

Ecología: inteligencia artificial para el cuidado del medio ambiente, un prototipo de clasificación de residuos sólidos en el punto de origen.

Ecology: artificial intelligence for environmental care, a prototype for classifying solid waste at the point of origin

Michael Pardo Burbano



Víctor Pinto Rodríguez



Julián Muñoz Ordóñez



Corporación Universitaria Comfacauca, Colombia

OPEN ACCESS

Recibido: 22/09/2021

Aceptado: 22/10/2021

Publicado: 13/12/2021

Correspondencia de autores:

jfmunoz@unicomfacauca.edu.co



Copyright 2020
by Investigación e
Innovación en Ingenierías

Resumen

Objetivo: Construir el primer prototipo de punto ecológico inteligente que asista al usuario en la correcta clasificación de residuos sólidos en punto de origen utilizando Deep Learning, aportando nuevas tecnologías que estén enfocadas en mitigar el impacto climático causado por la mala gestión de los residuos sólidos. **Metodología:** para el desarrollo de la investigación se implementó la metodología LEAN de Toyota y la herramienta Solid Works para diseñar un prototipo acorde a las necesidades de un punto ecológico, incluyendo un análisis estructural y pruebas de peso con el fin de medir su capacidad de resistencia. La metodología ágil aplicada para el desarrollo de la inteligencia artificial y la conformación del conjunto de imágenes fue programación extrema.

Resultados y conclusiones: se construye un conjunto de datos de tres clases acorde a la resolución 2184 de 2019 de Colombia, que contiene un total de 400 muestras tomadas desde el prototipo. El modelo de clasificación utilizando una arquitectura de bajo coste computacional: MobileNet obtuvo una precisión del 97.91% en la validación y un coeficiente kappa de 0.95. El modelo entrenado se ejecuta sobre una Raspberry Pi con el fin de minimizar costos de producción. La investigación presenta una prueba de aceptación y usabilidad del prototipo.

Palabras clave: Aprendizaje profundo, Redes neuronales convolucionales, Clasificación de residuos sólidos, Punto ecológico inteligente, Inteligencia artificial.

Abstract

Objective: To build the first prototype of a smart ecological point that assists the user in the correct classification of solid waste at the point of origin using Deep Learning, providing new technologies focused on mitigating climate impact caused by poor solid waste management. **Methodology:** to conduct the research, the Toyota LEAN methodology and the Solid Works tool were implemented to design a prototype according to the needs of an ecological point, including a structural analysis and weight tests in order to measure its resistance capacity. The agile methodology applied for the development of the artificial intelligence and the conformation of the set of images was extreme programming. **Results and conclusions:** a dataset of three classes was built according to resolution 2184 of 2019 of Colombia, containing a total of 400 samples taken from the prototype. The sorting model using a low computational cost architecture - MobileNet - obtained an accuracy of 97.91% in the validation and a kappa coefficient of 0.95. The trained model runs on a Raspberry Pi in order to minimize production costs. The research presents a test of acceptance and usability of the prototype.

Keywords: Deep learning, Convolutional neural networks, Classification of solid waste, Smart ecological point for recycling collection, Artificial intelligence.

Como citar (IEEE): M. Pardo-Burbano, V. Pinto-Rodríguez, y J. Muñoz-Ordóñez. "Ecología: Inteligencia Artificial para el cuidado del medio ambiente, prototipo de clasificación de residuos sólidos en punto de origen". Investigación e Innovación en Ingenierías, vol. 9, n°3, 46-56, 2021. DOI: <https://doi.org/10.17081/invinno.9.3.5312>

Introducción

Los seres humanos generamos gases de efecto invernadero todo el tiempo con nuestras actividades cotidianas, el 3% del total de los gases de efecto invernadero, corresponden a los residuos en los rellenos sanitarios y aguas residuales, a pesar de que el número parece pequeño, solo se habla del gas metano y no se tiene en cuenta la contaminación que genera el tratamiento de estos residuos. La explotación de recursos naturales que surgen de una economía lineal en la que muchos residuos sólidos potencialmente reutilizables terminan en rellenos sanitarios enterrados, se suman al incremento de los gases de efecto invernadero potencializando el cambio climático.

