

Red neuronal para la detección inteligente de residuos orgánicos: hacia una solución ambiental sostenible

Neuronal Network for Intelligent Detection of Organic Waste: Towards a Sustainable Environmental Solution

Guadalupe Navarro Enríquez^{1a}, Trinidad Reyes Portillo^{1b}, Dionisio Navarrete Baloes^{1c}, Irving Bruno López Santos^{1a}, Quetzal Elohim Bastarrachea Almodóvar^{1d}, Geu M. Puentes-Conde²  

¹ {^a Departamento de Ingeniería Eléctrica/Electrónica/Mecatrónica}, {^b Programa de Ingeniería Industrial, Departamento de Ingeniería Industrial y Logística}, {^c Programa de Ingeniería en Sistemas}, {^d Programa de Ingeniería Mecánica}, Tecnológico Nacional de México Campus Ciudad Juárez, Chihuahua, México

² Departamento de Ingeniería Industrial y Manufactura, Instituto de Ingeniería y Tecnología, Universidad Autónoma de Ciudad Juárez, Chihuahua, México

RESUMEN

El crecimiento poblacional es un fenómeno global que, a lo largo de las últimas décadas, ha cobrado una relevancia crítica en el contexto del desarrollo económico y de la sostenibilidad ambiental. A medida que la población mundial supera los 8000 millones, las naciones enfrentan el desafío de equilibrar el crecimiento económico con la protección del medio ambiente [1]. Por ello, se desarrolló un modelo basado en redes neuronales convolucionales para residuos orgánicos. La metodología consistió en la construcción de un *dataset* con 1000 imágenes de desechos en hogares y escuelas, el entrenamiento del modelo YOLOv5x mediante el descenso de gradiente y la evaluación de métricas. En los resultados iniciales se observó un rendimiento limitado; no obstante, al incrementar el número de épocas y mejorar la calidad del *dataset*, la precisión alcanzó el 80 %. Esto evidencia la importancia de contar con imágenes de alta calidad para optimizar el aprendizaje automático, así como la necesidad de ajustes iterativos durante el entrenamiento del modelo. En conclusión, la investigación confirma la viabilidad de aplicar la visión artificial a la clasificación de residuos. El modelo se limitó a residuos orgánicos. Estos avances contribuyen al fortalecimiento de la cultura ambiental y al desarrollo de sistemas inteligentes que promuevan prácticas sostenibles en México.

PALABRAS CLAVE: residuos orgánicos; redes neuronales convolucionales; visión artificial; clasificación de residuos; YOLOv5x.

ABSTRACT

By 2025, the population was recorded at 129.7 million, and it is estimated to reach 148.2 million by 2050. This increase generates a greater demand for resources and an increase in the production of urban solid waste, the classification of which remains a challenge due to lack of knowledge and citizen interest [1]. Therefore, a convolutional neural network-based model for organic waste was developed. The methodology consisted of constructing a dataset with 1000 images of waste from homes and schools, training the YOLOv5x model using gradient descent, and evaluating metrics. Initial results showed limited performance; however, by increasing the number of epochs and improving the quality of the dataset, accuracy reached 80%. This highlights the importance of high-quality images for optimizing machine learning, as well as the need for iterative adjustments during model training. In conclusion, the research confirms the feasibility of applying computer vision to waste classification. The model was limited to organic waste. These advances help strengthen environmental culture and develop intelligent systems that promote sustainable practices in Mexico.

KEYWORDS: eco-efficient control; organic waste; convolutional neural networks; computer vision; waste classification; YOLOv5x.

Correspondencia:

DESTINATARIO: Geu M. Puentes Conde

INSTITUCIÓN: Universidad Autónoma de Ciudad Juárez / Instituto de Ingeniería y Tecnología

DIRECCIÓN: Av. del Charro núm. 450 norte, C. P. 32320, Ciudad Juárez, Chih., México

CORREO ELECTRÓNICO: al252030@alumnos.uacj.mx

Fecha de recepción: 11 de noviembre de 2025. **Fecha de aceptación:** 19 de marzo de 2026. **Fecha de publicación:** 30 de abril de 2026.



