

ANÁLISIS DE LA DETECCIÓN E IDENTIFICACIÓN DE RESIDUOS MEDIANTE ULTRALYTICS YOLOV8

ANALYSIS OF DETECTION AND IDENTIFICATION OF RESIDUES USING ULTRALYTICS YOLOV8

BYAN ALECK AGUILAR
RODRÍGUEZ

FERNANDO CLEMENTE
COVARRUBIAS VELÁZQUEZ

ALAN REFUGIO PÉREZ
CASILLAS

JOSUÉ GÓMEZ CASAS

CARLOS ALBERTO TORO
ARCILA

JESÚS SALVADOR GALINDO
VALDÉS

DANIELA ESTEFANÍA ORTIZ
RAMOS

Facultad de Ingeniería,
Unidad Saltillo, UAdeC.

Correspondencia
jogomezc@uadec.edu.mx

Fecha de recepción
17 de febrero de 2025.

Fecha de aceptación
4 de abril de 2025.

RESUMEN

En México la generación de residuos sólidos es un desafío diario significativo, una proporción considerable de estos pertenecen a plásticos, cartón y latas de aluminio. Sin embargo, solo una pequeña parte de estos materiales se somete a reciclaje, mientras que el resto termina en vertederos o afecta a los ecosistemas. La presente investigación propone una metodología basada en redes neuronales convolucionales (CNNs) mediante el uso de YOLOv8 para la detección y segmentación de residuos sólidos como plásticos, cartón y latas en áreas naturales y urbanas. La investigación aborda las limitaciones de los métodos tradicionales de recolección y destaca la precisión de los modelos de visión por computadora en la identificación y clasificación de desechos, el modelo entrenado obtuvo precisiones de hasta 92.3 % en condiciones controladas y 40 % en entornos complejos con alta densidad de residuos, demostrando su eficiencia. La tecnología generada no solo mejora la cuantificación de desechos, sino que a su vez facilita la planificación de estrategias de remoción de estos, contribuyendo como una herramienta innovadora para la gestión ambiental en México.

Palabras clave: contaminación; redes neuronales convolucionales; detección de residuos; visión por computadora; inteligencia artificial.

ABSTRACT

In Mexico, the generation of solid waste is a significant daily challenge, with a considerable proportion of it consisting of plastics, cardboard, and aluminum cans. However, only a small fraction of these materials undergo recycling, while the rest ends up in landfills or affects ecosystems. This study proposes a methodology based on Convolutional Neural Networks (CNNs), specifically utilizing YOLOv8, for the detection and segmentation of solid waste, including plastics, cardboard, and aluminum cans, in both natural and urban environments. The research addresses the limitations of conventional waste collection methods and underscores the precision of computer vision models in waste identification and classification. The trained model achieved accuracy rates of up to 92.3% under controlled conditions and 40% in complex environments with high waste density, demonstrating its effectiveness. The developed technology not only enhances waste quantification but also facilitates the strategic planning of waste removal, serving as an innovative tool for environmental management in Mexico.

Keywords: *pollution; convolutional neural networks; waste detection; computer vision; artificial intelligence.*

INTRODUCCIÓN

La gestión de residuos sólidos en entornos urbanos y naturales representa un desafío ambiental significativo. En México la acumulación de desechos, particularmente en arroyos y cuerpos de agua, ha generado severas consecuencias ecológicas (Jiménez y col, 2001). La generación diaria de residuos sólidos supera las 120 mil toneladas, de las cuales el 12 % son plásticos, 10 % corresponde a cartón y 5 % a latas de aluminio. A pesar de este volumen significativo, solo una pequeña fracción de estos residuos se recicla, el resto acaba en



vertederos o en ecosistemas naturales. Mientras que los desechos orgánicos se degradan en semanas y el cartón en meses, los plásticos pueden persistir durante siglos, agravando la contaminación en ecosistemas frágiles (Segura y col., 2007). Productos de consumo masivo como plásticos, cartón y latas han invadido calles y cursos de agua debido a la limitada capacidad de los sistemas tradicionales de recolección, lo que deja espacios públicos expuestos a la contaminación.

