

CleanWater: Detección de Residuos Acuáticos con Imágenes Satelitales y Drones con Inteligencia Artificial

Augusto Javier Saporiti¹, Rubén Alejandro Casas ¹ y Pablo Ezequiel Inchausti¹

¹ Universidad Argentina de la Empresa (UADE)
Instituto de Tecnología (INTEC). Buenos Aires, Argentina
{ ausaporiti, rucasas, pinchausti}@uade.edu.ar

Resumen. La contaminación de los cuerpos de agua es un problema creciente, con 11 millones de toneladas de basura vertidas en los océanos cada año. En Argentina, se estima que un 70% de plásticos compone la basura de las costas bonaerenses y afecta al menos a 32 especies. El presente trabajo propone un sistema de monitoreo que combina imágenes satelitales e imágenes obtenidas con drones, para identificar la acumulación de basura con distinto grado de detalle. Para el procesamiento, se utilizan técnicas de *Aprendizaje Automático, Clasificación y Visión Artificial*, con una *ResNet-50* para el análisis de las imágenes satelitales provenientes de fuentes abiertas, y un modelo basado en *YOLOv8* para las imágenes recolectadas mediante el uso de un dron. Los resultados se presentan en tiempo real en un tablero desarrollado en *Tableau* y desplegado en *AWS*.

Palabras clave: Medio ambiente, Red Neuronal Profunda, Visión Artificial.

CleanWater: Detection of Aquatic Waste with Satellite Images and Drones with Artificial Intelligence

Abstract. Water body pollution is a growing problem, with 11 million tons of waste dumped into the oceans each year. In Argentina, it is estimated that 70% of the waste along the Buenos Aires coasts is plastic and affects at least 32 species. This work proposes a monitoring system that combines the analysis of satellite images and images captured by drones, to identify waste accumulation. It uses *Machine Learning, Classification, and Computer Vision* techniques, adapting a *ResNet-50* for the analysis of satellite images available from open data sources, and creating a model based on *YOLOv8* for images collected using a drone. Results are presented in real time on *Tableau* and deployed on *AWS*.

Keywords: Sustainability, Deep Neural Network, Computer Vision.

1 Introducción

La contaminación de los cuerpos de agua debido a la acumulación de basura es un problema creciente que afecta tanto al medio ambiente como a la vida marina. Se estima que, anualmente, se vierten alrededor de 11 millones de toneladas de basura en los océanos, y esa cifra podría triplicarse en los próximos 20 años. Este fenómeno también pone en peligro la biodiversidad, con estudios que demuestran que han ingerido plásticos la totalidad de las tortugas marinas, y casi la mitad de las aves y mamíferos marinos estudiados. (United Nations Environment Programme, 2021)

El problema también es preocupante en Argentina, donde estudios sobre las playas bonaerenses indican que más del 70% de los residuos son plásticos y al menos 32 especies se han visto afectadas por la basura acumulada en los cuerpos de agua (Fundación Vida Silvestre Argentina, 2023). A su vez, la falta de sistemas eficientes en la detección y monitoreo de la basura acumulada en el agua dificulta la implementación de medidas efectivas de prevención y limpieza.

El presente trabajo propone el desarrollo de un sistema de monitoreo ambiental que combina el análisis de imágenes satelitales con la captura de imágenes con drones para obtener resultados a diferente escala y grado de precisión. Las imágenes se analizan con técnicas de *Aprendizaje Automático, Clasificación y Visión Artificial* para identificar presencia de basura acumulada en los cuerpos de agua monitoreados. Los resultados se presentan en tableros con actualización en tiempo real.

Agradecimientos. Al Instituto de Tecnología (INTEC) de UADE por el apoyo a la investigación “*Vehículos Autónomos y Machine Learning aplicados a problemas de distribución, recolección y optimización*” (A24T15).

