

**PROPUESTA DE IMPLEMENTACIÓN DE CLASIFICACIÓN DE RESIDUOS SÓLIDOS POR MEDIO DE
INTELIGENCIA ARTIFICIAL EN SITIOS DE DISPOSICIÓN EN LA UNIVERSIDAD EAN**

JENIFFER ANDREA PUENTES AGUILAR

SARA SOFÍA JIMÉNEZ OLARTE

UNIVERSIDAD EAN

SEMINARIO DE INVESTIGACIÓN

DIANA PAOLA FIGUEROA HERNANDEZ

BOGOTÁ D.C., COLOMBIA

5 DE NOVIEMBRE DE 2023

TABLA DE CONTENIDO

RESUMEN	5
PROBLEMA DE INVESTIGACIÓN	7
OBJETIVO GENERAL.....	10
JUSTIFICACIÓN	11
MARCO TEÓRICO.....	16
DISEÑO METODOLÓGICO.....	27
RECOLECCIÓN DE DATOS	32
PROCESAMIENTO Y ANÁLISIS DE RESULTADOS.....	34
CONCLUSIONES Y RECOMENDACIONES	42
BIBLIOGRAFÍA	43

TABLA DE ILUSTRACIONES

Ilustración 1 Separación De Residuos Colombia.....	18
Ilustración 2 Lanzamiento inicial de yolov5.....	23
Ilustración 3 Cálculo de porcentaje de identificación correcta.....	31
Ilustración 4 Producto 1 detectado en el modelo	33
Ilustración 5 Producto 2 detectado en el modelo	33
Ilustración 6 Producto 3 y 4 detectado en el modelo	33
Ilustración 7 Porcentaje de confianza de los productos seleccionados.....	38
Ilustración 8 Porcentaje de confianza categoría caneca verde.....	39
Ilustración 9 Porcentaje de confianza categoría caneca negra.....	39
Ilustración 10 Porcentaje de confianza categoría caneca blanca con los tres productos	40
Ilustración 12 Valores de precisión del modelo.....	41

TABLA DE TABLAS

Tabla 1 Ejemplo de extracción categoría caneca blanca	35
Tabla 2 Ejemplo 2 de extracción categoría caneca blanca.	35
Tabla 3 Valores de precisión del modelo.....	38
Tabla 4 Datos de los productos seleccionados.....	40

TABLA DE ECUACIONES

Ecuación 1 Error absoluto producto uno	36
Ecuación 2 Error absoluto producto dos	36
Ecuación 3 Error absoluto producto tres	36
Ecuación 4 Error absoluto producto cuatro	37
Ecuación 5 Error absoluto medio cuatro productos	37
Ecuación 6 Desviación estándar cuatro productos.....	37
Ecuación 7 Coeficiente de correlación	37
Ecuación 8 Coeficiente de correlación cuatro productos.....	37

RESUMEN

El siguiente proyecto de investigación se enfoca en mejorar la gestión de residuos sólidos

en sitios de micro-disposición, utilizando Inteligencia Artificial (IA) para optimizar la clasificación. La relevancia de este tema radica en la necesidad de abordar eficientemente la clasificación de residuos para mitigar el impacto ambiental. (TS2, 2023)

En este contexto, se observa que los métodos tradicionales de clasificación de residuos son propensos a errores y laboriosos. Para superar estas limitaciones, se propone el desarrollo de un modelo de detección y reconocimiento de residuos basado en IA. Esta propuesta busca aportar una solución innovadora y eficaz a los desafíos actuales en la gestión de residuos sólidos.

La metodología adoptada para este proyecto se basa en un enfoque cuantitativo, respaldado por el método cuantitativo de investigación. Se destaca la construcción de un conjunto de datos personalizado y el entrenamiento de un modelo YOLOv5x. Este modelo se implementa para la detección en tiempo real de tres categorías de residuos: "Caneca blanca," "Caneca verde," y "Caneca negra."

Los resultados obtenidos durante la fase de prueba indican un rendimiento destacado en la identificación de residuos en la "Caneca blanca." Sin embargo, se identifica una limitación en la precisión para otras categorías, que no supera el 50%. Esta observación resalta la importancia de un mayor registro de imágenes para mejorar la capacidad del modelo de detección.

La evaluación del modelo se propone en dos fases: una prueba inicial en un entorno controlado y una evaluación a mayor escala en la Universidad EAN. La recopilación de datos cuantitativos en la segunda fase incluirá el número de identificaciones correctas e incorrectas, proporcionando información esencial para calcular el porcentaje de identificación correcta del modelo.

En conclusión, el proyecto ha logrado avances significativos en el desarrollo de un modelo

de IA para la clasificación de residuos sólidos. Los resultados prometedores en entornos controlados sugieren un potencial considerable para su aplicación en la Universidad EAN. Sin embargo, se identifican áreas de mejora, como un entrenamiento más exhaustivo y la consideración de tecnologías adicionales, como el reconocimiento de voz, para futuras implementaciones. Este enfoque innovador ofrece perspectivas valiosas para la gestión eficiente de residuos sólidos y promueve prácticas de reciclaje sostenibles.

Palabras clave: Aprovechamiento de residuos sólidos, Inteligencia Artificial, Medio Ambiente, Reciclaje, Modelo YOLOv5x, Redes Neuronales, Machine Learning.

PROBLEMA DE INVESTIGACIÓN

Los residuos sólidos han sido una constante a lo largo de la historia de la humanidad y siguen siendo una preocupación en la actualidad. Su presencia ha aumentado significativamente

debido al desarrollo de la sociedad, el incremento de la población y la alta demanda de los recursos naturales. Este aumento en la generación de residuos está contribuyendo a tres problemas ambientales graves en el planeta: la crisis climática, la pérdida de biodiversidad y la contaminación, los cuales se agravan año tras año.

La gestión inadecuada de los residuos sólidos ha tenido un impacto significativo en el recurso hídrico, la calidad del aire, la esterilización del suelo, la proliferación de plagas y la salud pública, como señala la Universidad Católica de Pereira (2016). Esto plantea desafíos considerables en términos de gestión ambiental, social y económica, que abarcan desde la producción y la recolección hasta el tratamiento y la disposición final de estos residuos.

Las prácticas de los sectores residencial, comercial e industrial son los principales responsables de la generación excesiva de residuos debido a la falta de concienciación, capacitación, información y control de los procesos involucrados.

Según Greenpeace Colombia (2020), Colombia genera unas 25,000 toneladas de residuos sólidos al día, lo que equivale a 9.1 millones de toneladas al año, de las cuales solo se recupera y comercializa entre el 7% y el 13%. Bogotá, por su parte, emite más de 11 millones de toneladas de Gases de Efecto Invernadero (GEI), y el 18% de estas emisiones son atribuibles a los residuos sólidos.

Además, según el Ministerio de Medio Ambiente (2018), aproximadamente el 50% de los rellenos sanitarios existentes en Colombia tienen una vida útil de entre tres y diez años. Esto se traduce en la pérdida significativa de nutrientes, altos niveles de contaminación ambiental y conflictos sociales en las comunidades cercanas.

En 2021, Bogotá declaró la Emergencia Climática, lo que puso en primer plano la gestión

integral de residuos sólidos y el papel de los recicladores. La Gestión Integral de Residuos Sólidos (GIRS) incluye un plan de acción que abarca la reducción, reutilización y reciclaje de residuos, la promoción del compostaje, la formalización y capacitación de recicladores. Estos procesos se han materializado a través de normativas ambientales del Ministerio de Ambiente, Vivienda y Desarrollo - Resolución 1045 de 2005 y el Ministerio de Desarrollo Económico - Decreto 1713 de 2002 modificado por el Decreto 838 de 2005.

