

An intelligent waste station: a contribution of Artificial Intelligence to the circular economy

Javier del Blanco¹[0009-0009-6338-1326], Santiago Chaves¹[0009-0008-6677-0573], Isabel Kimura¹[0009-0008-1180-1264] and Claudia Queiruga¹[0009-0004-1612-4902]

¹Laboratorio de Investigación en Nuevas Tecnologías Informáticas (LINTI), UNLP, La Plata
Buenos Aires, Argentina.

javierdelblanco01@gmail.com, santiagochaves242@gmail.com,
ikimura@linti.unlp.edu.ar claudiaq@info.unlp.edu.ar

Abstract. This work addresses the problem of urban solid waste management in the community of the Faculty of Informatics at the National University of La Plata, and was developed within an R&D project of the institution itself, which promotes the participation of students from its different degree programs under the supervision of teacher-researchers. In this context, a functional prototype of a physical intelligent waste station was developed, applying Machine Learning techniques, specifically a convolutional neural network, to classify images of recyclable waste such as paper, cardboard, glass, plastic, and metal generated within the faculty. The goal of the project is to foster environmental awareness in the institutional community through the separation of waste suitable for recycling by circular economy cooperatives within the UNLP's area of influence. To this end, a Machine Learning model was trained on photos of waste generated at the faculty and integrated into a web service that records user interactions and uses the trained model to classify waste. Additionally, a physical station was built using low-cost electronic components, comprising compartments for waste disposal and an Arduino microprocessor with LED indicators that guide users in the correct disposal of waste. The developed prototype was presented at the faculty's Science and Technology Exhibition, a space for student exchange. It is currently in a testing and improvement phase of both the learning model and the physical station, involving students and social actors from the circular economy.

Keywords: circular economy, artificial intelligence, machine learning, arduino.

Una estación de residuos inteligente: un aporte de la Inteligencia Artificial a la economía circular

Resumen. Este trabajo aborda la problemática de la gestión de residuos sólidos urbanos en la comunidad de la Facultad de Informática de la Universidad Nacional de La Plata y se desarrolló en un proyecto de I+D de la propia institución en el que se promueve la participación de estudiantes de sus diferentes carreras bajo la supervisión de docentes-investigadores. En este contexto se desarrolló

un prototipo funcional de una estación física de residuos inteligente que aplica técnicas de Aprendizaje Automático específicamente una red neuronal convolucional para clasificar imágenes de residuos reciclables como papel, cartón, vidrio, plástico y metal generados en la facultad. El objetivo del proyecto es fomentar la concientización ambiental de la comunidad de la institución mediante la separación de residuos plausibles de reciclar por cooperativas de la economía circular del área de influencia de la UNLP. Para ello, se entrenó un modelo de Aprendizaje Automático con fotos de los residuos generados en la facultad integrado a un servicio web que registra las interacciones de los usuarios y usa el modelo entrenado para clasificar. Asimismo, se construyó una estación física con componentes electrónicos de bajo costo compuesta por compartimentos para el depósito de residuos y un microprocesador Arduino con indicadores LED que orientan al usuario en la disposición correcta de los residuos. El prototipo desarrollado se presentó en la Exposición de Ciencia y Tecnología de la facultad, espacio de intercambio estudiantil. Actualmente se encuentra en una fase de pruebas y mejoras del modelo de aprendizaje y de la estación física, con estudiantes y actores sociales de la economía circular.

Palabras clave: economía circular, inteligencia artificial, aprendizaje automático, arduino.

1 Introducción

La problemática de los residuos sólidos urbanos ha alcanzado una dimensión crítica en el contexto global contemporáneo, exigiendo la transición urgente desde modelos de consumo lineales hacia paradigmas de economía circular. En Argentina, esta situación se manifiesta con particular severidad debido a las limitaciones estructurales en los sistemas de disposición final y la persistencia de prácticas de gestión ineficientes. Según datos relevados por la Secretaría de Ambiente y Desarrollo Sustentable de la Nación, existen en el territorio nacional aproximadamente 5.000 basurales a cielo abierto, infraestructuras que representan un riesgo sanitario y ambiental latente para las comunidades circundantes. La distribución de la disposición de residuos evidencia una brecha significativa en la modernización del sector: mientras el 45% de los residuos se destina a rellenos sanitarios controlados, un preocupante 25% termina en basurales a cielo abierto y un 30% en rellenos con control parcial (Ministerio de Desarrollo Social de Argentina, 2023).

