

IDENTIFICATION OF SOLID WASTE IN URBAN AREAS WITH IMAGE PROCESSING AND ARTIFICIAL INTELLIGENCE

IDENTIFICACIÓN DE RESIDUOS SÓLIDOS EN ZONAS URBANAS CON PROCESAMIENTO DE IMÁGENES E INTELIGENCIA ARTIFICIAL

**ORTIZ, D.M.¹; CASTRO, S.A.²; NIÑO, C.V.³; GUEVARA, D.⁴;
MEDINA, B.⁵**

¹ Ing. Danna Marcela Ortiz F. Ingeniera Electrónica, Programa de Ingeniería Electrónica, Departamento de Electricidad y Electrónica de la Universidad Francisco de Paula Santander, e-mail:

dannamarcelaof@ufps.edu.co

ORCID: <https://orcid.org/0009-0000-0163-8629>

² MSc. Sergio Alexander Castro Casadiego. Programa de Ingeniería Electrónica, Departamento de Electricidad y Electrónica de la Universidad Francisco de Paula Santander, e-mail:

sergio.castroc@ufps.edu.co

ORCID: <https://orcid.org/0000-0003-0962-9916>

³ Ing. Carlos Vicente Niño Rondón. Facultad de Ingeniería y Ciencias, Pontificia Universidad Javeriana Cali, e-mail:

carlosvicenteninor@javerianacali.edu.co

ORCID: <https://orcid.org/0000-0002-3781-4564>

⁴ PhD. Dinael Guevara Ibarra. Programa de Ingeniería Electrónica, Departamento de Electricidad y Electrónica de la Universidad Francisco de Paula Santander, e-mail: dinaelgi@ufps.edu.co

ORCID: <https://orcid.org/0000-0003-3007-8354>

⁵ PhD. Byron Medina Delgado, Programa de Ingeniería Electrónica, Departamento de Electricidad y Electrónica de la Universidad Francisco de Paula Santander, e-mail:

byronmedina@ufps.edu.co

ORCID: <https://orcid.org/0000-0003-0754-8629>

Recibido: 06/02/2022 / Aceptado: 28/05/2022

Resumen

Actualmente en Colombia, el incremento exponencial de la cantidad de residuos que cada individuo del hogar produce diariamente causa que los vertederos destinados para esto se encuentren a punto de cumplir con su vida útil, esto se debe a que un 78% de los colombianos no saben reciclar. Con el propósito de proponer una estrategia para apoyar en la solución de esta problemática, se elabora un algoritmo que tiene como propósito ayudar a las personas del sector de reciclaje, hogares e industrias con la identificación y clasificación de los residuos producidos por ellos. Este algoritmo, se realizó mediante técnicas basadas en aprendizaje profundo, en donde se encuentran tres tipos de modelos: denso, convolucional y convolucional con Drop Out. En estos modelos se aplican dos estados de activación que son sigmoial y ReLu, y a su vez transforman imágenes de distintos tamaños a uno solo de 200x200 para una mejor lectura de los pixeles y se transforman a escalas de grises para una mejor obtención de los bordes. Como resultado, se obtiene una precisión de un 80.5%, debido al entrenamiento y validación de 12.872 imágenes que fueron tomadas como muestra en la ciudad de Cúcuta, Colombia.

Palabras clave

detección, residuos sólidos, aprendizaje profundo, convolución, conjunto de datos.

Abstract

Currently in Colombia, the exponential increase in the amount of waste that each individual household produces daily causes that the landfills destined for this purpose are about to fulfill their useful life, this is due to the fact that 78% of Colombians do not know how to recycle. With the purpose of proposing a strategy to support the solution of this problem, an algorithm is developed to help people in the recycling sector, households and industries with the identification and classification of the waste produced by them. This algorithm was developed using techniques based on deep learning, where there are three types of models: dense, convolutional, and convolutional with Drop Out. In these models two activation states are applied which are sigmoidal and ReLu, and in turn transform images of different sizes to a single 200x200 for a better reading of the pixels and are transformed to grayscales for a better obtaining of the edges. As a result, an accuracy of 80.5% is obtained, due to the training and validation of 12,872 images that were taken as a sample in the city of Cúcuta, Colombia.

Keywords

Detection, solid waste, Deep learning, convolution, datasets.

1. INTRODUCCIÓN

El banco mundial (BM) en el año 2018 lanzo un informe denominado "What a Waste 2.0", el cual tenía como propósito principal alertar a la población de la cantidad de basura que se está generando y la poca conciencia que se tiene para manejar adecuadamente estos residuos, dentro de este informe se advierte que si no se toman medidas urgentes para controlar la contaminación de residuos, en tan solo 27 años los desechos aumentaran en un

70% (Alfeehan *et al.*, 2020; Ortega *et al.*, 2020). En la actualidad se registra un aproximado de 2.010 millones de toneladas de desechos sólidos anuales, de los cuales un 33% de ellos no son tratados (Mora *et al* 2018; Vianchá-Sánchez *et al.*, 2021; Niño Rondón *et al.*, 2021).

