

# ReEasy: A Bottle Scanning Application with a Reward Points System for Promoting Recycling

Asat Lautaro, Galan Laureano, Guzmán Benjamín, Veloso Mauricio y Martín Sposito Simón

Facultad de Ingeniería, Universidad Nacional de La Pampa  
{lautaronorielasat,lauregalan1}@gmail.com,  
{diego.guzman,mauricio.veloso,simon.martin}@ing.unlpam.edu.ar

**Abstract** This paper presents ReEasy, a mobile platform aimed at supporting PET waste management through the automatic identification of recyclable containers. Its main objective is to encourage citizen participation in recycling activities through an incentive system linked to the effective recovery of recyclable materials. The project was developed within the framework of the Systems Analysis and Design I and II courses, encompassing the analysis, design, and implementation of a functional prototype. The application was designed following a RESTful service-based architecture and integrates a computer vision model for the automatic validation of recyclable containers. Through this approach, the proposal seeks to support recyclable material recovery processes and promote more sustainable consumption practices aligned with the principles of the circular economy.

**Keywords:** recycling, computer vision, PET waste, REST architectural

## ReEasy: Aplicación para el Escaneo de Botellas y Sistema de Puntos para Fomentar el Reciclaje

**Resumen** Este trabajo presenta ReEasy, una plataforma móvil orientada a facilitar la gestión de residuos PET mediante la identificación automática de envases reciclables. Su objetivo es promover la participación ciudadana en actividades de reciclaje a través de un sistema de incentivos asociado a la recuperación efectiva de los residuos. El proyecto fue desarrollado en el marco de las asignaturas Análisis y Diseño de Sistemas I y II, abarcando las etapas de análisis, diseño e implementación de un prototipo funcional. La aplicación se diseñó siguiendo una arquitectura basada en servicios RESTful e integra un modelo de visión artificial. Se pretende contribuir al fortalecimiento de los procesos de recuperación de materiales reciclables y a la promoción de hábitos de consumo más sostenibles, alineados con los principios de la economía circular.

**Keywords:** reciclado, visión computacional, residuos PET, arquitectura REST

## 1. Introducción

La recuperación de residuos plásticos constituye uno de los desafíos ambientales más relevantes para las ciudades actuales (United Nations Environment Programme, 2023). En particular, el reciclaje de envases PET (Polietileno Tereftalato) requiere no solo infraestructura adecuada para su procesamiento, sino también, la participación activa de los ciudadanos en las etapas de separación y disposición de los materiales.

La problemática asociada a la disponibilidad de material reciclable y participación ciudadana fue analizada a partir del caso de una empresa local dedicada al procesamiento de envases PET. El relevamiento realizado permitió identificar que una de las principales limitaciones no radica únicamente en la capacidad industrial de reciclaje, sino también, en la dificultad para obtener material correctamente clasificado y en cantidades suficientes. Si bien existen iniciativas de recolección y recuperación de residuos, factores como la mezcla de distintos tipos de residuos, la presencia de alguno de ellos contaminados y las dificultades logísticas asociadas a la recolección, afectan la calidad y disponibilidad del material recuperado.

A partir de esta problemática, surge la oportunidad de incorporar herramientas tecnológicas que colaboren con la clasificación temprana de residuos y faciliten la vinculación entre quienes generan los materiales y quienes participan en su recuperación. En particular, las técnicas de visión artificial pueden utilizarse para asistir en la identificación automática de envases potencialmente reciclables, mientras que las tecnologías web permiten automatizar las tareas involucradas para registrar, organizar y dar seguimiento a los materiales disponibles para su recolección.

Como parte de un trabajo de cátedras con trayectos vinculados, se desarrolló ReEasy, una aplicación web orientada a la gestión de residuos PET que combina visión artificial y tecnologías web para apoyar el proceso de recuperación de materiales reciclables. El presente trabajo describe el análisis, diseño e implementación de la solución propuesta, así como los principales resultados obtenidos durante la construcción y evaluación del prototipo desarrollado.

## 2. Desarrollo

ReEasy surgió como una idea propuesta por un grupo de estudiantes para cumplimentar el trabajo integrador de las asignaturas Análisis y Diseño de Sistemas I y II <sup>1</sup>. El trabajo fue evolucionando a lo largo de los últimos dos años, desde una propuesta conceptual hasta la construcción de un prototipo funcional. La solución integra tecnologías de visión artificial, servicios web RESTful y contempla un mecanismo de incentivos asociado a la recuperación efectiva de materiales reciclables de tipo PET.

El proceso que implementa ReEasy comienza cuando el usuario captura una fotografía de los envases que desea reciclar utilizando la aplicación móvil. La imagen es enviada al sistema, donde un modelo de visión artificial analiza su

---

<sup>1</sup> Carreras Ingeniería en Sistema y Analista Programador de la UNLPam.

contenido, identifica las botellas presentes y determina cuáles corresponden a envases PET aptos para el circuito de recuperación considerado.

