja y bigote - Accuracy.




Figura 4.2: Diagrama de caja y bigote - AUC.




Figura 4.3: Diagrama de caja y bigote - Recall.




Figura 4.4: Diagrama de caja y bigote - Specificity.




Figura 4.5: Diagrama de caja y bigote - F1 Score.




Figura 4.6: Diagrama de caja y bigote - MCC.

Para finalizar esta sección, se presenta en la tabla 4.2 la representación ordenada de la media y desviación estándar de cada una de las métricas, cabe resaltar que se repitió el entrenamiento de cada modelo diez veces considerando una validación Hold-Out aleatoria en aras de obtener un criterio más robusto sobre cada modelo.

Modelo	Accuracy		Recall		Specificity		AUC		F1 Score		MCC	
	Media	Desviación estándar	Media	Desviación estándar	Media	Desviación estándar	Media	Desviación estándar	Media	Desviación estándar	Media	Desviación estándar
InceptionV1	0,8536	0,0314	0,8357	0,1014	0,8710	0,0508	0,8534	0,0329	0,8462	0,0464	0,7135	0,0563
ResNet50V2	0,8625	0,0063	0,8422	0,0196	0,8838	0,0246	0,9212	0,0037	0,8623	0,0061	0,7266	0,0130
MobileNetV3	0,9199	0,0111	0,9199	0,0155	0,9123	0,0144	0,9670	0,0085	0,9213	0,0101	0,8396	0,0224
MobileNetV3+SVM	0,8872	0,0182	0,8872	0,0314	0,8957	0,0173	0,9499	0,0119	0,8883	0,0181	0,7752	0,0360
VGG19	0,8997	0,0200	0,8997	0,0338	0,8934	0,0243	0,9359	0,0178	0,8997	0,0189	0,8105	0,0496
VGG19+SVM	0,8936	0,0180	0,8936	0,0264	0,9040	0,0219	0,9580	0,0093	0,8938	0,0172	0,7875	0,0362

Tabla 4.2: Media y desviación estándar de las métricas obtenidas

En suma de lo anterior se presenta en la figuras 4.7 y 4.8 el resumen de la información mostrada en la tabla 4.2.




Figura 4.7: Promedio en los resultados de cada modelo.

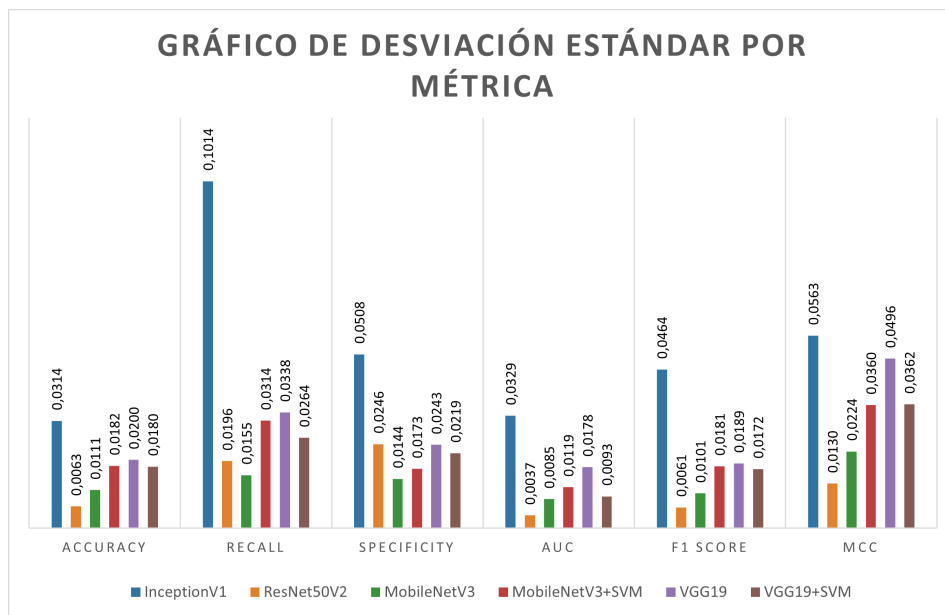


Figura 4.8: Desviación estándar de cada modelo por métrica.

4.2. Discusión

Tras finiquitar la etapa de obtención de resultados es necesario hacer un análisis de todos los datos generados, por ello cabe resaltar la importancia de las figuras 4.1 a 4.6, pues en estos diagramas de caja y bigotes se puede identificar de manera sencilla la dispersión en los resultados de cada entrenamiento. Apreciativamente se puede afirmar entonces que el modelo con un comportamiento más variable es InceptionV1 y como contraparte el modelo con la menor variabilidad es ResNet50V2 que a pesar de ser el modelo que menos variabilidad presenta no es el que se observa con los resultados más altos, dicho título se le podría atribuir al modelo MobileNetV3, sin embargo, a pesar de esta afirmación, con estos gráficos no se puede emitir un juicio concluyente puesto que, si bien el modelo MobileNetV3 resalta en este aspecto y en al menos la mitad de las métricas tiene entrenamientos con los mejores resultados conservando una dispersión baja, la extensión de los bigotes de sus gráficas presentan solapamiento sobre otros modelos y por ello se consideran estadísticamente indistinguibles.