En el 2016, Latinoamérica y la región Caribe, generaron 231 millones de toneladas de residuos [1], los países que más residuos sólidos generan en Latinoamérica son Brasil, (79.8 millones al año) [2], México (53.1 millones al año) [3], Argentina (17.9 millones al año) [1] y Colombia (11.1 millones al año) [4]; de estas cantidades de residuos, gran parte pueden ser aprovechadas implementando procesos de separación de residuos sólidos en la fuente, debido a que, si se hace en lugar de disposición final, estos residuos sólidos se contaminan unos a otros y al realizarse manualmente pueden generar enfermedades a los trabajadores [5]. Sin embargo, la adecuada separación de residuos sólidos es algo que genera confusión a la población mundial y varía de acuerdo con los tipos de residuos sólidos que se puedan aprovechar en los diferentes lugares del mundo, por lo que, para lograr una adecuada reutilización, es importante utilizar tecnologías que ayuden a clasificar correctamente los residuos sólidos; de esta forma, diferentes autores han trabajado en clasificadores de residuos sólidos basados en inteligencia artificial, desde diferentes enfoques. Para lograr una adecuada reutilización, es importante utilizar tecnologías que ayuden a clasificar correctamente los residuos sólidos junto a una correcta educación en el manejo de los desechos, a continuación, se describen algunos de ellos.

Diversas investigaciones han planteado soluciones entorno al problema de la inadecuada clasificación de residuos sólidos, a saber: desarrollo de un algoritmo clasificador de residuos sólidos entre biodegradable – no biodegradable basado en redes neuronales profundas (Deep Learning) [6]; un framework DNN-TC para clasificar residuos sólidos (orgánico, inorgánico, médico) con una precisión de 98% [7]; clasificación de residuos sólidos usando un AutoEncoder que combina 3 modelos de red neuronal, logrando una precisión del 99.95% al clasificar entre orgánico y reciclable [8]; prototipo clasificador de residuos sólidos domésticos por medio de visión por computadora que clasifica entre las cuatro clases estandarizadas en Shanghai [9], el prototipo logra una precisión del 94%; por otra parte, la creación de un prototipo que identifica entre vidrio y metal para las bolsas que llegan a los camiones recolectores de basuras fue implementado en [10], a partir de varios sensores y redes neuronales convolucionales logrando un 98% de precisión.

Existe un conjunto de datos bastante utilizado llamado TrashNet, está compuesto por 6 clases y fue creado por Yang et, al. [11], el resultado de la investigación logra entrenar el conjunto de datos con una máquina de soporte vectorial con un resultado del 63% de precisión, otros conjuntos de datos y algoritmos clasificadores de residuos sólidos han sido enfocados en los residuos de construcción: diseño y descripción de una red neuronal convolucional para identificar 7 tipos de muestras de materiales de construcción y demolición a través del uso de imágenes digitales, este desarrollo logra una precisión del 94% [9]. Más prototipos para clasificar residuos sólidos que buscan crear incentivos a sus usuarios han sido creados, por ejemplo, un punto de almacenamiento de residuos sólidos provenientes de un cajero automático que recarga la tarjeta de los usuarios con bonos dependiendo del uso adecuado fue implementado en [10], este prototipo resuelve el problema de clasificación utilizando una arquitectura de red neuronal convolucional AlexNet logrando una precisión del 96%.


El estado del arte presentado en esta sección permite inferir que en la actualidad diversos proyectos están enfocados a la clasificación de residuos sólidos de diferentes tipos, en el presente artículo, se da a conocer un prototipo de clasificador de residuos sólidos ajustado al modelo de recolección de residuos sólidos en Colombia y adicionalmente, se proyecta a la recolección en punto de origen como los hogares, centros comerciales, universidades y de más recintos públicos y privados, lo cual es sin duda alguna el factor innovador del prototipo.

