



Universidad Cenfotec

Maestría en software con énfasis en inteligencia artificial aplicada

Documento Final de Proyecto de Investigación Aplicada 2

Tema:

Desarrollo de un sistema de inteligencia artificial para clasificar el estado de los residuos domésticos reciclables

Elaborado por:

Jefry Baltodano Zamora

Didier Irias Méndez

Fecha: Marzo, 2024

TRIBUNAL EXAMINADOR

Este proyecto fue aprobado por el Tribunal Examinador de la carrera: **Maestría Profesional en Ingeniería del Software con énfasis en Inteligencia Artificial Aplicada**, requisito para optar por el título de grado de **Maestría**, para los estudiantes: **Baltodano Zamora Jefry Ismael y Irias Mendez Didier Ricardo**.

LUIS CARLOS NARANJO ZELEDON (FIRMA)
Firmado digitalmente por LUIS CARLOS NARANJO ZELEDON (FIRMA)
Fecha: 2024.03.01 21:13:47 -06'00'

Dr. Luis Carlos Naranjo Zeledón
Tutor

CARLOS ANDRES MORALES ALVARADO (FIRMA)
Firmado digitalmente por CARLOS ANDRES MORALES ALVARADO (FIRMA)
Fecha: 2024.03.04 20:26:25 -06'00'

M.Eng. Carlos Andrés Morales Alvarado
Lector 1

ALVARO CORDERO PEÑA (FIRMA)
Firmado digitalmente por ALVARO CORDERO PEÑA (FIRMA)
Fecha: 2024.03.05 10:58:20 -06'00'

M.Sc. Alvaro Cordero Peña
Lector 2



San José, Costa Rica, 29 de febrero de 2024

PENDING

Digital Object Identifier PENDING

Desarrollo de un sistema de inteligencia artificial para clasificar el estado de los residuos domésticos reciclables

DIDIER IRIAS MÉNDEZ¹, JEFRY BALTODANO ZAMORA¹, AND LUIS NARANJO ZELEDÓN¹¹Universidad CENFOTEC, San José, Costa Rica (e-mail: diriasm@ucenfotec.ac.cr; jbaltodanoz@ucenfotec.ac.cr; lnaranjo@ucenfotec.ac.cr)

Corresponding author: Luis Naranjo Zeledón (e-mail: lnaranjo@ucenfotec.ac.cr).

ABSTRACT La gestión eficiente de residuos sólidos sigue siendo un desafío a nivel mundial, así como en Costa Rica, a pesar de los avances en sostenibilidad. Los sistemas municipales de recolección inadecuados y la eliminación inadecuada de desechos persisten como problemas. Este proyecto responde al desafío introduciendo una solución innovadora, consistente en un modelo de Inteligencia Artificial (IA) que utiliza visión por computadora. El modelo se centra en clasificar con precisión los residuos domésticos, como plásticos, cartón, vidrio, latas y papel, para mejorar la eficiencia del reciclaje proporcionando beneficios económicos y sociales. La capacidad del modelo de IA para validar la calidad de los residuos brinda un aporte importante que permite a las empresas y los hogares tomar decisiones informadas sobre la gestión de residuos. El estudio evalúa el rendimiento y la eficacia del modelo en entornos de usuarios específicos. El entrenamiento de modelos implica un cuidadoso preprocesamiento de imágenes y transferencia de aprendizaje con la red neuronal convolucional MobileNetV2, con aumento del conjunto de datos para enriquecer su comprensión de diversos escenarios de desechos. Métricas como la matriz de confusión, F1-Score, precisión y pérdida garantizan una evaluación integral. La implementación del sistema incluye la preparación de datos, la construcción de modelos y el desarrollo de una interfaz amigable utilizando React Native para dispositivos móviles. Los resultados de la evaluación del modelo de IA, junto con los conocimientos de las pruebas controladas con voluntarios, contribuyen a comprender la aplicabilidad y la aceptación por parte de los usuarios de los modelos de IA en la gestión de residuos.

INDEX TERMS Aumento de datos, Clasificación de residuos, Gestión de residuos sólidos, MobileNetV2, Redes convolucionales, Transfer learning.

I. INTRODUCCIÓN

EN la actualidad, la gestión eficiente de residuos sólidos se ha convertido en un desafío en Costa Rica y en todo el mundo. A pesar de los avances en sostenibilidad, la falta de sistemas de recolección municipal y la inadecuada disposición de basura persisten como problemas significativos [1]. Este contexto nos impulsa a buscar soluciones innovadoras para optimizar la clasificación y gestión de residuos, con el objetivo de reducir su impacto negativo en el medio ambiente.

La inteligencia artificial (IA) se presenta como una herramienta revolucionaria que puede transformar la gestión de residuos sólidos. En este proyecto, se aborda la posibilidad de desarrollar un modelo de IA basado en visión por computadora. Este modelo permitiría la clasificación precisa de la

calidad de residuos domésticos, incluyendo plásticos, cartón, vidrio, latas y papel. La precisión de esta clasificación no sólo mejoraría la eficiencia del reciclaje, sino que también generaría beneficios económicos y sociales significativos en el futuro.

La importancia del tema se respalda en la creciente preocupación ambiental y la necesidad urgente de encontrar soluciones sostenibles para la gestión de residuos [2]. Un modelo de IA capaz de validar la calidad de residuos podría empoderar a empresas y hogares para tomar decisiones más informadas sobre su manejo de residuos, contribuyendo así a reducir el impacto ambiental negativo.

Con el propósito de lograr este objetivo, se ha desarrollado un modelo de inteligencia artificial capaz de llevar a cabo la clasificación de residuos domésticos, específicamente de

plástico, cartón, vidrio, latas y papel, con una posterior evaluación de su eficacia en situaciones reales. Se destaca que el enfoque se encuentra circunscrito a estos tipos de residuos, excluyendo otros posibles materiales.

La obtención de un conjunto de datos representativo se ha planteado como un desafío, dada la complejidad en la disponibilidad y accesibilidad de imágenes de residuos específicos. Es relevante subrayar que, debido al carácter académico de la investigación, los recursos disponibles son limitados en comparación con las implementaciones a gran escala en entornos comerciales, lo que puede influir en la calidad y cantidad de datos empleados para el entrenamiento, repercutiendo directamente en la precisión del modelo.