Posterior a lo mencionado anteriormente, se procede a hacer uso de la información listada en la tabla 4.2, en esta tabla se muestra el promedio de diez experimentos por cada métrica así como la desviación estandar de cada una. Sin embargo, al ser una gran cantidad de datos numéricos se dificulta el análisis comparativo, por tal razón es que se generaron las figuras 4.7 y 4.8 que condensan la información contenida en la tabla 4.2 y facilita el proceso en cuestión.

Usando la figura 4.7 como base, se puede afirmar que indiscutiblemente el modelo con mayor promedio en todas las métricas es MobileNetV3 apoyando así las apreciaciones hechas anteriormente con los diagramas de cajas y bigotes. Por otra parte, la figura 4.8 nos confirma lo que se observó anteriormente sobre la variabilidad de los diagramas de cajas y bigotes, el modelo con menor variabilidad en sus resultados fue ResNet50V2 mientras que como apoyo al modelo MobileNetV3 se evidencia que es el segundo con menor variabilidad en sus resultados, con esto en mente restringimos la comparación para la búsqueda del mejor modelo a estos dos últimos. Finalmente retomando los datos mostrados en la figura 4.7 vemos que la diferencia en los promedios de estos dos modelos se inclina a favor de MobileNetV3 pues en ninguna métrica se ve sobrepasada por ResNet50V2, es así entonces como el equipo de trabajo determina que el modelo que mejor se adapta al problema que trata este proyecto es MobileNetV3.

A continuación, la gráfica 4.9 presenta la evolución del entrenamiento correspondiente a MobileNet V3.




Figura 4.9: Comportamiento de Accuracy del mejor modelo durante el entrenamiento.

La figura 4.9 muestra el comportamiento de la métrica de Accuracy tanto en entrenamiento como en validación a lo largo de 50 épocas, en ella se denota con un marcador de punto rojo la época en la que se obtuvieron mejores resultados, esta métrica es importante debido a que una separación abrupta entre ellas es un indicio de sobreentrenamiento, sin embargo se aprecia que para la época marcada existe un comportamiento relativamente estable y una separación no mayor a 0.07.




Figura 4.10: Curva ROC - Mejor modelo.

La figura 4.10 muestra la curva ROC del mejor entrenamiento en el modelo elegido, idealmente un clasificador perfecto debería alcanzar un AUC de 1 obteniendo una curva semejante a la esquina de un cuadrado. En el caso de este modelo se observa que, aunque no se tiene la curva ideal el resultado se acerca al objetivo.

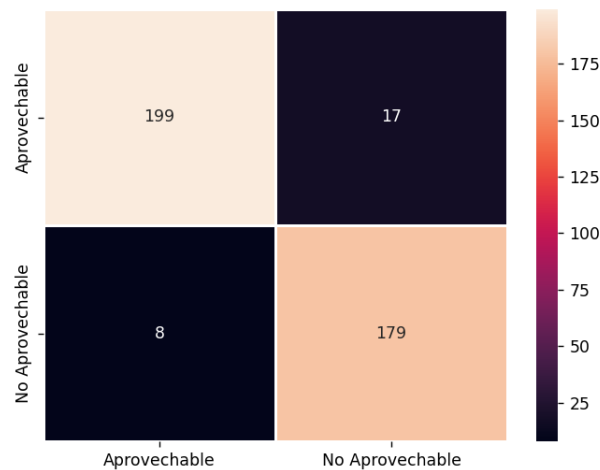


Figura 4.11: Matriz de confusión del mejor modelo entrenado.

La figura 4.11 muestra la matriz de confusión que el modelo elegido tuvo en su mejor entrenamiento, distinguiendo claro está que los datos mostrados son los de la validación de este entrenamiento. Cabe resaltar que el eje Y representa los valores predichos y el eje X los valores reales, y con ello se puede distinguir que de cerca de 200 elementos no aprovechables, la clasificación falla en un valor cercano al 10%, entonces se observa que el clasificador a pesar de ser el elegido como el mejor modelo tendrá a una tendencia a clasificar de manera aprovechable elementos que en realidad no lo son, sin embargo esto no se consideraría un problema ya que los elementos aprovechables al poder ser vendidos deben pasar por la supervisión de un encargado y es preferible que se concluya en que un elemento que estuvo en el contenedor de los residuos aprovechables sea descartado antes que por el contrario un elemento que si pudo ser aprovechable sea tirado como basura sin opción de reciclar.

Mejores resultados	
Accuracy	0,9380
Recall	0,9572
Specificity	0,9213
AUC	0,9740
F1 Score	0,9347
MCC	0,8766
Seed	3593322475
Epoch	18

Tabla 4.3: Mejores resultados obtenidos

Finalmente, la tabla 4.3 muestra los resultados de las de todas las métricas de validación obtenidas en el mejor modelo así como la época en el que se obtuvo el mejor resultado y la semilla que se utilizó en caso de que se quiera replicar el entrenamiento del modelo con la base de datos adjunta en anexos.

Como comentario extra, se aclara que se hizo uso de seis métricas dado que esto robustece la decisión que se toma sobre el modelo elegido puesto que las métricas dan distinta información sobre el comportamiento del modelo y lo que se espera de este.