Uno de los principales contaminantes es el tereftalato de polietileno (PET), cuya resistencia a la degradación le permite permanecer en el ambiente entre cien y mil años (Suasnavas Flores y col., 2017). Además, los microplásticos derivados de fibras y empaques han alcanzado niveles alarmantes en ecosistemas marinos y fluviales, con concentraciones de hasta 135 micropartículas por kilogramo de sedimento en playas mexicanas (Rivas y Garelli, 2021). Globalmente, se estima que 8 millones de toneladas de plástico llegan a los océanos anualmente, transportadas principalmente por arroyos y canales urbanos (Singh y col., 2016).

Los métodos convencionales de recolección han demostrado ser insuficientes para abordar esta crisis, por lo que se requieren soluciones innovadoras. Un enfoque emergente es el uso de redes neuronales convolucionales (CNNs), capaces de procesar grandes volúmenes de imágenes satelitales o captadas por drones para detectar y clasificar residuos (Bening, 2022; Weinstein, 2017). Estas tecnologías permiten la identificación precisa de "puntos críticos" de contaminación, facilitando operativos de limpieza más eficientes. La aplicación de CNNs en la detección de residuos plásticos, cartón y latas en arroyos representa una herramienta tecnológica prometedora para la optimización de estrategias de intervención, contribuyendo así a la mejora de la calidad ambiental y la salud pública.

El procesamiento de imágenes ha evolucionado significativamente con los avances en inteligencia artificial (IA). La introducción de un nuevo orden vectorial en espacios cromáticos ha mejorado la segmentación de imágenes, reduciendo brillos y ruido, lo que optimiza la creación de



bases de datos (Ortiz Zamora y col., 2002). Un etiquetado preciso es clave para la clasificación automática de imágenes y la efectividad de los modelos de procesamiento (Pérez-Careta y col., 2022).

La aplicación de redes neuronales para la detección y recolección de residuos ha demostrado su utilidad en entornos reales. Se han diseñado robots capaces de localizar botellas plásticas en playas, aunque la implementación en escenarios no controlados sigue siendo un desafío (Vázquez-Lucero y col., 2022). En 2023, nuevas arquitecturas lograron detectar basura en áreas urbanas, aunque la proximidad al vehículo recolector generó errores, resaltando la necesidad de drones para mejorar la recolección (Frutos y col., 2023). Estudios recientes evidencian que los sistemas de detección requieren optimización cuando la cantidad de residuos aumenta (Loaiza Alejandro y col., 2024).

En 2024, la IA ha avanzado en gestión y reciclaje de residuos, con modelos como YOLOv8 enfocados en detección sin cuantificación (Yáñez & Benavides, 2024). Matlab ha alcanzado un 70 % de éxito en la identificación de botellas, aunque con baja sensibilidad. El uso de bases de datos preentrenadas mejora los resultados y facilita la adaptación de modelos en plataformas como Raspberry Pi para la clasificación de residuos (Urgilez-Jaramillo et al., 2024; Salina y col., 2024). A pesar de estos avances, persisten retos en implementación real y optimización de sistemas de detección, siendo crucial la concientización y la adecuada preparación de datos para mejorar su eficacia.

La detección de plásticos en visión por computadora abarca diversas metodologías, sensores y software que ofrecen configuraciones con resultados favorables. Un enfoque es el uso de ondas sonoras para generar imágenes mediante el rebote en objetos, facilitando la segmentación en fluidos densos como el mar (Singh & Valdenegro-Toro, 2021). Para aplicaciones que requieren alta precisión en espacios reducidos, se emplean configuraciones de múltiples cámaras que capturan datos en 2D y 3D, útiles en plantas recicladoras para el conteo de material sobrante (Gursch y col., 2024).



Los algoritmos basados en espacios de color permiten identificar plásticos según su tonalidad (Khonáah y col., 2019). Sin embargo, el poder computacional puede ser un obstáculo, por lo que arquitecturas como U-Net, compatibles con plataformas de bajo consumo como Arduino, optimizan la detección en entornos remotos (Vázquez-Lucero y col., 2022).

La segmentación es esencial para refinar la silueta de objetos repetidos en múltiples instancias. Su uso en fotogramas de video mejora la precisión al ofrecer referencias consistentes (Perazzi y col., 2017; Wang y col., 2021). Redes bien entrenadas pueden clasificar una amplia variedad de objetos con alta precisión, incluso en imágenes densas (Chen y col., 2019). Este proyecto busca rapidez en la segmentación y versatilidad en diversas condiciones sin comprometer el rendimiento computacional. Para ello, se emplea YOLO, ampliamente utilizado en la detección de residuos (Loaiza Alejandro, 2024). En particular, se explora su octava versión, que permite segmentación avanzada, detallada en los siguientes apartados.