Sin embargo, este problema no solo corresponde a países europeos, asiáticos o norteamericanos, a su vez incluye a Latinoamérica. Investigaciones indican que los latinoamericanos producen un promedio de desechos entre el 1.16 – 0.47

kg diarios por persona (Montalvo *et al.*, 2018; Benito *et al.*, 2019), así mismo, países como México, Chile, Argentina, República Dominicana y Brasil son considerados los que más generan basura, en cambio países como Perú, Cuba, Honduras, Bolivia y Guatemala son de los países que menos generan residuos.

Por otro lado, países como Suiza, Suecia, Austria, Alemania, Bélgica y Países Bajos, han implementado modernos sistemas de reciclaje para lograr un desarrollo sostenible, en cambio, países como Colombia comprenden un sistema de reciclaje más autónomo y de libre elección, por lo cual, de los 12 millones de toneladas que son producidas al año en el país, solo un 16.5% es reciclada (Trujillo *et al.*, 2019; Corvacho Ponce *et al.*, 2022), esto se debe a que un 78% de los colombianos no saben o no les gusta reciclar, por lo cual, de los vertederos existentes en el país, 116 de ellos no se encuentran autorizados, 101 se convirtieron en botaderos a cielo abierto y tan solo 192 son autorizados para la disposición de residuos sólidos produciendo que los vertederos se encuentren a punto de un colapso (Castellanos *et al.*, 2020; Guerrero *et al.*, 2021; Jiménez Guethon *et al.*, 2022).

Así mismo, esta situación se encuentra presente en Norte de Santander, la cual se encuentra evidenciada en el plan de acción 2020-2023 por la Corporación Autónoma Regional de la Frontera Nororiental mejor conocida como "CORPONOR", en donde se menciona que en el área metropolitana de Cúcuta, existe un vertedero con problemas legales, por lo cual la empresa se encuentra en una nueva formulación de plan de contingencia para el manejo de los residuos. Los datos recolectados por CORPONOR evidencia que durante el año 2016 al 2019 se atendió una cantidad de 1.097.842 Toneladas de basura en la ciudad de Cúcuta (Batista y Urquiza, 2018; Flórez *et al.*, 2019; Corponor, 2020).

En la actualidad existen diversas investigaciones o proyectos que se han llevado a cabo con el propósito de realizar

un aumento considerable en el reciclaje de cada sector, un ejemplo de ello sería la investigación realizada por (Sastre, C.A) (Ramón y Moreno, 2018; Castellanos y Baldovino, 2021; Lozada Sastre, 2022), en el cual lleva a cabo un sistema autónomo para la clasificación de material reciclable usando IA, consistió en realizar un dataset con imágenes encontradas en internet y un 10% propias, para la clasificación de 8 tipos de residuos, para ello implementaron una red neuronal convolucional con dos tipos de imágenes, preprocesadas y originales, esto se hizo con el fin de observar si al realizar el preprocesado se lograba una mejor identificación y clasificación de los residuos, su investigación tuvo una precisión del 66% con imágenes normales y un 68.5% con imágenes preprocesadas. En el año 2021 (Alonso *et al.*, 2020; Mahecha *et al.*, 2020; Pinto Rodríguez *et al.*, 2021) se realizó un prototipo de clasificación de residuos sólidos en el origen, esta investigación tenía como propósito principal que por medio de la Deep Learning crear un prototipo que detectara y clasificara correctamente diversos residuos según la resolución 2184 de 2019 de Colombia, el prototipo tuvo un porcentaje de precisión del 97.91% debido a que las imágenes de entrenamiento fueron recolectadas en el mismo punto, y el prototipo fue implementado con metodología LEAN de Toyota y la herramienta Solid Works, por lo cual su precio para futuras implementaciones es un poco costoso para el acceso de todo el público (Bonilla *et al.*, 2021).

En este documento se presentará un procesamiento digital de imágenes realizadas en la ciudad de Cúcuta, de botaderos a cielo abierto encontrados desde la vía de prados del este hasta a los alrededores del centro comercial Jardín Plaza, a las cuales se les realizará un dataset para el entrenamiento y predicción con inteligencia artificial por medio de la Deep Learning, para la identificación y

clasificación de 6 tipos de residuos sólidos.