4.2.1. Análisis del error

Una vez con los resultados finales recopilados se procede a hacer el análisis del error que tiene el algoritmo elegido al clasificar residuos, para ello se recoge en un mosaico todas las imágenes mal clasificadas y se muestran en la figura 4.12. En el mosaico mencionado se describe por cada imagen la clase a la que pertenece el residuo y la clase a la que fue asignado, esto se hace haciendo uso de la siguiente convención "**Clase real** \rightarrow **Clase predicha**", donde "Apr." significa aprovechable y "No Apr." significa no aprovechable.

Imágenes mal clasificadas

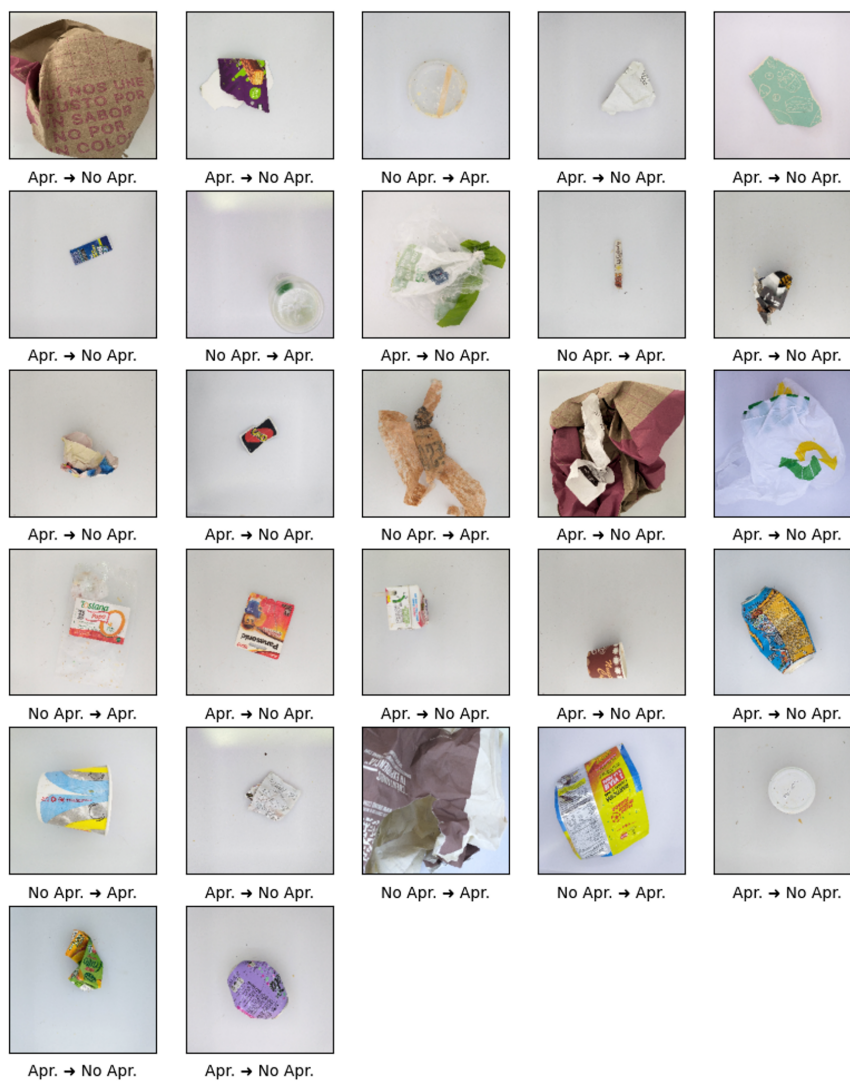


Figura 4.12: Mosaico de imágenes mal clasificadas.

El anterior mosaico nos presenta un total de 27 fotografías donde el clasificador ha fallado, al realizar un análisis de estas se puede percibir cierta tendencia a que los elementos de pequeño tamaño, con un color transparente o similar al fondo del ambiente controlado (blanco) o que su tamaño es tan grande que la fotografía no ha sido capaz de captar por completo su forma, presentan problemas al ser procesador por el clasificador final. Este es sin duda un gran problema y limitante para el clasificador dado que existen muchos residuos que cumplen con las características mencionadas y que ocasionarán que estos fallos se sigan presentando.

Una alternativa para mejorar la capacidad del clasificador y dotarlo de un mayor criterio para clasificar los residuos es implementar un sistema de detección de contornos previo a la clasificación, de modo que los elementos de color transparente o similar al fondo puedan ser identificados. Sin embargo, existe la posibilidad de que esto no sea suficiente, es por ello que al mismo tiempo puede ser contemplado la transformación de la tonalidad o saturación de las fotografías de manera que sea posible identificar este tipo de residuos en los cuales el clasificador presenta problema para adquirir las características y posteriormente clasificarlos.

Respecto a los elementos de gran tamaño, el ambiente controlado usado fue construido para poder almacenar residuos considerablemente grandes dentro del entorno de estudio, más sin embargo no se consideró la distancia ideal de la cámara para la toma de las fotografías, por ello existen residuos donde el cuerpo del objeto no es totalmente capturado por el sensor de la cámara usada y por lo tanto el clasificador no es capaz de determinar correctamente su etiqueta.