En la Provincia de Buenos Aires, el desafío es aún mayor debido a la densidad demográfica y la concentración de la actividad industrial. Se estima la generación diaria de 20.000 toneladas de residuos sólidos urbanos y de los 135 municipios, 80 disponen sus residuos en basurales a cielo abierto (Ministerio de Ambiente de la Provincia de Buenos Aires, 2025). Este volumen masivo de desechos si no se gestiona mediante procesos de separación en origen y recuperación efectiva, se traduce en una pérdida irreparable de recursos y un incremento en la presión sobre los ecosistemas locales. En este escenario, el papel de los recuperadores urbanos y las cooperativas de reciclaje resulta fundamental. En la provincia, existen al menos 120 cooperativas que agrupan a aproximadamente 6.000 trabajadores formalizados, quienes actúan como el

primer eslabón de la economía circular al garantizar la reinserción de materiales en la cadena productiva (Mapa Federal de Reciclado, s.f.).

En particular en la ciudad de La Plata existen iniciativas gubernamentales que atienden esta problemática como el programa “#ChauPlástico”¹ de la Secretaría de Ambiente de la Municipalidad de La Plata. También se destaca el programa “Berisso Recicla”² que realiza la separación de residuos, el reciclado y el cuidado del ambiente, generando conciencia ambiental y buenas prácticas de cuidado en su localidad.

La Universidad Nacional de La Plata (UNLP) no es ajena a esta realidad. La ausencia de separación en origen provoca que una gran proporción de residuos con potencial reciclable sea descartada como basura común. El uso de tecnologías de Inteligencia Artificial (IA), específicamente técnicas de Aprendizaje Automático (Machine Learning, ML) ofrece una oportunidad para automatizar y optimizar los procesos de clasificación e integrarlos a la cadena de valor del reciclaje (Organización de las Naciones Unidas Medio Ambiente, 2024), potenciando así la recolección diferenciada y facilitando el tratamiento posterior por cooperativas locales (Nafiz et al., 2023).

El presente trabajo describe el desarrollo de un prototipo funcional de una estación de residuos inteligente diseñada para operar en la Facultad de Informática de la UNLP. Este proyecto se inscribe en una política institucional de la Facultad que promueve la participación de estudiantes en proyectos de I+D con el acompañamiento de docentes-investigadores de la casa de estudios. En particular el proyecto aquí presentado corresponde a la convocatoria 2025³ de proyectos propuestos por el LINTI (Laboratorio de Investigación en Nuevas Tecnologías Informáticas) en el que se combinan un modelo de visión por computadora para la identificación automática de materiales con un servicio web que ofrece una interfaz visual (GUI) para interactuar con el modelo de aprendizaje y con un circuito electrónico basado en Arduino que indica mediante el encendido/apagado de LEDs el compartimiento de la estación en el cual depositar el residuo clasificado. El objetivo central es optimizar la separación de residuos inorgánicos reciclables mediante IA entrenada con datos recolectados localmente, promoviendo a su vez una cultura de sostenibilidad ambiental en la comunidad universitaria. En línea con los Objetivos de Desarrollo Sostenible (ODS) 9, 11, 12 y 13 de la ONU (Organización de las Naciones Unidas, 2015), este prototipo sienta las bases para modernizar la gestión de residuos desde su origen, reducir la presión sobre basurales y mitigar la huella de carbono asociada a la ineficiencia en la recolección y la extracción de materias primas.

¹ Sitio oficial del programa ChauPlástico: <https://www.chauplastico.com/> e Instagram de la Municipalidad de La Plata: <https://www.chauplastico.com/>

² Instagram de la Municipalidad de Berisso con el Balance anual del programa Berisso Recicla: <https://www.instagram.com/p/DS2a-YFjo34/>

³ Proyecto de I+D con estudiantes “Una estación de residuos inteligente para la facultad”, coordinado por las docentes Isabel Kimura y Claudia Queiruga y desarrollado por los estudiantes Javier Del Blanco, Santiago Chaves, Nicolás Ricciardi y Francisco Marcó del Pont
<https://www.linti.unlp.edu.ar/index.php/2025/10/22/proyectos-en-la-expo-de-ciencia-y-tecnologia/>

2 Marco conceptual

La clasificación de residuos urbanos para su posterior reciclaje depende, en general, exclusivamente de la mano de obra humana o de costosos sistemas mecánicos de separación. La aplicación de algoritmos de ML para este tipo de problemas complejos de clasificación de imágenes, permite mediante el entrenamiento con grandes volúmenes de imágenes, distinguir entre diferentes tipos de plásticos, metales o papeles con una precisión que iguala o supera la capacidad humana en entornos controlados (Nafiz et al., 2023). Esto permite introducir tecnologías de IA en una cadena productiva de economía circular como lo es el reciclaje de residuos sólidos urbanos. Además, el uso de dispositivos electrónicos de hardware libre y de bajo costo, como Arduino, integrado con tecnologías de IA permiten construir herramientas tecnológicas adaptadas a necesidades específicas como el caso de estudio que aquí se presenta.

2.1 Economía circular

La economía circular es un modelo de producción y consumo que busca extender el ciclo de vida de los productos minimizando el desperdicio y fomentando la reutilización y el reciclaje. En contraste con el modelo lineal de "tomar-hacer-desechar", propone un sistema restaurativo que mantiene el valor de los materiales en la economía durante el mayor tiempo posible (Ellen MacArthur Foundation, 2015), concibiendo los materiales desechados no como basura sino como recursos secundarios transformables en nuevos productos.