Licencia Creative Commons



I. INTRODUCCIÓN

El crecimiento poblacional es un problema severo en todo el mundo. En particular, se prevé que la población mexicana continúe aumentando en décadas futuras, para alcanzar en el año 2040 un total de 144 millones 476 530 personas [2]. Aunado a esto, el consumo masivo de productos para satisfacer las necesidades de alimentación genera una gran cantidad de residuos que van a parar al relleno sanitario.

En Ciudad Juárez, Chihuahua, México, como parte de las acciones ciudadanas respecto del desecho de residuos domiciliarios, ha iniciado la separación en orgánicos e inorgánicos, buscando su aprovechamiento. De acuerdo con la información obtenida de las encuestas de percepción ciudadana en 2021, en la [Figura 1](#) se muestra que el 26.5 % de la población sí separa sus residuos, mientras que el 73.5 % no lo hace.

Existen distritos que colaboran más con la separación de residuos domiciliarios en comparación con otros, por ejemplo, los distritos 3 y 8 con 30.0 % y 30.6 %, mientras que en la mayoría de los distritos es de menos del 30 %, imposibilitando procesos de compostaje y reciclado o reúso de materiales.

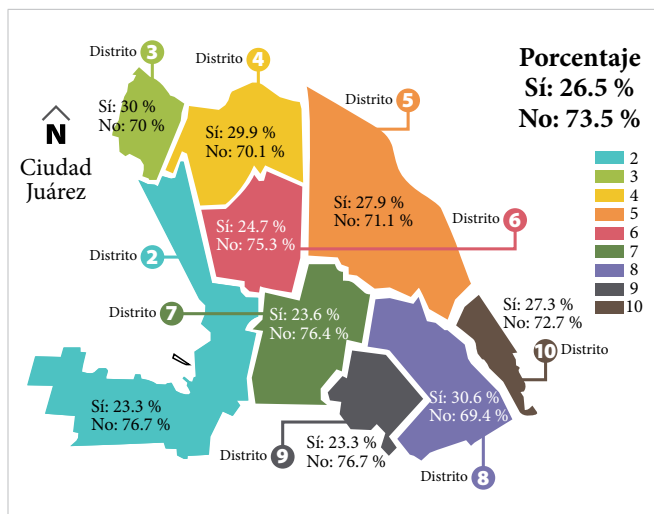


Figura 1. Distritos de reciclaje y separación. Fuente: Así Estamos Juárez, Encuesta de Percepción Ciudadana 2021.

El relleno sanitario de Ciudad Juárez consta de una macrocelda con el 45 % de capacidad libre y se tiene una proyección de otra macrocelda 3 (200 hectáreas) con capacidad de recibir 2400 toneladas diarias (comparado con las 2300 de la celda actual) y una vida útil de 15

años. Esto resulta por demás relevante, dado que se prevé un aumento del 1 % anual en cuanto a la generación de residuos sólidos para los próximos 10 años, haciendo urgente contar con un plan adecuado de residuos municipales, con visión de circularidad. Los residuos, según el Diagnóstico Básico para la Gestión Integral de los Residuos, se componen de la siguiente manera: plásticos 19.62 %, papel 5.07 %, cartón 6.06 % y metal 2.43 %, entre otros, siendo los más importantes para el presente estudio los de comida 33.07 % y los de jardinería 10.84 %.

Por ende, las recomendaciones para establecer un programa de separación de residuos deben centrarse en la adecuación del servicio de recolección por tipo de residuo, en la oferta de incentivos o en la aplicación de sanciones, entre otras medidas [3]. Por tal motivo, es importante que se fomente la cultura del manejo de residuos en cada uno de los niveles educativos, a través de las materias de desarrollo sustentable o relacionadas.

La generación de residuos sólidos urbanos (RSU) constituye una de las mayores preocupaciones a nivel mundial debido al impacto social y ambiental que producen. Alrededor del 50 % de los RSU está compuesto por residuos orgánicos (RO) y, actualmente, las principales prácticas de gestión de estos resultan inadecuadas, lo que favorece el avance del calentamiento global [4].

El enfoque de cero residuos tiene como finalidad evitar que no se generen estos y asegurar que la mayor parte de los materiales producidos se reutilicen, reciclen, composten o valoricen, reduciendo al mínimo los desechos que se envían a disposición final [5]. Considerando que los residuos orgánicos se podrían reducir si se tuviera conocimiento en el tema, el objetivo de la presente investigación es ayudar a la correcta clasificación para realizar el tratamiento adecuado. Una opción que debe tomarse en cuenta antes de comenzar a tratar el residuo es la separación, también conocida como segregación, aunque es un problema evidente el hecho de que las personas no saben identificar los tipos de residuos que producen.

