

PROPUESTA DE IDENTIFICACIÓN DE RESIDUOS SÓLIDOS URBANOS PARA LA CLASIFICACIÓN EN LA FUENTE MEDIANTE VISIÓN ARTIFICIAL

Autor: Luis Jesús López Castiblanco¹ – lujlopezc@udistrital.edu.co

Docente asesor: Juan Pablo Rodríguez Miranda

Semillero de investigación: Aquaformat

RESUMEN

Esta investigación propone la identificación y clasificación de residuos sólidos urbanos en la fuente mediante visión artificial, alineándose a la metodología de clasificación normativa de la resolución 2184 de 2019. Se desarrolló una red neuronal artificial (RNA) convolucional utilizando Teachable Machine, estructurada en dos capas, con una entrada de 224×224 píxeles y 3 canales RGB. El modelo procesó 2600 imágenes de entrenamiento y logró una precisión del 80% y una sensibilidad del 71%. Para optimizar la clasificación, se agruparon etiquetas según criterios normativos y visuales, reduciendo las categorías a 11 etiquetas o clases. La interfaz gráfica (GUI) facilitó la interacción del usuario al permitir la

identificación en tiempo real mediante la cámara o el análisis de imágenes almacenadas. Esta solución representa un avance en la gestión de residuos sólidos urbanos en Colombia, promoviendo su correcta clasificación y mejorando su reincorporación a la economía circular, contribuyendo así a la sostenibilidad ambiental.

PALABRAS CLAVES

Visión artificial, red neuronal artificial, residuos sólidos urbanos, modelo, identificación, clasificación.

¹ Tecnología en Saneamiento Ambiental, Universidad Distrital Francisco José de Caldas.

ABSTRACT

This research proposes the identification and classification of municipal solid waste at the source using artificial vision, aligning to the regulatory classification methodology of resolution 2184 of 2019. A convolutional artificial neural network (ANN) was developed using Teachable Machine, structured in two layers, with an input of 224×224 pixels and 3 RGB channels. The model processed 2600 training images and achieved an accuracy of 80% and a sensitivity of 71%. To optimize classification, labels were grouped according to normative and visual criteria, reducing the categories to 11 labels or classes. The graphical user interface (GUI) facilitated user interaction by allowing real-time identification via camera or analysis of stored images. This solution represents a breakthrough in the management of urban solid waste in Colombia, promoting its correct classification and improving its reincorporation into the circular economy, thus contributing to environmental sustainability.

KEYWORDS

Artificial vision, artificial neural network, municipal solid waste, model, identification, classification.

INTRODUCCIÓN

En Colombia, los residuos sólidos urbanos inadecuadamente clasificados (RSUIC) son empaquetados que contienen dos o tres tipos de residuos sólidos (residuos aprovechables, residuos no aprovechables y residuos orgánicos aprovechables). Los RSUIC en ciudades y cabeceras municipales aumentan la demanda de espacio (volumen) en los rellenos sanitarios y en ocasiones se genera la necesidad de crear nuevos rellenos sanitarios y/o crear y utilizar botaderos a cielo abierto, que impactan directamente el recurso hídrico, atmosférico y el suelo, generando malas condiciones sanitarias para los asentamientos humanos cercanos y perjudicando los ecosistemas acuáticos y terrestres.

Con la acelerada expansión demográfica en los municipios y ciudades de Colombia, aumenta la generación de residuos sólidos (Vargas et al., 2021) y sin la debida concientización colectiva sobre la clasificación en la fuente de estos, la mayoría de los residuos sólidos aprovechables y orgánicos aprovechables son dispuestos en rellenos sanitarios o botaderos a cielo abierto, donde su valor energético para su reincorporación a la economía circular desaparece (Ceballos et al., 2022). Entonces, la visión artificial se convierte en una herramienta que puede optimizar la clasificación de los residuos sólidos urbanos en la fuente mediante su identificación, teniendo en cuenta la resolución 2184 de 2019 (código de colores) que estipula los lineamientos normativos sobre la adecuada clasificación de los residuos sólidos según su identificación.