Metodología

La construcción del prototipo es el primer paso para el desarrollo de la investigación su finalidad es la conformación del conjunto de datos utilizando la bandeja de disposición de residuos sólidos (ver Figura 5). El conjunto de imágenes estará compuesto de 3 clases ajustadas a las normativas colombianas de reciclaje. El proceso de construcción del prototipo tiene una mejora continua con el fin de generar valor y los principios de fabricación de la metodología LEAN.

El diseño del prototipo se divide en tres partes: Estructura del prototipo, subsistema mecánico y el subsistema electrónico: la estructura del prototipo tuvo como objetivo facilitar el proceso de construcción, llevando a cabo un diseño 3D de este subsistema, teniendo en cuenta piezas comerciales y haciendo uso del software de diseño asistido por computador (CAD) SolidWorks. Con este proceso se obtuvo una idea de la estética del prototipo, así como, diferentes factores asociados a la resistencia mecánica, con el diseño CAD se busca primero reducir la curva de aprendizaje del usuario, se mantuvo la forma de los puntos ecológicos actuales (ver Figura 1); segundo, un tamaño adecuado al reducido espacio en los hogares modernos y por último, se tuvo en cuenta el código de colores que plantea la resolución 2184 del 2019 para los contenedores de los puntos ecológicos (ver Figura 2).

Figura 1. Código de colores unificado para la clasificación de residuos sólidos según normativa colombiana.



Fuente: propia.

Figura 2. Clasificación de residuos sólidos según la Resolución 2184 de 2019.



Fuente: propia

La estructura del prototipo es el componente más susceptible a fallos mecánicos; por tal motivo se hizo uso de la herramienta SolidWorks Simulation para identificar los diferentes esfuerzos en el prototipo: el factor de seguridad y la deformación de las piezas. Lo anterior aplicando una carga de 147N, es decir, aproximadamente 15 Kg; este peso fue estimado teniendo en cuenta que el tamaño de los cestos de residuos sólidos no admite una capacidad mayor a 5 Kg de desechos. La construcción del prototipo se llevó a cabo haciendo uso de la metodología LEAN, especialmente el concepto de las 5S: organizar, ordenar, limpiar, estandarizar y mantener; y el método de la mejora continua con un enfoque en la reducción del desperdicio y la generación de valor.

Inicialmente se llevó a cabo el despiece del diseño en Solid Works con el fin de estimar la cantidad de materia prima requerida, por lo que se procedió a la construcción de la estructura. Una vez terminado el cuerpo del prototipo, se llevó a cabo un diagrama de componentes electrónicos y electromecánicos basándose en la funcionalidad requerida. Por otra parte, se tiene el modelo de red neuronal convolucional (CNN) desarrollado bajo los principios de la metodología XP, utilizando algunas características de las fases como: planeación, iteraciones, programación en pareja, reuniones diarias, diseños simples, recodificación, ritmo sostenido, correcciones de errores y pruebas de aceptación.


Con el fin de entrenar un modelo de CNN que se ajuste a la solución requerida, es decir la resolución 2184 del 2019, se creó un conjunto de datos de tres clases con imágenes tomadas desde la cámara del prototipo construido, este conjunto de datos fue reprocesado y entrenado para crear un clasificador ajustado al prototipo; a continuación, se detalla el proceso: el conjunto de imágenes creado tiene 3 clases y 400 registros por clase. Las imágenes fueron capturadas desde la Raspberry Pi 3 por medio de una cámara con una resolución de 640 x 480 píxeles. Las muestras se tomaron con diferentes condiciones de iluminación, dejando el residuo sólido sobre la superficie de disposición del punto ecológico inteligente.