No obstante, estos esfuerzos no se han ejecutado con pleno éxito, ya que requieren la participación de consumidores, recolectores y quienes gestionan la disposición final de los residuos. Según el informe "What a Waste 2.0" del Banco Mundial (2018), la generación de residuos sólidos está aumentando a un ritmo alarmante en todo el mundo. Se producen anualmente 2010 millones de toneladas de desechos sólidos municipales, y al menos el 33% de ellos no se gestiona de manera ambientalmente responsable. La rápida urbanización, el crecimiento poblacional y el desarrollo económico auguran un aumento del 70% en la generación de residuos en los próximos 30 años.

Este panorama deja en claro que los esfuerzos actuales para abordar la creciente generación de residuos sólidos no están funcionando eficazmente, y la contaminación ambiental se está propagando más rápido de lo que se puede controlar. Por tanto, se vuelve imperativo el desarrollo de proyectos que mitiguen los impactos negativos en el medio ambiente y mejoren los procesos existentes.

El proyecto de investigación que se presenta tiene como objetivo contribuir a la mitigación del impacto ambiental a través de la universidad. La Universidad Ean servirá como laboratorio de prueba para implementar un mecanismo destinado a fomentar el reciclaje y abordar el problema de la contaminación ambiental. Según una encuesta realizada por VISION 30/30 y la Asociación

Nacional de Empresarios de Colombia (ANDI), la principal dificultad que enfrentan los colombianos al reciclar es la falta de información y la confusión sobre cómo separar los residuos en diferentes tipos de bolsas.

La encuesta reveló que solo el 46% de las personas sabe qué tipo de residuo debe ir en cada bolsa. Además, se observó que el 36% de los menores de 25 años no comprenden el concepto de "aprovechables", y solo el 44% de ellos sabe que el icopor puede ser reciclado. Esto lograría concientizar a la población para generar mayores atribuciones a los impactos medioambientales que los residuos causan.

En resumen, el problema de los residuos sólidos es una preocupación creciente a nivel mundial, y su gestión ineficiente está generando contaminación ambiental de manera acelerada. Para abordar este desafío, es necesario implementar proyectos que promuevan el reciclaje y se centren en la educación de las generaciones más jóvenes. El proyecto de investigación que se propone tiene como objetivo contribuir a esta causa y se llevará a cabo en la Universidad Ean.

Finalmente, del planteamiento anterior determina la siguiente pregunta de investigación; ¿Cómo promover a los estudiantes de la Universidad Ean el manejo eficiente de los residuos sólidos desde los sitios de descarga para así optimizar el proceso de recolección y posterior entrega a los pasivos ambientales?

OBJETIVO GENERAL

Este proyecto tiene como objetivo principal la identificación de residuos mediante inteligencia artificial, contribuyendo a la eficiencia de los procesos de manejo de residuos ya que se

estima que esta iniciativa promueve la capacitación a los jóvenes a contribuir con el impacto positivo al medio ambiente, mediante un reciclaje más consciente por medio de un sistema de clasificación usando el modelo neuronal YOLOv5x capaz de identificar diferentes desechos en tiempo real, indicando la categorización de colores para el reciclaje.

Objetivos Específicos

1. Recopilación de datos: En este proceso se construirá una base de datos con imágenes que contribuyan al etiquetado de colores según el etiquetado de separación de residuos estipulado por el Ministerio de Ambiente y desarrollo sostenible del Gobierno de Colombia.
2. Pre procesamiento de datos: Se realizarán tareas de limpieza a la base de datos creada, normalización y etiquetado de las imágenes y los materiales correspondientes para preparar los datos para el entrenamiento del modelo.
3. Entrenamiento del modelo: Se desarrollará y se entrenará un modelo de inteligencia artificial utilizando técnicas de aprendizaje profundo (como machine learning y Deep learning) para aprender a identificar los materiales a partir de las imágenes.
4. Validación y pruebas: Se evaluará la precisión del modelo utilizando un conjunto de datos de prueba independiente y métricas de evaluación.

JUSTIFICACIÓN

De acuerdo con la información planteada y descrita en donde se ha dado a conocer la problemática de residuos que maneja ahora el país y el mundo, sumado a las afectaciones y

consecuencias que han traído mayormente medioambientales, los rellenos sanitarios existentes están terminando su vida útil por la cantidad de residuos, de los cuales muchos podrían tener otro tipo de disposiciones y/o procedimientos.

El proyecto tiene como objetivo principal instruir a una parte significativa de la población, en particular a los jóvenes, que a menudo tienen una menor participación en las prácticas de reciclaje, como lo muestran los estudios. Esto se logra mediante el uso del aprendizaje repetitivo o repetición espaciada, que combate el olvido, mejora la retención y ahorra tiempo. Además, promueve una comprensión más profunda del material. Numerosos estudios respaldan la eficacia de esta forma de aprendizaje, incluyendo la investigación de Ebbinghaus sobre la curva de olvido y revisiones de la literatura.

El enfoque de la investigación consiste en desarrollar un sistema de detección y categorización de objetos en tiempo real. Los estudiantes pueden escanear sus residuos frente a una cámara que les indicará a qué color de bolsa o contenedor deben ir los residuos (blanco, verde o negro). El propósito es que más jóvenes estudiantes conozcan los tipos de residuos que deben ir en cada bolsa y se sientan motivados a hacerlo correctamente. Con la práctica repetitiva, esta acción se volverá casi automática, ya que se habrá interiorizado el conocimiento sobre el tipo de residuo que corresponde a cada contenedor.

En segundo lugar, este proyecto permitirá optimizar y automatizar la separación de residuos, desde los sitios de disposición en la Universidad Ean por medio de la detección de imágenes con la Inteligencia Artificial. En este contexto, según Oracle Colombia (2020), la Inteligencia Artificial (IA) permite la automatización en la clasificación de residuos desde un micro – entorno como lo son los sitios de descarga de residuos en un establecimiento donde se da lugar a una incorrecta gestión, se cometen errores a la hora de hacer la separación o no se tiene la

responsabilidad social para hacerlo.

Por lo que es un primer paso a la implementación de nuevas tecnologías (mecanismos inteligentes) permitiendo una disposición de residuos controlada y más sencilla para los usuarios, y de igual manera aportando a los siguientes procesos que manejan los residuos (recolección, transporte, descarga).

Adicionalmente, este estudio y según los resultados del modelo de detección de objetos, se buscaría la manera de promover la implementación del modelo en otras universidades, instalando cámaras de detección en cada punto de reciclaje o contenedor de reciclaje, con el propósito de fomentar prácticas sostenibles y la separación adecuada de los desechos para su posterior reciclaje.

- **Conveniencia:** El proyecto busca abordar la gestión de residuos sólidos de manera más eficiente y sostenible utilizando inteligencia artificial para clasificar los residuos. Esto debería hacer que la gestión de residuos sea más conveniente y efectiva en términos de reciclaje y separación.
- **Relevancia social:** La gestión adecuada de residuos sólidos es de gran relevancia social. Además, el proyecto se enfoca en educar a los jóvenes sobre las prácticas de reciclaje, lo que contribuiría a la conciencia ambiental y la participación de la comunidad.
- **Implicaciones prácticas:** El proyecto tiene implicaciones prácticas significativas al abordar un problema creciente y grave de residuos sólidos en Colombia y en todo el mundo. Proporciona una solución práctica para la clasificación y el reciclaje de residuos.
- **Valor teórico:** El proyecto emplea técnicas de aprendizaje profundo (machine learning y Deep learning) para desarrollar un sistema de clasificación de residuos. Esto tiene un valor teórico ya que contribuye al conocimiento y avance en la aplicación de la inteligencia

artificial en la gestión de residuos sólidos.