Hoy en día, la tecnología avanza y se considera en este estudio el aprovechamiento de herramientas que faciliten la clasificación. El manejo integral de residuos urbanos no solo consiste en reciclar y reutilizar, sino también en emplear las opciones más adecuadas para su tratamiento.

A. DETECCIÓN DE OBJETOS MEDIANTE EL ENTRENAMIENTO DE REDES NEURONALES CONVOLUCIONALES

El aprendizaje profundo o Deep Learning (DL) es una técnica que, mediante el entrenamiento, busca lograr la toma de decisiones para la identificación de objetos. Las redes neuronales convolucionales facilitan el aprendizaje profundo, ya que extraen y procesan imágenes mediante varias capas y facilitan su clasificación e identificación.

En la revisión exhaustiva de la literatura se encontró que la identificación de imágenes no es algo nuevo, por ejemplo, en la detección de gestos de somnolencia al conducir es una buena medida para evitar accidentes [6]. Para entrenar una red neuronal en tareas de visión por computadora, es necesario disponer de un conjunto de imágenes que represente los casos de uso deseados. A cada imagen se le asigna una o más etiquetas, que indican el contenido de la imagen o las características específicas que la red debe aprender a reconocer (por ejemplo, la clase del objeto, su posición o sus puntos clave). El proceso de etiquetado consiste en anotar, manual o automáticamente, cada imagen con su información correspondiente (clase, coordenadas, etc.), generando un conjunto de datos estructurado que puede utilizarse para entrenar modelos de aprendizaje supervisado. Este proceso es crítico, ya que la calidad y precisión de las etiquetas afectan directamente al rendimiento del modelo entrenado.

B. DETECCIÓN DE OBJETOS MEDIANTE EL ENTRENAMIENTO DE REDES NEURONALES CONVOLUCIONALES

YOLO enfoca la detección de objetos como un problema de regresión de cajas delimitadoras separadas espacialmente y las probabilidades de clase asociadas. Una sola red neuronal predice las cajas y las probabilidades de clase directamente a partir de imágenes completas durante la evaluación. Es una familia de arquitecturas y modelos de detección de objetos entrenados previamente en el conjunto de datos COCO, y representa la investigación sobre métodos de inteligencia artificial en visión futura, que incorpora prácticas desarrolladas durante miles de horas de investigación y desarrollo.

II. METODOLOGÍA

La metodología se determinó para construir un sistema eficiente para la clasificación de residuos orgánicos

mediante visión por computadora. Para ello, se empleó un *dataset* integrado por imágenes de alta resolución descargadas de fuentes abiertas y capturadas durante la elaboración de lombricomposta en el Campus Ciudad Juárez del Tecnológico Nacional de México ([Figura 2](#)).



Figura 2. Tomates cultivados usando lombricomposta del Campus Ciudad Juárez del TecNM.

A diferencia de la literatura consultada, que solo consideraba los desechos inorgánicos, se tomaron en cuenta los desechos orgánicos, que se desestiman al momento de separar los residuos [7], [8], [9]. El proceso metodológico incluyó tres etapas principales:

1. Crear el *dataset*. Almacenar un conjunto de imágenes del objeto que se desea detectar, etiquetadas cada una, m señalando el objeto a detectar.
2. Entrenamiento. Elegir el marco de aprendizaje para entrenar una red neuronal.
3. La inferencia. Poner en práctica el aprendizaje de la red neuronal en tiempo real.

B. CREACIÓN DEL DATASET

Se dividió el *dataset* en 70 % de entrenamiento, 20 % de validación y 10 % de prueba. En la [Figura 3](#) se muestran las imágenes etiquetadas con la herramienta MakeSense.ai, lo que genera anotaciones compatibles con YOLOv5x.




Figura 3. Etiquetado y clasificación de imágenes en MakeSense.ai

B. ENTRENAMIENTO EN GOOGLE COLAB (PYTHON)

Como muestra la [Figura 4](#), se clonó el repositorio oficial de YOLOv5 desde GitHub y se instalaron las dependencias a partir del archivo requirements.txt, que contiene todas las librerías necesarias para ejecutar y entrenar el modelo correctamente.

```
!git clone https://github.com/ultralytics/yolov5 # clone
%cd yolov5
%pip install -qr requirements.txt comet_ml # install

import torch
import utils
display = utils.notebook_init() # checks
```

Figura 4. Instalación de requerimientos en Yolo.