Por otra parte, las 3 clases corresponden a residuos que se deben clasificar en: inorgánicos aprovechables, orgánicos aprovechables y residuos sólidos no aprovechables como se aprecia en la Figura 3, además, es importante resaltar que las muestras que componen el conjunto de datos fueron tomadas a partir de residuos sólidos desechados comúnmente en los hogares colombianos, en esta investigación se establece como un punto principal de generación de residuos los hogares familiares (puntos de origen).

Una descripción de los diferentes objetos que conforman las tres clases principales del conjunto de datos son: dentro de los residuos sólidos inorgánicos aprovechables se tiene: plástico, cartón, metal, electrónico, papel y vidrio; en los orgánicos aprovechables están las cáscaras de frutas, frutas en buen estado, residuos de comida, residuos de frutas, combinaciones de frutas y vegetales; finalmente, en inorgánicos no aprovechables se encuentran: envolturas de comida, servilletas utilizadas, máscaras quirúrgicas, residuos peligrosos y tóxicos.

La partición del conjunto de datos consistió en 70% de las imágenes para entrenamiento, 20% para validación y 10% para pruebas. Posteriormente, las imágenes fueron redimensionadas en 16 tamaños, desde 32x32 hasta 512x512 con saltos de 32px; adicionalmente, previo al entrenamiento se utilizó la función ImageDataGenerator de Tensorflow, que llevó a cabo el procesamiento de imágenes para aumentar el conjunto de datos. El proceso de entrenamiento fue realizado utilizando diferentes arquitecturas de redes neuronales convolucionales disponibles en TensorFlow/Keras. Los resultados son consignados en la Tabla 1 y se ordenan con respecto al tamaño en disco, siendo MobileNetV2, la arquitectura de menor peso en Bytes. Los hiperparámetros generales del entrenamiento de las redes neuronales son: 500 épocas, un tamaño de lote de 16, una tasa de aprendizaje de 0.001 y el optimizador del gradiente descendente Adam.

Figura 3. Conjunto de datos de tres clases para la clasificación de residuos sólidos.



Fuente: propia.

Tabla 1. Experimentación de modelos de red neuronal con imágenes redimensionadas.

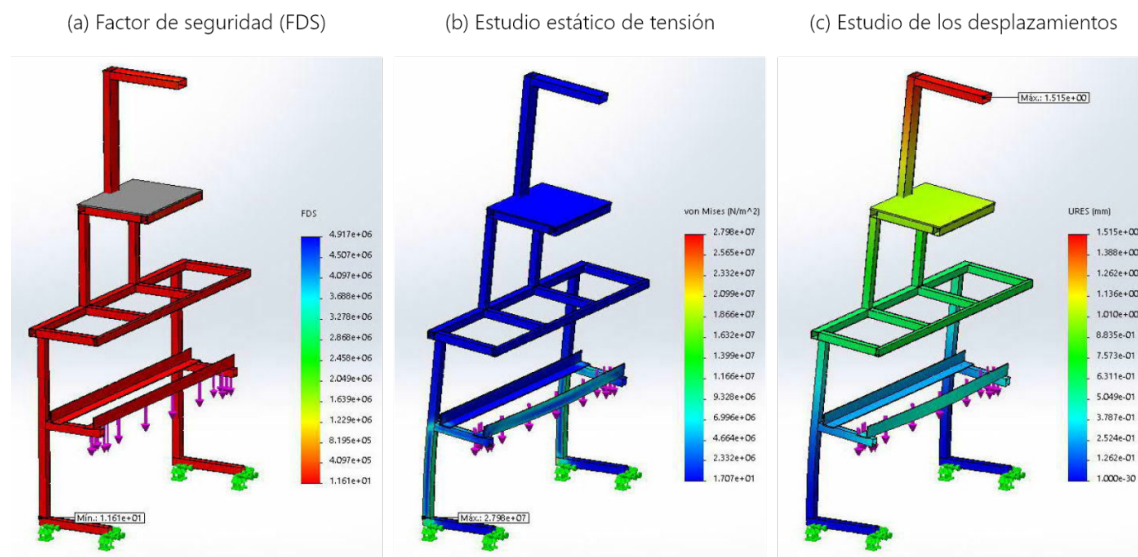
Arquitectura CNN	Precisión en la validación (%)	
	Imágenes de 64 x 64	Imágenes de 128 x 128
MobileNetV2	87.50	92.50
MobileNet	93.75	97.91
NASNetMobile	92.08	92.08
EfficientNetB0	90.83	99.16
EfficientNetB1	86.25	98.75
DenseNet121	97.08	97.91
EfficientNetB2	81.25	97.91
EfficientNetB3	83.74	99.58
DenseNet169	94.58	97.50
EfficientNetB4	87.50	
DenseNet201	94.58	
ResNet50	91.66	