Finalmente, se logra ver que el clasificador tuvo una tasa de fallos mayor cuando los residuos eran aprovechables, esto si bien puede deberse a los factores anteriormente expuestos, también existe un factor de subjetividad a la hora de clasificar las etiquetas usadas para el entrenamiento. Esta subjetividad está ligada a la apreciación del personal experto de la UCA, pues durante la etapa de investigación y conformación de la base de datos se partió en varios casos de la decisión de este personal para determinar si un residuo es o no aprovechable. Estos casos donde la subjetividad cumplió un papel relevante son principalmente en residuos donde la suciedad toma un valor importante pues si bien un residuo puede ser aprovechable en caso de que este se encuentre en un estado de suciedad elevado puede ser descartado. Evidentemente el clasificador no cuenta con un sentido de subjetividad propio para tomar decisiones acertadas en estos casos específicos, así que este depende en gran medida de la información de entrenamiento suministrada, dando por resultado que el sistema de clasificación tenga un sometimiento a la opinión de los encargados de su entrenamiento y por consiguiente que esta logre influir en los resultados como se expuso en el anterior mosaico.

4.2.2. Rendimiento del modelo elegido utilizando aumento de datos

En aras de mejorar los resultados y observar el impacto de un entrenamiento con una base de datos más amplia se procede a generar cinco variantes de cada imagen con variaciones en rotación de ± 20 grados, zoom de $\pm 20\%$, corrimientos horizontales y verticales de $\pm 10\%$ y reflejado de imagen. Las imágenes se generaron tomando combinaciones aleatorias de las características anteriormente mencionadas y se hizo la partición de la base de datos en datos de entrenamiento y datos de validación en una proporción de 80% y 20% respectivamente, esto teniendo en cuenta la semilla

que mejores resultados arrojó con el modelo y puede ser consultada en la tabla 4.3. Los resultados de la métrica Accuracy obtenida se muestran en la figura 4.13.

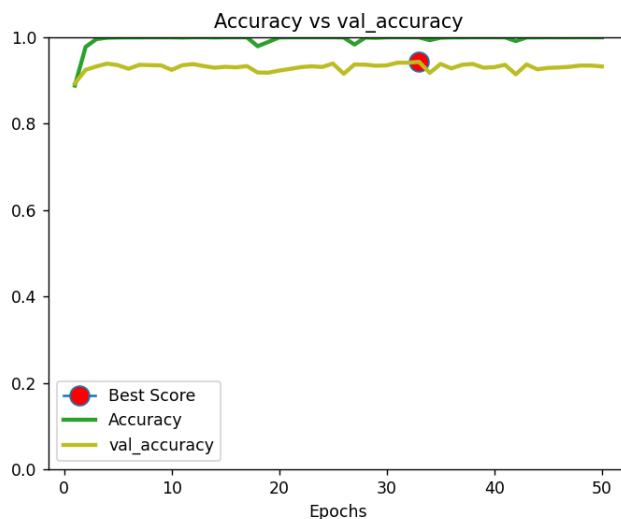


Figura 4.13: Comportamiento de Accuracy del modelo con datos aumentados durante el entrenamiento.

En la figura 4.13 se resalta un comportamiento similar al caso de la base de datos sin aumento, sin embargo la época en la que se obtienen mejores resultados se encuentra después en este caso.

En la figura 4.14 se muestra la curva ROC y muestra un rendimiento superior al modelo entrenadosin aumentar datos ya se encuentra tan solo a 2% de lograr ser un clasificador ideal lo que muestra que el aumento de datos ayudó levemente a mejorar el rendimiento del clasificador.

La figura 4.15 da noción del comportamiento del modelo en validación con datos aumentados, para sorpresa del equipo de trabajo se nota que es distinto al caso anterior, ya no hay un marcado sesgo de elección ya sea por residuos aprovechables o no aprovechables pues la diferencia entre falsos residuos aprovechables y falsos residuos no aprovechables no supera el 1%.

En la tabla 4.4 se observa que se ha ganado un rendimiento superior al aumentar la base de datos para entrenar el modelo que fue elegido como el mejor, con esto en mente se puede abstraer que el modelo puede mejorar aún más si se amplía de manera orgánica la base de datos en vez de hacerlo de manera artificial como en este caso, pues se ha observado que el error en varias clasificaciones se ha dado por el hecho de no poder diferenciar la suciedad presente en los residuos lo que puede llevar a distinguir entre que un residuo sea aprovechable o no, también por la transparencia de los objetos y por ocupar mucho espacio en la foto. Por cuestiones de espacio no es posible mostrar directamente en este documento el mosaico que recopila las imágenes mal clasificadas del modelo entrenado con datos aumentados, por tal motivo si se desea consultar este recurso haga click [aquí](#) para acceder a él.




Figura 4.14: Curva ROC - Modelo con datos aumentados.

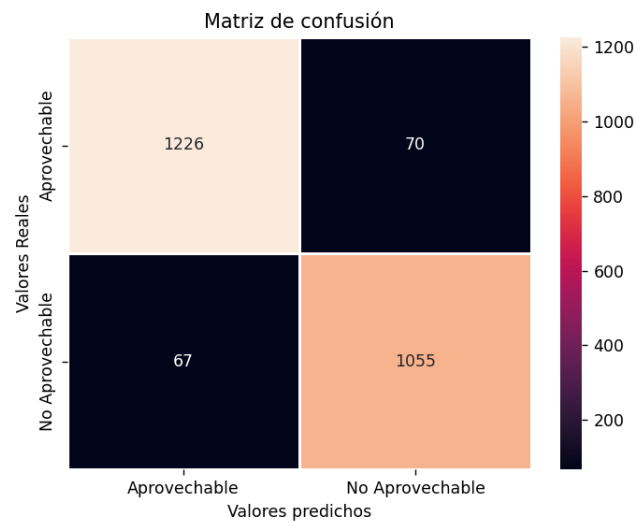


Figura 4.15: Matriz de confusión del modelo entrenado con datos aumentados.