Se generó la ruta de la configuración del *dataset* y se creó el archivo YAML que es el encargado de indicar la dirección del conjunto de datos y de las clases [10]. Para llevar a cabo el entrenamiento de la red neuronal, se utilizó el archivo de configuración coco128.yaml, que es fundamental para definir los parámetros y rutas necesarios para la correcta ejecución del modelo. Para esto se usó el editor PyCharm. El archivo YAML fue modificado de la siguiente manera:

- Definición de clases y número de clases. Se actualizaron las clases a reconocer por el modelo, adaptando el archivo para reflejar las clases específicas del conjunto de datos utilizado. En lugar de las clases estándar del conjunto de datos COCO, se ajustó el número de clases y sus etiquetas correspondientes para adaptarse al problema de clasificación específico. Este cambio asegura que el modelo esté entrenado para detectar únicamente las clases relevantes.
- Especificación de la ruta de los datos. Se modificó la ruta del archivo comprimido data.zip, que contiene tanto las imágenes como las anotaciones del conjunto de datos. Este archivo se descomprime automáticamente al iniciar el proceso de entrenamiento. La especificación correcta de la ubicación de los datos es crucial para que la red neuronal pueda acceder a las imágenes y sus etiquetas durante la fase de entrenamiento.

C. ENTRENAMIENTO

El modelo YOLOv5x se entrenó con imágenes de 640×640 px, *batch size* de 4 y 50 épocas, utilizando el

optimizador SGD con una *learning rate* de 0.01, en Google Colab con un GPU Tesla T4. Las épocas son los ciclos de entrenamiento. Entre mayor número de épocas, mayor entrenamiento y entre mayor entrenamiento más precisa es la red. Las imágenes se agruparon en paquetes. Esto se relacionó directamente a la forma en la que aprende la red agrupando las imágenes orgánicas en un solo lote y comparando los resultados contra los resultados verdaderos mediante el método de minimización descenso del gradiente.

El entrenamiento se configuró con base en la capacidad del hardware. Estos parámetros son cruciales para el rendimiento y la efectividad del entrenamiento, y pueden mejorarse. Para la detección y clasificación de residuos orgánicos, se empleó el modelo YOLO (You Only Look Once) [11] debido a su alta eficiencia en tareas de visión por computadora en tiempo real.

La implementación se realizó en el entorno de Google Colab, aprovechando su soporte para Python y su compatibilidad con la aceleración de GPU, lo que permitió entrenar y ejecutar el modelo de forma eficiente. Se utilizó la versión del modelo YOLOv5x, desarrollada íntegramente en Python con la biblioteca PyTorch. El flujo metodológico incluyó la configuración del entorno, la carga del conjunto de datos anotado en formato YOLO, la definición de hiperparámetros, el entrenamiento del modelo y, finalmente, la evaluación mediante métricas de precisión y visualización de resultados.

El modelo YOLO utiliza el algoritmo de descenso del gradiente para optimizar los parámetros de la red neuronal durante el entrenamiento. Mediante el cálculo del error (función de pérdida) entre las predicciones del modelo y los valores reales del *dataset* anotado, se ajustan los pesos internos de la red para minimizar dicho error. Ortiz [12] refiere que Bobulski y Kubanek utilizan un vector de características basado en el gradiente para clasificar imágenes en categorías de plásticos (PS, PP, PE-HD y PET), logrando alrededor del 84 % de precisión, al separar las imágenes en canales RGB sin requerir análisis espectrales complejos.

La [Figura 5](#) muestra cómo el modelo ajusta sus parámetros iterativamente para minimizar el error, partiendo de un valor aleatorio, hasta encontrar el mejor ajuste posible mediante el algoritmo de descenso del gradiente.