En Argentina, este concepto se aplica mediante la Gestión Integral e Inclusiva de Residuos Sólidos (GIIRSU), que promueve la formalización de los recuperadores urbanos y su inclusión en todas las etapas del ciclo, complementada por el programa nacional Argentina Recicla⁴. Como marco normativo, la Ley Nacional 25.916/2004, la Ley provincial N° 13.592/2006 y la Ordenanza municipal N° 10.661/2009 de La Plata establecen conjuntamente los criterios para el manejo adecuado de residuos domiciliarios, su aprovechamiento económico y el saneamiento de basurales a cielo abierto.

En el plano internacional, la OCDE (Organización para la Cooperación y el Desarrollo Económicos) promueve estrategias para la transición a economías circulares, enfatizando la Responsabilidad Extendida del Productor (REP), un enfoque que traslada la responsabilidad del ciclo de vida de los productos desde los municipios hacia los fabricantes, incentivando el diseño ambientalmente responsable (OCDE, 2016).

2.2 Modelos de ML para clasificación de imágenes

El uso de IA para la clasificación automática de residuos ha experimentado un crecimiento sostenido desde aproximadamente 2020, impulsado por la necesidad de optimizar los procesos de reciclaje y reducir los errores asociados a la clasificación manual. Revisiones sistemáticas sobre este tema evidencian un incremento significativo en las publicaciones entre 2020 y 2024, con predominio de técnicas de aprendizaje profundo, en particular redes neuronales convolucionales (CNN), transfer learning y

⁴ Sitio del programa Argentina Recicla:
<https://www.argentina.gob.ar/justicia/derechofacil/leysimple/seguridad-social/programa-argentina-recicla>

modelos híbridos, y uso extensivo de conjuntos de datos públicos como TrashNet, usados en este proyecto (Fotovvatikhah et al., 2025)(Yevle & Mann, 2025).

En cuanto al rendimiento, numerosos trabajos reportan una precisión superior al 90% en tareas de clasificación de entre 6 y 12 clases de residuos domésticos (vidrio, metal, papel, plástico, orgánico, entre otros) utilizando variantes de ResNet y EfficientNet. Paralelamente, se han desarrollado sistemas embebidos orientados a la clasificación en tiempo real, enfoque compartido con el proyecto aquí presentado. Un ejemplo de prototipos de contenedores inteligentes que usan este enfoque es MobileNetV2 sobre Raspberry Pi alcanzando aproximadamente un 90% de precisión (Ahmed et al., 2023) (Hossen et al., 2024). Para la detección en entornos dinámicos (cintas transportadoras, hogares, líneas de reciclaje) se destaca la librería YOLO⁵ (You Only Look Once) (Midigudla et al., 2025).

Un referente relevante en esta área es el proyecto RedCiclaCh⁶, desarrollado en la Universidad de Santiago de Chile (USACH). Esta iniciativa implementó contenedores inteligentes dotados de visión artificial para mejorar la clasificación de residuos en entornos urbanos y universitarios (Radio Usach, 2024). Este proyecto obtuvo el reconocimiento internacional "Smart City Award 2024", demostrando que la combinación de tecnología y participación ciudadana puede generar un impacto positivo medible en la tasa de recuperación de materiales (Universidad de Santiago de Chile, s.f.).

2.3 Hardware libre y electrónica de bajo costo

El hardware libre se basa en el principio de compartir esquemas y diseños para que cualquier persona pueda estudiarlos, modificarlos y distribuirlos. Bajo este concepto, la plataforma Arduino es uno de los mejores ejemplos ya que se enfoca en acercar y facilitar el uso de la electrónica y programación de sistemas embebidos, permitiendo descargar los planos de cualquiera de sus placas y fabricar una versión propia, además de permitir el desarrollo de extensiones bajo esta misma filosofía.

Los aportes fundamentales del hardware libre incluyen la democratización tecnológica, permitiendo el desarrollo de soluciones sin depender de licencias propietarias y la soberanía y sostenibilidad, facilitando la creación de dispositivos locales adaptados a las necesidades regionales, mejorando la autonomía tecnológica.

En el contexto de la estación inteligente, la integración con Arduino permite que sea replicado fácilmente e incluso iterado libremente por otras instituciones o a nivel municipal, ofrece transparencia sobre la lógica del dispositivo y facilita el mantenimiento local y la reutilización de componentes con un bajo costo asociado, asegurando la prolongación de su vida útil.

3 Metodología

El desarrollo del proyecto se estructuró en cinco etapas: el diseño de la arquitectura del sistema, la recolección y preparación de datos, el desarrollo del modelo de clasificación, el desarrollo de la aplicación web y la integración del hardware y software.