1.1 Antecedentes

La preocupación por el crecimiento descontrolado del plástico y su acumulación en los océanos dio origen a diversas iniciativas. Además del presente trabajo, con su diferencial de analizar con visión artificial imágenes de distintas fuentes, se propone:

Global Plastic Watch: la plataforma monitorea la contaminación global de plásticos mediante el análisis de imágenes satelitales de alta resolución. Utiliza algoritmos avanzados para identificar y cuantificar la cantidad de desechos plásticos flotantes en los océanos. El acceso a los datos proviene de colaboración con agencias espaciales y plataformas de imágenes satelitales. (Global Plastic Watch, 2022)

The Ocean Cleanup: El proyecto se centra en la limpieza directa de los océanos mediante sistemas de barreras pasivas y activas para recolectar desechos plásticos. Utiliza sensores para monitorear su eficacia y los datos son recopilados en tiempo real durante sus operaciones de limpieza. (The Ocean Cleanup, 2025)

Marine Debris Tracker: La plataforma permite a los ciudadanos reportar y rastrear basura marina mediante una aplicación móvil, generando de forma colaborativa mapas globales con datos recolectados por voluntarios. (Debris Tracker, s. f.)

2 Materiales y Métodos

Para la solución *CleanWater*, se enumeran los principales materiales utilizados:

- **Dron Dji Mavic Air 2:** (Fig. 1) utilizado para tomar imágenes y videos.
- **Set de Datos Satelital:** imágenes obtenidas de fuentes de datos abiertas
- **Set de Datos Aéreos:** capturadas por Dron
- **Modelo sobre ResNet-50:** adaptado para las imágenes satelitales
- **Modelo sobre YOLOv8:** adaptado a las imágenes obtenidas por Dron



Fig. 1. Materiales de *CleanWater*: dron utilizado en captura e imagen integrada con YOLO v8

2.1 Procesamiento de Datos de Imágenes Satelitales

En la fase inicial, se filtraron imágenes satelitales tomadas de plataformas de datos abiertos para encontrar imágenes de alta calidad en clases de basura. Esto resultó complejo, ya que muchas imágenes en formato JPG y PNG no alcanzaban criterios básicos para una clasificación efectiva. Después de un extenso proceso de depuración, se redujo de 450 GB a 3 GB el set de datos a utilizar.

Con esta primera selección de imágenes, se logró diversidad y equilibrio entre las distintas clases de basura, minimizando posibles sesgos. Posteriormente, se aplicaron técnicas de aumentación de imagen – como rotaciones, recortes, espejados, entre otras – para ampliar la variedad del conjunto de entrenamiento y mejorar la capacidad de generalización del modelo. Esto incrementó significativamente su robustez ante diferentes condiciones de iluminación y perspectivas. En la Fig. 2 se observa un extracto de la muestra de imágenes satelitales utilizadas para el entrenamiento.



Fig. 2. Extracto del dataset de clasificación de las imágenes satelitales utilizadas.

2.2 Implementación del Modelo ResNet-50 para Imágenes Satelitales

Para la clasificación de residuos en imágenes satelitales, se empleó una *Red Neuronal Convolutiva (CNN)* debido a su eficacia en el reconocimiento de patrones visuales complejos. En particular, se utilizó un modelo *ResNet-50* preentrenado en *ImageNet*, el cual se adaptó para la clasificación multiclase de distintos tipos de basura en los cuerpos de agua, como plásticos, residuos orgánicos, escombros, entre otros.

Para el entrenamiento, se utilizó el dataset curado durante la etapa inicial del procesamiento de datos. El objetivo del modelo consistía en identificar y etiquetar como "*trash*" las imágenes que contenían alguna de las clases de residuos, con el fin de presentarlas, luego, con su posición georreferenciada en el mapa de la plataforma.

En la Fig. 3 se observan las curvas de Pérdida y Precisión del modelo, que muestran una precisión consistente tanto en el set de datos de entrenamiento como en el de validación, sin evidencias de sobreajuste (*overfitting*). Además, se incluye un ejemplo del resultado de una clasificación realizada por el modelo entrenado.




Fig. 3. Gráficos de Pérdida vs. Epochs, Precisión vs. Epochs, y resultado de una clasificación.

La arquitectura ResNet-50 mostró su mayor efectividad en la clasificación de imágenes satelitales con un total de hasta 6 clases, donde alcanzó una precisión del 91.3% en la detección de basura y una sensibilidad del 79.9%.