2. METODOLOGÍA

El desarrollo de este proyecto se dividió en tres partes, en la primera la recolección de los seis tipos de residuos para la creación del dataset, segundo el entrenamiento y validación de la red y por último la precisión de la red neuronal, estos pasos mencionados anteriormente ayudan a la clasificación e identificación de residuos sólidos que sean colocados frente a la cámara, para mejorar la comprensión del sistema se explicara algunos términos:

Modelo Denso: En este modelo se puede ver los componentes básicos, los cuales consta de una entrada, pesos, compensaciones y funciones de activación de los cuales se utilizará la sigmoidea y la ReLu (Figura 1).

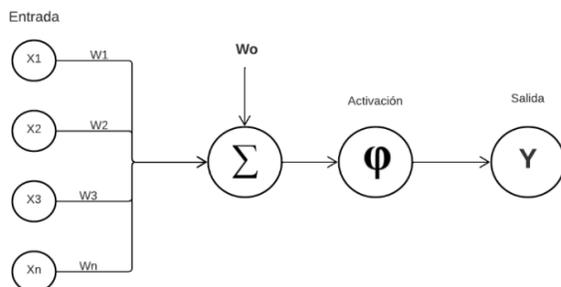


Figura 1. Modelo Denso

a. Entrada: En esta sección encontramos aquellos datos que provienen del exterior, se encuentran nombrados por X1, X2, X3, Xn, para el desarrollo de este proyecto se utilizó un total de 12.872 de imágenes, las cuales se encuentran clasificadas en seis categorías: Cartón, papel, plástico, vidrio, biológico y metal. Para ello, se realizó la recolección de imágenes para la creación de un dataset, capturando fotos desde el sector prados del este hasta el centro comercial Jardín Plaza de la ciudad de Cúcuta, las imágenes fueron tomadas por medio de varios

dispositivos móviles de diferentes pixeles la cámara, por lo cual las imágenes tienden a ser de diversos tamaños para cada categoría.

b. Peso: Se puede recibir una gran cantidad o múltiples entradas simultaneas, la diferencia entre estas dos es la cantidad de peso que aporta cada uno, debido a que según su de peso obtienen un mayor efecto en el proceso de la neurona para la producción de una respuesta, en este caso encontramos W1, W2, W3, Wn (Chauhan *et al.*, 2018; Higuera *et al.*, 2018; Torrado *et al.*, 2020). Como se mencionó en el inciso a, al capturar las imágenes por diferentes dispositivos móviles, se obtuvo un rango de peso por imagen entre 9.47KB – 28 KB. Por otro lado, encontramos a Wo, el cual es un parámetro que se le adiciona a la función para que esta no se encuentre adicionada a pasar por el origen, obteniendo un resultado más realista. Para el desarrollo del proyecto se realiza la transformación de las imágenes a escala de grises, por lo cual, el valor puede variar entre 0 a 255.

$$Z = X_1W_1 + X_2W_2 + X_3W_3 + X_nW_n + W_o \quad (1)$$

c. Activación: La salida de una neurona puede tener u(Sharma *et al.*, 2018)n filtro, una función de corte o un umbral que modifica el valor de salida o impone un umbral que debe superarse para continuar otra neurona.

d. Sigmoidal: Es esta función la que transforma valores en la escala (0,1), con valores muy bajos que tienden a 0 asintóticamente y valores positivos que tienden a 1 de la misma forma. Sus características principales es que la función se satura y mata el gradiente, es de lenta convergencia, no

se encuentra centrada en el cero, como se indicó anteriormente se encuentra entre el (0,1) y tiene un buen rendimiento en su última capa (Jordan et al., 2021), por lo tanto, durante este proyecto se le ha asignado a X el valor de 1.

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

- e. **ReLu:** A diferencia de la anterior función, ReLu tiende a dejar los valores positivos tales como entran al sistema, pero en cambio sus valores negativos tienden a anularlos. Sus características principales es que solo se activa si los valores son positivos, no llega a acotarse, se puede morir muchas neuronas, la función suele ser utilizada con imágenes y tiene buen desempeño en CNN (Shorten & Khoshgoftaar, 2019). En la capa densa el valor X se realiza doble de 150 neuronas cada uno, en cambio en las dos capas CNN su valor es de 256 neuronas cada uno.

$$f(x) = \max(0, x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases} \quad (3)$$

- f. **Salida:** En este punto se ha realizado la sumatoria de los pesos con la entrada, adicional a eso se realiza la activación de las funciones para obtener así una red neuronal con capa densa.

$$Y = \varphi (W * X) \quad (4)$$

Modelo CNN: Es un algoritmo utilizado comúnmente para aplicar el modelo Deep Learning debido a que aprende directamente de los datos sin necesidad de extraer características de forma manual, esta red es muy utilizada cuando se necesita clasificar objetos, rostros o siluetas (Chandan et al., 2018; Terrero et

al., 2020).