II. REVISIÓN DE LITERATURA

Para fomentar esta investigación, se han tomado como base informes de entidades nacionales, como es el caso del Ministerio de Salud, que describen el estado actual del reciclaje en Costa Rica señalando que durante el primer año de la pandemia (2020) los costarricenses produjeron 1.459.288 toneladas de residuos ordinarios, lo que representó un aumento del 8% en comparación con el año 2019, cuando se generaron 1.343.608 toneladas de residuos ordinarios. Sin embargo, estos mismos datos indican que solo un 6.75% de estos residuos se recupera para su posterior tratamiento, y menos del 3% se destina al proceso de reciclaje [2]. Este aumento en la generación de residuos sólidos refleja la creciente preocupación por la gestión adecuada de los desechos en tiempos de crisis sanitaria.

Para abordar esta preocupación y mejorar la gestión de residuos sólidos, se han realizado diversos análisis sistemáticos, entre ellos el estudio realizado por Abdallah et al [4]. Esta revisión sistemática destaca varias técnicas, como redes neuronales artificiales, support vector machines, análisis de regresión lineal, árboles de decisión, algoritmos genéticos y modelos híbridos, que se han empleado para crear modelos de inteligencia artificial con el fin de detectar y clasificar residuos sólidos [4]. Estas técnicas se presentan como herramientas fundamentales para mejorar la eficiencia y la precisión en la gestión de residuos sólidos, lo que contribuye significativamente a la sostenibilidad y la protección del medio ambiente. Para fortalecer aún más estas iniciativas, también se han consultado informes anuales de la Contraloría Ambiental [1] y los informes de Estado de la Nación en Desarrollo Humano Sostenible [3]."

III. METODOLOGÍA

En el marco metodológico de este estudio, se emplea un enfoque mixto, combinando elementos cuantitativos y aplicados. El enfoque cuantitativo se centra en el diseño, desarrollo y evaluación de un modelo de inteligencia artificial para mejorar el proceso de reciclaje de residuos domésticos en Costa Rica. Se recopilan y analizan datos cuantitativos, utilizando métricas de rendimiento y precisión para evaluar el desempeño del modelo. Además, se contempla una fase

exploratoria para investigar tecnologías existentes antes del desarrollo del modelo.

La investigación se basa en información pública que afecta todo el territorio costarricense, aunque el alcance directo de la investigación no se extiende a la totalidad del país. Se enfoca en evaluar la viabilidad de desarrollar un sistema de inteligencia artificial basado en visión por computadora para clasificar el estado de los desechos, específicamente plásticos, cartón, vidrio, latas y papel. El objetivo principal es determinar la posibilidad de automatizar eficientemente el proceso de reciclaje, indicando si los materiales están listos o no para ser reciclados. Si bien el tiempo limitado impide la aplicación a gran escala, los resultados servirán como cimientos para investigaciones futuras.

El estudio se llevará a cabo durante el segundo cuatrimestre de 2023, con plazos definidos para cada objetivo específico, prestando especial atención a distritos que carecen de sistemas de recolección municipal de residuos sólidos, asegurando así la aplicabilidad de los resultados para investigaciones posteriores. El enfoque metodológico combina una investigación cuantitativa para recopilar datos numéricos y medir la precisión del modelo, con un enfoque aplicado que valida su comportamiento y eficiencia en entornos específicos de usuarios.

En el proceso de investigación, se implementarán rigurosas pruebas controladas y cuestionarios estructurados como métodos principales para recopilar datos. Estos instrumentos proporcionarán una base sólida para obtener información detallada sobre las percepciones, actitudes y prácticas de los residentes involucrados en el reciclaje doméstico. Además, se emplearán técnicas estadísticas avanzadas para realizar un análisis exhaustivo de los datos recopilados, permitiendo así la identificación de patrones significativos y la obtención de resultados cuantitativos robustos.

La población objetivo para este estudio estará conformada por residentes que participan activamente en el reciclaje doméstico, específicamente en distritos que carecen de sistemas municipales de recolección de residuos. Este enfoque permitirá obtener percepciones valiosas de aquellos que enfrentan desafíos particulares relacionados con la gestión de residuos en entornos sin sistemas de recolección centralizados.

En cuanto al proceso de muestreo, se optará por un enfoque no probabilístico basado en criterios cuidadosamente definidos por los investigadores. Esta selección estratégica permitirá centrarse en individuos que representen de manera precisa las diversas perspectivas y circunstancias presentes en los distritos sin sistemas municipales de recolección, maximizando así la relevancia y aplicabilidad de los resultados obtenidos.

IV. CREACIÓN DEL SISTEMA

Esta sección, detalla la implementación del sistema de inteligencia artificial diseñado para clasificar el estado de los residuos reciclables. La implementación abarca desde la obtención y preparación del conjunto de datos hasta la construc-

ción y entrenamiento del modelo de inteligencia artificial. Además, se presenta la interfaz de usuario desarrollada para permitir la interacción intuitiva de los usuarios con el modelo en dispositivos móviles.

A. DATOS DE ENTRENAMIENTO

En el contexto de este estudio, el conjunto de datos de entrenamiento se compone de imágenes de botellas plásticas, cartón, vidrio, latas y papel, así como de un archivo que contiene información sobre la ubicación de las imágenes y sus etiquetas de estado de los elementos [6]. Se seleccionaron cuidadosamente 500 imágenes, distribuidas de manera equitativa en los cinco tipos de residuos, con 100 unidades asignadas a cada uno y subdivididas en dos categorías de estado, con 50 unidades en cada una. Estas imágenes se capturaron específicamente para el proyecto, y son esenciales para enseñar al modelo a reconocer y distinguir el estado de los residuos reciclables, según los objetivos de la investigación.

Además, se aplicó una técnica de aumento de datos con el propósito de ampliar y enriquecer el conjunto de datos. Esto implicó la aplicación de diversas transformaciones y variaciones a las imágenes originales, generando un conjunto de datos expandido que captura una mayor diversidad de situaciones y escenarios. La visualización de la cantidad de imágenes en el conjunto de datos original y el conjunto de datos aumentado se presenta en la figura número 1, que destaca la importancia de esta técnica para mejorar la robustez del modelo de inteligencia artificial.