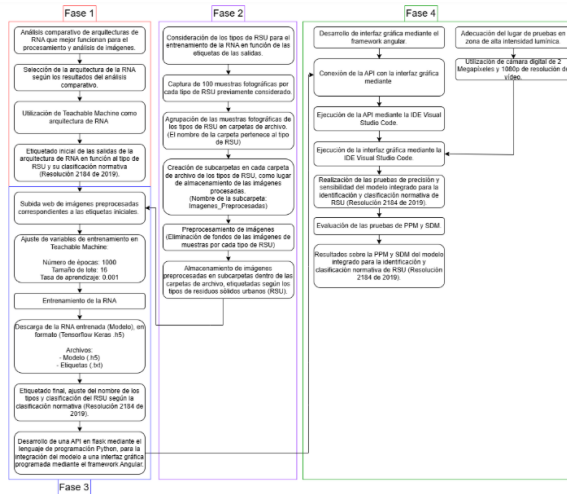
La visión artificial es un campo de la inteligencia artificial que permite procesar y analizar imágenes (García & Caranqui, 2015). Este campo es utilizado en diferentes ámbitos de la ingeniería y de ciencias como: biología,

inspección y control de calidad, geología, medicina, meteorología, modelado y visualización en 3D, Reconocimiento y clasificación, robótica, seguridad y teledetección (García & Caranqui, 2015). El procesamiento y análisis de imágenes mediante la visión artificial, comprende en la estructuración de una red neuronal artificial (RNA), donde su unidad mínima de funcionamiento se denomina perceptrón (Mohammed et al., 2022). Hay dos tipos de perceptrones: Perceptrón simple utilizado para resolver problemas lineales (Gil & Quintero, 2021). Perceptrón multicapa utilizado para resolver problemas no lineales o complejos (Mohammed et al., 2022). Procesar y analizar imágenes es un proceso complejo; por ello, esta investigación se centra en formular la identificación de residuos sólidos urbanos para la clasificación en la fuente mediante la técnica de visión artificial.

MÉTODOS

El desarrollo de esta investigación tuvo cuatro fases (véase figura 1):

Figura 1. Diagrama de flujo metodológico.



Fuente: Autor, 2025.

Fase 1: Selección y diseño de la RNA. Seleccionar la RNA en esta investigación, se empleará un cuadro comparativo para analizar los siguientes criterios de las diferentes RNA empleadas o utilizadas en el campo de la visión artificial: 1. Capacidad de clasificar imágenes o detectar objetos, según su arquitectura. 2. Tamaño estructural pequeño o mediano.

Fase 2: Insumos fotográficos y preprocesamiento. Consideración de los tipos de RSU para el desarrollo de esta investigación, así mismo la estimación sobre la cantidad de fotografías por cada tipo de RSU considerado, como muestras de insumo para el proceso de entrenamiento. También, el preprocesamiento de imágenes (Eliminación de fondos y segmentación del objeto o RSU).

Fase 3: Entrenamiento de la RNA e integración GUI. Entrenamiento de la RNA mediante Teachable Machine, exportación del modelo e integración a la GUI mediante una API.

Fase 4: Ejecución del modelo mediante GUI. Ejecución del modelo mediante una GUI con opciones de identificación continuo de RSU a través de la cámara de la computadora, o mediante el procesamiento de archivos (imágenes) almacenadas en la computadora.

RESULTADOS

En el desarrollo de esta investigación, se optó por utilizar la RNA – CNN (véase tabla 1), ya que mediante un análisis comparativo la CNN y la PCNN fueron las RNA que cumplieron los criterios de selección. La estructuración de la RNA se realizó mediante Teachable Machine, dónde se obtuvo un modelo de dos capas.