Durante el entrenamiento del modelo, se ajustaron los siguientes hiperparámetros:

- **Tasa de aprendizaje:** entre 0.001 y 0.0001, según su efecto en la estabilidad del entrenamiento y la velocidad de convergencia del modelo.
- **Tamaño de batch:** Se utilizaron tamaños de 16, 32 y 64 para determinar el tamaño óptimo que maximizara la precisión.
- **Optimizador:** Se evaluaron diferentes optimizadores, como Adam y SGD, para encontrar el más efectivo para la reducción de la función de pérdida.
- **Número de épocas (Epochs):** se utilizaron entre 10 y 20, con una duración aproximada de 40 minutos por época hasta completarse.

Además, se utilizó *OneCycleLR* como planificador de tasas de aprendizaje, lo que facilitó una convergencia rápida y estable a lo largo del proceso de entrenamiento.

Tras el ajuste final, el modelo fue guardado con las mejores configuraciones encontradas durante el proceso de entrenamiento.

2.3 Modelo de Clasificación de Imágenes Capturadas por Dron

El modelo YOLOv8 se evaluó con conjuntos de datos capturados por drones, que contenían diferentes configuraciones de clases. Desde 2 clases (basura/no basura) hasta 4 clases (residuos orgánicos, residuos no identificados, plásticos y escombros).

A diferencia de *ResNet-50*, que clasifica la imagen completa, *YOLOv8* permite señalar con rectángulos (*bounding boxes*), cada una de las clases de residuos detectadas. Respecto a los hiperparámetros, los principales ajustados incluyeron:

- **Tamaño de las imágenes:** Se redimensionaron a 608x608 píxeles, típico de YOLO, para brindar un equilibrio de precisión y velocidad en la detección de objetos.
- **Tasa de aprendizaje:** Se probaron valores de 0.001, 0.0005 y 0.0001 para encontrar el mejor balance entre la velocidad de convergencia y la estabilidad del modelo.
- **Escalas de anclaje:** Se ajustaron para residuos de diferentes tamaños y formas.
- **Tamaño de red:** Con variantes desde redes más pequeñas para imágenes de baja resolución hasta versiones completas para detección multiescala.

En cuanto al rendimiento, el modelo *YOLOv8* alcanzó una precisión de 84.2% en la detección multiclase para imágenes con dos clases, y un *F1-Score* de 74.8% para imágenes con cuatro clases. La tabla 1 muestra el rendimiento del modelo, también respecto a *ResNet-50*

Tabla 1. Rendimiento de los dos modelos entrenados.

| Modelo | Tipo de imagen | Clases | Precisión | Sensibilidad | F1-Score |
|-----------|-------------------------------|--------|-----------|--------------|----------|
| ResNet-50 | Detección de Basura Satelital | 6 | 91.3 % | 79.9 % | 76.8 % |
| YOLOv8 | Detección de Basura Dron | 4 | 84.2 % | 82.4 % | 74.8 % |

3 Conclusiones y discusión

El presente trabajo demuestra cómo las técnicas de visión artificial contribuyen a una problemática actual como la acumulación de basura en los cuerpos de agua. Combinar imágenes de satélite y de drones ofrece versatilidad para lograr resultados a distintos grados de exigencia. Como discusión, la preparación del set de datos, especialmente imágenes de fuentes abiertas, resultó una gran limitante en la solución, que podría superarse mediante convenios de acceso a imágenes de alta resolución.

Referencias

- Debris Tracker, <https://debristracker.org>, último acceso 12/04/2025
- Fundación Vida Silvestre Argentina. (2023). *Alerta plástico: Más del 70% de los residuos censados en las playas bonaerenses continúan siendo plásticos*. <https://www.vidasilvestre.org.ar/?25000/Alerta-plastico-mas-del-70-de-los-residuos-censados-en-las-playas-bonaerenses-continuan-siendo-plasticos>
- Global Plastic Watch, <https://www.globalplasticwatch.org>, último acceso 12/04/2025
- The Ocean Cleanup, <https://theoceancleanup.com>, último acceso 12/04/2025
- United Nations Environment Programme. (2021). *From Pollution to Solution: A global assessment of marine litter and plastic pollution*. ISSN 978-92-807-3881-0