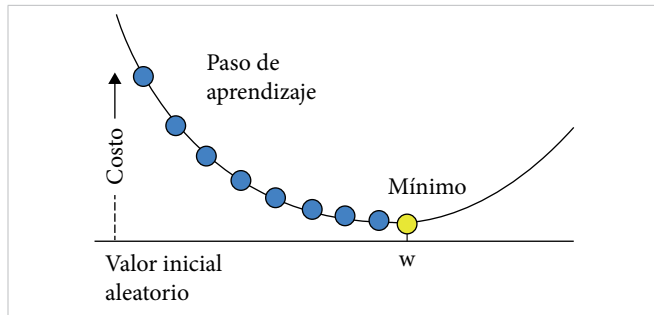


Figura 5. Entrenamiento en Google Colab.

Al concluir el entrenamiento, se evaluó el rendimiento del modelo con un conjunto de datos de prueba. El rendimiento del modelo se evaluó mediante métricas estándar: precisión, *recall* y mAP. Se observó un aumento progresivo de estas métricas durante el entrenamiento, lo que confirma la eficacia del modelo para clasificar residuos orgánicos.

D. EVALUACIÓN DEL ENTRENAMIENTO

Para el monitoreo del entrenamiento del modelo YOLO, se utilizó la herramienta TensorBoard, que se observa en la [Figura 6](#) y visualiza el comportamiento de métricas clave como la función de pérdida, precisión, recuperación y mAP a lo largo de las épocas. Esta herramienta facilitó el análisis del desempeño del modelo y permitió ajustar parámetros y detectar problemas como el sobreajuste. TensorBoard se integró directamente en el entorno de entrenamiento de Google Colab mediante los registros generados por YOLOv5x.

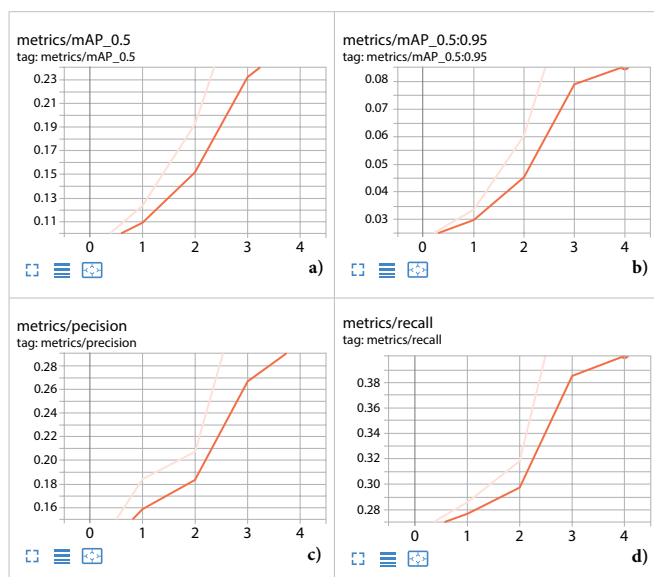


Figura 6. Evaluación del entrenamiento en Tensorboard.

Para evaluar el desempeño del modelo durante el proceso de entrenamiento, se utilizaron varias métricas estándar en tareas de detección de objetos, en particular en la clasificación de residuos orgánicos. Las métricas elegidas fueron el Mean Average Precision (mAP), la precisión (*precision*) y el recuerdo (*recall*).

1. mAP a 0.5 (metrics/mAP_0.5)

El mAP es una métrica que mide la precisión promedio del modelo, considerando un umbral de intersección sobre la unión (IoU) de 0.5. Este valor refleja la capacidad del modelo para identificar correctamente los residuos orgánicos, tomando en cuenta que las predicciones se consideran correctas si la superposición entre la predicción y la etiqueta real es de al menos el 50 %. La evolución de esta métrica a lo largo del tiempo se muestra en la gráfica a) de la [Figura 6](#), donde una curva ascendente indica que el modelo mejora su rendimiento en la clasificación a medida que avanza el entrenamiento.

2. mAP a 0.5:0.95 (metrics/mAP_0.5:0.95)

A diferencia del mAP a 0.5, esta métrica considera un rango de umbrales de IoU de 0.5 a 0.95, promediando la precisión entre dichos valores. Esta métrica es más estricta, ya que evalúa la precisión del modelo en una variedad de condiciones. En la gráfica b) de la [Figura 6](#), la curva ascendente también indica que el modelo está mejorando su capacidad para detectar residuos orgánicos con mayor precisión en un rango más amplio de umbrales.