Mejores resultados	
Accuracy	0,9433
Recall	0,9403
Specificity	0,9460
AUC	0.9800
F1 Score	0.9390
MCC	0.8861
Seed	3593322475
Epoch	33

Tabla 4.4: Resultados con aumento de datos.

Conclusiones

Al culminar el desarrollo de este proyecto se ha logrado determinar por medio de un benchmark regido por métricas enfocadas en la clasificación de objetos usando inteligencia artificial que, dentro de los modelos seleccionados, MobileNetV3 es el modelo que mejor se ajusta a la problemática planteada. Adicionalmente, a lo largo de las pruebas y construcción de modelos, se evidenció que el contexto al que se enfoca la clasificación cuenta con una gran influencia al momento de probar los modelos, esto dado a que se consideraron varios modelos exitosos en el estado del arte, pero que al probarlos en este problema dejaban mucho que desear en sus métricas. Así mismo, se encontró con modelos con entrenamientos inestables que ante una variación en la semilla para la partición pseudoaleatoria contaba con grandes variaciones de rendimiento o modelos que no aprendían a lo largo del entrenamiento, es decir, sus métricas se mantenían constantes desde las primeras épocas. Fue en estos casos donde la optimización y experimentación con los modelos cumplió un papel fundamental.

Con respecto al dataset, si bien se intentó desde un principio mantener una captura de fotografías lo más uniforme posible, la iluminación no logró mantenerse en su totalidad uniforme, eso dado a distintos factores que radican incluso en los mismos objetos, pues estos reflejan la luz de distinta forma según el color de su superficie, y esto al reflejar en el ambiente controlado cambiaba la tonalidad y generaba variación. Aun así, hay que recalcar que estas variaciones si bien no son ideales, no son del todo negativas debido a que este tipo de alteraciones le permite al modelo contar con mayor robustez frente a estos cambios, así como las variaciones de rotaciones de los objetos que fueron ingresadas intencionalmente. Por otro lado, la conformación del dataset ha sido compleja por la dificultad para la adquisición de residuos, en principio parece sencillo conseguir desechos pues a diario los generamos, pero al momento de querer tomar miles de fotografías la verdad es que no se cuenta con tal cantidad en poco tiempo. Es por ello que se tuvo que recurrir a las instalaciones de la UCA para la adquisición de los mismos y esto implicó numerosas visitas donde se requirió de instrumentos de protección y largo periodos de tiempo separando residuos en busca de productos para fotografiar.

Finalmente, el entrenamiento y validación de estos modelos de inteligencia artificial enfocados en la clasificación de residuos dentro de las instalaciones de la PUJC deja la puerta abierta para una implementación física/digital que le permita a la comunidad de esta institución realizar una separación correcta apoyados en una herramienta tecnológica que ya ha sido probada dentro de un ambiente controlado, por lo que se debe considerar ampliar las pruebas a otros ambientes antes de proseguir con implementaciones.

Trabajos futuros

Finalizado este proyecto, como recomendación para trabajos futuros se proponen varias sugerencias:

- **Aumento de la base de datos:** La base de datos cuenta con poca cantidad de fotografías aún, por lo que para un mejor resultado lo recomendable es ampliar la base de datos siempre conservando el balance entre las clases aprovechables y no aprovechables.
- **Experimentación de modelos:** A lo largo de este proyecto se experimentó con varias técnicas y modelos hasta obtener resultados que cumplieren los objetivos, sin embargo, existen muchas otras arquitecturas y técnicas que pueden ser implementadas a la problemática planteada, por lo que continuar con la experimentación haciendo uso de nuevas técnicas o existentes es recomendable.
- **Implementación física de clasificación automática:** Una implementación física para la clasificación de residuos es posible al exportar los modelos entrenados y compilarlos en controladores de tamaño reducido de modo que sea posible llevar a cabo una clasificación física automática dentro de las instalaciones de la PUJC. Esta implementación podría empezar su plan piloto ubicando un dispositivo que haga uso de un controlador y una cámara que al momento que se le indique tome una fotografía y determine a que tipo de residuo pertenece el objeto, posterior a ello puede informar al usuario y así este puede depositarlo en la caneca indicada.
- **Implementación móvil de clasificación automática:** Otro tipo de implementación posible para los modelos entrenados en este proyecto es el desarrollo de una aplicación multiplataforma o móvil que permita ejecutar la clasificación de los residuos desde un dispositivo electrónico portátil. Para ello el modelo puede ser ejecutado desde un servidor y por medio de una API cualquier dispositivo con conexión a internet podría acceder a ella y solicitar la clasificación de un residuo tomando como base una fotografía del mismo.
- **Uso y adaptación en otros entornos:** La totalidad del proyecto está enfocado en las instalaciones de la PUJC, sin embargo, los modelos entrenados cuentan con la capacidad para funcionar en entornos ajenos al campus de la PUJC. Aun así, cabe notar que dadas las características del entorno objetivo, el dataset puede requerir modificaciones ya que ciertos residuos suelen tener mayor afinidad a ciertos entornos distintos a los universitarios tratados en este proyecto.