Durante la fase de aumento de datos, se empleó la herramienta ImageDataGenerator [7] para generar diversas variaciones de las imágenes. Estas modificaciones abarcaron la rotación de las imágenes, desplazamientos tanto horizontales como verticales en un rango aleatorio del 0 al 20%, sesgos para introducir distorsiones, zoom de hasta el 20%, volteo horizontal para simular diversas orientaciones y la aplicación de la función de preprocesamiento de MobileNet V2. Esta estrategia permitió que el modelo se familiarizara con una amplia gama de situaciones, mejorando significativamente su capacidad de generalización y su habilidad para clasificar los distintos tipos de residuos con precisión.

B. CONSTRUCCIÓN DEL MODELO

1) Preprocesamiento de imágenes

El proceso de obtención de imágenes destinadas al entrenamiento del modelo de redes convolucionales fue llevado a cabo mediante un minucioso trabajo de campo, el cual fue ejecutado con gran meticulosidad por parte de los investigadores. Esta fase crucial implicó una cuidadosa selección de muestras representativas de residuos domésticos comunes que suelen encontrarse en los hogares costarricenses.

El objetivo principal de esta selección detallada fue garantizar que el modelo resultante esté debidamente capacitado y pueda desempeñarse de manera óptima en escenarios del mundo real, reflejando con precisión las complejidades y

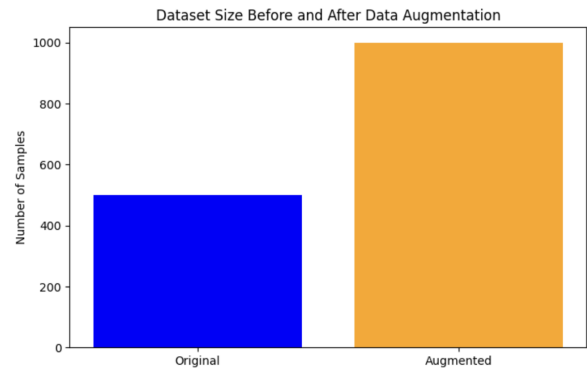


Figura 1. Comparación del conjunto de datos original y el conjunto de datos aumentado.

variaciones presentes en la gestión de residuos en entornos cotidianos.

Durante este trabajo de campo, se tomaron en cuenta diversos factores, como la diversidad de materiales presentes en los residuos domésticos, las posibles combinaciones de objetos, y las distintas condiciones ambientales a las que el modelo podría enfrentarse. Este enfoque integral asegura que el modelo de redes convolucionales esté equipado para reconocer y procesar de manera efectiva una amplia gama de situaciones, contribuyendo así a su robustez y capacidad para adaptarse a las complejidades del entorno doméstico.

De manera complementaria, se efectuó una cuidadosa selección de imágenes no domésticas para diversificar los datos de entrenamiento y evitar la sobreajustación de los mismos (Overfitting) [8]. Estas imágenes no domésticas se obtuvieron de fuentes en línea que disponen de material sin restricciones de derechos de autor.

En el proceso de preprocesamiento de imágenes, se redimensionaron todas las imágenes a una resolución de 512x512 píxeles. Luego, se realizó una fase de verificación para garantizar la calidad de los datos después de la redimensión. Una vez verificados, las imágenes se organizaron en una carpeta para su posterior uso en el modelo de redes convolucionales, manteniendo intactos los valores de color RGB en tres dimensiones.

Finalmente, se procedió a generar un archivo CSV que almacena la URL indicando la ubicación de cada imagen, junto con las respectivas categorías a las que pertenecen, como se visualiza en la Figura 2.

2) Arquitectura del modelo

El desarrollo del modelo de inteligencia artificial se basó en la utilización de la librería Keras con Tensor Flow [9], lo que se reveló como una elección conveniente para su creación. Keras proporciona una interfaz de alto nivel que simplifica el desarrollo de modelos de aprendizaje profundo y permite centrarse en el diseño y rendimiento en lugar de preocuparse por detalles técnicos.

La arquitectura del modelo se estructuró utilizando la API Sequential de Keras [17], que facilita la creación de modelos

| | name | category |
|-----|---|---------------|
| 0 | ./data/cleaned_images/can/no_acceptable/imagen... | no_acceptable |
| 1 | ./data/cleaned_images/can/no_acceptable/imagen... | no_acceptable |
| 2 | ./data/cleaned_images/can/no_acceptable/imagen... | no_acceptable |
| 3 | ./data/cleaned_images/can/no_acceptable/imagen... | no_acceptable |
| 4 | ./data/cleaned_images/can/no_acceptable/imagen... | no_acceptable |
| ... | ... | ... |
| 495 | ./data/cleaned_images/paper/no_acceptable/imag... | no_acceptable |
| 496 | ./data/cleaned_images/paper/no_acceptable/imag... | no_acceptable |
| 497 | ./data/cleaned_images/paper/no_acceptable/imag... | no_acceptable |
| 498 | ./data/cleaned_images/paper/no_acceptable/imag... | no_acceptable |
| 499 | ./data/cleaned_images/paper/no_acceptable/imag... | no_acceptable |

Figura 2. Datos preprocesados.

secuenciales. Esta estructura lineal se adaptó a la clasificación de imágenes, donde los datos fluyen en una dirección única. La utilización de Keras y la API Sequential simplificó la creación y el entrenamiento del modelo, liberando a los desarrolladores de las complejidades de los detalles de bajo nivel.

El diseño del modelo se fundamentó en una red neuronal convolucional especialmente concebida para la clasificación del estado de los desechos, distinguiendo entre "aceptable" o "no aceptable". En este proceso, cuando la etiqueta incluye la cadena "no aceptable", se le asigna el valor 0; de lo contrario, se le asigna el valor 1.