Tabla 1. *Cuadro comparativo de redes neuronales artificiales según su capacidad de clasificar o detectar objetos y su tamaño estructural.*

Tipo de RNA	Clasificación de imágenes o detección de objetos	Tamaño estructural de la RNA		
		Pequeño	Mediano	Grande
CNN	Cumple	X	X	X
RNN	No cumple			X
GAN	No cumple			X
Red Neuronal Celular	No cumple	X	X	
ONN	No cumple	X	X	
PCNN	Cumple	X	X	
Red Neuronal con Funciones de Base Radial	No cumple		X	
RPNN	No cumple	X	X	
SNN	Cumple			X
Red de Crecimiento de Tensor	Cumple			X
SOM	No cumple	X	X	

Fuente: Autor, 2025.

El modelo procesa una imagen de entrada con dimensiones de 224×224 píxeles y tres canales RGB. Inicialmente, una capa convolucional preentrenada extrae características de alto nivel y las reduce a un vector de 1.280 dimensiones. Este vector es posteriormente procesado por una capa densa que asigna probabilidades a cada una de las 26 etiquetas de salida. Aunque no se tiene certeza sobre la función de activación empleada en esta etapa, dicha función permite determinar la clase con mayor probabilidad, facilitando así la clasificación final de la imagen.

Las 26 etiquetas utilizadas en esta investigación fueron ajustadas a partir de una versión preliminar, siguiendo los lineamientos establecidos en la Resolución 2184 de 2019 para la clasificación de residuos sólidos.

Ejemplo:

establecer la cantidad de muestras a utilizar en pruebas de precisión y sensibilidad.

Etiquetas preliminares:

1. Chatarra.
2. Latas de Aluminio Clausen.
3. Botellas PET Azul.
4. Botellas PET Verde.
5. Botellas PET Ambar.

Agrupación de etiquetas:

1. Metal (R.S Aprovechable)
2. Papel (R.S Aprovechable)
3. Cartón-Plegadiza (R.S Aprovechable)
4. Plástico (R.S Aprovechable)
5. Vidrio (R.S Aprovechable)
6. Envase de tetra pak (R.S Aprovechable)
7. Restos de comida (R.S Orgánico)
8. Pañal (R.S No Aprovechable)
9. PPHH-S (R.S No Aprovechable)
10. Empaque metalizado de comida (R.S No Aprovechable)
11. Envase de Icopor (EPS) (R.S No Aprovechable).

Etiquetas finales:

1. Metal.
2. Metal.
3. Plástico.
4. Plástico.
5. Plástico.


En las etiquetas finales se aplicó una agrupación para las etiquetas del mismo nombre, con el fin de describir finalmente cuantos tipos de RSU puede predecir el modelo en función a las clases estipuladas en la resolución 2184 de 2019, y así mismo

Ahora bien, se utilizó un conjunto de muestras de 220 imágenes de RSU (20 imágenes por cada agrupación de etiquetas) y el modelo arrojó una precisión promedio (PPM) del 80% y una sensibilidad promedio

del 71%, en la identificación y clasificación normativa de los RSU.

La creación de la interfaz gráfica permitió la ejecución interactiva del modelo, facilitando su uso mediante botones de comando. Esto permite al usuario analizar imágenes en tiempo real con la cámara de la computadora o procesar archivos almacenados de manera sencilla obteniendo resultados de inmediato (véase imagen 1).

Imagen 1. *Procesamiento y análisis de imágenes en la GUI, utilizando la cámara de computadora y archivos de imagen.*



Fuente: Autor, 2025.

DISCUSIÓN

Se estructuró el modelo mediante la arquitectura de la CNN, ya que es útil en la extracción de características y en la clasificación de imágenes (Pal & Sudeep, 2016). Por otro lado, la arquitectura PCNN es útil en la extracción de características, pero no es muy útil en la clasificación de imágenes. (Liu Q. et al., 2009).

El diseño y la estructura del modelo se basaron en el número de salidas necesarias para la clasificación de residuos sólidos, definiendo un total de 11 etiquetas. Estas etiquetas fueron clasificadas a partir de la normativa establecida por el (Ministerio de Ambiente y Desarrollo Sustentable, 2019), tomando únicamente aquellas clases pertinentes para los fines de este estudio.