Anexo 1 – Entrevista en la UCA

Entrevista del día 18/03/2022 a las 9:00 a.m

Santiago de Cali (Valle del Cauca), Pontificia Universidad Javeriana Cali

Objetivo: El objetivo de esta entrevista es documentar la información relevante a destacar dentro de la visita al UCA (Unidad Central de Almacenamiento) dentro de las instalaciones de la Pontificia Universidad Javeriana Cali.

Respuestas brindadas por el operario Jair.

■ **¿Con qué frecuencia se realiza el depósito de basuras en la UCA?**

El depósito de desechos en la UCA se realiza siete veces al día, cuatro en la jornada diurna y tres en la jornada nocturna.

■ **Durante el recogimiento de los desechos en los puntos ecológicos, ¿Se puede notar clasificación por parte de la comunidad javeriana?**

Según palabras del operario la clasificación es nula, para demostrar ello las siguientes fotografías presentan el contenido de algunas bolsas donde se puede apreciar que sin importar el color de la bolsa el contenido es totalmente mixto, tanto así que se puede incluso encontrar desechos biológicos como papel de manos o tapabocas.

■ **¿Cuáles son los desechos que más predominan en la comunidad javeriana?**

Los desechos que más predominan entre la comunidad javeriana son las botellas plásticas pet, las siguientes fotos presentan algunas de las bodegas destinadas al almacenamiento de los desechos aprovechables y no aprovechables (Es el más grande pues no se clasifica), dentro de estas bodegas se puede notar como el contenido de botellas pet es predominante.

Cabe aclarar que el mayor productor de cartón dentro de la universidad es el minimercado La Mercadería, el cual hace entrega del cartón listo para su procesamiento (pesado y atado). Otros residuos a destacar dentro del manejo de la UCA son los siguientes:

En ocasiones se presenta depósito de dispositivos electrónicos en los puntos ecológicos, así como marcadores y cables, incluso baterías las cuales cuentan con sus propios puntos de desecho, por lo que los operarios separan estos residuos de manera diferente para ser procesados por otra entidad distinta a la encargada de los residuos aprovechables



Figura 7.1: Bolsa de residuos aprovechables.



Figura 7.2: Contenido de la bolsa de residuos aprovechables.



Figura 7.3: Bodega de botellas PET.



Figura 7.4: Bodega de cartón retal (no atable).



Figura 7.5: Bodega de cartón (atable).



Figura 7.6: Bodega de papel.



Figura 7.7: Bodega de residuos no aprovechables.



Figura 7.8: Componentes electrónicos.



Figura 7.9: Cables varios.



Figura 7.10: Marcadores.



Figura 7.11: Baterías.

- **Considerando que algunos desechos aprovechables vienen contaminados con restos de comida o manchas, ¿Es fácil limpiarlos? ¿Con qué frecuencia se limpian?**

Los desechos no reciben ningún proceso de limpieza en sus superficies sucias, la única labor que sí se realiza es la de verter el líquido restante en algunas botellas para ser clasificados. La siguiente imagen presenta el recipiente que contiene la mezcla de los líquidos vertidos así como otro recipiente donde se depositan algunas tapas de botellas plásticas para ser donadas a fundaciones de niños con cáncer. Cabe aclarar que no todas las tapas de las botellas plásticas son separadas para la fundación sino solamente las que reciben el proceso de vertido de líquido restante.

- **¿Cómo se clasifican los desechos dentro de la UCA (aprovechables, no aprovechables y orgánicos)?**

Las bolsas recolectadas de los puntos ecológicos (blancas y negras) son llevadas a la UCA, allí éstas son abiertas una por una y se procede a separar los residuos que está contiene. La siguiente fotografía muestra la apertura de las bolsas y el contenido de ellas, además de la bandeja usada para esta labor.

- **¿Cuántas personas se dedican a la reclasificación de desechos?**

Específicamente a la reclasificación de desechos se dedica una sola persona durante toda la jornada laboral.

- **¿Con qué frecuencia viene el cliente de los desechos aprovechables?**

Cada vez que la universidad se comunica con ellos.



Figura 7.12: Mezcla de líquidos sobrantes y tapas de botellas plásticas destinadas a fundación de niños con cáncer.



Figura 7.13: Bandeja de reclasificación junto al contenido de una bolsa de residuos aprovechables y residuos no aprovechables.

- **¿Considera que una solución tecnológica como una ayuda en la clasificación podría brindar una reducción en la carga energética de este trabajo?**

Según la opinión del operario una solución tecnológica podría ayudar a reducir en gran medida el trabajo de la reclasificación dado que la nula conciencia por parte de la comunidad javeriana hace que los puntos ecológicos no cumplan su función de clasificación y todo el trabajo recaiga en la UCA. Por lo que si las basuras pudiesen llegar clasificadas no sería necesario inspeccionar las bolsas no aprovechables en busca de residuos aprovechables, sólo sería necesario examinar las bolsas aprovechables para seleccionar los productos que serán vendidos.