Esta transformación de etiquetas a valores numéricos resulta esencial para el entrenamiento eficiente de modelos de aprendizaje automático, dado que la mayoría de los algoritmos requieren representaciones numéricas de las etiquetas. La asignación de valores numéricos a las categorías facilita que el modelo comprenda y procese las etiquetas de manera más efectiva durante el entrenamiento. Asimismo, simplifica la interpretación de los resultados y la evaluación del rendimiento del modelo mediante métricas numéricas durante las fases de validación y prueba.

Se investigaron varias arquitecturas, y se optó por emplear transfer learning con MobileNetV2 [10] en lugar de desarrollar una arquitectura desde cero debido a limitaciones de procesamiento y tiempo. Esta estrategia de transferencia de aprendizaje aprovecha un modelo pre-entrenado como punto de partida para la clasificación del estado de los desechos.

Los beneficios de utilizar transfer learning radican en la capacidad del modelo pre-entrenado para aprender patrones complejos y representaciones útiles de grandes conjuntos de datos. MobileNetV2, al haber sido entrenado en un conjunto de datos extenso como ImageNet, ha adquirido un conocimiento generalizable sobre una amplia variedad de características visuales. Al adaptar este conocimiento a nuestra tarea de clasificación del estado de los residuos, podemos beneficiarnos de una inicialización de pesos más robusta y una convergencia más rápida durante el entrenamiento.

Además, la utilización de transfer learning permite aprovechar la capacidad de generalización del modelo pre-entrenado, lo que es particularmente valioso cuando se

dispone de recursos limitados. Esto implica que, aunque nuestra tarea puede tener requisitos específicos, el modelo pre-entrenado puede proporcionar representaciones iniciales sólidas que luego adaptamos a las peculiaridades de la clasificación de residuos.

3) Entrenamiento

El entrenamiento del modelo se realizó dividiendo los datos en un 80% para entrenamiento y un 20% para pruebas, se utilizó el optimizador "Adam" de 0.0001 y la función de pérdida de entropía cruzada categórica dispersa. El objetivo era minimizar la función de pérdida en un problema de clasificación binaria, donde "1" denota el desecho como "Aceptable" y "0" como "No Aceptable" para su respectivo reciclaje.

El entrenamiento se basó en la arquitectura de MobileNetV2 disponible en TensorFlow Hub. Esta arquitectura, preentrenada en datos de ImageNet, proporciona una base sólida para la clasificación de imágenes. La estructura del modelo se compone de la capa base MobileNetV2, seguida de una capa densa con 256 unidades y activación ReLU. Se añadió una capa de Dropout con una tasa del 50% para mitigar el sobreajuste. La capa final consiste en una capa densa con 2 unidades y una activación softmax para la clasificación final.

La clasificación de datos en las categorías se llevó a cabo siguiendo criterios establecidos, los cuales se basaron en la información recopilada del Ministerio de Salud de Costa Rica [11]. Este ministerio proporciona directrices precisas sobre la correcta separación y preparación de residuos antes de su reciclaje. Dicha información se puede observar en la figura 3.

| Materia | Aceptable | No Aceptable | No evaluado |
|----------|---|---|---|
| Plástico | <ul style="list-style-type: none"> • Seco • Ausencia de contaminantes como alimentos, aceites o productos químicos. • Limpio • No debe estar degradado, por ejemplo debido a altas temperaturas. • No debe tener materiales que afecten su reciclaje, como etiquetas adhesivas, o tapas. | <ul style="list-style-type: none"> • Mojado • Sucio • Degradado | <ul style="list-style-type: none"> • Debe tener un tamaño y forma adecuada. Trozos de plástico muy pequeños o formas complejas dificultan su reciclaje. • Engrugado |
| Cartón | <ul style="list-style-type: none"> • Sin manchas de humedad. • No debe estar contaminado con comida, aceite o grasa. • No debe estar muy dañado con rasgaduras grandes o perforaciones. • No puede estar mezclado con materiales como plástico o metales. • No debe tener revestimientos o laminados, como los envases de alimentos. | <ul style="list-style-type: none"> • Con manchas de humedad. • Contaminado. • Rasgaduras grandes o perforaciones | <ul style="list-style-type: none"> • Manchas de humedad o manchas pequeñas poco notorias. |
| Vidrio | <ul style="list-style-type: none"> • Debe estar seco. • Debe estar libre de productos químicos contaminantes. • No debe estar mezclado con otros productos como plástico o metal. • No pueden ser espejos. | <ul style="list-style-type: none"> • Mojado • Con etiquetas de papel. | <ul style="list-style-type: none"> • Gotas de líquido poco o manchas notorias. |
| Lata | <ul style="list-style-type: none"> • Debe estar seca. • Libre de contaminantes como alimentos o líquidos tóxicos. • No debe tener materiales que afecten su reciclaje, como etiquetas adhesivas. • No debe estar gravemente oxidada. | <ul style="list-style-type: none"> • Mojadas • Contaminadas • Con etiquetas. • Oxidadas | <ul style="list-style-type: none"> • Gotas de líquido poco o manchas notorias. |
| Papel | <ul style="list-style-type: none"> • Debe estar seco. • No debe tener contaminantes como comida, aceite o residuos químicos o pegajosos. | <ul style="list-style-type: none"> • Mojadas • Contaminadas | <ul style="list-style-type: none"> • Manchas de agua poco notorias. |

Figura 3. Criterios de calidad.

4) Métricas de validación

Se utilizaron las siguientes métricas para evaluar el desempeño del modelo:

- **Matriz de confusión:** La métrica de confusión desempeña un papel crucial al discernir la precisión de las predicciones del modelo. Un verdadero positivo se produce cuando el modelo acierta al predecir un resultado positivo, mientras que un falso negativo indica que el modelo erróneamente pronosticó un resultado negativo

cuando en realidad era positivo. Además, es importante considerar situaciones en las que el modelo arroja falsos positivos o falsos negativos, ya que estas instancias revelan márgenes de error en el modelo[12].

| | | Predicted | |
|--------|---|-----------|----|
| | | 1 | 0 |
| Actual | 1 | TP | FN |
| | 0 | FP | TN |

Figura 4. Matriz de confusión.