Según la clasificación establecida por el Ministerio de Ambiente y Desarrollo Sostenible (2019), los residuos sólidos urbanos (RSU) se dividen en tres categorías

principales, cada una de las cuales agrupa diferentes tipos de residuos. En el marco de esta investigación, dichos tipos se denominan *etiquetas*:

1. **Residuos aprovechables:** Comprenden materiales que pueden ser reincorporados a los ciclos productivos, tales como plástico, vidrio, metales, papel, cartón y envases multicapa.
2. **Residuos orgánicos aprovechables:** Incluyen aquellos residuos de origen biológico que pueden ser transformados mediante procesos como el compostaje, entre ellos los restos de alimentos, residuos de corte de césped y poda de jardín.
3. **Residuos no aprovechables:** Agrupan materiales que, por su naturaleza o estado de contaminación, no pueden ser reutilizados o reciclados. Entre ellos se encuentran el papel higiénico, servilletas, papeles y cartones contaminados con

restos de comida, papeles metalizados, entre otros.

La imagen de entrada al modelo entrenado y exportado por *Teachable Machine* utiliza las mismas dimensiones estándar de 224×224 píxeles con tres canales RGB que otras arquitecturas de redes neuronales convolucionales (CNN), como *MobileNet*, *VGG16* y *ResNet*. Estas dimensiones son ampliamente empleadas en modelos de visión por computador debido a su eficacia en la extracción de características y su equilibrio entre precisión y eficiencia computacional (Howard et al., 2017; Krizhevsky et al., 2012).

La reducción de las dimensiones a un vector de 1.280 características en el modelo no solo responde a un criterio técnico, sino que también sigue un enfoque probado en arquitecturas optimizadas como *MobileNetV2*. Esta dimensionalidad intermedia permite conservar la capacidad del modelo para discriminar entre clases sin incurrir en una sobrecarga de parámetros,

facilitando así una clasificación precisa y eficiente en la etapa final del modelo, ya que un vector de 1.280 dimensiones resume de forma eficiente las características extraídas de la imagen, manteniendo la información más representativa con un bajo costo computacional (Sandler et al., 2018).

La función de activación empleada en la etapa de clasificación del modelo no se encuentra explícitamente definida, es razonable suponer que se trata de la función Softmax, dado que esta es comúnmente utilizada en tareas de clasificación multiclase (Goodfellow & Bengio, 2016).

Algunas etiquetas finales de residuos sólidos urbanos (RSU) fueron ajustadas mediante un proceso de unificación, el cual consistió en agrupar bajo una sola etiqueta aquellos residuos que presentan similitudes físicas evidentes, tales como color, forma, textura o tamaño. No obstante, para que dos o más etiquetas puedan ser unificadas, es requisito que pertenezcan a la misma categoría

normativa según la clasificación establecida por (Ministerio de Ambiente y Desarrollo Sustentable, 2019). Si bien la similitud física es un criterio relevante, la unificación no se lleva a cabo si no existe correspondencia normativa.

Como resultado de este proceso, se consolidaron etiquetas como papel higiénico, paños húmedos y servilletas bajo la categoría PPHH-S, y cartón junto con plegadiza bajo la etiqueta Cartón-Plegadiza.

Según (He et al., 2015) los modelos de visión artificial pueden presentar confusión cuando múltiples clases comparten características visuales similares; por tanto, la unificación de etiquetas puede contribuir a mejorar la precisión del modelo y reducir errores en la predicción.

El modelo desarrollado en este estudio alcanzó una precisión promedio del 80%, utilizando un conjunto de datos compuesto por 2.600 imágenes. Se aplicó un proceso de preprocesamiento para la eliminación de

fondos, se emplearon dos capas convolucionales y se utilizó la función de activación Softmax para clasificar probabilísticamente las imágenes en 11 etiquetas finales, correspondientes a diferentes clases de residuos sólidos urbanos (RSU).