- **Unidad metodológica:** El proyecto utiliza un enfoque cuantitativo y una metodología específica que incluye la recopilación de datos, el pre procesamiento de datos, el entrenamiento del modelo y la validación. Esto muestra una unidad metodológica sólida.

Nuestro proyecto aborda y contribuye a varios Objetivos de Desarrollo Sostenible (ODS) de las Naciones Unidas, destacando la importancia de la gestión eficiente y sostenible de los residuos en entornos urbanos, específicamente en la Universidad EAN. A continuación, detallamos la inclusión de nuestro proyecto en varios ODS:

1. ODS 4

Educación de Calidad: El impacto de nuestro proyecto se extiende a la comunidad universitaria al involucrarla en prácticas eficientes de reciclaje y promover el uso de tecnologías avanzadas en la gestión de residuos. Este compromiso educativo podría integrarse en programas formativos, contribuyendo así a la calidad educativa y concientizando sobre la importancia de la sostenibilidad ambiental.

2. ODS 9

Industria, Innovación e Infraestructura: Aportamos a este ODS mediante la implementación de tecnologías innovadoras de inteligencia artificial para mejorar la gestión de residuos. Nuestra iniciativa destaca el papel crucial de la innovación y la infraestructura tecnológica en la búsqueda de soluciones efectivas para desafíos ambientales, especialmente en el ámbito de la gestión de residuos.

3. ODS 11

Ciudades y Comunidades Sostenibles: Nuestro proyecto contribuye a este objetivo mediante la gestión más eficiente y sostenible de los residuos en entornos urbanos, centrándose

específicamente en la Universidad EAN. Buscamos mejorar la calidad de vida de la comunidad universitaria al implementar un sistema de detección de residuos sólidos, promoviendo prácticas sostenibles y reduciendo la carga ambiental en la universidad

4. ODS 12

Producción y Consumo Responsables: El impacto de nuestro proyecto se refleja en la identificación precisa y clasificación de residuos, fomentando prácticas de reciclaje y reduciendo la generación de residuos no aprovechables. Nuestra iniciativa aboga por un enfoque más responsable en la producción y el consumo, contribuyendo así a la sostenibilidad ambiental.

5. ODS 13

Acción por el Clima: Nuestra iniciativa tiene el potencial de impactar positivamente en la mitigación del cambio climático al mejorar la gestión de residuos. Al reducir la carga ambiental mediante prácticas más eficientes, contribuimos a la acción global por el clima, alineándonos con los esfuerzos para frenar el calentamiento global.

6. ODS 15

Vida de Ecosistemas Terrestres: Nuestra contribución a la gestión de residuos de manera más eficiente tiene el potencial de reducir el impacto negativo en los ecosistemas terrestres. Al abordar la gestión de residuos de manera responsable, buscamos preservar la biodiversidad y la salud de los ecosistemas terrestres, alineándonos con el objetivo de garantizar la vida sostenible en la Tierra.

MARCO TEÓRICO

Residuos sólidos

Los residuos sólidos son materiales que se descartan después de su vida útil y, en general, no tienen un valor económico por sí mismos. Están compuestos principalmente por desechos provenientes de la fabricación, transformación o uso de productos de consumo. La mayoría de estos residuos sólidos se pueden reutilizar o transformar adecuadamente a través del reciclaje. En gran medida, los residentes de las ciudades son los principales generadores de residuos sólidos, y esto se debe en gran parte a la falta de conciencia sobre la importancia del reciclaje en la actualidad. (Ambiente, 2018)

Plan de Gestión Integral de Residuos Sólidos

Un PGIRS es un instrumento de planificación utilizado a nivel municipal o regional para gestionar de manera efectiva los residuos sólidos. Contiene una serie de elementos como objetivos, metas, programas, proyectos, actividades y recursos, y está basado en una política de gestión integral de los residuos sólidos. El propósito del PGIRS es asegurar que el manejo de los residuos sólidos sea sostenible y cumpla con los estándares ambientales, además de garantizar la prestación adecuada de servicios de aseo en el territorio.

Este plan se crea a partir de un diagnóstico inicial que analiza la situación actual de la gestión de residuos, considera proyecciones futuras y establece un plan financiero que permita la mejora continua en la gestión de residuos y la prestación de servicios de aseo en la región. La entidad territorial es responsable de formular, implementar, evaluar, dar seguimiento, controlar y actualizar el PGIRS para garantizar que se cumplan los objetivos establecidos y se mejore la gestión de residuos sólidos a lo largo del tiempo. (Ambiente, 2018)

El manejo adecuado de los residuos sólidos es esencial para la preservación del medio ambiente y la promoción de una economía circular. La clasificación de residuos desempeña un papel crucial en este proceso, permitiendo la separación y recuperación de materiales valiosos. En los últimos años, la inteligencia artificial (IA) se ha convertido en una herramienta poderosa para abordar este desafío, ofreciendo soluciones precisas y eficientes para la clasificación de residuos. (Salina, Osio, & Cappelletti, 2021)

La clasificación de residuos sólidos es diversa, ya que depende de la terminología utilizada y no se limita únicamente a áreas urbanas, sino que también abarca zonas rurales y cualquier entorno en el que las personas interactúen con el medio ambiente. Los tres enfoques más comunes para categorizar los residuos sólidos son los siguientes:

- 1.** Clasificación en función de la peligrosidad de los residuos.
- 2.** Clasificación según la procedencia de los residuos.
- 3.** Clasificación basada en la composición de los residuos.

Ilustración 1 Separación De Residuos Colombia



(Minambiente, 2019)

Sin embargo, la gestión de residuos sólidos es un problema global de gran relevancia, con implicaciones tanto ambientales como económicas. La clasificación de residuos es un paso crítico en el proceso de reciclaje y recuperación de recursos. No obstante, este proceso puede ser costoso y requiere mano de obra intensiva cuando se realiza de manera manual. Además, la precisión de la clasificación manual puede ser limitada, lo que lleva a una recuperación ineficiente de materiales valiosos y a la contaminación de residuos reciclables.

La inteligencia artificial (IA) presenta una solución prometedora para abordar las limitaciones del reciclaje en términos de mano de obra, gastos y precisión de clasificación debido a sus capacidades únicas y ventajas, a continuación, se comparten algunas de estas.

La inteligencia artificial (IA)

Es un campo de la informática que se centra en la creación de sistemas y programas capaces de realizar tareas que normalmente requerirían de la inteligencia humana. Estas tareas pueden incluir el aprendizaje, la resolución de problemas, la toma de decisiones, el procesamiento de

lenguaje natural, la percepción visual y la toma de decisiones, entre muchas otras.

Automatización: La IA puede automatizar muchas tareas en el proceso de reciclaje que normalmente requerirían mano de obra humana. Por ejemplo, en el proyecto a cabo, se utiliza un modelo neuronal YOLOv5x para identificar diferentes tipos de residuos en tiempo real. Esto significa que no es necesario que los seres humanos realicen la clasificación manualmente. La automatización ahorra tiempo y reduce los costos asociados con el empleo de personal.

Velocidad: Los algoritmos de IA pueden procesar grandes cantidades de datos y realizar tareas de clasificación rápidamente, lo que aumenta la velocidad de procesamiento y la eficiencia del reciclaje. En lugar de esperar a que un trabajador humano clasifique los materiales, la IA puede hacerlo en milisegundos.

Precisión: Los modelos de IA, especialmente aquellos basados en el aprendizaje profundo, pueden lograr niveles significativamente altos de precisión en la clasificación de materiales. Pueden distinguir entre diferentes tipos de residuos con una precisión que es difícil de alcanzar para los seres humanos. Esto es fundamental para garantizar que los materiales se reciclen de manera efectiva.