YOLO emplea una red neuronal para procesar imágenes a distintos niveles, identificando patrones con rapidez y precisión según su entrenamiento. Cada capa del modelo contribuye a la detección de características específicas, similar al funcionamiento de las neuronas biológicas, pero a mayor escala y con mayor sofisticación.

El reconocimiento de patrones ha avanzado significativamente gracias al aumento en la capacidad de cómputo y una mejor comprensión de sus mecanismos en seres humanos y animales (Basu y col., 2010). Las redes neuronales destacan en esta tarea por su resistencia a distorsiones, menor demanda de recursos y facilidad de entrenamiento (Hijazi y col., 2015).

El proceso de detección de un objeto divide la imagen en una cuadrícula, donde cada celda evalúa la presencia de un objeto y asigna un nivel de confianza. Además, genera contornos delimitadores



(*bounding boxes*), optimizando la localización y facilitando la identificación visual.

El algoritmo de detección de objetos se originó como una herramienta innovadora para la detección de objetos, destacándose por su rapidez y su capacidad para analizar imágenes de entrada en un único paso. Este enfoque, fiel a su nombre, logra procesar la información manteniendo un alto nivel de detalle en sus resultados. YOLO combina precisión y velocidad, posicionándose como una solución ideal para aplicaciones en tiempo real. Desarrollado inicialmente como un proyecto de código abierto, este algoritmo ha sido continuamente mejorado por una activa comunidad de desarrolladores, quienes han optimizado su rendimiento y ampliado sus funcionalidades en versiones posteriores. Es relevante comparar YOLOv8 con otros modelos de segmentación e identificación de objetos, como SSD y Mask R-CNN. SSD (Single Shot MultiBox Detector) se caracteriza por su capacidad de detección en tiempo real con menor precisión en la segmentación, mientras que Mask R-CNN proporciona contornos más detallados, aunque con mayor demanda computacional. YOLOv8 equilibra velocidad y precisión, ofreciendo un rendimiento adecuado para la detección de residuos en escenarios no estructurados. Esta comparación permite justificar la selección de YOLOv8 en la presente investigación.

En este trabajo se utilizó el algoritmo en su octava versión, esta decisión se fundamentó en su capacidad avanzada de segmentación, una característica crucial para la estimación precisa de la cantidad de desechos en diversos entornos. A diferencia de la simple detección de objetos, la segmentación no solo identifica la presencia de un objeto, sino que delimita su silueta, permitiendo determinar la proporción del área afectada por desechos. El uso de redes neuronales en tareas de limpieza no es una innovación reciente; a nivel global, numerosos equipos han explorado la efectividad de los algoritmos de detección computarizada en aplicaciones similares. Sin embargo, el contexto en el que se implementa este algoritmo en particular resalta su capacidad para ofrecer una utilidad más allá de las zonas urbanizadas, donde la presencia de desechos es fácilmente identificable. En contraste, en áreas poco desarrolladas, particularmente aquellas cubiertas por vegetación,



arena o rocas, el algoritmo enfrenta un desafío adicional, pues estos factores dificultan la detección. En México, persisten numerosas áreas con escaso desarrollo humano, pero con una considerable acumulación de residuos sólidos en carreteras, terrenos, arroyos, lagos y ríos. Esto complica la estimación de la presencia de desechos en extensas áreas mediante métodos convencionales, como la inspección visual o el uso de drones, los cuales pueden pasar por alto zonas afectadas.

El objetivo de este estudio es evaluar la detección de residuos sólidos (plástico, cartón y latas), mediante el uso de herramientas de visión por computadora como el algoritmo de detección de objetos avanzado, permite la identificación de estos debido a la vegetación, factores cromáticos y ambientes no estructurados como en el caso de arroyos.

MATERIALES Y MÉTODOS

El uso de redes neuronales convolucionales permite la detección y segmentación de plásticos, cartón y latas en arroyos y áreas circundantes. Este enfoque es ideal para entornos complejos, ya que las redes neuronales aprenden características relevantes de las imágenes, optimizando la identificación de residuos. A continuación, se describe la metodología utilizada en este proyecto.