Cuando se refiere al modelo CNN, se enfoca en una red neuronal la cual consta de tres etapas: capa de entrada, capas ocultas y capa de salida (Figura 2). Una capa de entrada es cuando las neuronas reciben los datos reales con los cuales se alimenta la red neuronal, por otro lado, en las capas ocultas no se conoce los valores de entrada ni de salida, y por último tenemos la capa de salida, en la cual encontramos el resultado visible de la red (Mao et al., 2016).

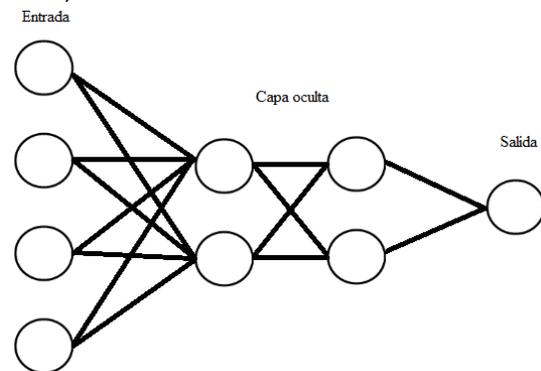


Figura 2. Modelo CNN

Por otro lado, como se evidencia en la (Figura 3), podemos obtener un diagrama más resumido del proceso que se lleva a cabo para la clasificación de los residuos sólidos, el cual comprende 3 pasos.

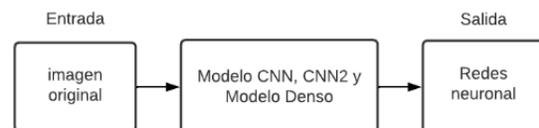


Figura 3. Sistema

Como se menciona anteriormente, la imagen original que entra en el sistema es aquella que tenemos almacenada en el dataset en una de las seis categorías: Cartón, papel, plástico, vidrio, biológico y metal. Para ello se ha realizado un dataset por cada una de las categorías, en las cuales encontramos dos subcarpetas una de entrenamiento y otra de validación, como segundo paso se aplica una capa de modelo denso y dos capas CNN, esto se

hace con el propósito de obtener una red neuronal por cada modelo.

Para la predicción del sistema se encontrarán nueve etapas, en la primera se realiza la lectura del entrenamiento del modelo denso y dos capas de redes convolucionales (CNN), este proceso es uno de los más importantes, y se realiza el llamado a cada red neuronal de cada modelo.

Luego de ello, se realiza configura la cámara en la cual se realizará la identificación de los residuos, para ello se ha utilizado una cámara externa USB fosmon 3.85 mm megapíxel 10x digital zoom, posteriormente se realiza un cambio de colores a escalas grises y una interpolación de 200x200 que es el tamaño que se le ha designado desde el entrenamiento.

Interpolación: Es el proceso por el cual un programa añade pixeles extra a la imagen original para obtener un archivo con más datos y un mejor resultado [30]. Como se puede observar en la (Figura 5) se pasa se tener una imagen 3x3 a una 9x9 en la cual se podrá obtener una mejor visión de la imagen.




Figura 4. Interpolación

Se procede a realizar la normalización de la imagen para luego convertir en matriz, la cual tiene como objetivo extraer de una imagen los pixeles como mayor peso, permitiendo obtener de muchas imágenes con muchas neuronas a una reducción de pocas imágenes con pocas neuronas, sin

embargo, las neuronas que quedan son las que poseen una mayor información de las características que las imágenes que se desean clasificar, este proceso facilita la predicción y la clasificación de los objetos u imágenes que se muestran frente al lente de la cámara y las etiquetas aparecerán en el borde superior de la imagen, para una mejor comprensión del paso a paso del algoritmo se podrá apreciar en la Figura 5.




Figura 5. Diagrama del sistema

3. ANÁLISIS Y DISCUSIÓN DE RESULTADOS

Se realiza la creación de un dataset compuesto por 6 carpetas, los cuales corresponden a residuos de cartón, plástico, metal, vidrio, papel y biológico. Para la obtención de los dataset fue necesario la detección de residuos sólidos en la ciudad de Cúcuta, obteniendo un total de 12.872 imágenes, las cuales corresponden a 2.416 papel, 2.008 biológico, 2.216 cartón, 2.072 plástico, 2.072 metal y 2.088 de vidrio (Figura 6 - 11).




Figura 6. Dataset vidrio



Figura 11. Dataset biológico



Figura 7. Dataset Metal

Debido a la cantidad de imágenes, se realizó como primer paso la clasificación de imágenes de entrenamiento y de validación, obteniendo un resultado de 2.984 imágenes para la validación y 9.888 para el entrenamiento del sistema, además de ello debido a los diferentes ángulos y dispositivos con los que fueron captadas las imágenes, se realizó un ajuste de 200x200 a todas las imágenes de la red neuronal. Posteriormente, las imágenes de cada dataset fueron convertidas a escalas de grises para obtener una mejor detección de los contornos de cada residuo (Figura 12 – 13).