3. Precisión (metrics/precision)

La precisión mide la proporción de predicciones correctas entre todas las predicciones realizadas por el modelo. En la gráfica c) de la [Figura 6](#), la curva ascendente refleja que el modelo está haciendo un número creciente de predicciones correctas, reduciendo los falsos positivos. Esto indica que el modelo está aprendiendo a identificar mejor los residuos orgánicos sin etiquetar incorrectamente objetos no orgánicos.

4. Recuerdo (metrics/recall)

El *recall* mide la capacidad del modelo para identificar todos los residuos orgánicos presentes en los datos. En la gráfica d) de la [Figura 6](#), la evolución de esta métrica

sistemas físicos de separación automática y la mejora del dataset mediante técnicas de aumento de datos o el uso de sensores adicionales. También se sugiere explorar el uso de modelos más avanzados si se cuenta con una infraestructura computacional más robusta.

El desarrollo de un modelo de detección automática de residuos orgánicos mediante visión artificial demostró que las redes neuronales convolucionales, en particular YOLOv5x, son una herramienta viable para apoyar la gestión sustentable de residuos en México. La construcción de un *dataset* propio y la optimización del proceso de entrenamiento evidenciaron que la calidad y diversidad de las imágenes son factores determinantes para alcanzar un rendimiento adecuado.

Si bien el modelo se limitó al reconocimiento de residuos orgánicos, los resultados obtenidos confirman el potencial de ampliar esta tecnología para la clasificación de residuos inorgánicos y de manejo especial, con miras a desarrollar sistemas inteligentes de mayor alcance. De esta forma, la investigación contribuye no solo al fortalecimiento de la cultura ambiental, sino también al diseño de soluciones tecnológicas que promuevan prácticas sostenibles en la universidad y en otros contextos, frente al crecimiento poblacional y a los desafíos ambientales que enfrenta el país.

IV. CONCLUSIONES

El desarrollo e implementación de un modelo de detección automática de residuos orgánicos, basado en redes neuronales convolucionales, evidenció el potencial de las tecnologías de visión artificial para apoyar la gestión sustentable de residuos en contextos urbanos. El uso de YOLOv5x como arquitectura base demostró ser una alternativa viable, logrando un desempeño eficiente, incluso en condiciones de hardware limitadas y con un conjunto de datos personalizado. Uno de los principales aprendizajes fue la relevancia de la calidad, la diversidad y la representatividad del conjunto de datos para obtener resultados satisfactorios.

El entrenamiento del modelo evidenció que factores como las condiciones de iluminación, el estado físico del residuo y la composición visual del entorno influyen significativamente en el reconocimiento efectivo. El enfoque limitado a residuos orgánicos fue una decisión estratégica basada en observaciones de campo, en las que se identificó una alta presencia de este tipo

de desechos sin una clasificación adecuada. Si bien esta decisión permitió concentrar el esfuerzo técnico, también redujo el alcance general del sistema. Esto abre una línea clara de mejora para investigaciones futuras, en las que se integren nuevas clases de residuos (inorgánicos, reciclables, peligrosos, etc.) y se evalúe la escalabilidad del modelo en escenarios más complejos.

Asimismo, se identifican oportunidades para combinar esta tecnología con sistemas físicos de separación automatizada o plataformas móviles de uso ciudadano, e integrarla en contenedores electrónicos, lo cual permitiría ampliar su impacto en la educación ambiental, el reciclaje comunitario y la gestión inteligente de residuos a nivel local. También resulta pertinente explorar nuevas arquitecturas de aprendizaje profundo y enfoques de entrenamiento que optimicen el rendimiento sin comprometer la eficiencia computacional.

En síntesis, este trabajo demuestra la viabilidad técnica de aplicar la visión artificial a la clasificación de residuos en contextos reales y plantea una base sólida para el desarrollo de soluciones tecnológicas que contribuyan a enfrentar los retos ambientales asociados al crecimiento poblacional, al consumo masivo y a la falta de cultura de separación de residuos en México.