⁵ YOLO es un algoritmo de detección de objetos en tiempo real, presentado en 2015 por Joseph Redmon, Santosh Divvala, Ross Girshick y Ali Farhadi. Se usa para la detección y reconocimiento de objetos en tiempo real en imágenes y videos.

⁶ Sitio del proyecto RedCiclaCh: <https://redciclach.com/>

3.1 Diseño de la Arquitectura del Sistema

La arquitectura del sistema se concibió como una solución que integra una aplicación web, un modelo de ML y un dispositivo de control físico. La Fig. 1 muestra la interacción de los diferentes componentes del sistema.




Fig. 1. Diagrama de la interacción entre los componentes del sistema.

En el diagrama de la Fig. 1 se puede observar la interacción coordinada entre el software de reconocimiento de imágenes (que se ejecuta en la aplicación web), el hardware de control (Arduino) y los elementos físicos de señalización (LEDs), integrando así todos los componentes en un sistema único y funcional.

3.2 Recolección y preparación de datos

Imágenes de datasets públicos

El dataset seleccionado es TrashNet⁷, disponible en repositorios de acceso libre en Internet. Su versión "dataset-resized" ofrece imágenes de tamaño uniforme que facilitan el entrenamiento de modelos de clasificación. Las clases disponibles son: cartón, vidrio, metal, papel, plástico y basura general; categorías que, a excepción del vidrio, corresponden a los residuos generados por el buffet de la Facultad. El conjunto incluye alrededor de 2.500 imágenes distribuidas de manera relativamente equilibrada entre las seis clases (ver Tabla 1), con variaciones en ángulos, iluminación y fondos que favorecen la capacidad de generalización del modelo.

En la Fig. 2 se pueden observar algunas imágenes del dataset TrashNet. Este dataset fue elegido por su pertinencia con los objetivos del proyecto y por tratarse de un recurso de acceso libre.

Tabla 1. Categorías y cantidades de Trashnet

Categoría	Cantidad de imágenes	Ejemplo de objeto
Cartón	403	Cajas de cartón
Vidrio	501	Botellas y frascos de vidrio
Metal	410	Latas y piezas metálicas
Papel	594	Hojas y cuadernos de papel
Plástico	482	Botellas y envases plásticos
Basura general	137	Residuos no reciclables
Total	2527	

⁷ Dataset TrashNet: <https://github.com/garythung/trashnet>




Fig. 2. Imágenes de muestra del dataset TrashNet

Captura de datos locales

Para complementar los datasets se tomaron fotografías de residuos en la Facultad de Informática con la colaboración de estudiantes de la EEST N° 9 de La Plata, quienes se encontraban realizando las Prácticas Profesionalizantes del 7° año en el ámbito de la Secretaría de Extensión. Para ello, desde el proyecto se elaboró una guía para la obtención de las muestras con el objetivo de garantizar la homogeneidad en las capturas de fotos (ángulos, iluminación y calidad) y facilitar el posterior entrenamiento del modelo.

En la Tabla 2 se presentan las categorías y la cantidad de imágenes obtenidas por los estudiantes de la EEST N°9: cartón (101), metal (160), papel (137), plástico (202) y basura general (63), conformando un total de 653 imágenes. Estas capturas fueron incorporadas al conjunto de datos para fortalecer la representación de residuos efectivamente generados en la Facultad. En la Fig. 3 se muestran ejemplos de las imágenes tomadas en la Facultad por los estudiantes de la EEST N°9 y que formaron parte del dataset final utilizado en el entrenamiento del modelo de clasificación.

Tabla 2. Categorías y cantidad de imágenes tomadas por los estudiantes de la EEST N° 9

Categoría	Cantidad de imágenes
Cartón	101
Metal	160
Papel	137
Plástico	202
Basura general	63
Total	653




Fig. 3. Imágenes de la muestra elaborada por los estudiantes de la EEST N° 9

3.3 Desarrollo del modelo de clasificación

El desarrollo del modelo se realizó en 2 etapas:

Etapla 1: Google Teachable Machine (GTM)⁸

Con el propósito de contar con una primera versión del modelo de aprendizaje entrenado y evaluar la factibilidad de su uso para el problema planteado se decidió usar la herramienta GTM. La misma es una herramienta desarrollada por Google, disponible en línea, gratuita, con licencia de uso libre (Apache 2.0) que permite entrenar modelos de aprendizaje automático de manera sencilla y sin programar. La Fig. 4 muestra la interfaz de GTM durante el entrenamiento del modelo de clasificación de imágenes en seis categorías de residuos: papel, cartón, metal, plástico, vidrio y basura general. Este modelo se entrenó con aproximadamente 400 imágenes por categoría. La Fig. 5 permite observar el desempeño del modelo entrenado a partir de las siguientes métricas y herramientas de evaluación, ofrecidas por GTM: tabla de precisión por clase, curva de precisión por época y pérdida y, matriz de confusión. GTM usa el 15% de las muestras para realizar la evaluación del desempeño del modelo. A continuación, se analiza la evaluación del modelo:

- La tabla de precisión por clase es una métrica que indica la proporción de las predicciones correctas realizadas para cada categoría. Con los datos entrenados, el modelo clasificó correctamente el 93% de las imágenes de plástico, el 90% de las de metal, seguidas por papel (88%) y vidrio (86%), mientras que las imágenes de cartón (79%) y basura general (76%) obtuvieron valores más bajos. Un dato que permite explicar la falta de precisión para clasificar imágenes de basura general es que el dataset de entrenamiento contó con solamente 140 muestras totales y 21 para evaluar, mientras que las demás clases contaban entre 400 y 600 muestras, y 60 y 90 para evaluar.
- Las curvas de precisión por época y pérdida por época son métricas que muestran el comportamiento del modelo durante el entrenamiento y validación (test). La curva de precisión muestra un buen desempeño general, con una leve brecha entre entrenamiento y validación, lo que sugiere una adecuada capacidad de generalización, aunque con indicios moderados de sobreajuste. La curva de pérdida evidencia un proceso de sobreajuste u *overfitting*, donde la pérdida en entrenamiento disminuye sostenidamente mientras que la pérdida en validación se mantiene más elevada y con variaciones, indicando una limitada capacidad de generalización del modelo.
- La matriz de confusión es una herramienta de evaluación que permite identificar los errores de clasificación por clase; en la diagonal de la matriz se ubican los valores más altos de acierto. Se puede observar que la clase metal muestra un buen nivel de acierto, con solo 6 confusiones (5 confusiones con vidrio y una con plástico). Se observan mayores dificultades en la discriminación entre clases con características visuales similares, como cartón y papel, donde se registran 7 errores de cartón clasificado como papel y 3 de papel como cartón, algo similar ocurre entre

⁸ Google Teachable Machine (<https://teachablemachine.withgoogle.com>): es una herramienta online, utilizada en contextos educativos para crear modelos de aprendizaje automático para clasificar imágenes, sonidos o poses a partir de ejemplos cargados por el usuario.

plástico y vidrio, con 7 casos de vidrio clasificado como plástico y 3 de plástico como vidrio. La clase basura general, que cuenta con poca cantidad de muestras, presenta 5 confusiones (3 como papel, 1 como plástico y 1 como vidrio), lo que impacta negativamente en su desempeño. Estos resultados sugieren que tanto la similitud visual entre clases como la menor representatividad de algunas clases influyen en la cantidad de confusiones.




Fig. 4. Entrenamiento inicial usando GTM: el panel izquierdo presenta las clases con sus respectivas muestras de entrenamiento, el panel central es el de configuración de los parámetros del modelo y el panel derecho muestra la vista previa del modelo entrenado clasificando una imagen en tiempo real.

A partir de las métricas y herramientas de evaluación analizadas es posible concluir que el modelo es funcional y adecuado para la clasificación de imágenes de un primer prototipo de estación inteligente de residuos dado que generaliza bien y tiene precisiones adecuadas en la mayoría de las clases. Del análisis surge la incorporación de mejoras para optimizar la clasificación de aquellas clases en las que se observan confusiones y de las que cuentan con baja precisión como basura general. Entre las posibles estrategias de mejora se pueden señalar: a) el aumento de la cantidad de imágenes locales en las categorías con menor precisión; b) la aplicación de técnicas de *data augmentation*, y c) la diversificación de las condiciones de captura (ángulos, iluminación y fondos). Todas estas estrategias buscan lograr una mayor capacidad de generalización.

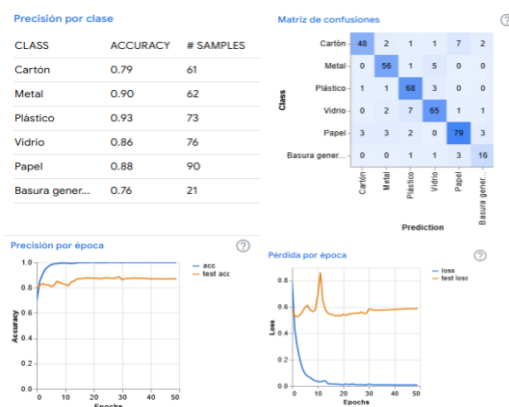


Fig. 5. Panel del resultado del entrenamiento inicial con GTM: en la esquina superior izquierda está la tabla de precisión por clase, en la esquina superior derecha está la matriz de confusión y en la parte inferior están las curvas de precisión por época y pérdida por época.

Etapa 2: Google Colab⁹ con Python

Con el objetivo de mejorar el desempeño del modelo obtenido en la etapa anterior y superar las limitaciones de generalización observadas, se desarrolló una segunda etapa de entrenamiento utilizando Google Colab junto con TensorFlow/Keras¹⁰.

Este entorno permitió un mayor control sobre el proceso de entrenamiento y la incorporación de estrategias orientadas a mejorar el desempeño del modelo. Se utilizó como base un modelo preentrenado, EfficientNetV2S¹¹, que fue adaptado a las categorías específicas de residuos definidas en el proyecto.