Escalabilidad: Los sistemas de IA son escalables. Pueden implementarse en diferentes ubicaciones y ajustarse para adaptarse a las necesidades cambiantes. Esto es especialmente importante en un contexto como el reciclaje, donde la cantidad de residuos puede variar significativamente.

Reducción de errores humanos: Los errores humanos son inevitables y pueden llevar a una clasificación incorrecta de los materiales. La IA está diseñada para minimizar los errores y garantizar una clasificación precisa y coherente.

Costo-efectividad a largo plazo: Aunque la implementación inicial de sistemas de IA puede requerir una inversión significativa en tecnología y capacitación, a largo plazo, pueden resultar en

ahorros sustanciales debido a la reducción de mano de obra y la mejora de la eficiencia.

Para el uso de la IA, se tienen en cuenta las siguientes tecnologías:

Redes Neuronales Convolucionales (CNN) en la Clasificación de Residuos

Las redes neuronales son un subconjunto del machine learning y el núcleo de los algoritmos de aprendizaje profundo. Están compuestas por capas de nodos, que incluyen una capa de entrada, una o más capas ocultas y una capa de salida. Cada nodo está conectado a otro y tiene un peso y un umbral asociados. Si la salida de un nodo individual está por encima del valor de umbral especificado, ese nodo se activa y envía datos a la siguiente capa de la red. De lo contrario, no se pasa ningún dato a la siguiente capa de la red (IBM SPSS Neural Networks, 2021).

Estas redes son capaces de extraer características relevantes de las imágenes de residuos y asignarlas a categorías específicas, pues las capas convolucionales en redes neuronales aprenden patrones locales en imágenes en dos dimensiones, como bordes, líneas y colores. También tienen la capacidad de aprender jerarquías espaciales de patrones, lo que significa que una capa puede construir sobre lo que aprendió la capa anterior para identificar patrones más complejos. Esto permite que las redes neuronales convolucionales aprendan conceptos visuales cada vez más abstractos de manera eficiente. Las redes neuronales convolucionales (CNN) han demostrado ser altamente efectivas en la clasificación de imágenes, y su aplicación en la clasificación de residuos ha ganado prominencia. (Quiñones, 2022)

Transfer Learning y Modelos Pre-Entrenados

ImageNet, más que un conjunto de datos realmente es un proyecto a gran escala que involucra a diversas instituciones educativas, como Stanford y Princeton. Su objetivo es ser un banco de data visual enorme para la investigación y desarrollo de software especializado en reconocimiento de imágenes (Datasmarts, 2019)

La técnica de Transfer Learning ha demostrado ser valiosa en la clasificación de residuos.

Al aprovechar modelos pre-entrenados en conjuntos de datos masivos, como ImageNet, la IA puede generalizar la clasificación de residuos de manera más eficiente. Esto permite un rápido entrenamiento de modelos con conjuntos de datos más pequeños y especializados, lo que ahorra tiempo y recursos.

Reconocimiento de Objetos en Tiempo Real

La IA aplicada a la clasificación de residuos también ha permitido el reconocimiento de objetos en tiempo real. Esto es especialmente útil en sistemas de recogida de residuos automatizados, donde los robots pueden identificar y clasificar los residuos a medida que se recogen, mejorando la eficiencia y la precisión del proceso. (Jiménez, 2021)

Por lo que se puede afirmar que, las redes neuronales convencionales, el transfer learning y el reconocimiento de objetos en tiempo real han innovado la clasificación de residuos, mejorando la eficacia y precisión de este proceso.

La innovación en la recuperación de materiales reciclables atribuye significativamente a la economía circular. Esta contribución se ve reflejada tanto a nivel ambiental como económico. La recuperación eficiente de materiales reciclables reduce la necesidad de recursos naturales y disminuye la contaminación ambiental al reducir la extracción de materias primas y la energía necesaria para la fabricación de nuevos productos. Además, la automatización de la clasificación de residuos puede disminuir los costos operativos y aumentar la rentabilidad de las instalaciones de reciclaje, fomentando así prácticas más sostenibles. Esta transformación no solo beneficia la preservación del medio ambiente, sino que también se alinea estrechamente con los principios de la economía circular, donde los materiales se reciclan y reutilizan de manera efectiva, promoviendo una gestión más eficiente de los recursos y un futuro más limpio y sostenible. La continúa investigación y desarrollo en este campo promete soluciones aún más avanzadas y eficientes para fortalecer aún más estos beneficios.


Pycharm

Pycharm es un entorno de desarrollo integrado (IDE) enfocado en Python, desarrollado por JetBrains S.R.O., que forma parte de una gama de IDEs para varios lenguajes de programación, incluyendo Java, JavaScript, PHP, .NET, C/C++, Ruby, iOS/macOS, y Go. JetBrains ofrece versiones tanto gratuitas como profesionales de sus IDEs, con las segundas proporcionando características adicionales y opciones de pago recurrente. Además, ofrecen una versión educativa llamada PyCharm EDU, diseñada para su uso en cursos y universidades por profesores y estudiantes. (Phytonista, 2020)

Yolov5x

YOLOv5 es un modelo de la familia YOLO (You Only Look Once) utilizado en visión por computadora para la detección de objetos. Viene en cuatro versiones principales, desde pequeña (s) hasta extra grande (x), con tasas de precisión crecientes. Cada variante tiene tiempos de entrenamiento diferentes. En términos de rendimiento, YOLOv5 destaca al ofrecer un equilibrio notable entre precisión y velocidad de inferencia en comparación con otras técnicas de vanguardia. En particular, el modelo YOLOv5x logra un alto grado de precisión y procesa imágenes considerablemente más rápido que el modelo EfficientDet D4, como se muestra en el gráfico de rendimiento.

Ilustración 2 Lanzamiento inicial de yolov5



(Github, 2020)

Python

Python es un lenguaje de programación ampliamente utilizado en aplicaciones web, desarrollo de software, ciencia de datos y machine learning (ML). Es apreciado por su eficiencia y facilidad de aprendizaje, y es versátil al poder ejecutarse en diversas plataformas. Además, el software Python es gratuito y se integra bien con diferentes sistemas, lo que acelera el desarrollo.

En el ámbito de la ciencia de datos, Python se emplea para tareas como la limpieza y corrección de datos, la selección de características, el etiquetado de datos, el análisis estadístico y la visualización de datos con gráficos. También se utilizan bibliotecas de ML en Python para entrenar modelos y crear clasificadores precisos en campos como la clasificación de imágenes, texto, reconocimiento de voz y rostros, así como en tareas de aprendizaje profundo. Python se ha convertido en una herramienta fundamental para aquellos que trabajan en estos campos. (Amazon, 2023)

Makesense.ai

Makeense.ai es una herramienta en línea gratuita para etiquetar fotografías, diseñada para facilitar la preparación de conjuntos de datos en proyectos de aprendizaje profundo de visión por computadora. No requiere instalación complicada y es multiplataforma, lo que permite a los usuarios etiquetar imágenes de manera eficiente. Ofrece la descarga de etiquetas en varios formatos y utiliza modelos de inteligencia artificial (IA) para automatizar tareas y proporcionar recomendaciones. Entre los modelos de IA utilizados se encuentra SSD entrenado en el conjunto de datos COCO y PoseNet para estimar la pose de una persona en imágenes. La aplicación está basada en TypeScript y se apoya en TensorFlow.js, lo que garantiza la privacidad de los datos, ya que no es necesario transferir las fotos al servidor. Makeense.ai planea añadir más modelos y funcionalidades de IA en el futuro, como la clasificación de fotografías y la detección de rasgos faciales, para agilizar el proceso de etiquetado. (Github, 2020)

Curva de precisión - recuperación

La curva de precisión – recuperación es una herramienta importante en la evaluación del rendimiento de modelos de clasificación y detección, y no está necesariamente limitada a modelos de detección de objetos. Esta curva se utiliza comúnmente en el ámbito de la inteligencia artificial, el aprendizaje automático y la recuperación de información;

Precisión: La precisión es la proporción de verdaderos positivos (elementos correctamente identificados) con respecto al total de elementos identificados (verdaderos positivos más falsos positivos). En otras palabras, mide la exactitud de las predicciones positivas del modelo.