En comparación con otros trabajos, el modelo de (Mohammed et al., 2022) empleó una red neuronal artificial (RNA) de tipo perceptrón multicapa (MLP) para identificar únicamente tres tipos de residuos (cartón, metal y empaques contaminados con comida), alcanzando una precisión del 91,7% sobre un conjunto de 2.400 imágenes. Aunque su precisión fue superior, el número de clases a clasificar fue considerablemente menor.

Por su parte (Melinte et al., 2020) diseñaron una RNA basada en redes neuronales convolucionales (RNC), utilizando dos enfoques: Detectores de Disparo Único (SSD) y Redes de Propuestas Regionales (R-CNN). Su modelo identificó cinco tipos de residuos (vidrio, metal, plástico, papel y cartón),

utilizando 2.527 imágenes en total (1.895 para entrenamiento y 632 para prueba). Obtuvieron precisiones promedio de 97,63% con SSD y 95,76% con R-CNN, mostrando un alto desempeño, pero también con una menor diversidad de clases en comparación con el presente estudio.

Finalmente, (Zheng et al., 2023) propusieron el modelo Focus RCNet junto con la técnica de *knowledge distillation* para clasificar seis tipos de residuos. Trabajaron con una base de datos de 2.528 imágenes (70% para entrenamiento y 30% para evaluación), alcanzando una precisión promedio del 92%. Aunque este modelo mostró un excelente rendimiento, la cantidad de clases sigue siendo inferior a las consideradas en este trabajo.

Aunque la precisión del modelo de esta investigación es menor en comparación a los estudios anteriormente mencionados, se destaca por abordar un problema de mayor complejidad al clasificar 11 tipos distintos de residuos, lo que implica una mayor

variabilidad visual y, por tanto, un reto más significativo en términos de clasificación. Esta comparación evidencia que el desempeño del modelo es competitivo si se considera tanto el número de clases como las características del conjunto de datos utilizado. Además, se observa que, en los estudios previamente mencionados, donde se alcanzaron mayores niveles de precisión, se emplearon modelos con arquitecturas más profundas y complejas —es decir, con un mayor número de capas— lo cual contribuye significativamente a mejorar la capacidad del modelo para extraer y aprender patrones visuales complejos. En este sentido, los resultados obtenidos no solo representan un avance en el campo de la clasificación de residuos sólidos mediante visión artificial, sino que también sugieren oportunidades claras para mejorar el rendimiento mediante el uso de redes convolucionales más profundas en futuros desarrollos.

La integración del modelo con una interfaz gráfica de usuario (GUI) facilitó

significativamente su ejecución, permitiendo que cualquier usuario pudiera interactuar con el sistema sin necesidad de conocimientos en programación o manejo de entornos de desarrollo integrados (IDE). Esta funcionalidad resulta especialmente relevante en contextos donde se busca una adopción práctica y accesible de herramientas basadas en inteligencia artificial, como es el caso de la clasificación de residuos sólidos. De acuerdo con (Moran et al., 2020), el uso de interfaces gráficas incrementa la usabilidad y democratiza el acceso a modelos complejos como las redes neuronales convolucionales (CNN), convirtiéndose en un puente entre el desarrollo técnico y la aplicación práctica. En este sentido, la GUI implementada en este proyecto no solo mejoró la experiencia del usuario final, sino que también representó una herramienta clave para poner en funcionamiento el modelo de forma intuitiva, eficiente y sin barreras técnicas.

CONCLUSIONES

Se formuló la identificación de residuos sólidos urbanos (RSU) para la clasificación en la fuente mediante la técnica de visión artificial. Así mismo, se logró seleccionar y estructurar una RNA que tuviera la capacidad de identificar imágenes de RSU para poder clasificarlos según los lineamientos normativos de la resolución 2184 de 2019. Se creó una interfaz gráfica que permitiera la ejecución del modelo, garantizando un manejo simple al usuario para el análisis de imágenes de RSU considerados en el marco de identificación y clasificación normativo colombiano. Comparando la precisión promedio del modelo con resultados de precisión promedio de modelos de IA de otras investigaciones, se observó que, a mayor complejidad en la arquitectura (Mayor número de capas) aumenta la precisión.