Definición de parámetros y detección: Se establecen las clases a detectar (cartón, latas y plásticos), considerando sus características visuales para asegurar una base de datos diversa y representativa.

1. **Recolección de imágenes:** Se obtienen imágenes de bases de datos en línea y capturas manuales en Ciudad Universitaria y Boulevard Fundadores, aplicando técnicas de preprocesamiento para mejorar la variabilidad de los datos.
2. **Creación de base de datos:** Se adaptan los datos a la segmentación utilizando algoritmos como YOLOv8 y SAM (Segment Anything Meta



AI), garantizando una detección precisa mediante la automatización de polígonos en las imágenes.

3. Entrenamiento y validación: Se entrena la red neuronal con diversas condiciones de los objetos y se valida su precisión con imágenes de prueba y ensayos en entornos controlados.
4. Segmentación semántica: Se desarrolla un algoritmo para calcular los píxeles ocupados por cada objeto y asignar su categoría, asegurando una identificación precisa.
5. Implementación en campo: Se prueba el modelo en escenarios reales mediante fotos, videos y streaming, evaluando su desempeño y ajustándolo para mejorar su eficacia y ampliar su aplicabilidad.

ENTRENAMIENTO DE LA RED

Para entrenar una red neuronal, es esencial definir su tarea específica. YOLOv8 ofrece funciones como detección, segmentación, clasificación y estimación de pose. En este proyecto, se elige la segmentación, ya que permite no solo detectar un objeto, sino también delimitar su silueta con precisión.

El entrenamiento en segmentación requiere datos que representen la forma completa del objeto, diferenciándose del enfoque de detección, que solo identifica su presencia y ubicación. Se emplean dos tipos de datos:

- Cuadros delimitadores: Utilizan recuadros con etiquetas para cada clase, especificando la ubicación del centro, altura y ancho del objeto, adecuados para detección.
- Polígonos: Formados por múltiples puntos que siguen el perímetro del objeto con detalle, esenciales para la segmentación semántica de formas complejas.

TRANSFORMACIÓN DE BASES DE DATOS

Para adaptar una base de datos de detección al formato de segmentación, es necesario modificar las etiquetas de las imágenes.



Este proceso puede realizarse manualmente, aunque resulta laborioso, o mediante herramientas automatizadas.

YOLOv8 incluye opciones para facilitar esta conversión, recomendándose el uso de SAM (Segment Anything Model), un algoritmo que segmenta automáticamente los objetos en una imagen. Cuando se trabaja con bases de datos etiquetadas para detección, SAM ajusta su alcance para segmentar solo las clases correctas.

El uso de una versión pre-entrenada de YOLOv8 mejora la precisión, reduciendo errores en la segmentación manual. Este proceso se realiza en un editor de código como PyCharm, donde se importan las dependencias y el modelo SAM-L. Luego, se especifican las rutas de las imágenes y del modelo pre-entrenado. Tras la segmentación, se generan archivos con las coordenadas de los polígonos, obteniendo una base de datos actualizada en formato de segmentación.

PRUEBAS DE LAS BASES DE DATOS GENERADAS

La integración de herramientas como YOLO y Roboflow ha optimizado la creación de bases de datos, mejorando el etiquetado y la organización de los datos. Estas herramientas facilitan la revisión de segmentaciones y la corrección de errores, evitando fallos en la identificación de clases y reduciendo la carga de trabajo.

El uso de segmentación automática ahorra tiempo en comparación con el etiquetado manual. Ejemplos como la base de datos TrashCan (Hong, 2020), con 7,212 imágenes, requirieron 1,700 horas de trabajo manual, mientras que ZeroWaste (Bashkirova y col., 2022), con 4,661 imágenes, tomó un promedio de 12 minutos por imagen.

Un enfoque mixto, que combina segmentación automática con revisión manual, optimiza significativamente el tiempo. En un caso práctico, se procesaron 2 mil 500 imágenes en tres clases en solo 40 horas, evidenciando una mejora sustancial respecto a los métodos manuales.



CÁLCULO DEL NIVEL DE CONFIANZA

Para evaluar la precisión del modelo se comparan visualmente las predicciones con la imagen original. Sin embargo, YOLOv8 también proporciona una métrica cuantitativa basada en la confianza, la cual mide la certeza del modelo en sus detecciones.