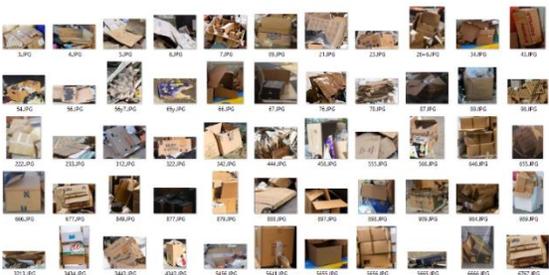


Figura 8. Dataset Cartón




Figura 12. Dataset cartón escalas grises



Figura 9. Dataset plastico



Figura 13. Dataset biologico escalas grises.




Figura 10. Dataset papel

Para la clasificación de los residuos solidos se dividió en tres carpetas: en la carpeta 1 se encuentra los residuos de cartón y

plástico, al realizar el entrenamiento compuesto por 200 capas, con una activación ReLu de 150 y una activación sigmud de 1, estas dos activaciones se realizan con el proposito que la activación sigmud transforme la escalas grises y la activación ReLu solo tome los valores positivos de la identificación y clasificación de los residuos.

Como se evidencia (Figura 14) el entrenamiento de la segunda CNN, evidenciando que la capa 196 se encuentra en el punto mas alto con una precisión de 0.8163, por otro lado, en la grafica de validación de la carpeta 1 (Figura 15) en la capa 194 se obtuvo una precisión de 0.7547.

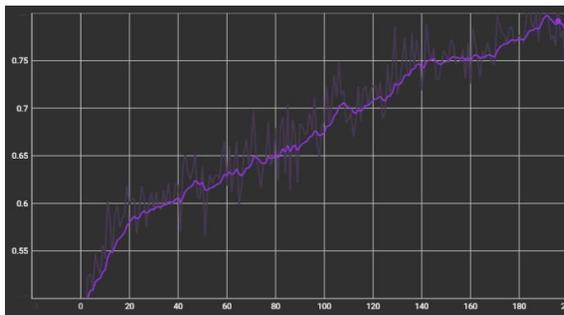


Figura 14. Precisión durante el entrenamiento del dataset de cartón y plástico

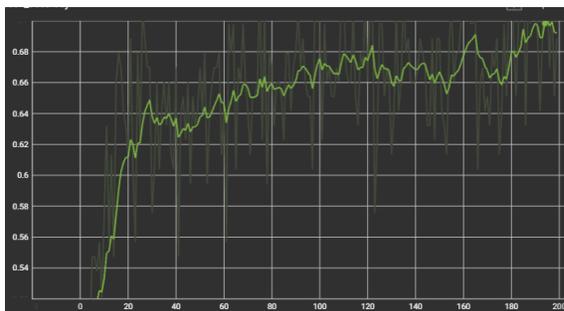


Figura 15. Precisión durante la validación del dataset de cartón y plástico

Sin embargo, en la carpeta 2 se encuentran los residuos del metal y vidrio, en el cual contamos con una precisión de 0.7463 en el entrenamiento (Figura 16) en la capa 184 y una precisión de 0.6667 en validación en la capa 195 (Figura 17).




Figura 16. Precisión durante el entrenamiento del dataset de metal y vidrio

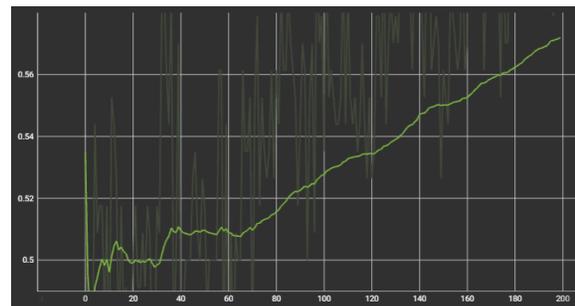


Figura 17. Precisión durante la validación del dataset de metal y vidrio

En ultimo lugar, se encuentra la carpeta 3 con los residuos de papel y biológicos, con una precisión de 0.8 (Figura 18) en entrenamiento en la capa 194 y 0.6716 en la capa 184 en validación (Figura 19).