- **¿Se realiza composta con los desechos orgánicos?**

La composta únicamente se lleva a cabo en el centro de compostaje por parte de los jardineros, lo demás es tratado como desecho no aprovechable y llevado a los rellenos sanitarios.

- **¿Dónde se depositan las hojas que caen de los árboles?**

Las hojas son llevadas por los jardineros al centro de compostaje y no tienen contacto con la UCA.

- **¿Qué procedimiento se sigue con los desechos biológicos/peligrosos?**

Los desechos biológicos que llegan al UCA son llevados a una bodega destinada donde los cadáveres de seres vivos son congelados y los residuos son almacenados sin ningún otro tipo de procedimiento mientras se realiza la recolección por parte de una entidad encargada de este tipo de desechos.

- **¿Cuál es el residuo más grande en dimensiones que llega al UCA?**

El residuo más grande que suele verse dentro de los puntos ecológicos son las cajas de pizza.





Anexo 2 – Repositorio GitHub con código y dataset

Para acceder al repositorio de GitHub donde se almacenan los códigos y el dataset completo se debe seguir este enlace: <https://github.com/jett220201/Usable-and-No-Usable-Waste-Classififer-with-DL>

Anexo 3 – Tabla de clasificación de residuos con fotografías y nombre

A continuación, se presenta la tabla con los nombres de los residuos, un ejemplar fotográfico y su respectiva clasificación considerando únicamente los residuos usados dentro de este proyecto y basándose en el PGIR de la PUJC.

Tipo de residuo	Fotografía	Clasificación
Plástico PET		Aprovechable
Plástico polietileno de baja densidad [PEBD]		Aprovechable
Plástico polipropileno		Aprovechable
Plástico poliestireno		No aprovechable
Papel prensa		Aprovechable
Papel imprenta		Aprovechable
Papel Kraft		No aprovechable
Papel Tissue		No aprovechable
Cartón corrugado		Aprovechable
Cartón compacto		Aprovechable
Cartón compuesto por más de dos materiales [Tetrapack]		Aprovechable

Cartón laminado		Aprovechable
Plegadiza		Aprovechable
Envoltura de alimentos		No aprovechable
Vidrio		Aprovechable
Aluminio		Aprovechable
Chatarra		Aprovechable
Hojas de aluminio		No aprovechable

Bibliografía

- [1] Obando Moreno, J. A. (2020, Febrero 21). Resolución 2184 de 2019 “Por la cual se modifica la resolución 668 de 2016 sobre el uso racional de bolsas plásticas y se adoptan otras disposiciones” - Derecho del Medio Ambiente. [En línea], Disponible: <https://medioambiente.uexternado.edu.co/resolucion-2184-de-2019-por-la-cual-se-modifica-la-resolucion-668-de-2016-sobre-el-uso-racional-de-bolsas-plasticas-y-se-adoptan-otras-disposiciones/>
- [2] Monterrosa, H. (2019). Colombia podría aprovechar 40 % de las toneladas de residuos que genera anualmente. La República. [En línea], Disponible: <https://www.larepublica.co/responsabilidad-social/colombia-podria-aprovechar-cerca-de-40-de-los-116-millones-de-toneladas-de-residuos-que-genera-al-ano-2813141>.
- [3] DNP. (2016). Rellenos sanitarios de 321 municipios colapsarán en cinco años, advierte el DNP. [En línea], Disponible: <https://www.dnp.gov.co/Paginas/-Rellenos-sanitarios-de-321-municipios-colapsar-en-cinco-años,-advierte-el-DNP-.aspx>
- [4] SalinasValleyRecycles.org. Todo sobre Vertederos - Autoridad de Desperdicios Sólidos del Valle de Salinas (SVSWA). [En línea], Disponible: <https://svswa.org/es/schools/kids-corner/all-about-landfills/>
- [5] Pacto Global Red Colombia. (2021). La Reciclación 2021 de Pacto Global Colombia y sus aliados fue un éxito, 3.6 toneladas recolectadas | news. [En línea], Disponible: <https://www.pactoglobal-colombia.org/news/la-reciclacion-2021-de-pacto-global-colombia-y-sus-aliados-fue-un-exito-3-6-toneladas-recolectadas.html>.
- [6] Naciones Unidas. Objetivos y metas de desarrollo sostenible - Desarrollo Sostenible. [En línea], Disponible: <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- [7] Residuos profesional. (2021, Mayo 13). Más de la mitad de la población tiene problemas para comprender el reciclaje de los diferentes plásticos. [En línea], Disponible: <https://www.residuosprofesional.com/problemas-comprender-reciclaje-plasticos/>. .
- [8] ICONTEC. (2009). NORMA TÉCNICA GTC COLOMBIANA 24
- [9] Pontificia Universidad Javeriana Cali. (2021). Plan gestión integral de residuos - PGIR
- [10] Acoplasticos. (2019). Residuos aprovechables y no aprovechables. [En línea], Disponible: <https://www.acoplasticos.org/boletines/2019/NormasAmbientales/IG-11.%20Residuos%20aprovechables%20y%20no%20aprovechables.pdf>