- **F1-Score:** La métrica F1-Score se basa en la matriz de confusión y se compone de dos componentes clave: precisión y recuperación [13]. La precisión se calcula dividiendo los verdaderos positivos (TP) entre la suma de verdaderos positivos y falsos positivos (FP), mientras que la recuperación se calcula dividiendo TP entre la suma de TP y falsos negativos (FN). La métrica F1-Score se obtiene mediante la fórmula:

$$F1 = 2 \cdot \frac{\text{Precisión} \times \text{Recuperación}}{\text{Precisión} + \text{Recuperación}}. \quad (1)$$

En términos generales, un valor elevado de F1 indica un modelo con una sólida capacidad para clasificar de manera equilibrada las instancias positivas y negativas, demostrando tanto precisión como recuperación efectivas.

- **Precisión y Pérdida:** Estas dos métricas desempeñan un papel fundamental en la evaluación del modelo durante su fase de entrenamiento [13]. La métrica de precisión temprana proporciona una evaluación de la exactitud de las predicciones positivas a medida que el modelo se entrena. Por otro lado, la métrica de pérdida (MSE) [14] arroja luz sobre el margen de error durante el proceso de entrenamiento. Sus fórmulas son las siguientes:

$$\text{Precisión} = \frac{TP}{TP + FP}. \quad (2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{\text{pred}} - y_{\text{real}})^2. \quad (3)$$

Estas métricas se emplean en la fase de entrenamiento para brindar una visión temprana del rendimiento del modelo. Esto les permite identificar áreas de mejora y ajustar parámetros con el objetivo de optimizar su rendimiento.

C. INTERFAZ DE USUARIO

La aplicación móvil desarrollada se presenta como una solución innovadora, con una interfaz gráfica diseñada para

ofrecer la máxima comodidad y facilidad de uso a los usuarios. El objetivo principal de esta aplicación es simplificar y optimizar la interacción de los usuarios con el modelo de inteligencia artificial, brindándoles la capacidad de clasificar la calidad de los residuos de manera intuitiva y desde la conveniencia de sus propios dispositivos móviles.

Con una interfaz gráfica amigable e intuitiva, la aplicación busca eliminar barreras de entrada, permitiendo a usuarios de diferentes niveles de experiencia participar de manera efectiva en el proceso de clasificación. La experiencia del usuario ha sido cuidadosamente considerada en cada detalle, desde la presentación de instrucciones claras hasta la implementación de elementos visuales que facilitan la comprensión y navegación.

El diseño de la interfaz gráfica de la aplicación móvil se ha realizado con una atención especial para asegurar que los elementos visuales, incluyendo botones y controles, estén organizados de manera clara y comprensible. El enfoque principal fue hacer que la aplicación sea accesible para cualquier usuario, sin importar su nivel de experiencia, proporcionando una experiencia de usuario fluida y sin complicaciones.

Cada elemento visual ha sido colocado estratégicamente, considerando la lógica del flujo de interacción y la intuición del usuario. Se ha prestado atención a la jerarquía visual, asegurando que los elementos más importantes sean prominentes y fácilmente identificables. La disposición de botones y controles busca minimizar la posibilidad de malentendidos y maximizar la eficiencia en el uso de la aplicación.

La aplicación móvil fue desarrollada utilizando React Native en su versión 0.71.8 [15], aprovechando las ventajas que esta plataforma ofrece en términos de versatilidad y rendimiento. React Native se reveló como una elección ideal para este proyecto, gracias a su capacidad para proporcionar herramientas poderosas que agilizan el proceso de desarrollo y garantizan un rendimiento óptimo.

Una de las ventajas más significativas de React Native es su capacidad de desarrollo multiplataforma. Esta característica permitió que la misma base de código se utilizara de manera eficiente en dispositivos tanto Android como iOS. La posibilidad de compartir código entre estas dos plataformas redujo significativamente tanto el tiempo de desarrollo como los costos asociados, eliminando la necesidad de crear aplicaciones separadas para cada sistema operativo. Este enfoque eficiente no solo acelera la implementación, sino que también facilita las actualizaciones y mantenimiento continuo de la aplicación.

Asimismo, la aplicación móvil no solo simplifica la clasificación de residuos, sino que también fomenta la participación activa de los usuarios en prácticas sostenibles. Al proporcionar una herramienta accesible para la identificación precisa de la calidad de los residuos reciclables, la aplicación contribuye a la conciencia ambiental y al fomento de hábitos responsables [16].

1) Pantalla de Inicio

Esta pantalla es la primera que el usuario visualiza al iniciar la aplicación, proporcionando información clave sobre su funcionamiento, como los nombres de los colaboradores y la versión de la aplicación, tal como se muestra en la Figura 5.



Figura 5. Pantalla de inicio.

2) Pantalla de captura de imágenes

La pantalla de captura de imágenes habilita al usuario para tomar fotos con la cámara incorporada en el dispositivo. Esta interfaz incluye dos botones: el icono verde permite capturar la foto, mientras que el botón "Flip Camera" posibilita el uso de la cámara frontal, como se muestra en la Figura 6.

Es fundamental que el usuario otorgue los permisos necesarios para que la aplicación pueda utilizar la cámara del dispositivo de manera efectiva. Sin estos permisos, la aplicación no podrá acceder a la cámara.



Figura 6. Pantalla de captura de imágenes.

3) Pantalla de evaluación

Después de que el usuario presiona el botón de tomar foto (icono verde), la aplicación llevará al usuario a la pantalla de visualización de resultados, en donde mostrará la foto tomada

previamente, e indicará al usuario si el desecho está listo o no para ser reciclado, y la categoría a la que pertenece, como se puede apreciar en la Figura 7.




Figura 7. Pantalla de visualización de resultados.

V. RESULTADOS

A continuación, se exponen los resultados de la evaluación del modelo de inteligencia artificial creado para valorar la calidad de residuos domésticos reciclables. Esta evaluación se desarrolló en entornos domésticos controlados mediante una prueba de campo. Además, se emplearon métricas reconocidas en el ámbito de la inteligencia artificial con el propósito de validar la capacidad del modelo para categorizar la calidad de residuos predefinidos [].