REFERENCIAS

- [1] J. C. Feijoo y K. Cali, “El crecimiento poblacional entre el crecimiento económico y la contaminación ambiental. Caso China e India”, en *La quinta ola del progreso de la humanidad: la protección del medio ambiente, sociedad y economía*, Atena, 2024, cap. 4.
- [2] C. G. García, M. C. Valles y M. C. Nevárez, “Escenarios en la dinámica demográfica de los municipios de México con base en las nuevas proyecciones de la población del año 2024”, en *Procesos urbanos y dinámica del mercado laboral*, E. R. Morales y C. A. Ken, coords. México: UNAM/AMECIDER, 2024, pp. 273-288.
- [3] Plan Estratégico de Juárez, A.C., *Informe medio ambiente 2022*. Ciudad Juárez, México: Plan Estratégico de Juárez, A.C., 2022, pp. 97-132. [En línea]. Disponible: <https://planjuarez.org/wp-content/uploads/2022/11/Informe-Medio-Ambiente-2022.pdf>
- [4] A. De Anda-Trasviña, E. García-Galindo, A. Peña-Castañón, J. Seminario-Peña y A. Nieto-Garibay,

- “Residuos orgánicos: ¿basura o recurso?” *Recursos Naturales y Sociedad*, vol. 7, n.º 3, pp. 19-42, 2021, doi: [10.18846/renaysoc.2021.07.07.03.0004](https://doi.org/10.18846/renaysoc.2021.07.07.03.0004).
- [5] Instituto Politécnico Nacional, “Programa Institucional de Economía Circular y Cero Residuos del IPN 2026–2030 PIECC-IPN”, *Gaceta Politécnica Extraordinaria*, año LXII, vol. 22, n.º 1928, mar. 6, 2026. [En línea]. Disponible: <https://www.ipn.mx/assets/files/imageninstitucional/docs/gaceta-extraordinaria/2026/03/g-extra-1928.pdf>
- [6] D. E. Contreras y M. J. Guevara, “Sistema automatizado para separación y de residuos a través de una neurona artificial en la Universidad de Córdoba sede Sahagún”, trabajo de grado, Universidad de Córdoba, Colombia, 2021. [En línea]. Disponible: <https://repositorio.unicordoba.edu.co/entities/publication/8f2c1a34-7e59-4063-a5c1-911543bffecl>
- [7] Á. M. Del Carpio y A. E. Nuñez, “Simulación de sistema de clasificación de desechos sólidos basado en reconocimiento de imagen en el campus de la Universidad Nacional Pedro Henríquez Ureña (UNPHU)”, tesis doctoral, Universidad Nacional Pedro Henríquez Ureña, República Dominicana, 2022.
- [8] M. Castro, V. M. Romero, J. Fuentes, S. R. Zagal, A. Bárcenas y D. E. Gutiérrez, “Dataset de clasificación de Residuos Sólidos Urbanos para Redes Neuronales Convolucionales”, *Dilemas contemporáneos*, año XII, n.º 3, may. 2025, doi: [10.46377/dilemas.v12i3.4675](https://doi.org/10.46377/dilemas.v12i3.4675).
- [9] J. R. Lapo y O. M. Cumbicus-Pineda, “Detection of recyclable solid waste using convolutional neural networks and PyTorch”, en *IEEE Latin America Transactions*, vol. 22, n.º 6, pp. 475-483, jun. 2024, doi: [10.1109/TLA.2024.10534304](https://doi.org/10.1109/TLA.2024.10534304).
- [10] R. A. León, K. D. Barreto, K. J. Cabanillas, J. S. Muñoz, S. A. Peña y A. E. Tafur, “Desarrollo de un algoritmo mediante redes neuronales convolucionales para la clasificación de residuos sólidos en universidades”, en *Memorias de la 23.ª Conf. Iberoamericana en Sis., Ciber. e Informática (CISCI 2024)*, 2024, pp. 505-512, doi: [10.54808/CISCI2024.01.505](https://doi.org/10.54808/CISCI2024.01.505).
- [11] B. A. Aguilar, F. C. Covarrubias, A. R. Pérez, J. Gómez, C. A. Toro, J. S. Galindo y D. E. Ortiz, “Análisis de la detección e identificación de residuos mediante ultralytics YOLOv8”, *CienciAcierta*, vol. 21, n.º 83, pp. 117-133, 2025.
- [12] D. M. Ortiz, “Identificación y clasificación de residuos sólidos mediante procesamiento de imágenes e inteligencia artificial”, trabajo de grado, Universidad Francisco de Paula Santander, Colombia, 2023. [En línea]. Disponible: <https://repositorio.ufps.edu.co/server/api/core/bitstreams/b4651542-87da-4000-a4e2-96930e32aa05/content>