Asimismo, se aplicaron técnicas de aumento de datos, introduciendo variaciones en las imágenes de entrenamiento, con el fin de mejorar la capacidad de generalización y reducir el sobreajuste observado en la etapa previa.

El modelo se entrenó durante 50 épocas utilizando el optimizador Adam¹² y una función de pérdida de Sparse Categorical Crossentropy¹³. En la Fig. 6 se pueden ver las evaluaciones hechas sobre el modelo:

- Las curvas de precisión y pérdida muestran un comportamiento estable. La precisión de entrenamiento alcanzó el 91%, mientras que la de validación se estabilizó en un 86%-87%.
- Según la tabla de precisión por clase se alcanzó un buen nivel en vidrio (95%), cartón (94%) y papel (91%). La clase basura general (68%) obtuvo el desempeño más bajo, lo que se relaciona directamente con su baja representatividad en el dataset.
- La matriz de confusión revela que las mayores dificultades se centran en la distinción entre materiales similares, como sucedió con el primer modelo entrenado. Se observaron confusiones de vidrio con metal (8 casos) y plástico (7 casos). Asimismo, se registraron confusiones entre cartón y papel (5 casos).

Los resultados obtenidos muestran un comportamiento más estable del modelo, con niveles de precisión adecuados en la mayoría de las clases. No obstante, persisten dificultades en la clasificación de categorías con menor representatividad, como “basura general”, y en la distinción entre materiales con características visuales similares.

⁹ Google Colab (<https://colab.research.google.com/>): es un entorno de computación en la nube que permite ejecutar notebooks de Python desde el navegador, con acceso a recursos de hardware acelerado (GPU/TPU) sin necesidad de instalación local.

¹⁰ Keras (<https://keras.io>): biblioteca de Python para el desarrollo de modelos de aprendizaje, que actúa como interfaz sobre TensorFlow y facilita la construcción y entrenamiento de redes neuronales.

¹¹ EfficientNetV2S (<https://arxiv.org/abs/2104.00298>): arquitectura de red neuronal convolucional, utilizada para desarrollar modelos de visión para clasificación de imágenes, optimizando el uso de recursos computacionales mediante bloques de procesamiento eficientes y técnicas de escalado inteligente.

¹² Optimizador Adam: método para ajustar los parámetros del modelo durante el entrenamiento, adaptando automáticamente la forma en que aprende para lograr mejores resultados de manera más eficiente.

¹³ Sparse Categorical Crossentropy: función de pérdida utilizada en problemas de clasificación multiclase, que mide la diferencia entre las clases reales y las predichas por el modelo cuando las etiquetas se encuentran representadas como valores enteros.




Fig. 6. Resultados del entrenamiento en Google Colab: en la esquina superior izquierda está la tabla de precisión por clase, en la esquina superior derecha está la matriz de confusión y en la parte inferior están las curvas de precisión por época y pérdida por época.

3.4 Desarrollo de la aplicación web

Se implementó un servidor web en Django (Python) bajo los lineamientos de una arquitectura API Restful. Dicho servidor integra el sistema de clasificación de imágenes desarrollado. Las funcionalidades del servidor son:

- Gestionar la captura de imágenes en tiempo real desde la cámara de la computadora y, procesarla con el algoritmo YOLO para identificar la imagen a clasificar (Fig. 7 Izq.).
- Clasificar imágenes usando el modelo de aprendizaje entrenado. De todos los objetos detectados por YOLO en la escena, se selecciona únicamente aquel que se encuentra más centrado en la imagen, asumiendo que es el residuo que el usuario presenta deliberadamente a la cámara. La imagen de ese objeto recortado es la que se envía al modelo entrenado para su clasificación.
- Generar un código QR asociado a las imágenes de los residuos clasificados con la finalidad de facilitar la integración con una app móvil destinada a los usuarios de la estación que mediante estrategias de gamificación permita difundir el uso de la misma (Fig. 7 Der.). Si bien la app móvil no se desarrolló aún, se plantea como un trabajo futuro del proyecto.

Actualmente la app web se encuentra disponible en el repositorio GitHub: https://github.com/Nack34/ProyectoLINTI-Contenedores_inteligentes-UNLP

3.5 Integración de la aplicación web con Arduino

Para la estación física se empleó una placa Arduino Uno, la cual cuenta con un microcontrolador de 8 bits ATmega328P como unidad central de procesamiento. Este dispositivo se conecta a la computadora en la que se ejecuta la aplicación web a través del protocolo de comunicación UART (Universal Asynchronous Receiver-Transmitter). Características del protocolo: a) serial: se transmite bit a bit en un único

canal; b) asíncrono: no hay señal de *clock* o reloj común entre los dispositivos y se establece la velocidad de transferencia antes de que ésta comience; y c) *full duplex*: transmite y recibe simultáneamente entre ambos dispositivos, aunque en este proyecto se comunican en un solo sentido. La aplicación web una vez clasificado el residuo, envía al Arduino un número (entre 0 y 3), que corresponde a la clase de residuo detectada, y activa uno de los cuatro LEDs, cada uno asociado a un compartimento específico del contenedor inteligente (cartón, metal, papel o plástico). La Fig. 8 muestra la estación física, con los 4 compartimientos de depósito, cada uno con un LED asignado.