1) Evaluación del modelo

Matriz de confusión: Esta matriz de confusión nos proporciona información detallada sobre cómo nuestro modelo está manejando las clasificaciones en positivo y negativo. Podemos usar estos valores para calcular métricas como precisión, exhaustividad y F1-Score, que nos darán una comprensión más completa del rendimiento del modelo.

Verdaderos Negativos (TN): 385 - Estos son casos que nuestro modelo clasificó correctamente como negativos. En otras palabras, son instancias que realmente no pertenecen a la categoría que estamos prediciendo, y nuestro modelo las identificó correctamente.

Falsos Positivos (FP): 0 - Aquí tenemos casos que nuestro modelo clasificó como positivos, pero que en realidad son negativos. Estos son errores en los que nuestro modelo "se equivocó" al prever casos positivos que no lo eran.

Falsos Negativos (FN): 22 - Estos son casos que nuestro modelo clasificó como negativos, pero que en realidad son positivos. Es decir, el modelo no logró identificar algunos casos que deberían haber sido clasificados como positivos.

Verdaderos Positivos (TP): 393 - Estos son los casos que nuestro modelo clasificó correctamente como positivos. Son instancias que realmente pertenecen a la categoría que estamos prediciendo, y nuestro modelo las identificó correctamente.

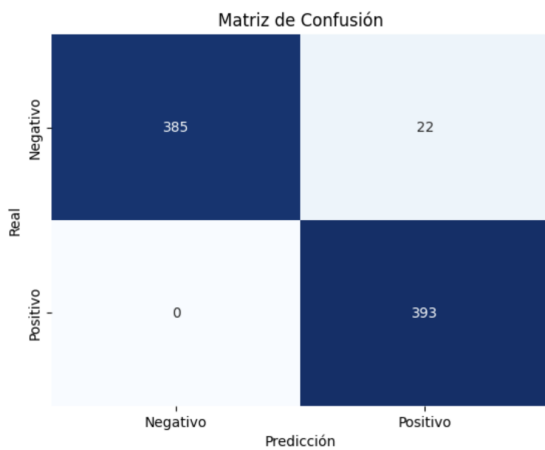


Figura 8. Matriz de confusión.

F1-Score: El F1-Score obtenido de 0.8618 en nuestro estudio representa un logro significativo en la evaluación del rendimiento del modelo propuesto. Esta métrica encapsula de manera integral la capacidad del modelo para lograr un equilibrio óptimo entre la precisión y la exhaustividad, siendo un indicador clave de su eficacia en la tarea específica abordada en el estudio.

Este valor de F1-Score resalta la habilidad del modelo para gestionar con éxito la identificación de instancias positivas, minimizando tanto los falsos positivos como los falsos negativos. Un F1-Score de 0.8618 indica un alto grado de confianza en la capacidad del modelo para realizar clasificaciones precisas y evitar omisiones importantes.

Precisión y Pérdida: Durante el proceso de entrenamiento, el modelo logró alcanzar una pérdida de 0.2058 , lo que se tradujo en una impresionante precisión del 0.9721 . No obstante, al enfrentarse a entornos del mundo real, se observaron ajustes en los resultados, manifestándose en una pérdida ligeramente superior de 0.3051 y una precisión del 0.8044 .

Este cambio en las métricas al trasladarse a situaciones prácticas puede deberse a diversos factores, como la variabilidad en los datos de entrada, condiciones ambientales no consideradas durante el entrenamiento, o la presencia de nuevas clases o patrones que no estaban presentes en el conjunto de datos de entrenamiento. Es crucial tener en cuenta estos desafíos del mundo real al evaluar el rendimiento del modelo, ya que proporcionan una comprensión más completa de su capacidad para generalizar y adaptarse a escenarios diversos.

2) Pruebas de campo

En colaboración con voluntarios, quienes participaron activamente en la evaluación del modelo, se implementó una prueba de campo utilizando un dispositivo móvil con una aplicación preinstalada. La aplicación presentaba una interfaz gráfica diseñada para interactuar de manera intuitiva con el modelo de inteligencia artificial. Se proporcionó una breve capacitación a los participantes para garantizar el uso cor-

recto de la aplicación, permitiéndoles medir la calidad de los residuos reciclables en sus hogares.

La prueba de campo abarcó diversos hogares con variaciones en la cantidad y tipo de residuos generados, proporcionando un conjunto diverso de datos para evaluar el modelo en diferentes contextos. Además, se recopiló la retroalimentación de los participantes, destacando aspectos positivos y posibles mejoras para trabajos futuros.

Los resultados obtenidos muestran que de los 17 participantes, 10 tenían hábitos de reciclaje y 7 no reciclaban.

Es usted una persona que recicla?

17 respuestas




Figura 9. Encuestas realizadas 1

El 41,2% de las pruebas se enfocaron en clasificación de botellas de plástico domésticas, el 23,5% en latas domésticas y un 11,8% tanto en cartón, papel y vidrio.

Que materiales utilizó para probar el modelo?

17 respuestas




Figura 10. Encuestas realizadas 2

Adicionalmente, 8 de los participantes evaluaron el modelo con otros tipos de desechos.

Cuál otra categoría utilizó?

8 respuestas




Figura 11. Encuestas realizadas 3

En cuanto a la clasificación de botellas de plástico, los usuarios categorizaron el rendimiento como bueno en un 77,8, y como regular en un 22,2.

Como se desempeño el modelo con la clasificación de plástico?

9 respuestas




Figura 12. Encuestas realizadas 4

En el caso de las latas, el desempeño de la aplicación fue categorizado como 'bueno' en su totalidad.

Como se desempeño el modelo con la clasificación de Latas?

8 respuestas




Figura 13. Encuestas realizadas 5

Con respecto al papel, todos los participantes categorizaron como 'bueno' el desempeño del modelo.

Como se desempeño el modelo con la clasificación de papel?

2 respuestas




Figura 14. Encuestas realizadas 6

Considerando el vidrio, los participantes respondieron que el desempeño del modelo era 'bueno'.

En el caso del cartón, todos los participantes concordaron que el desempeño del modelo era 'bueno'.

Además, todos los participantes indicaron que este tipo de aplicaciones tiene el potencial de mejorar significativamente el proceso de reciclaje.