Recuperación (también llamada sensibilidad o tasa de verdaderos positivos): La recuperación es la proporción de verdaderos positivos con respecto al total de elementos

verdaderamente positivos en el conjunto de datos. Representa la capacidad del modelo para identificar todos los elementos positivos.

La curva de precisión-recuperación muestra cómo varían estos dos valores a medida que se ajusta el umbral de decisión del modelo. El umbral de decisión es el valor que determina si una instancia se clasifica como positiva o negativa. Al ajustar este umbral, puedes obtener diferentes pares de valores de precisión y recuperación.

En una curva de precisión-recuperación ideal, la precisión sería siempre 1 (100%) independientemente de la recuperación, lo que significa que el modelo nunca produce falsos positivos. Sin embargo, en la práctica, a menudo hay un equilibrio entre la precisión y la recuperación. Un buen modelo se caracteriza por tener una alta precisión incluso cuando la recuperación es alta. (Pro, 2020)

Error Absoluto Medio (MAE)

El MAE es una medida que cuantifica la magnitud promedio de los errores entre las predicciones de un modelo y los valores reales. Se calcula como la suma de las diferencias absolutas entre las predicciones y los valores reales, dividida por el número de observaciones. El MAE se expresa en las mismas unidades que los datos originales y representa la magnitud promedio de los errores de predicción. (Pro, 2020)

Desviación Estándar (STD)

La desviación estándar es una medida de la dispersión o variabilidad de un conjunto de datos. En el contexto de la evaluación de un modelo, la desviación estándar generalmente no se utiliza para evaluar la calidad de las predicciones en sí, sino para comprender la variabilidad de los

datos reales en relación con las predicciones del modelo. (Pro, 2020)

Coefficiente de Correlación (R)

El coeficiente de correlación es la medida específica que cuantifica la intensidad de la relación lineal entre dos variables en un análisis de correlación. En los informes de correlación, este coeficiente se simboliza con la r . (Discovery, s.f.)

DISEÑO METODOLÓGICO

La metodología de investigación se fundamenta en el método cuantitativo debido a que la visión de nuestro trabajo es analítica, dirigida por teoría expresada explícitamente, haciendo énfasis en el número, datos y predicciones con el fin de permitir la evaluación del modelo de detección y reconocimiento de residuos. Este método contribuye a la evaluación y precisión del modelo. El análisis cuantitativo se basa inicialmente en la identificación de residuos a pequeña escala. Esta prueba inicial de detección e identificación de residuos se llevará a cabo en el hogar de una de las estudiantes, donde se intentarán identificar varios elementos. El sistema debe responder a la categoría a la que pertenece cada producto y a sus características correspondientes. Dependiendo de los resultados obtenidos, se instalará una cámara que identificará en tiempo real los residuos depositados en los sitios de disposición.

PRIMERA FASE PROPUESTA

1. Identificación de la población

El espacio propuesto para evaluar el modelo y su precisión a mayor escala es la Universidad Ean. Esto se debe al cumplimiento del objetivo principal, que es motivar a los jóvenes a contribuir con prácticas eficientes de reciclaje, así como a la facilidad para la construcción del modelo en los espacios correspondientes y a la toma de muestras de residuos en los sitios de disposición, instalación y pruebas del prototipo.

Adicionalmente, la solución propuesta en este proyecto de investigación se llevará a cabo en 10 contenedores de residuos sólidos de la Universidad Ean. Esto permitirá obtener mayores datos para continuar con el desarrollo del detector de residuos y mejorar la precisión del modelo.

2. Recopilación de Datos

Implementación del modelo de identificación de residuos en los contenedores seleccionados:

En esta fase, se realizó la construcción del conjunto de datos que contiene imágenes correspondientes a las tres categorías. Inicialmente, se empleó la extensión de Google Down load para descargar masivamente las imágenes. Una vez descargadas, se procedió a limpiar los datos y a dividir las imágenes en dos grupos: uno destinado al entrenamiento y otro para la validación.

Luego, se llevó a cabo el etiquetado de las imágenes utilizando la herramienta Makesense.ai, la cual facilita la creación de etiquetas para cada categoría. En este caso, se generaron etiquetas para las tres categorías: "caneca blanca," "caneca verde" y "caneca negra." Una vez completado este proceso, las etiquetas se exportaron en formato Yolo.

3. Entrenamiento del Modelo

Se creó una carpeta llamada "data" que contiene las imágenes. Esta carpeta se subdivide en dos directorios: uno destinado a las imágenes de entrenamiento y otro para las imágenes de validación. Lo mismo se aplicó a las etiquetas, con una carpeta para las etiquetas de las imágenes de entrenamiento y otra para las de validación. A continuación, se procedió a acceder al repositorio de YOLOv5x en GitHub, que es el modelo de detección de objetos seleccionado para este proyecto.

En dicho repositorio, se buscó la sección de entrenamiento con datos personalizados. En esta sección, se seleccionó la red neuronal YOLOv5x, que es la versión más avanzada y de mayor rendimiento dentro de la familia YOLO. Se siguieron los pasos proporcionados por la herramienta YOLOv5x para llevar a cabo el entrenamiento de los datos. Esto incluyó la descarga e instalación de los servicios necesarios para el entrenamiento. Un aspecto crucial fue la configuración de aproximadamente 60 épocas, que determinan los mejores valores de ponderaciones y sesgos de entrada para lograr un resultado preciso o minimizar la pérdida. Una vez completado el entrenamiento del modelo y exportado, se procedió a crear el código para ejecutar dicho modelo.

Para ello, se utilizó PyCharm, que es un entorno de desarrollo para Python, ya que YOLOv5x se ejecuta con el lenguaje de programación Python en su versión 3.8. En el entorno de

desarrollo, se instalaron las siguientes librerías de Python: torch, cv2, numpy y pandas. La librería "torch" permite cargar el modelo previamente entrenado, mientras que "cv2" se utiliza para realizar la detección de objetos a través de la cámara. "Numpy" se emplea para enmarcar el objeto detectado y mostrar su etiqueta, y la librería "pandas" proporciona información sobre la posición espacial del objeto, la categoría a la que pertenece y el porcentaje de precisión del objeto de acuerdo con el modelo.

4. Identificación correcta de cada objeto o residuo

Durante el período de prueba (Fase I – implementación del proyecto entre octubre y noviembre de 2023), el modelo de identificación de residuos analizó un par de objetos. Para cada objeto o residuo identificado, se registró si la identificación fue correcta o incorrecta. Esto implicó que el sistema fuese capaz de determinar si el objeto en cuestión se clasificó correctamente en una categoría específica, como "plástico", "vidrio", "metal", "papel", "cartón", "orgánico" o "no reciclable". Los resultados se almacenaron en una base de datos que permitió un seguimiento detallado de cada identificación realizada por el modelo.

Identificación correcta

En el contexto del proyecto, una identificación se considera correcta cuando el modelo de inteligencia artificial (IA) asigna de manera precisa un objeto o residuo a su categoría específica, correspondiendo a la categorización real del objeto o residuo en el contenedor de basura. Por ejemplo, si el modelo clasifica un objeto como "plástico" y ese objeto realmente es plástico, se considera una identificación correcta.