Fig. 7. Detección de imágenes usando YOLO (Izquierda) y Resultado de la clasificación junto con un código QR en la aplicación web (Derecha)

El montaje se realizó conectando los pines digitales 10, 11, 12 y 13 del Arduino a los cátodos de los LEDs, mientras que los ánodos se enlazaron a resistencias de $220\ \Omega$ y luego a tierra (GND). El cableado se organizó dentro de una caja de cartón pequeña para proteger y ordenar los componentes. La placa Arduino se conectó a la computadora mediante un cable USB tipo B.



Fig. 8. Prototipo de la estación de residuos inteligente desarrollado.

4 Conclusiones y trabajo a futuro

El presente trabajo describe el desarrollo de un prototipo funcional de estación de residuos inteligente que integra técnicas de ML, desarrollo web y hardware de bajo

costo, con el objetivo de contribuir a la gestión sostenible de residuos sólidos urbanos en la comunidad de la Facultad de Informática de la UNLP. El prototipo valida de manera integral el flujo completo del sistema: detección de objetos mediante YOLO, clasificación con un modelo CNN entrenado en dos etapas, interfaz web y señalización física mediante Arduino, demostrando la viabilidad técnica de la propuesta en un entorno real.

Desde el punto de vista del modelo de ML, los resultados obtenidos son prometedores para un primer prototipo funcional, aunque evidencian aspectos que requieren mejora. El modelo desarrollado en Google Colab con EfficientNetV2S logra clasificar correctamente varias categorías de residuos, si bien presenta dificultades en la distinción entre materiales con características visuales similares.

Más allá de los resultados técnicos, el proyecto evidencia el valor de que estudiantes de grado aborden problemáticas socioambientales concretas de su propia institución, integrando y aplicando conocimientos de ML, desarrollo de software y electrónica que habitualmente se desarrollan de manera independiente en la formación de grado. Esta articulación entre saberes disciplinares y un problema real constituye en sí misma un aporte formativo significativo del proyecto. La validación del prototipo se llevó a cabo mediante evaluaciones entre pares y a través de su presentación en la Expo de Ciencia y Tecnología de la Facultad de Informática en octubre de 2025, espacio que permitió recibir retroalimentación de la comunidad institucional. Asimismo, el servicio web desarrollado fue incorporado como material de estudio en la asignatura "Laboratorio de Software", donde se amplió su funcionalidad, lo que da cuenta del potencial del proyecto como recurso de enseñanza más allá de sus objetivos originales. Durante el corriente año se prevé dar continuidad al proyecto mediante pruebas más amplias y diversas con distintos usuarios de la comunidad de la Facultad. La colaboración con estudiantes de la EEST N° 9 en la recolección de datos locales constituye, asimismo, un antecedente de vinculación entre la universidad y la escuela técnica que enriquece el proyecto desde una perspectiva extensionista.

Como trabajo futuro se prevé avanzar en varias líneas de mejora. En el plano del modelo de clasificación, se explorarán estrategias de aumento de datos y el incremento de imágenes locales en las categorías con menor precisión, con el fin de mejorar la capacidad de generalización. En el plano del hardware, se incorporarán sensores de llenado para monitorear la capacidad de cada compartimento en tiempo real, y un servomotor para la apertura automática de la tapa correspondiente al residuo clasificado. Respecto de la interfaz con los usuarios, se desarrollará una app móvil que implemente estrategias de gamificación mediante acumulación de puntos y rankings, con el objetivo de incentivar la separación en origen. Finalmente, se prevé establecer vínculos formales con cooperativas y recuperadores urbanos del área de influencia de la UNLP, consolidando la integración del prototipo en la cadena real de la economía circular local.

Referencias

Ahmed, M., Alotaibi, R., Al-Qahtani, R., Al-Qahtani, R., Al-Hetela, S., Al-Matar, K., Al-Saqer, N., Rahman, A., Sarairoh, L., Youldash, M., & Krishnasamy, G. (2023). Deep learning approach to recyclable products classification: Towards sustainable waste management. Sustainability. <https://doi.org/10.3390/su151411138>