Este estudio contribuye a la comprensión de la aplicabilidad y aceptación de modelos de inteligencia artificial en la gestión de residuos, resaltando la importancia de la participación de los usuarios. Además, este análisis proporciona

Como se desempeño el modelo con la clasificación de Vidrio?

2 respuestas




Figura 15. Encuestas realizadas 7

Como se desempeño el modelo con la clasificación de Cartón?

2 respuestas




Figura 16. Encuestas realizadas 8

una valiosa base de conocimientos que es fundamental para orientar futuras investigaciones en el ámbito de la gestión de residuos mediante inteligencia artificial. La información recopilada y los hallazgos obtenidos sirven como punto de partida para explorar nuevas vías, identificar áreas de mejora y fomentar la innovación en el diseño y la implementación de sistemas más eficientes y sostenibles.

VI. LIMITACIONES

El proyecto se encontró con desafíos sustanciales, y uno de los más destacados fue la restricción en la disponibilidad de datos representativos. Abordar esta limitación fue crucial para garantizar la solidez y eficacia de los resultados obtenidos. Como respuesta a este obstáculo, se implementó un esfuerzo minucioso destinado a la recopilación de datos, con el objetivo de constituir un conjunto lo más completo y diverso posible.

Durante este proceso, se llevó a cabo una meticulosa selec-

Considera usted que este tipo de aplicaciones puede mejorar el proceso de reciclaje?

14 respuestas




Figura 17. Encuestas realizadas 9

ción de datos para asegurar la representatividad y relevancia de la información recabada. Además, se aplicaron técnicas avanzadas de curación de datos con el propósito de mejorar la calidad del conjunto y eliminar posibles inconsistencias. Este enfoque no solo contribuyó a superar la limitación inicial de disponibilidad de datos, sino que también fortaleció la validez y confiabilidad de los resultados del proyecto.

Además de los desafíos previamente mencionados, otro aspecto crítico que enfrentó el proyecto estuvo relacionado con los sesgos inherentes a los modelos de inteligencia artificial basados en visión por computadora. Estos sesgos pueden surgir debido a la composición específica del conjunto de datos de entrenamiento, lo que podría afectar la imparcialidad y la precisión de las predicciones del modelo.

Con el objetivo de abordar este desafío, se llevó a cabo una revisión exhaustiva de los datos de entrenamiento para identificar y minimizar posibles sesgos. Esta revisión detallada no solo permitió una comprensión más profunda de las posibles influencias en el modelo, sino que también sirvió como una medida proactiva para mitigar sesgos antes de que afectaran negativamente a los resultados finales.

Otro desafío importante que surgió durante el desarrollo del proyecto fue la variabilidad en las condiciones de captura de datos. Esta variabilidad, manifestada en diferencias en la iluminación y ángulos de captura, se identificó como una limitación potencial que podría incidir en la precisión y confiabilidad del modelo de inteligencia artificial.

Para hacer frente a esta variabilidad, se llevó a cabo una investigación exhaustiva para desarrollar estrategias que incrementaran la robustez del modelo. Entre estas estrategias, se exploró activamente la implementación de técnicas de aumento de datos. Estas técnicas no solo permitieron diversificar el conjunto de datos, sino que también posibilitaron al modelo adaptarse de manera más efectiva a diversas situaciones de captura.

La adopción de técnicas de aumento de datos representó un esfuerzo proactivo para contrarrestar los desafíos vinculados a las condiciones variables de captura. Al introducir variaciones controladas en el conjunto de datos, se buscó simular una gama más amplia de escenarios posibles, permitiendo al modelo aprender patrones más robustos y generalizables. Este enfoque estratégico no solo abordó la limitación identificada, sino que también contribuyó a mejorar la capacidad del modelo para funcionar con condiciones de captura del mundo real, fortaleciendo así su aplicabilidad y eficacia en diferentes entornos.

La limitación de desplegar la aplicación en entornos reales, común en proyectos académicos, se gestionó mediante el establecimiento de servidores locales que emulaban un entorno de producción. Estos servidores se mantuvieron operativos, facilitando la realización de pruebas efectivas por parte de usuarios e investigadores. Aunque se reconoce que este enfoque no sustituye completamente un despliegue a gran escala, se considera un paso inicial para evaluar la investigación de manera práctica.

Además de los desafíos mencionados, el proyecto se vio

afectado por limitaciones de recursos computacionales, como CPU/GPU y memoria limitada. Dada la naturaleza de la tarea de clasificación de residuos mediante inteligencia artificial, se optó por utilizar transfer learning con V2 ImageNet para aprovechar los beneficios de modelos preentrenados en conjuntos de datos masivos. Esta elección se debió a las restricciones de capacidad de cómputo y memoria, comunes en entornos académicos y proyectos de investigación con recursos limitados.

VII. CONCLUSIONES

El proyecto, aunque desarrollado en un entorno académico y con limitaciones de tiempo, ha alcanzado hitos significativos que sientan las bases para futuras investigaciones y aplicaciones prácticas en el campo de la gestión de residuos sólidos. Se destacan los siguientes puntos:

- El modelo de inteligencia artificial diseñado para la clasificación de residuos ha demostrado su capacidad en un entorno controlado. Aunque no se implementó en un entorno de producción debido a las limitaciones académicas y temporales, la evaluación en entornos domésticos proporciona valiosa retroalimentación sobre su rendimiento práctico.
- La creación de una aplicación móvil con una interfaz gráfica intuitiva demuestra el potencial de la inteligencia artificial para ser accesible y utilizada por usuarios finales. La simplicidad y claridad en el diseño de la interfaz facilitan la interacción, lo que es esencial para la adopción exitosa de tecnologías por parte de los usuarios.
- A pesar de las limitaciones de recursos, la recopilación cuidadosa y la ampliación del conjunto de datos mediante técnicas de aumento son pasos fundamentales en el desarrollo de modelos de aprendizaje automático robustos. Estos datos proporcionan la base para el entrenamiento y la mejora continua del modelo.
- La prueba de campo con la participación activa de usuarios reales en la evaluación del modelo es un aspecto clave. La retroalimentación proporcionada por los participantes no solo valida la aplicabilidad del modelo en contextos del mundo real, sino que también destaca áreas de mejora y posibles ajustes.