La confianza se calcula mediante la ecuación:

$$\text{Confianza} = P(\text{obj}) \times \text{IoU} \quad (1).$$

Donde:

- $P(\text{obj})$ es la probabilidad de que un objeto esté presente en la caja de detección.
- IoU (Intersección sobre Unión) cuantifica la superposición entre la caja predicha y la real (ground truth).

Esta métrica permite evaluar la certeza y precisión espacial del modelo, filtrando detecciones erróneas. Posteriormente, se analiza la clase del objeto detectado y se asigna un valor numérico a cada predicción, optimizando la identificación precisa dentro de la imagen.

FASE DE VALIDACIÓN DE LA RED NEURONAL

Durante la fase de validación se realizan pruebas iterativas para evaluar el desempeño del modelo y comparar bases de datos manuales con un enfoque híbrido. Este paso es clave para analizar la evolución de la confianza del algoritmo en un entorno con poco ruido.

En las primeras iteraciones los modelos entrenados con clases individuales mostraron baja confianza, debido a que los datos de entrenamiento correspondían a condiciones ideales (buena iluminación, orientación y estado del residuo). Sin embargo, en entornos reales, los residuos presentan deformaciones, manchas y deterioro, afectando la precisión del modelo. Dado que las redes



neuronales convolucionales aprenden exclusivamente de los datos proporcionados, es necesario ampliar la diversidad de instancias para

RESULTADOS

En esta investigación se compararon dos zonas geográficas para evaluar diferencias en la densidad cromática y la variabilidad de patrones del terreno, factores clave en la detección de residuos. La primera zona analizada fue en el Campus Arteaga de la Universidad Autónoma de Coahuila, ubicado en Blvd. Fundadores, km 13, Arteaga, Coahuila. Su baja densidad cromática facilita la identificación de residuos, ya que la escasa vegetación y el terreno árido permiten que plásticos, cartón y latas resalten en las imágenes, simplificando su análisis. En contraste, el Parque Hundido en Saltillo, Coahuila presenta una alta densidad cromática debido a su variada vegetación y diversidad de colores en el terreno. Esto dificulta la detección de residuos por la interferencia visual, pero también permite obtener información más detallada sobre su distribución, requiriendo un procesamiento más complejo.



Figura 1: a) imágenes de baja concentración de residuos; b) imágenes de alta concentración de residuos.



El modelo fue evaluado en dos escenarios: baja y alta densidad de residuos. En la Figura 1a se muestra un entorno con poca concentración de residuos, la segmentación alcanzó una precisión del 86 al 88 %, demostrando su efectividad en áreas urbanas con distribución uniforme y menor interferencia. En contraste, en la Figura 1b se presenta un escenario con alta densidad de residuos, el volumen y la irregularidad de los desechos dificultaron la segmentación. Aun así, el modelo mantuvo una precisión del 83 al 92.3 %, mostrando una alta confianza en la identificación de plásticos, incluso en condiciones más complejas.

MODELO DE RED NEURONAL CON TRES CLASES DE DETECCIÓN

El modelo YOLOv8 demuestra una gran capacidad de adaptación en la detección de plásticos, cartón y latas, operando con precisión tanto en entornos controlados como no controlados. Su rendimiento se mantiene estable frente a variaciones en iluminación, ángulos de cámara y elementos distractores. Utilizando mean Average Precision (mAP) como métrica principal, alcanza un promedio de precisión del 86 %. Además, realiza segmentaciones semánticas detalladas, permitiendo identificar y clasificar residuos incluso cuando diferentes tipos coexisten en una misma escena.

Los resultados de la Figura 2 muestran que el modelo marca y etiqueta claramente los objetos, proporcionando predicciones consistentes y diferenciando con precisión los materiales reciclables, incluso cuando están agrupados, lo que representa un desafío común en la clasificación automática.



Figura 2. Imagen Segmentada para botellas y latas, Ciudad universitaria, Arteaga, Coahuila.

En la Figura 3 se muestra como YOLOv8 reentrenado identifica y segmenta residuos como botellas de PET y latas de aluminio en entornos no controlados, alcanzando precisiones entre 70 y 75 %. Su capacidad para detectar múltiples objetos, incluso con variaciones en textura y color, demuestra su eficacia en la clasificación de materiales en escenarios complejos. Estos resultados resaltan la fiabilidad del modelo, manteniendo predicciones consistentes a pesar de las condiciones no ideales del entorno.