- [22] Guevara, M., Castaño, S., Guevara, P., Contreras, D. (2021). Punto ecológico automatizado para separación y clasificación de residuos a través de una neurona artificial. In *Revista Infometric@-Serie Ingeniería* (Vol. 4, Issue 1).
- [23] Chu, Y., Huang, C., Xie, X., Tan, B., Kamal, S., Xiong, X. (2018). Multilayer hybrid deep-learning method for waste classification and recycling. *Computational Intelligence and Neuroscience - IEEE*, 2018. <https://doi.org/10.1155/2018/5060857>
- [24] Vo, A. H., Hoang Son, L., Vo, M. T., Le, T. (2019). A Novel Framework for Trash Classification Using Deep Transfer Learning. *IEEE Access*, 7, 178631–178639. <https://doi.org/10.1109/ACCESS.2019.2959033>
- [25] Sidharth, R., Rohit, P., Vishagan, S., Karthika, R., M, G. M. (2020). Deep Learning based Smart Garbage Classifier for Effective Waste Management. 1086–1089. <https://doi.org/10.1109/ICCES48766.2020.9137938>
- [26] A. Patil, A. Tatke, N. Vachhani, M. Patil and P. Gulhane, "Garbage Classifying Application Using Deep Learning Techniques,"2021 International Conference on Recent Trends on Electronics, Information, Communication Technology (RTEICT), 2021, pp. 122-130, doi: 10.1109/RTEICT52294.2021.9573599.
- [27] M. S. Haque Sunny, D. Roy Dipta, S. Hossain, H. M. Resalat Faruque and E. Hossain, "Design of a Convolutional Neural Network Based Smart Waste Disposal System,"2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT), 2019, pp. 1-5, doi: 10.1109/ICASERT.2019.8934633.
- [28] C. Srinilta and S. Kanharattanachai, "Municipal Solid Waste Segregation with CNN,"2019 5th International Conference on Engineering, Applied Sciences and Technology (ICEAST), 2019, pp. 1-4, doi: 10.1109/ICEAST.2019.8802522.
- [29] N. Ramsurrun, G. Suddul, S. Armoogum and R. Foogooa, Recyclable Waste Classification Using Computer Vision And Deep Learning,"2021 Zooming Innovation in Consumer Technologies Conference (ZINC), 2021, pp. 11-15, doi: 10.1109/ZINC52049.2021.9499291.
- [30] Google Colab: todo lo que necesitas saber. (s.f.). Geekflare. <https://geekflare.com/es/google-colab/>
- [31] Project Jupyter. (s.f.). Project Jupyter | Home. <https://jupyter.org/>
- [32] TensorFlow. (s.f.). TensorFlow. <https://www.tensorflow.org/>
- [33] Keras: the Python deep learning API. (s.f.). Keras: the Python deep learning API. <https://keras.io/>
- [34] Scikit-learn: machine learning in Python — scikit-learn 1.2.0 documentation. (s.f.). scikit-learn: machine learning in Python — scikit-learn 0.16.1 documentation. <https://scikit-learn.org/stable/>

- [35] Scikit-Learn, herramienta básica para el Data Science en Python. (s.f.). Máster en Data Science. <https://www.master-data-scientist.com/scikit-learn-data-science>
- [36] Matplotlib — Visualization with Python. (s.f.). Matplotlib — Visualization with Python. <https://matplotlib.org/>
- [37] Welcome to Python.org. (s.f.). Python.org. <https://www.python.org/>
- [38] ¿Qué es Python? | Guía de Python para principiantes de la nube | AWS. (s.f.). Amazon Web Services, Inc. <https://aws.amazon.com/es/what-is/python/>
- [39] mrgrhn, “GoogLeNet (InceptionV1) | Artificial Intelligence ”, ene. 20, 2021. <https://ai.plainenglish.io/googlenet-inceptionv1-with-tensorflow-9e7f3a161e87>
- [40] Datagen. (s.f.). ResNet-50: The Basics and a Quick Tutorial. <https://datagen.tech/guides/computer-vision/resnet-50/>
- [41] Kvak, Daniel. (2022). Leveraging Computer Vision Application in Visual Arts: A Case Study on the Use of Residual Neural Network to Classify and Analyze Baroque Paintings. 10.48550/arXiv.2210.15300. <https://arxiv.org/abs/2210.15300>
- [42] Howard, Andrew, et al. "Searching for mobilenetv3." Proceedings of the IEEE/CVF international conference on computer vision. 2019. <https://ieeexplore.ieee.org/document/9008835>
- [43] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition.."arXiv preprint arXiv:1409.1556 (2014). <https://arxiv.org/abs/1409.1556>
- [44] datascientest. (2022, 6 de abril). VGG: ¿Qué es este modelo? ¡Daniel te lo cuenta todo!. <https://datascientest.com/es/vgg-que-es-este-modelo-daniel-te-lo-cuenta-todo>
- [45] Khatrar, Anuradha Quadri, Syed. (2022). “Generalization of convolutional network to domain adaptation network for classification of disaster images on twitter”. Multimedia Tools and Applications. 81. 10.1007/s11042-022-12869-1. https://www.researchgate.net/publication/359771670_Generalization_of_convolutional_network_to_domain_adaptation_network_for_classification_of_disaster_images_on_twitter
- [46] Camera FV5. (s.f.). Detalles técnicos de la cámara del Samsung Galaxy J8 (cámara 1 de 2) - Camera FV-5. Discover a new experience in mobile photography - Camera FV-5. <https://www.camerafv5.com/es/devices/manufacturers/samsung/sm-j810y8y18lte0/>