Fuente: propia

Resultados

En la Figura 4, se puede apreciar el análisis estático de la estructura del prototipo cuando se aplica un peso de 15Kg, cabe aclarar que el estudio estático considera que los objetos de estudio se encuentran en reposo. En este análisis se encontraron los siguientes resultados: La tensión máxima de Von Mises en la estructura (Figura 4-a), aplicando un peso de 15Kg en los contenedores es de 27.98 MPa; teniendo en cuenta que el límite elástico de los tubos de hierro comerciales es superior a 200MPa, se infiere que la estructura soportará adecuadamente el uso. El factor de seguridad (FDS) según el criterio de tensión de Von Mises es de 11.61 (Figura 4-b), teniendo en cuenta que el valor de este factor cuando la estructura comienza a fallar es igual o menor a 1 [12], se infiere que la estructura es segura e incluso el diseño puede ser modificado utilizando tubos de menor calibre con el fin de reducir costos.

Figura 4. Simulaciones de la estructura del prototipo aplicando una carga de 15Kg. (a) Estudio de tensión de Von Mises; (b) Estudio de desplazamientos de la estructura; (c) Factor de Seguridad (FDS).



Fuente: propia

Después de refinar el diseño inicial, se llevó a cabo el proceso de construcción que consistió en cortar, unir, pulir por medio de soldadura y pintar las diferentes piezas de la estructura metálica; para este proceso se tuvo en cuenta el despiece. Finalmente, en la Figura 5 se puede apreciar el resultado final y como el prototipo se puede desarmar en tres partes: etiquetas 1, 3 y 5 de la Figura 5, unidas por tornillos para facilitar su transporte; las uniones se pueden apreciar en las etiquetas 2 y 4 de la Figura 5.

Para la integración de los componentes electromecánicos, se realizó un diagrama mostrado en la Figura 6, donde se representan los diferentes elementos requeridos de acuerdo con su funcionalidad. Se puede dividir en cuatro subsistemas, subsistema de control compuesto por un Arduino Uno, subsistema de apertura compuesto por tres motores y dos puentes H, el subsistema de reconocimiento compuesto por un sensor de proximidad, una cámara Web y el computador de placa reducida Raspberry Pi 3, finalizando con un subsistema de iluminación compuesto por una lámpara y un sensor de luz (LDR).

En el entrenamiento de las redes neuronales convolucionales se obtuvieron 9 modelos de clasificación de residuos sólidos que fueron probados con el conjunto correspondiente a las 120 imágenes de prueba establecidas previamente, la sintonización de los parámetros fue realizada basándose en los valores reportados en investigaciones con resultados de entrenamientos exitosos. Utilizando métricas de evaluación como la matriz de confusión, la precisión general y el coeficiente Kappa se realiza la validación de los modelos. El modelo con las métricas más altas se presenta en la Tabla 2.


Figura 5. Resultado final de la construcción del prototipo.