Identificación incorrecta

En contraposición, una identificación se considera incorrecta cuando el modelo de IA asigna un objeto o residuo a una categoría que no corresponde a su verdadera naturaleza. Por ejemplo, si el modelo clasifica un objeto de vidrio como "metal", se considera una identificación

incorrecta.

Recopilación de datos numéricos sobre el número total de contenedores, el número de identificaciones correctas y el número de identificaciones incorrectas.

SEGUNDA FASE PROPUESTA

Durante el período de prueba (Fase II – implementación del proyecto en los puntos de disposición de residuos de la Universidad Ean) dependiendo de los resultados del modelo se propone evaluar la eficacia del modelo de identificación de residuos, para ello es fundamental recopilar datos cuantitativos. Esto implica contar con un registro numérico de los siguientes elementos:

- Número total de contenedores: 10 contenedores, del segundo piso de la Universidad Ean.
- Número de identificaciones correctas: En este paso se registrará cuántas veces el modelo identifica los objetos o residuos de manera precisa y los asigna a la categoría correcta (por ejemplo, "plástico" si es plástico).
- Número de identificaciones incorrectas: Se llevará un registro de las ocasiones en las que el modelo cometió errores al identificar objetos o residuos, es decir, asignando una categoría incorrecta.

Estos datos numéricos son esenciales para calcular el porcentaje de identificación correcta del modelo, lo que proporcionará una métrica objetiva sobre el rendimiento en la clasificación de residuos en los contenedores de la universidad. Además, estos registros permitirán identificar patrones de errores y áreas de mejora en el sistema, si es necesario.

Análisis de datos

En esta etapa se evaluará de manera objetiva la eficacia del modelo de identificación de residuos. Por lo que se llevará al cabo las siguientes acciones:

Cálculo del porcentaje de identificación correcta del modelo

Esta métrica es fundamental para comprender cuántas veces el modelo identificó los objetos o residuos correctamente en comparación con el número total de contenedores evaluados.

La fórmula utilizada para calcular esta métrica es:

Ilustración 3 Cálculo de porcentaje de identificación correcta

$$= \frac{\text{NÚMERO DE IDENTIFICACIÓN CORRECTAS}}{\text{TOTAL DE IDENTIFICACIONES}} * 100\%$$

Esta métrica proporciona una medida cuantitativa de la precisión del modelo en la identificación de residuos en los contenedores.

Interpretación de resultados

En esta etapa, se interpreta la información cuantitativa recopilada y se busca comprender el rendimiento real del modelo. Esto implica analizar el porcentaje de identificación correcta calculado previamente y considerar lo siguiente:

Precisión del modelo

Evaluar si el porcentaje de identificación correcta es alto, lo que indicaría que el modelo es efectivo en la clasificación de residuos en los contenedores.

Errores comunes

Examinar los tipos de residuos o situaciones en los que el modelo tiende a cometer errores. Esto en búsqueda de identificar áreas de mejora o ajustes necesarios en el modelo.

Variabilidad

Analizar si el rendimiento del modelo es consistente en diferentes contenedores o si hay variaciones significativas en su precisión.

RECOLECCIÓN DE DATOS

La investigación "Clasificación de Residuos por Medio de la Inteligencia Artificial (IA) en Sitios de Micro-disposición en la Universidad EAN" implicó una meticulosa recolección de datos a través de la creación de un conjunto de datos personalizado. Para construir este conjunto de datos, se empleó una extensión de Google denominada "Down load Images All," que permitió descargar un total de 800 imágenes correspondientes a distintas categorías de residuos sólidos. Estas categorías incluyeron residuos verdes (orgánicos aprovechables), residuos blancos (aprovechables) y residuos negros (no aprovechables).

El proceso de recolección de datos incluyó la organización de imágenes y etiquetas en estructuras de carpetas específicas que constaban de divisiones en "train" y "validation." Posteriormente, se llevó a cabo un minucioso procedimiento de limpieza y etiquetado de las imágenes. La limpieza de las imágenes se realizó de manera manual, garantizando la calidad y consistencia visual, mientras que para el etiquetado se aprovechó la plataforma "makesense.ai," una herramienta gratuita y de código abierto diseñado para etiquetar imágenes, lo que permitió asignar a cada imagen su categoría correspondiente de manera precisa. Este conjunto de datos personalizado resulta fundamental para el entrenamiento y evaluación de modelos de inteligencia artificial destinados a la clasificación de residuos sólidos en los sitios de micro-disposición de la Universidad EAN.

Ilustración 4 Producto 1 detectado en el modelo



Ilustración 5 Producto 2 detectado en el modelo



Ilustración 6 Producto 3 y 4 detectado en el modelo



PROCESAMIENTO Y ANÁLISIS DE RESULTADOS

El procesamiento de esta investigación involucró una serie de pasos técnicos y cuidadosamente planificados. Una vez obtenido y etiquetado el conjunto de datos personalizado, se procedió a utilizar una red neuronal YOLOv5x, que es la versión más actual de la familia de arquitecturas y modelos de detección de objetos. Aunque esta familia de modelos se ha entrenado previamente en el conjunto de datos COCO, para este proyecto se construyó un conjunto de datos personalizado específico.

El proceso se llevó a cabo en el entorno de Google Colab, que permite la ejecución de código de Python en línea. Se seleccionó el modelo YOLOv5x y se configuró para aprovechar las GPU disponibles. Además, se realizaron ajustes en el entorno de Colab y se instalaron los requisitos necesarios. También se creó un archivo YAML que contenía las clases o categorías correspondientes a los diferentes tipos de residuos. Este archivo se editó utilizando el editor de Python PyCharm.

A continuación, se procedió a entrenar el modelo con el conjunto de datos personalizado, que se había construido en Google Colab. Una vez finalizado el entrenamiento, el modelo estaba listo y asignaba pesos a las diferentes categorías de residuos. La implementación del sistema de detección de desechos se realizó utilizando Python versión 3.8 y el editor PyCharm. El código de este sistema se encuentra disponible en la carpeta adjunta, junto con el conjunto de datos.

Para cargar el modelo entrenado, se utilizó la biblioteca torch junto con la función torch.hub.load. Para capturar video en tiempo real desde la cámara, se hizo uso de la biblioteca cv2 y la función Video Capture. Finalmente, para que la red neuronal pudiera seleccionar y clasificar los residuos detectados, se empleó la función squeeze de la biblioteca cv2.

Este proceso técnico y minucioso permitió desarrollar un sistema de detección de residuos sólidos mediante inteligencia artificial, lo que representa un avance significativo en la gestión y clasificación de desechos en entornos específicos, como los sitios de micro-disposición en la Universidad EAN.

Se extrae la información de la detección y las posiciones de residuos, continuamente se realiza extracción de la categoría y porcentaje de precisión de ella, por medio de la librería de Python Pandas. Aquí algunos ejemplos:

Tabla 1 Ejemplo de extracción categoría caneca blanca

OBJETO	NÚMER	XMIN	YMIN	XMAX	YMAX	CONFIDENCE	CLASS	NAME
	0							
0	250.0200 35	208.408279	405.316895	480.0	0.665379	0	CANECA	BLANCA

Tabla 2 Ejemplo 2 de extracción categoría caneca blanca.