- Ellen MacArthur Foundation. (2015). Towards a circular economy: Business rationale for an accelerated transition. <https://content.ellenmacarthurfoundation.org/m/4384c08da576329c/original/Towards-a-circular-economy-Business-rationale-for-an-accelerated-transition.pdf>
- Fotovvatikhah, F., Ahmedy, I., Noor, R. M., & Munir, M. U. (2025). A systematic review of AI-based techniques for automated waste classification. *Sensors*, 25(10), 3181. <https://doi.org/10.3390/s25103181>
- Hossen, M., Majid, M., Kashem, S., Khandakar, A., Nashbat, M., Ashraf, A., Hasan-Zia, M., Kunju, A., Kabir, S., & Chowdhury, M. (2024). A reliable and robust deep learning model for effective recyclable waste classification. *IEEE Access*, 12, 13809–13821. <https://doi.org/10.1109/access.2024.3354774>
- Mapa Federal de Reciclado. (s.f.). Mapa Federal de Reciclado y Aportes No Reembolsables (ANR) para cooperativas de reciclado. <https://www.argentina.gob.ar/capital-humano/familia/inclusion-laboral-y-economia-popular/argentina-recicla/mapa-federal-de>
- Midigudla, R., Dichpally, T., Vallabhaneni, U., Wutla, Y., Sundaram, D., & Jayachandran, S. (2025). A comparative analysis of deep learning models for waste segregation: YOLOv8, EfficientDet, and Detectron 2. *Multimedia Tools and Applications*, 84, 35941–35964. <https://doi.org/10.1007/s11042-025-20647-y>
- Ministerio de Ambiente de la Provincia de Buenos Aires. (2022a). Ambiente en diálogo: Gestión de residuos en Buenos Aires. https://www.ambiente.gba.gob.ar/contenido/ambiente_en_di%C3%A1logo_julio_inal_2022
- Ministerio de Ambiente de la Provincia de Buenos Aires. (2022b). Residuos sólidos urbanos y economía circular. https://www.ambiente.gba.gob.ar/pdfs/008_RSU_MANUAL_ABRI24.pdf
- Ministerio de Ambiente de la Provincia de Buenos Aires. (2025). Informe de gestión 2025. <https://www.ambiente.gba.gob.ar/pdfs/Informe-Gestion-Min-Ambiente-PBA-2025-2.pdf>
- Ministerio de Desarrollo Social de Argentina. (2023). Aprender de los residuos: La gestión integral e inclusiva de los residuos y su impacto socio-ambiental. <https://www.educ.ar/recursos/158671/aprender-de-los-residuos-la-gestion-integral-e-inclusiva-de>
- Municipalidad de La Plata. (2009). Ordenanza Municipal N° 10.661. <https://www.argentina.gob.ar/sites/default/files/rsu-la-plata-ley-basura-cero.pdf>
- Nafiz, M. S., Das, S. S., Morol, M. K., Juabir, A. A., & Nandi, D. (2023). ConvoWaste: An automatic waste segregation machine using deep learning.
- OCDE. (2016). Extended producer responsibility: Updated guidance for efficient waste management. OECD Publishing. <http://dx.doi.org/10.1787/9789264256385-en>
- OCDE. (2024). Extended producer responsibility. https://www.oecd.org/content/dam/oecd/en/publications/reports/2024/04/extended-producer-responsibility_4274765d/67587b0b-en.pdf
- Open Source Hardware Association (OSHWA). (s.f.). Open source hardware definition. <https://oshwa.org/resources/open-source-hardware-definition/>
- Poder Ejecutivo Nacional. (2004). Ley N° 25.916: Presupuestos mínimos de protección ambiental para la gestión de residuos domiciliarios. <https://www.argentina.gob.ar/normativa/nacional/ley-25916-98327/texto>
- Provincia de Buenos Aires. (2006). Ley N° 13.592: Gestión integral de residuos sólidos urbanos. <https://www.ambiente.gba.gob.ar/sites/default/files/Ley%2013592.pdf>
- Organización de las Naciones Unidas para el Medio Ambiente. (2024). El mundo debe superar la era de los desechos y convertirlos en recursos. <https://www.unep.org/es/noticias-y-reportajes/comunicado-de-prensa/el-mundo-debe-superar-la-era-de-los-desechos-y>
- Organización de las Naciones Unidas. (2015). Transformar nuestro mundo: la Agenda 2030 para el Desarrollo Sostenible (Resolución A/RES/70/1). <https://www.un.org/sustainabledevelopment/es/>
- Radio Usach. (2024). Proyecto Usach sobre reciclaje con contenedores inteligentes gana Smart City Award 2024 [Video]. YouTube. <https://www.youtube.com/watch?v=LyFvCy9zbK4>
- Tan, M., & Le, Q. V. (2021). EfficientNetV2: Smaller models and faster training. <https://arxiv.org/abs/2104.00298>
- Universidad de Santiago de Chile. (s.f.). Proyecto de reciclaje con contenedores inteligentes – RedCiclaCh. <https://redciclach.com/>
- Yevle, D. V., & Mann, P. S. (2025). Artificial intelligence based classification for waste management: A survey based on taxonomy, classification & future direction. *Computer Science Review*, 56, 100723. <https://doi.org/10.1016/j.cosrev.2024.100723>