Fuente: propia

El resultado más preciso obtenido en este proceso de entrenamiento fue el diseñado para imágenes con un tamaño de 192x192 (ver Tabla 2), logrando una precisión de 99.58% en la etapa de validación (20% del conjunto de datos), este modelo también fue probado con el conjunto de prueba correspondiente al 10% del conjunto de datos inicial obteniendo una precisión de 98.33% y un coeficiente kappa de 0.97, sin embargo, al ejecutar este clasificador en la Raspberry Pi (pruebas del prototipo funcionando en un entorno real), presentó una baja precisión, por tal motivo, se procedió a ejecutar el segundo mejor clasificador, es decir, el entrenado con imágenes de 128x128 (Tabla 3), el cual logró una precisión del 97.91% en la validación y una precisión general del 96.66% con un coeficiente kappa de 0.95 en las pruebas con el 10% del conjunto de datos; al ejecutar este clasificador en la Raspberry Pi, los resultados fueron óptimos, mostrando un alto recuerdo y precisión ante la presencia de nuevas muestras en un ambiente de ejecución real.

Figura 6. Diagrama de componentes electrónicos



Fuente: propia

El anterior comportamiento, tiene su explicación basándose en que el primer modelo (Tabla 3) tiene un sobreajuste sobre el conjunto de datos y que posiblemente este conjunto de datos aún no es completamente

representativo para todos los residuos sólidos que se manejan en un ambiente real, por tales motivos, se infiere que los resultados obtenidos en los clasificadores a partir de las métricas de evaluación como el coeficiente Kappa, matriz de confusión, precisión y recuerdo, no corresponden completamente a un panorama real de cómo se comportará el clasificador en condiciones operativas.

Tabla 2. Matriz de confusión para el modelo de CNN entrenado con el conjunto de datos de tres clases: imágenes con tamaño 192x192.

Predicción Real \	Aprovechable	No Aprovechable	Orgánico	Total, clasificadas	Precisión
Aprovechable	40	2	0	42	95.23
NoAprovechable	0	38	0	38	100
Orgánico	0	0	40	40	100
Total, reales	40	40	40		
Exhaustividad	100	95	100		

Fuente: propia.

Tabla 3. Matriz de confusión para el modelo de CNN entrenado con el conjunto de datos de tres clases: imágenes con tamaño 128x128.

Predicción Real \	Aprovechable	No Aprovechable	Orgánico	Total, clasificadas	Precisión
Aprovechable	38	2	0	40	95
NoAprovechable	2	38	0	40	95
Orgánico	0	0	40	40	100
Total, reales	40	40	40		
Exhaustividad	95	95	100		

Fuente: propia.

Una comparación de la mejor arquitectura de red neuronal convolucional (ver Tabla 3) contra algoritmos clásicos de clasificación de aprendizaje máquina: Gradiente descendente estocástico (SGD), Perceptrón multicapa (MLP), Bosques aleatorios (RF), Máquinas de soporte vectorial (SVM) y Árboles de decisión (DT) fue realizada con el objetivo de verificar si los resultados mejoran el proceso de clasificación de residuos sólidos tratando de reducir el coste computacional, los resultados de la precisión general y el coeficiente Kappa se presentan en la Tabla 4.

Tabla 4. Comparaciones de algoritmos clásicos de aprendizaje máquina contra la mejor arquitectura de red neuronal convolucional (CNN) implementada en Ecología.

Clasificador	Precisión general (%)	Kappa
SGD	92.5	0.89
MLP	95.0	0.93
RF	86.7	0.80
SVM	95.0	0.93
DT	82.5	0.74
CNN	96.6	0.95