OBJET	NÚMERO	XMIN	YMIN	XMAX	YMAX	CONFIDENCE	CLASS	NAME
0								
1	214.778717	215.637405	370.47464	480.0	0.585273	0	CANECA	BLANCA

A continuación se hace el siguiente análisis de resultados de la predicción correspondiente de precisión de estos productos es del 90% al 100%, y tuvimos los siguientes porcentajes de precisión para los tipos de productos detectados en el modelo:

PRODUCTO UNO (1)

- Valor de Predicción del 90%, Valor real del 48%
- Error Absoluto

Ecuación 1 Error absoluto producto uno

$$|90\% - 48\%| = 42\%$$

PRODUCTO DOS (2)

- Valor de Predicción del 95%, Valor real del 30%
- Error Absoluto

Ecuación 2 Error absoluto producto dos

$$|95\% - 30\%| = 65\%$$

PRODUCTO TRES (3)

- Valor de Predicción del 100%, Valor real del 46%
- Error Absoluto

Ecuación 3 Error absoluto producto tres

$$|100\% - 46\%| = 54\%$$

PRODUCTO CUATRO (4)

- Valor de Predicción del 92%, Valor real del 43%
- Error Absoluto

Ecuación 4 Error absoluto producto cuatro

$$|92\% - 43\%| = 49\%$$

Luego se calcula el error absoluto medio (MAE) promediando los errores absolutos individuales:

Ecuación 5 Error absoluto medio cuatro productos

$$MAE = (42\% + 65\% + 54\% + 49\%) / 4 = 52.5\%$$

Se calcula la desviación estándar (STD) de los errores absolutos: para calcular la diferencia entre cada error absoluto y el MAE, cuadrado (para eliminar los signos negativos), debe promediar estos valores cuadrados y toma la raíz cuadrada de ese promedio:

Ecuación 6 Desviación estándar cuatro productos

$$STD = \sqrt{[(42\% - 52.5\%)^2 + (65\% - 52.5\%)^2 + (54\% - 52.5\%)^2 + (49\% - 52.5\%)^2] / 4} \approx 7.14\%$$

Finalmente, se calcula el coeficiente de correlación (Q):

Ecuación 7 Coeficiente de correlación

$$Q = (1 - (MAE / Rango)) * 100$$

Donde el rango es la diferencia entre el valor máximo y mínimo de los valores reales. En este caso, el valor máximo es 48% y el valor mínimo es 30%, por lo que el rango es 48% - 30% = 18%.

Ecuación 8 Coeficiente de correlación cuatro productos

$$Q = (1 - (52.5\% / 18\%)) * 100 \approx 70.83\%$$

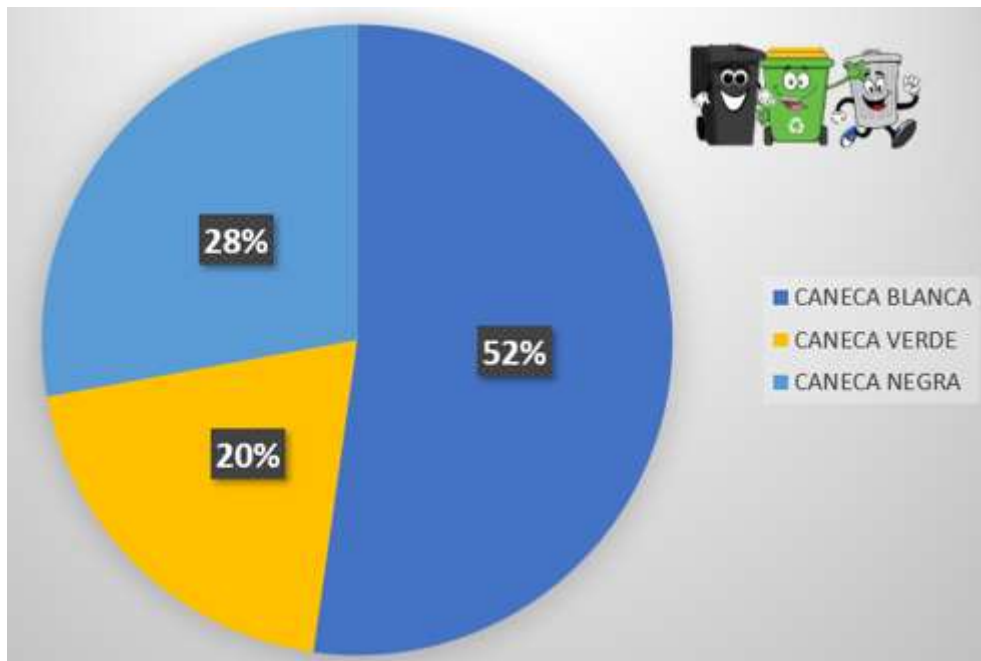
Tabla 3 Valores de precisión del modelo

ERROR ABSOLUTO MEDIO	DESVIACIÓN ESTANDAR	COEFICIENTE DE CORRELACIÓN
52,5%	7,14%	70,83%

Estas métricas reflejan el rendimiento del modelo en la predicción de los valores reales de cada producto.


Con base en lo mencionado anteriormente, se obtuvieron los siguientes gráficos de porcentaje de confianza en las categorías de clasificación y precisión de los datos obtenidos en el modelo:

Ilustración 7 Porcentaje de confianza de los productos seleccionados



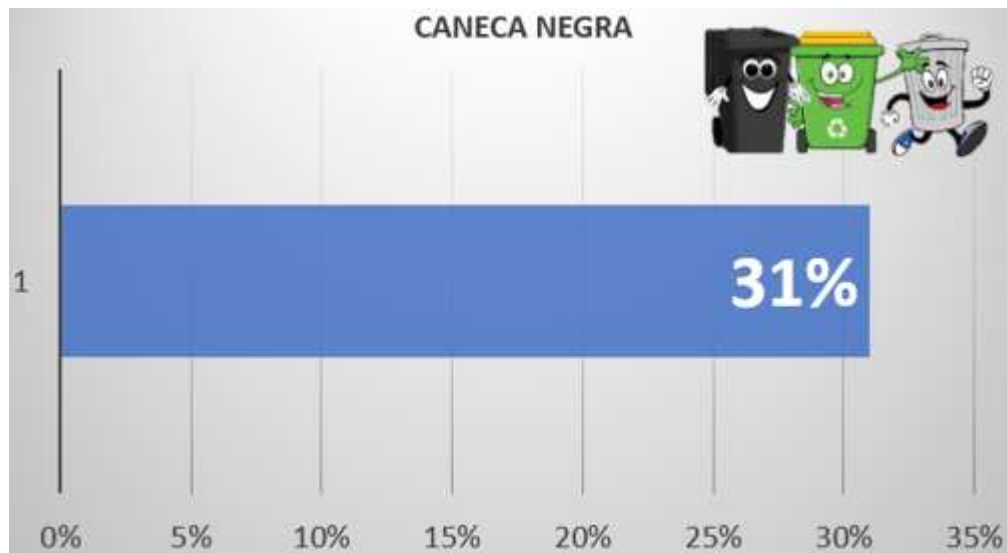
En la gráfica puede visualizarse un porcentaje de confianza con respecto a los tres productos leídos en el modelo, siendo un 28% para caneca negra, 20% para caneca y verde y 52% caneca blanca respectivamente.

Ilustración 8 Porcentaje de confianza categoría caneca verde



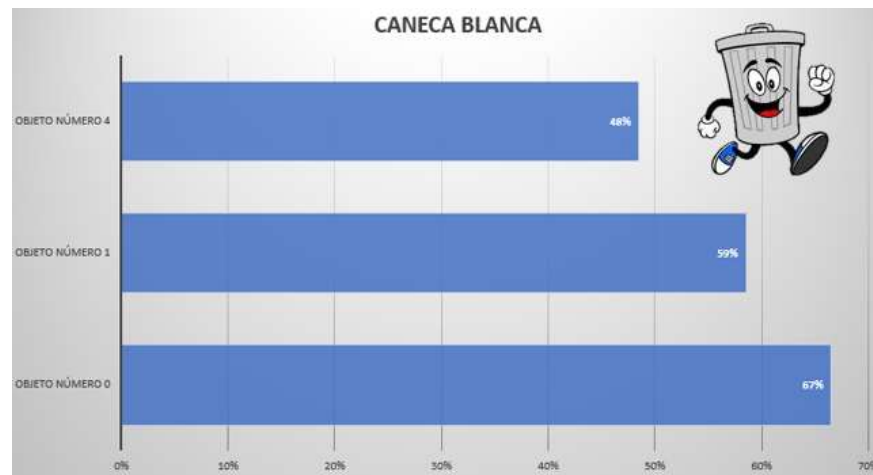
En este gráfico se encuentra un porcentaje de confianza específicamente para la categoría caneca verde con un 22% respectivamente.