La investigación ha trascendido la mera demostración de la viabilidad de la aplicación de la inteligencia artificial en la gestión de residuos sólidos, abriendo un camino hacia oportunidades significativas para futuras investigaciones y aplicaciones prácticas en este campo. La validación concreta de la aplicabilidad práctica de la inteligencia artificial constituye un hito clave, respaldando la idea de que estas tecnologías pueden ofrecer soluciones efectivas en entornos del mundo real. La capacidad de adaptación de los modelos a condiciones variables y escenarios cambiantes ha revelado su escalabilidad y aplicabilidad en diferentes contextos, lo que subraya la relevancia de investigaciones adicionales para explorar y expandir estas capacidades.

VIII. RECOMENDACIONES

Con base en la experiencia obtenida en el desarrollo del proyecto, se brindan las siguientes recomendaciones:

- Se recomienda implementar el modelo de IA en un entorno de producción para evaluar su rendimiento y eficacia en situaciones del mundo real. De este modo, se puede validar la viabilidad práctica y la utilidad del modelo en condiciones más diversas y desafiantes.
- Dada la importancia de un conjunto de datos robusto, se sugiere continuar con la recopilación de datos y la expansión del conjunto de datos utilizado para entrenar el modelo. Esto contribuirá a mejorar la capacidad de generalización del modelo, asegurando un rendimiento óptimo en diversas situaciones y escenarios.
- Considerar la inclusión de una característica de retroalimentación en la aplicación móvil para permitir a los usuarios proporcionar comentarios sobre las clasificaciones, contribuyendo así a una mejora continua y ajustes en tiempo real.
- Establecer colaboraciones con entidades gubernamentales y organizaciones relacionadas con la gestión de residuos para asegurar la alineación con regulaciones existentes y futuras.

IX. TRABAJOS FUTUROS

Como parte de futuras líneas de investigación, se sugieren los siguientes puntos:

- Optimización del modelo para escenarios específicos, como entornos industriales o comerciales. La personalización del modelo para adaptarse a necesidades particulares puede maximizar su eficacia y aceptación en diversos sectores.
- Investigar estrategias para optimizar el rendimiento del modelo en tiempo real, especialmente en entornos dinámicos donde la clasificación de residuos debe realizarse de manera rápida y precisa.
- Analizar la eficiencia energética del modelo, buscando maneras de optimizar el consumo de recursos durante la clasificación de residuos. Esto puede contribuir a la sostenibilidad general del sistema y reducir su impacto ambiental.
- Investigar sistemas de gestión de residuos existentes y la forma en como integrar el modelo en estos sistemas para facilitar una transición suave hacia la adopción de tecnologías de inteligencia artificial en el ámbito de la gestión de residuos sólidos.

REFERENCES

- [1] Contraloría Ambiental [contraloriaambiental]. (2022). Residuos ordinarios notificados voluntariamente a SIPRECCA (Gestores ambientales municipales y operadores de rellenos sanitarios). Informe Anual. https://www.contraloriaambiental.go.cr/doc/doc_1677506137.pdf
- [2] Especialistas se reúnen para analizar situación actual del tema en residuos. (2022, May 17). <https://www.ministeriodesalud.go.cr/index.php/prensa/52-noticias-2022/1312-especialistas-se-reunen-para-analizar-situacion-actual-del-tema-en-residuos>
- [3] Soto Córdoba, S. C. (2019). Gestión de los residuos sólidos en Costa Rica. https://repositorio.conare.ac.cr/bitstream/handle/20.500.12337/7818/Soto_%202019_Gestion_Residuos.pdf?sequence=1&isAllowed=y
- [4] Abdallah, M., Abu Talib, M., Feroz, S., Nasir, Q., Abdalla, H., & Mahfood, B. (2020). Artificial intelligence applications in solid waste management: A systematic research review. *Waste Management*, 112, 258-270. <https://doi.org/10.1016/j.wasman.2020.04.057>
- [5] Figshare. (2023). Trash State Classification Dataset. Recuperado de https://figshare.com/articles/dataset/Trash_state_classification_/24624564/
- [6] TensorFlow. (2023). ImageDataGenerator Documentation. Recuperado de https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator
- [7] Amazon Web Services. (2023). What is Overfitting? Recuperado de <https://aws.amazon.com/es/what-is/overfitting/>
- [8] TensorFlow. (2023). Keras API Documentation. Recuperado de <https://www.tensorflow.org/guide/keras>
- [9] TensorFlow. (2023). MobileNetV2 Documentation. Recuperado de https://www.tensorflow.org/api_docs/python/tf/keras/applications/mobilenet_v2/MobileNetV2
- [10] Ministerio de Salud de Costa Rica. (2023). Reciclaje de Desechos Sólidos. Recuperado de <https://www.ministeriodesalud.go.cr/index.php/biblioteca-de-archivos-left/documentos-ministerio-de-salud/tecnologia-ciencia/inventario-de-tecnologias-en-girs/valorizacion-girs-tecnologia-ciencia/reciclaje-valORIZACIONGIRS-tecnologia-ciencia/1545-reciclaje-de-desechos-solidos/file>
- [11] ShivamPandey-Msft. (2023, March 8). Resultados de los modelos de aprendizaje automático - Finance | Dynamics 365. Microsoft Learn. <https://learn.microsoft.com/es-es/dynamics365/finance/finance-insights/confusion-matrix>
- [12] Amazon Web Services. (n.d.). Image Metrics in Amazon Rekognition Custom Labels. <https://docs.aws.amazon.com/rekognition/latest/custom-labels-dg/im-metrics-use.html>
- [13] React Native. (0.71). Getting Started. <https://reactnative.dev/docs/0.71/getting-started>
- [14] Dirias, A. (n.d.). RecyCam-UI. <https://github.com/dirias/RecyCam-UI>
- [15] Dirias, A. (n.d.). RecyCam-API. <https://github.com/dirias/RecyCam-API>
- [16] Stanford University. (2023). Artificial Intelligence Index Report. https://aiindex.stanford.edu/wp-content/uploads/2023/04/HAI_AI-Index-Report_2023.pdf

...