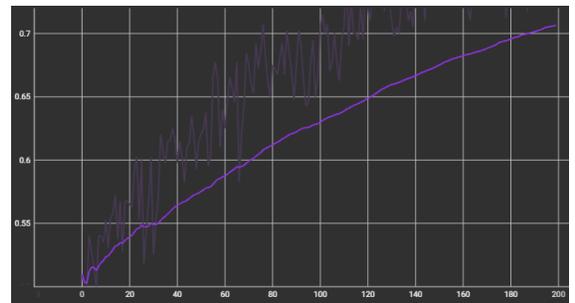


Figura 18. Precisión durante el entrenamiento del dataset de papel y biológico

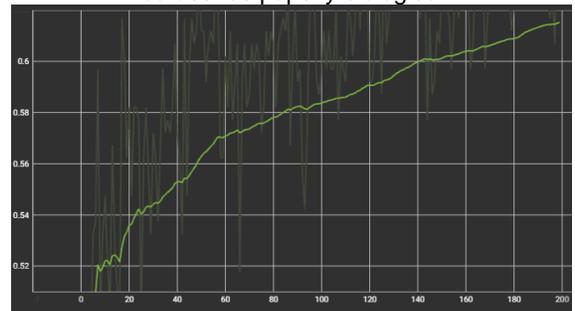


Figura 19. Precisión durante la validación del dataset de papel y biológico

De las anteriores graficas se puede concluir que el entrenamiento tiene un porcentaje de 78.75% de precisión y un 69.77% de precisión en la validación, lo cual demuestra que la red neuronal puede detectar y clasificar diferentes tipos de residuos, para lograr una clasificación en tiempo real, se conecta una camara externa la cual sirve como visor para comenzar con la predicción de diferentes residuos solidos. Por lo tanto, se realizó la prueba con 1260 diferentes tipos de residuos de forma aleatoria encontrados en la ciudad (Tabla 1), de los cuales 210 serán de cada categoria.

Tabla 1. Predicción de tipos de residuos

Tipos de residuos	Total	Identificó	No identificó
Plastico	210	190	20
Cartón	210	200	10
Metal	210	175	35
Vidrio	210	150	60
Papel	210	188	22
Biologico	210	112	98

4. CONCLUSIONES

Como se evidencia en los resultados, al igual que Colombia, Cúcuta se encuentra en un estado de emergencia debido a la gran acumulación de basura que es producida diariamente por cada uno de los habitantes de la ciudad, debido a que la crisis se encuentra en que los ciudadanos no clasifican sus residuos de una forma que pueda ser reaprovechada o reutilizada por las empresas encargadas de la recolección y reutilización de desechos, las industrias solo logran una correcta separación de residuos en un bajo porcentaje. Es por ello, que se realizó el desarrollo de un algoritmo de aprendizaje que permite conocer la precisión qué podría llegar a tener la identificación y clasificación de residuos

sólidos, con el fin de ayudar a las personas encargadas de esta separación. Para lo anterior, se utilizó inteligencia artificial, y a su vez se definió el sector en la que se realizó la recolección de imágenes.

La técnica utilizada fue Deep Learning y las imágenes recolectadas corresponden al sector desde prados del este hasta alrededores del centro comercial jardín plaza de la ciudad de Cúcuta. De igual manera, como se puede evidenciar en la tabla 1, la clasificación de los residuos es de un 80.6% de precisión en la identificación. Al observar las gráficas de entrenamiento y validación que se obtuvieron con los 6 tipos de categorías de residuos las cuales son: plástico, cartón, papel, vidrio, metal y biológico, se aprecia que el índice de entrenamiento más bajo es el del metal y vidrio, el cual obtuvo un 74,63% y a su vez una validación del 66.67%.

Por otro lado, para la creación total del dataset se recolectaron 12.872 imágenes, de las cuales el menor índice de imágenes tomadas fueron del dataset de biológicos, debido a que esta última categoría no es tan común encontrar en el sector que comprende desde prados del este hasta al rededores del centro comercial jardín plaza de la ciudad de Cúcuta, por lo cual, de las 210 pruebas realizadas en esta categoría, noventa y ocho de ellas no fueron detectadas correctamente por el sistema, en cambio, las otras cinco categorías de residuos al tener un promedio de 2.072 a 2.416 imágenes, obteniendo resultados superiores o iguales a un 71%, por lo cual, si el sistema se sigue alimentando de imágenes de residuos de la ciudad de Cúcuta, la red neuronal tendrá un entrenamiento y validación con mejores resultados, llegando a superar los valores establecidos en el presente trabajo.

Se propone como un trabajo futuro a implementar el algoritmo de aprendizaje en una tarjeta Raspberry con una cámara externa, que sirva para la recolección y obtención de imágenes con una calidad de píxeles, la misma se usará para tomar las imágenes que servirán para la identificación de los residuos, este sistema será de gran aprovechamiento para las empresas encargadas de la recolección y clasificación de los residuos, y a su vez, se podría implementar en puntos estratégicos de la ciudad o incluso desde los hogares, para que sea desde casa que se inicie una mejor metodología y correcta separación de los residuos, permitiendo que una mayor parte sea reutilizada.