Ilustración 9 Porcentaje de confianza categoría caneca negra



En este gráfico se encuentra un porcentaje de confianza específicamente para la categoría caneca negra con un 31% respectivamente.

Ilustración 10 Porcentaje de confianza categoría caneca blanca con los tres productos



En este gráfico se analizan los tres productos debido a que la categoría caneca blanca tiene el porcentaje de confianza más alto, en el que respectivamente;

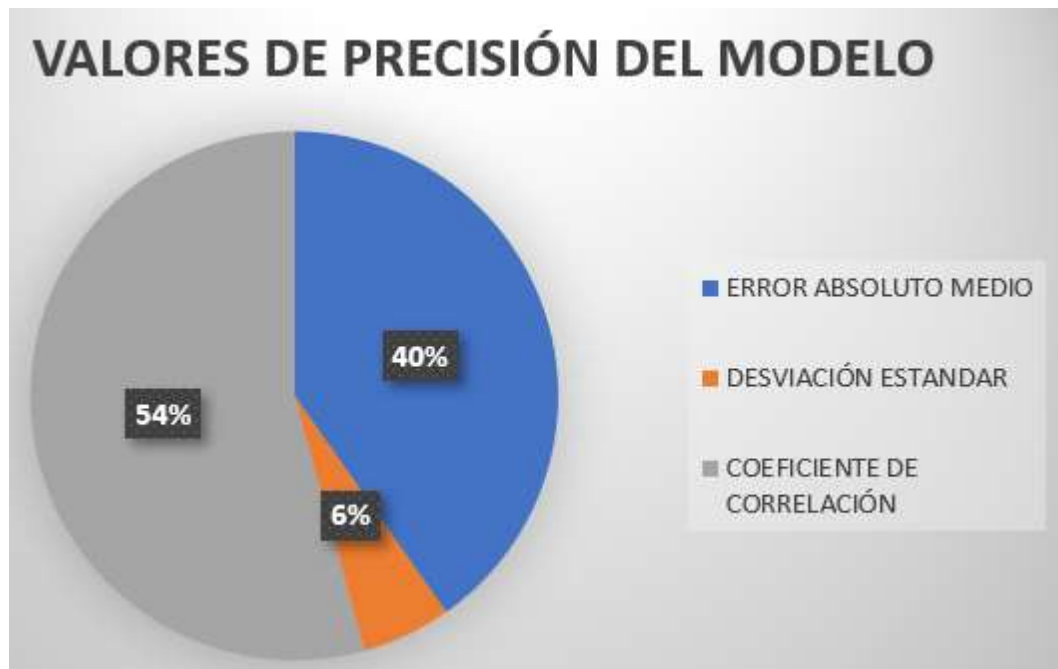
- Primer producto hubo un 48% de confianza.
- Segundo producto hubo un 59% de confianza.
- Tercer producto hubo un 67% de confianza.

Tabla 4 Datos de los productos seleccionados

OBJETO NÚMERO	POSICIÓN XMIN	POSICIÓN YMIN	POSICIÓN XMAX	POSICIÓN YMAX	PORCENTAJE DE CONFIDENCIA	CLASE	NOMBRE DE LA CATEGORÍA
0	250	208	405	480	0,67	0	CANECA BLANCA
1	214	215	370	480	0,59	0	CANECA BLANCA
2	223	85	640	402	0,31	2	CANECA NEGRA
4	201	54	404	480	0,48	0	CANECA BLANCA
5	207	47	395	480	0,22	1	CANECA VERDE

En la siguiente tabla pueden encontrarse los valores arrojados por el modelo con respecto a los objetos leídos; teniendo su posición XMIN, YMIN, XMÁX, Y MÁX, porcentaje de confianza, clase y clasificación.

Ilustración 11 Valores de precisión del modelo



Para finalizar, se detalla la precisión en la clasificación de residuos en el modelo, con un 54% de coeficiente de correlación, 40% de error absoluto medio y 6% de desviación estándar.

CONCLUSIONES Y RECOMENDACIONES

El entrenamiento del modelo permitió obtener mejores resultados para productos de caneca blanca, debido a que en la obtención de las imágenes, hubo mayores fuentes de información para ese tipo de residuos en específico, lo que a su vez facilitó el porcentaje de precisión en la detección del modelo. Para los tres tipos de canecas, no se obtuvieron porcentajes de precisión mayores al 50%, por lo que se concluye que entre mayor registro de imágenes, aumentaría proporcionalmente la fácil detección de imágenes por medio del modelo.

El objetivo general fue obtenido, debido a que se pudo demostrar mediante imágenes la categorización de los residuos exitosamente por el modelo, sin embargo, en los objetivos específicos, el modelo no se puso a prueba en una evaluación independiente para demostrar su efectividad en la Universidad Ean. La propuesta cumplió con la promoción en el uso de nuevas tecnologías, sin embargo, el camino es largo para la construcción de macro proyectos en función de la mitigación del impacto ambiental que generan los residuos sólidos.

Como recomendación para el mejoramiento del modelo, es esencialmente el entrenamiento del mismo, permitiendo que las métricas de precisión sean las esperadas entre el 90% y 100%, al igual que adiciones en el sistema como detección de imágenes implementadas en las canecas con reconocimiento de voz.

BIBLIOGRAFÍA

Amazon. (2023). *¿Qué es Python?* Obtenido de <https://aws.amazon.com/es/what-is/python/>

Ambiente, M. (2018). *Gestión Integral de Residuos*. Obtenido de <https://www.mincit.gov.co/getattachment/c957c5b4-4f22-4a75-be4d-73e7b64e4736/17-10-2018-Uso-Eficiente-de-Recursos-Agua-y-Energi.aspx#:~:text=GESTI%C3%93N%20INTEGRAL%20DE%20RESIDUOS%20S%C3%93LIDOS,posibilidades%20de%20aprovechamiento%20y%20comercializaci%C>

Datasmarts. (2019). *Qué es ImageNet y Por Qué Necesitas Conocerlo*. Obtenido de <https://www.datasmarts.net/que-es-imagenet-y-por-que-necesitas-conocerlo/>

Discovery, S. (s.f.). Obtenido de https://www.jmp.com/es_co/statistics-knowledge-portal/what-is-correlation/correlation-coefficient.html

Github. (2020). *v7.0 - YOLOv5 SOTA Realtime Instance Segmentation*. Obtenido de <https://github.com/ultralytics/yolov5/releases>

Jiménez, S. R. (2021). *Estudio de la arquitectura YOLO para la detección de imágenes de objetos mediante deep learning*. Obtenido de <http://uvadoc.uva.es/handle/10324/45359>

Minambiente. (2019). *Gobierno unifica el código de colores para la separación de residuos en la fuente a nivel nacional*. Obtenido de <https://archivo.minambiente.gov.co/index.php/noticias-minambiente/4595-gobierno-unifica-el-codigo-de-colores-para-la-separacion-de-residuos-en-la-fuente-a-nivel->