Fuente: propia

La Tabla 4, presenta en negrilla el algoritmo con las mejores métricas alcanzadas, la red neuronal convolucional demuestra ser el algoritmo con tasas superiores en las dos métricas evaluadas. Finalmente, se realizó una encuesta a 40 personas con la finalidad de evaluar la usabilidad de la tarea relacionada

con ubicar el residuo sólido en la bandeja de reconocimiento y posteriormente la tarea de depositarlo en el cesto correspondiente una vez se abra la tapa; el principal objetivo de la encuesta es buscar la retroalimentación que permita mejorar el sistema de interacción usuario/prototipo, los resultados de la encuesta están disponibles en el siguiente enlace: <https://n9.cl/lesu9>. La encuesta arroja que al 97.5% de los usuarios les queda claro el sitio donde se debe colocar el residuo sólido para que la cámara capture la imagen; el 97.4% de los encuestados esperarían a que la tapa del cesto abriera para depositar el residuo sólido y el 92.5% aceptan el tiempo que tarda la tapa del cesto en estar abierta. De la encuesta realizada, se encontró que es un prototipo intuitivo, de fácil uso y que los tiempos de espera son adecuados, sin embargo, se identificó que los usuarios mayores de 60 años fueron directamente a los cestos de reciclaje ignorando la bandeja de reconocimiento; por tal motivo, se debe en futuras versiones del prototipo incluir señalizaciones o símbolos que permitan el uso del prototipo de una manera adecuada.

Conclusiones

La construcción de la estructura del prototipo fue realizada utilizando los principios de la metodología LEAN, lo que permitió la simplificación de los procesos asociados a la manufactura, reduciendo el desperdicio de tiempo, trabajo y dinero; garantizando un proceso más ordenado, estandarizado y basado en la mejora continua.

Se realizó una prueba de simulación basada en el método de elementos finitos con el Software CAD SolidWorks, se logró identificar que la estructura en condiciones ideales soporta hasta 217Kg de residuos sólidos. Una vez construida, se llevaron a cabo pruebas con 20Kg que es el peso máximo estimado que soporta el prototipo en condiciones normales de operación; los resultados fueron satisfactorios ya que el centro de masa no se vio comprometido, es decir, la estructura además de resistir sin sufrir deformación plástica conservó el equilibrio.

Se construye un conjunto de datos ajustado al prototipo, compuesto por imágenes tomadas directamente desde la plataforma de reconocimiento y clasificadas en tres clases (usable, no usable y orgánico) el cual está disponible en Zenodo para futuras investigaciones [15], además, el conjunto de datos está alineado con la Resolución 2184 de 2019 relacionada con procesos de reciclaje en Colombia.

El conjunto de datos construido fue entrenado utilizando diversas arquitecturas de redes neuronales convolucionales profundas y validados a través de métricas de evaluación como la matriz de confusión, precisión general y coeficiente Kappa. El mejor resultado con imágenes de dimensión 128x128 alcanzó una precisión del 96.66% y un coeficiente Kappa de 0.95 utilizando una arquitectura MobileNet, esta arquitectura facilitó la implementación del sistema final sobre una Raspberry Pi 3.

Una encuesta de usabilidad del prototipo fue realizada a 40 personas, los resultados demuestran que el punto ecológico inteligente (EcologIA) tiene un grado alto de aceptación y usabilidad, debido a que el 97.4% de los encuestados toleran el tiempo de respuesta del prototipo, el 97.5% tienen claro dónde ubicar los residuos sólidos y el 92.5% aceptan el tiempo en que la tapa de los cestos permanece abierta para el depósito del residuo.

Teniendo en cuenta los resultados de las métricas de evaluación de los modelos de red neuronal, se procedió a seleccionar los mejores clasificadores para ser ejecutados en el prototipo funcional, se logra destacar un factor crítico que está relacionado con los tiempos de ejecución sobre la Raspberry Pi; diferentes experimentos demostraron que la diferencia en predecir con un clasificador diseñado para imágenes de

dimensión 32x32 y un clasificador para 288x288 solo es de 0.53 segundos. Por lo contrario, el tamaño de los modelos de red neuronal si afecta el tiempo; la duración que tarda en predecir con un clasificador entrenado a partir del MobileNet es 7 veces menor con respecto a un modelo entrenado con EfficientNetB3; es decir, la Raspberry Pi 3 tarda 0.5 segundos en predecir una imagen con MobileNet y 3.68 segundos en predecir una similar con EfficientNetB3, por lo tanto, los autores de esta investigación como trabajo a futuro recomiendan explorar redes neuronales convolucionales con arquitecturas similares a MobileNet y así lograr una mayor eficiencia en los procesos de clasificación, además, se implementarán nuevas arquitecturas convolucionales con el objetivo de maximizar el rendimiento del proceso de clasificación siempre teniendo presente el bajo coste computacional.