AGRADECIMIENTOS

Agradezco a la Universidad Distrital Francisco José de Caldas por haberme brindado espacios de investigación, a mi familia y amigos por su motivación constante, y al docente Juan Pablo Rodríguez Miranda por creer en esta idea realmente maravillosa. También agradezco a la empresa M & M Universal E.S.P y a mi amigo y colega Daniel Bernal, por su colaboración en el desarrollo de esta investigación.

REFERENCIAS BIBLIOGRÁFICAS

- Ceballos, S., Brambila, J., & Pérez, V. (2022). Residuos sólidos urbanos y economía circular en Pachuca, Hidalgo, México. 32. <https://doi.org/10.15174/au.2022.3437>
- García, I., & Caranqui, V. (2015). La visión artificial y los campos de aplicación. *Tierra Infinita*, 1, 98–108. <https://doi.org/10.32645/26028131.76>

- Gil, V., & Quintero, C. (2021). Predicción del rendimiento académico estudiantil con redes neuronales artificiales. *Información Tecnológica*, 32 (6), 221–228. <https://doi.org/10.4067/s0718-07642021000600221>
- Goodfellow, I., & Bengio, I. (2016). Deep Feedforward Networks. In *Deep Learning* (pp. 182–182).
- Press. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. <http://arxiv.org/abs/1512.03385>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. <http://arxiv.org/abs/1704.04861>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. <http://code.google.com/p/cuda-convnet/>
- Liu Q., Wang Y., & Ma Y. (2009). Image Feature Extraction and Recognition Based on Adaptive Unit-Linking Pulse Coupled Neural Networks. *IEEE*.
- Melinte, D. O., Travediu, A. M., & Dumitriu, D. N. (2020). Deep convolutional neural networks object detector for real-time waste identification. *Applied Sciences* (Switzerland), 10(20), 1–18. <https://doi.org/10.3390/app10207301>
- Ministerio de Ambiente y Desarrollo Sustentable. (2019). Por la cual se modifica la resolución 668 de 2016 sobre el uso racional de bolsas plásticas y se adoptan otras disposiciones.
- Mohammed, M. A., Abdulhasan, M. J., Kumar, N. M., Abdulkareem, K. H., Mostafa, S. A., Maashi, M. S., Khalid, L. S., Abdulaali, H. S., & Chopra, S. S. (2022). Automated

- waste-sorting and recycling classification using artificial neural network and features fusion: a digital-enabled circular economy vision for smart cities. *Multimedia Tools and Applications*, 82(25), 39617–39632. <https://doi.org/10.1007/s11042-021-11537-0>
- Moran, K., Bernal-Cardenas, C., Curcio, M., Bonett, R., & Poshyvanyk, D. (2020). Machine Learning-Based Prototyping of Graphical User Interfaces for Mobile Apps. *IEEE Transactions on Software Engineering*, 46(2), 196–221. <https://doi.org/10.1109/TSE.2018.2844788>
 - Pal, K., & Sudeep, K. (2016). Preprocessing for Image Classification by Convolutional Neural Networks. *IEEE International Conference On Recent Trends In Electronics Information Communication Technology*, 1778–1781. <https://doi.org/DOI:10.1109/RTEICT.2016.7808140>
 - Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. <http://arxiv.org/abs/1801.04381>
 - Vargas, C., Gutiérrez, J., Vélez, D., Gómez, M., Aguirre, D., Quintero, L., & Franco, M. (2021). Solid Waste Management, an Environmental Problem in the University. *Pensamiento y Gestión*, 50.
 - Zheng, D., Wang, R., Duan, Y., Pang, P. C. I., & Tan, T. (2023). Focus-RCNet: a lightweight recyclable waste classification algorithm based on focus and knowledge distillation. *Visual Computing for Industry, Biomedicine, and Art*, 6(1). <https://doi.org/10.1186/s42492-023-00146-3>