5. REFERENCIAS BIBLIOGRÁFICAS

- Alfeehan, A., Mohammed, M., Jasim, M., Fadehl, U., Habeeb, F., Alfeehan, A., Mohammed, M., Jasim, M., Fadehl, U., & Habeeb, F. (2020). Utilización de desechos metálicos industriales en los paneles de hormigón armado nervados unidireccionales. *Revista Ingeniería de Construcción*, 35(3), 246–256. <https://doi.org/10.4067/S0718-50732020000300246>
- Alonso, L., Castellanos, L. y Meseguer, O. (2020). Efectos alelopáticos de residuos de *Sorghum Halepense* (L.) sobre dos arvenses dicotiledóneas en condiciones de laboratorio. *Revista Ambiental Agua, Aire y Suelo* (RAAAS), 11(1). DOI: <https://doi.org/10.24054/aaas.v11i1.354>
- Batista, C. R. y Urquiza, R. I. (2018). Experiencias de la Universidad Antonio Nariño, Sede Tunja, en el aprovechamiento de las fuentes de energía renovable. *Revista Ambiental Agua, Aire y Suelo* (RAAAS), 9(2). DOI: <https://doi.org/10.24054/aaas.v9i2.406>
- Benito, J. F., Escobar, M. A. H., & Villaseñor, N. R. (2019). Conservación en la ciudad: ¿Cómo influye la estructura del hábitat sobre la abundancia de especies de aves en una metrópoli latinoamericana? *Conservation in the city: How does habitat structure influence the abundance of individual bird species in a Latin American metropolis?* In *Gayana* (Vol. 83, Issue 2).
- Bonilla, C. A., Rubio, Y. M. y Bonilla, S. A. (2021). Afectación por derrames de crudo ocasionados por acciones subversivas al oleoducto Caño Limón Coveñas. *Revista Ambiental Agua, Aire y Suelo* (RAAAS), 12(2). <https://ojs.unipamplona.edu.co/index.php/aaas/article/view/2572>
- Castellanos, L., Serrano, S. y Becerra, W. M. (2020). Preferencia por morfoespecies de babosas en diferentes cultivos y ambientes del municipio Pamplona, Norte de Santander. *Revista Ambiental Agua, Aire y Suelo* (RAAAS), 11(1). DOI: <https://doi.org/10.24054/aaas.v11i1.356>
- Castellanos, L. y Baldovino, A. L. (2021). Enfermedades foliares más importantes del cultivo de la fresa en la zona de Pamplona. *Revista Ambiental Agua, Aire y Suelo* (RAAAS), 12(1). DOI: <https://ojs.unipamplona.edu.co/index.php/aaas/article/view/2569/3133>
- Chandan, G., Jain, A., Jain, H., & Mohana. (2018). Real Time Object Detection and Tracking Using Deep Learning and OpenCV. *Proceedings of the International Conference on Inventive Research in Computing Applications, ICIRCA 2018, Icirca*, 1305–1308. <https://doi.org/10.1109/ICIRCA.2018.8597266>
- Chauhan, R., Ghanshala, K. K., & Joshi, R. C. (2018). Convolutional Neural Network (CNN) for Image Detection