Agradecimientos

Los autores agradecen a la Corporación Universitaria Comfacauca – Unicomfacauca en especial al grupo de investigación en Computación e Informática Aplicada – MIND y a la V Convocatoria de Prototipado realizada por la oficina de emprendimiento de Unicomfacauca por el apoyo en la realización del proyecto.

Referencias bibliográficas

1. S. Kaza, L. Yao, P. Bhada-Tata y F. Van Woerden, "What a waste 2.0, a global snapshot of solid waste management to 2050," World Bank Group, Washington, DC, 2018.
2. ABRELPE, "Panorama dos resíduos sólidos no Brasil 2015," São Paulo, 2015.
3. SEMARNAT, "Informe de la situación del medio ambiente en México," Semarnat, México, 2016.
4. Superservicios, "Informe de disposición final de residuos sólidos; informe nacional - 2018," Bogotá, 2019.
5. H. N. Guo, S. B. Wu, Y. J. Tian, J. Zhang y H. T. Liu, "Application of machine learning methods for the prediction of organic solid waste treatment and recycling processes: A review," *Bioresource Technology*, vol. 319, 2020.
6. S. Sudha, M. Vidhyalakshmi, K. Pavithra, K. Sangeetha y V. Swaathi, "An automatic classification method for environment: Friendly waste segregation using deep learning," *IEEE TIAR*, pp. 65 - 70, 2016.
7. A. H. Vo, L. H. Son, M. T. Vo y T. A. Le, "A novel framework for trash classification using deep transfer learning," *IEEE Access*, Volume 7, pp. 178631 - 178639, 2019.
8. M. Toğaçar, B. Ergen y Z. Cömert, "Waste classification using autoencoder network with integrated feature selection method in convolutional neural network models," *Measurement*, 2019.
9. Z. Song, Y. Chen, Z. Yang y H. Gong, "Computer vision based two-stage waste recognition-retrieval algorithm for waste classification," *Resources, Conservation & Recycling*, vol. 169, nº 105543, 2021.
10. O. I. Funch, R. Marhaug, S. Kohtala y M. Steinert, "Detecting glass and metal in consumer trash bags during waste collection using convolutional neural networks," *Waste management*, vol. 119, pp. 30 - 38, 2021.
11. M. Yang y G. Thung, "Classification of trash for recyclability status," 2016.
12. P. Davis, F. Aziz, M. T. Newaz, W. Sher y L. Simon, "The classification of construction waste material using a deep convolutional neural network," *Automation in construction*, vol. 122, nº 103481, 2021.

13. S. H. Sunny, D. R. Dipta, S. Hossain, H. M. Faruque y E. Hossain, "Design of a convolutional neural network based smart waste disposal system," IEEE - ICASERT, 2019.
14. SolidWorks, "Comprobación del factor de seguridad," 2020. [En línea]. Available: http://help.solidworks.com/2020/spanish/solidworks/cworks/c_factor_of_safety_check.htm.
15. V. Pinto-Rodríguez, M. Pardo-Burbano y J. Muñoz-Ordóñez, Ecología Net, Zenodo, 2020.
16. CJSCANECAS, "CJSCANECAS," [En línea]. Available: <https://www.catorce6.com/actualidad-ambiental/legales/19004-el-1-de-enero-entra-en-vigencia-el-nuevo-codigo-de-colores-para-separacion-de-residuos-en-colombia>. [Último acceso: 01 Junio 2021].