Figura 3. Segmentación semántica de botellas, latas y cartón en escenarios con bajos índices cromáticos.



Figura 4. Segmentación de botellas, latas y cartón en el Parque Hundido de Saltillo, Coahuila, en escenarios con altos índices cromáticos.

La Figura 4 muestra como el YOLOv8 modificado logra una precisión del 92% en la segmentación de residuos de cartón, incluso en escenarios con ángulos variables y superficies irregulares. Su capacidad para adaptarse a diferentes condiciones y distinguir entre materiales similares demuestra su eficacia en la clasificación automatizada de desechos, consolidándolo como una herramienta robusta para este tipo de aplicaciones.



En áreas con alta densidad de datos, como el Parque Hundido en Saltillo, Coahuila, YOLOv8 modificado enfrenta desafíos debido a la distancia y variabilidad cromática del entorno. A pesar de estas dificultades, el modelo logra un 40 % de precisión en la detección de residuos. Si bien este valor es inferior al obtenido en entornos controlados, se encuentra dentro de los rangos reportados en estudios previos para escenarios no estructurados (Gursch y col., 2024). Esto indica que el modelo presenta un desempeño funcional en condiciones visuales complejas, aunque con margen de mejora para aumentar su precisión.

DISCUSIÓN

En México los productos residuos sólidos están presentes en prácticamente todos los aspectos de la vida diaria, destacando por su alto nivel de consumo y desecho. El uso masivo de plásticos se refleja en la cifra de un millón 951 mil 785 kg de residuos plásticos generados diariamente, lo que coloca a México como un gran productor de estos materiales (Ocampo y col., 2019). A pesar de la creciente conciencia sobre los efectos contaminantes de los plásticos, cartón y productos de aluminio, la falta de herramientas para medir estos residuos en el medio ambiente sigue siendo un obstáculo significativo para una gestión efectiva y acciones concretas que mitiguen el impacto. En la visión por computadora, existen diversas alternativas y enfoques para llevar a cabo el proceso de detección de residuos sólidos. Estas tecnologías pueden mejorar la optimización, así como los procesos operativos, facilitando la recopilación de datos estadísticos. Dichos datos permiten tomar decisiones informadas que favorecen el diseño de políticas públicas en gestión de desechos. De este modo, la presente investigación se posiciona como una solución en un sector en expansión, respaldado por iniciativas gubernamentales orientadas a la reducción de residuos y la promoción del reciclaje.



CONCLUSIONES

El uso de redes neuronales convolucionales, específicamente YOLOv8, representa un avance significativo en la detección y segmentación de residuos sólidos como plásticos, cartón y latas en entornos urbanos y naturales. La implementación del modelo requirió la definición de parámetros de detección, recolección de imágenes, entrenamiento y validación, asegurando su precisión en distintos escenarios.

Los resultados muestran una precisión del 86 % en entornos controlados y hasta 92.3 % en zonas con alta concentración de residuos, aunque en áreas con alta variabilidad cromática, la precisión se reduce al 40 %, representando una oportunidad de mejora como trabajo a futuro de esta investigación. La combinación de Inteligencia Artificial y Visión por Computadora optimiza la planificación de estrategias de reciclaje y reducción del impacto ambiental. Como trabajo futuro, se plantea la integración de técnicas de cuantificación de residuos para estimar con mayor precisión la distribución y volumen de desechos, fortaleciendo las estrategias de gestión y mitigación en distintos entornos.

REFERENCIAS

- Bashkirova, D., Abdelfattah, M., Zhu, Z., Akl, J., Alladkani, F., Hu, P., y Saenko, K. (2022). Zerowaste dataset: Towards deformable object segmentation in cluttered scenes. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022*: 21147–21157.
- Basu, J. K., Bhattacharyya, D. y Kim, T. H. (2010). Use of artificial neural network in pattern recognition. *International Journal of Software Engineering and Its Applications, 4*(2): 23–34.
- Bening, C. R., Kahlert, S. y Asiedu, E. (2022). The true cost of solving the plastic waste challenge in developing countries: The case of Ghana. *Journal of Cleaner Production, 330*: 129649. <https://doi.org/10.1016/j.jclepro.2021.129649>