- and Recognition. *ICSCCC 2018 - 1st International Conference on Secure Cyber Computing and Communications*, 278–282. <https://doi.org/10.1109/ICSCCC.2018.8703316>
- Corponor. (2020). *Plan de Acción 2020-2023*.
- Corvacho Ponce, C. de J., Hernández Reyes, A., & Jiménez Barriosnuevo, M. del C. (2022). Reciclaje tecnológico en Colombia: Reto desde las instituciones educativas. *CienciaMatria*, VIII(3), 1–13. <https://doi.org/10.35381/cm.v8i3.930>
- Flórez, M. A., Mosuquera, J., Ramón, J. D. y Caballero, J. E. (2019). Análisis de la contaminación de ruido generada por el flujo vehicular en el casco urbano del municipio de Chinácota, Norte de Santander. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 10(2). DOI: <https://doi.org/10.24054/19009178.v2.n2.2019.3964>
- Guerrero, J., Hernández, B. y Castellanos, L. (2021). Calidad del agua para sistemas de riego en Colombia. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 12(2). <https://ojs.unipamplona.edu.co/index.php/aaas/article/view/2573/3137>
- Higuera, F., Salamanca, J. R., Acosta, L. F. y Acero, M. (2018). Análisis de acero laminado antes y después de soldado, mediante pruebas de metalografía y macroataque. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 9(1). DOI: <https://doi.org/10.24054/19009178.v1.n1.2018.3209>
- Jiménez Guethon, R. M., Figueredo Hernández, J. A., & Almaguer Guerrero, M. R. (2022). Cooperativism-Some Notes on Social Responsibility and Solid Waste Management. *Revista Estudios Del Desarrollo Social: Cuba y América Latina*, 1–16. <https://orcid.org/0000-0002-4450-445X>
- Jordan, A. A., Pegatoquet, A., Castagnetti, A., Raybaut, J., & le Coz, P. (2021). Deep Learning for Eye Blink Detection Implemented at the Edge. *IEEE EMBEDDED SYSTEMS LETTERS*, 13(3). <https://doi.org/10.1109/LES.2020.3029313>
- Lozada Sastre, C. A. (2022). *Sistema autónomo para clasificación de material reciclable usando IA*.
- Mahecha, J. G., Castellanos, L. y Céspedes, N. (2020). Alternativas para Suplir la Carencia de Fósforo en Fresa y Disminuir la Contaminación Ambiental en Pamplona Norte de Santander. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 10(1). DOI: <https://doi.org/10.24054/aaas.v11i1.384>
- Montalvo, A., Aldana, R., López, A., Álvarez, E., Aldana, F. y Rivera, Y. (2018). Mantenimiento centrado en confiabilidad en motocompresores. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 9(1). DOI: <https://doi.org/10.24054/19009178.v1.n1.2018.3212>
- Mao, X.-J., Shen, C., & Yang, Y.-B. (2016). Image Restoration Using Very Deep Convolutional Encoder-Decoder Networks with Symmetric Skip Connections. *29th Conference on Neural Information Processing Systems*. <https://bitbucket.org/chhshen/image-denoising/>
- Mora, E. A., Martínez, E. y Velasco, J. A. (2018). Simulación y validación del prototipo de un colector térmico solar hecho con neumáticos reciclados. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 9(2). DOI: <https://doi.org/10.24054/aaas.v9i2.404>
- Niño Rondón, C. V., Castro Casadiego, S. A. y Ortíz Fonseca, D. M. (2021). Análisis de herramientas para desarrollar un sistema de apoyo ambiental para identificar residuos

- sólidos. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 12(2). <https://ojs.unipamplona.edu.co/index.php/aaas/article/view/2572/3136>
- Ortega, A., Cáceres, L. y Castiblanca, L. (2020). Introducción al Uso de Coagulantes Naturales en los Procesos de Potabilización del Agua. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 11(2). DOI: <https://doi.org/10.24054/aaas.v11i2.873>
- Pinto Rodríguez, V., Muñoz Ordóñez, J., & Pardo Burbano, M. (2021). Ecología: Inteligencia Artificial para el cuidado del medio ambiente, prototipo de clasificación de residuos sólidos en punto de origen. *Investigación e Innovación En Ingenierías*, 9(3), 46–56. <https://doi.org/10.17081/invinno.9.3.5312>
- Ramón, B. y Moreno, J. (2018). Estudio de materiales precursores del reciclaje y sus atributos mecánicos con aplicación al diseño y fabricación de ladrillo ecológico. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 9(1). DOI: <https://doi.org/10.24054/19009178.v1.n1.2018.3213>
- Sharma, N., Jain, V., & Mishra, A. (2018). An Analysis of Convolutional Neural Networks for Image Classification. *Procedia Computer Science*, 132(Iccids), 377–384. <https://doi.org/10.1016/j.procs.2018.05.198>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/s40537-019-0197-0>
- Terrero, W., Castellanos, L. y Vicet, L. (2020). Potencialidades alelopáticas del residual paja de la caña de azúcar (SACCHARUM SPP., HYBRID) para el manejo de arvenses. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 11(1) DOI: <https://doi.org/10.24054/aaas.v11i1.357>
- Torrado, J. M., Castellanos, L. y Céspedes, N. (2020). Evaluación de alternativas biológicas para el control de *Ascochyta Spp.* en el cultivo de arveja, Pamplona, Norte de Santander. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 11(1). DOI: <https://doi.org/10.24054/aaas.v11i1.353>
- Trujillo, J. E., Caballero, J. E. y Ramón, J. D. (2019). Determinación de las concentraciones de metales pesados presentes en el material particulado PM10 del municipio de San José de Cúcuta, Norte de Santander. *Revista Ambiental Agua, Aire y Suelo (RAAAS)*, 10(1). DOI: <https://doi.org/10.24054/19009178.v1.n1.2019.3957>
- Vianchá-Sánchez, Z., Rojas-Pinilla, H., & Barrera-Rojas, M. Á. (2021). Turismo y vulnerabilidad social. Reflexiones para algunos casos latinoamericanos. *Debates En Sociología*, 52, 7–30. <https://doi.org/10.18800/debatesensociologia.202101.001>