- Chen, X., Girshick, R., He, K. y Dollár, P. (2019). Tensormask: A foundation for dense object segmentation. *Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019*: 2061–2069.
- Gursch, H., Schlager, E., Thaler, F., Waltner, G., Ganster, H., Rinnhofer, A., Jaschik, M., Oberwinkler, C., Meisenbichler, R., Bischof, H., et al. (2024). Image capturing, segmentation and data analysis of shredded refuse streams. *Waste Management & Research, 42*(9): 738–746.
- Hijazi, S., Kumar, R. y Rowen, C. (2015). Using convolutional neural networks for image recognition. *Cadence Design Systems Inc.* <https://www.edge-ai-vision.com/2015/11/using-convolutional-neural-networks-for-image-recognition/>
- Hong, J., Fulton, M., & Sattar, J. (2020). Trashcan: A semantically-segmented dataset towards visual detection of marine debris. *arXiv preprint arXiv:2007.08097*.
- Jiménez, B. E. (2001). *La contaminación ambiental en México*. Editorial Limusa.
- Khona'ah, B., Rosiliani, D. y Yani, I. (2019). Identification and classification of plastic color images based on the RGB method. *Journal of Multidisciplinary Engineering Science and Technology (JMEST), 6*(5): 543–549.
- Loaiza Alejandro, B. J. (2024). *Sistema de clasificación de botellas mediante el reconocimiento de imágenes para el tratamiento de basura* (B.S. thesis). Universidad Nacional de Chimborazo, Riobamba.
- Ocampo, M., & Santa Catarina, C. (2019). Plásticos en los océanos. *INCyTU Of. Inf. Científica y Tecnológica para el Congr. la Unión, 34*(6): 9-034.
- Ortiz Zamora, F. G. (2002). *Procesamiento morfológico de imágenes en color: Aplicación a la reconstrucción geodésica*. Tesis Doctoral. Departamento de Física, Ingeniería de Sistemas y Teoría de la Señal. Universidad de Alicante. <https://rua.ua.es/dspace/handle/10045/10053>
- Pérez-Careta, E., Guzmán-Sepúlveda, J. R., Lozano-García, J. M., Torres-Cisneros, M. y Guzmán-Cabrera, R. (2022). Clasificación de imágenes médicas mediante aprendizaje automático. *DYNA, 97*(1): 35–38. <https://doi.org/10.6036/10117>
- Perazzi, F., Khoreva, A., Benenson, R., Schiele, B. y Sorkine-Hornung, A. (2017). Learning video object segmentation from static images. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017*: 2663–2672. <https://doi.org/10.1109/CVPR.2017.284>



- Singh, P. y Sharma, V. S. (2016). Integrated plastic waste management: Environmental and improved health approaches. *Procedia Environmental Sciences*, 35: 692–700.
- Rivas, M. y Garelli, O. (2021). Impacto de la contaminación por plásticos en la biodiversidad y patrimonio biocultural de México. *Heinrich Böll Stiftung (ING, México)*. <https://mx.boell.org/es/2021/03/10/impacto-de-la-contaminacion-porplasticos-en-la-biodiversidad-y-patrimonio-biocultural> (Activo Febrero de 2022).
- Salina, M., Pezet, B., Osés, L., Cappelletti, M., Osio, J. y Morales, M. (2024). Técnicas de deep learning aplicadas a un sistema de clasificación de objetos para un recolector de residuos inteligente. *Electronic Journal of SADIO (EJS)*, 23(1): 81–98.
- Segura, D., Noguez, R. y Espín, G. (2007). Contaminación ambiental y bacterias productoras de plásticos biodegradables. *Biotecnología*, 14(3): 361–372.
- Singh, D. y Valdenegro-Toro, M. (2021). The Marine Debris Dataset for Forward-Looking Sonar Semantic Segmentation. *Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021*: 3741–3749.
- Suasnavas Flores, D. F. (2017). *Degradación de materiales plásticos “PET” (Polyethylene Terephthalate), como alternativa para su gestión*. [Formato por definir].
- Wang, H., Jiang, X., Ren, H., Hu, Y. y Bai, S. (2021). SwiftNet: Real-time video object segmentation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021*: 1296–1305.
- Weinstein, B. G. (2017). A computer vision for animal ecology. *Journal of Animal Ecology*, 87: 1–15.
- Yáñez, J. M. S. y Benavides, L. M. (2024). Gestión de residuos sólidos y la inteligencia artificial en el contexto mexicano. *Ciencia Nicolaita*, 90: 121–134.