Cuando finaliza el análisis, el sistema registra los materiales detectados y genera una solicitud de recolección asociada al usuario. Además, se le informa la cantidad de puntos potenciales que podrían obtenerse por los envases registrados. En esta instancia, los puntos cumplen únicamente una función informativa, ya que todavía no forman parte del saldo disponible del usuario.

Posteriormente, un recolector realiza el retiro de los materiales registrados. Durante esta etapa se verifica la correspondencia entre los envases efectivamente entregados y aquellos previamente informados por el sistema. Tan pronto confirmada la recolección, los puntos son acreditados de acuerdo con la cantidad de material recuperado. Si la recolección no puede realizarse total o parcialmente, la acreditación se ajusta en consecuencia.

Una vez acreditados, los puntos pueden ser utilizados dentro de la plataforma para acceder a beneficios ofrecidos por organizaciones y comercios adheridos a la iniciativa. Entre ellos se incluyen descuentos, promociones y productos canjeables, con el objetivo de fomentar la participación sostenida de los usuarios y fortalecer el vínculo entre la recuperación de residuos y la economía circular.

De esta manera, el esquema de incentivos queda vinculado a la incorporación efectiva de residuos PET al circuito de recuperación y no únicamente a la acción de escanear imágenes. Esto permite fortalecer la trazabilidad del proceso y reducir posibles inconsistencias entre el material declarado por los usuarios y el material efectivamente recuperado.

A partir de esta propuesta se llevó adelante el análisis, diseño e implementación de un prototipo funcional, cuyos principales aspectos técnicos se presentan en las secciones siguientes.

**2.0.1. Análisis y Diseño de los requerimientos** A partir de los requerimientos definidos y modelados durante la etapa de análisis, se elaboraron distintos modelos UML (Booch et al., 2005) de diseño, con el objetivo de representar tanto la estructura del sistema como el comportamiento de sus principales funcionalidades <sup>2</sup>. En particular, se construyeron modelos de diseño estáticos para describir los componentes involucrados y modelos de diseño dinámicos, para analizar las interacciones necesarias entre ellos durante la ejecución de los casos de uso. La Figura 1 presenta el modelo de diseño dinámico correspondiente al caso de uso *Escanear envases*. Mediante este modelo es posible visualizar la secuencia de mensajes intercambiados entre los distintos componentes del sistema desde que el usuario inicia el proceso de escaneo hasta la generación de la respuesta final.

La secuencia del modelo de diseño dinámico muestra la interacción que sucede cuando el usuario captura una imagen de los envases que desea registrar para su posterior recolección. La solicitud es recibida por el controlador de la aplicación, que delega la coordinación del proceso al servicio encargado de la lógica de negocio. A continuación, la imagen escaneada es enviada al componente especializado en

---

<sup>2</sup> Por cuestiones de espacio, solo se describe el diseño del caso de uso considerado más importante

análisis de imágenes, responsable de ejecutar el proceso de detección y clasificación de los envases presentes. Como resultado del análisis, se obtiene información sobre los materiales identificados, incluyendo su categoría y cantidad. Estos datos son posteriormente utilizados para registrar el escaneo realizado, asociarlo al usuario correspondiente y generar una solicitud de recolección.

Finalmente, el sistema devuelve al usuario el resultado del procesamiento, informando los envases detectados y la cantidad de puntos potencialmente asociados a la futura recuperación del material.

Este modelo permitió validar tempranamente la distribución de responsabilidades entre los componentes involucrados para el caso de uso y verificar la consistencia del flujo definido antes de avanzar hacia las etapas de implementación.




Figura 1: Modelo de diseño dinámico: Caso de uso: Escanear botellas

## 2.1. Arquitectura del sistema

La arquitectura de ReEasy fue diseñada con el objetivo de mantener separadas las responsabilidades asociadas a la interacción con los usuarios, la lógica de negocio y el procesamiento de imágenes. Para ello, la arquitectura se organiza en cuatro componentes principales: una componente cliente encargada de la interacción con los usuarios, un componente *backend* responsable de la lógica de negocio, un servicio especializado de visión artificial para el análisis de imágenes y una base de datos relacional destinada a la persistencia de la información del sistema.

La comunicación entre estos componentes sigue un esquema cliente-servidor. Las solicitudes realizadas desde el cliente son recibidas por el *backend*, que coordina las invocaciones solicitadas y gestiona la comunicación a los distintos servicios. Por ejemplo, cuando se requiere validar imágenes de residuos, se delega el procesamiento al servicio de visión artificial, el cual devuelve los resultados obtenidos para que puedan ser incorporados al flujo de negocio correspondiente.

El componente *backend* fue organizada utilizando el patrón *Package by Feature* (Martin, 2017), agrupando el código según las funcionalidades del dominio,

favoreciendo la cohesión y reduciendo el acoplamiento entre módulos. Como se observa en el modelo de paquetes de la Figura 2, la arquitectura se divide en módulos como *users*, *scan*, *redeem*, *coupons* y *chat*. Cada uno de ellos encapsula los componentes necesarios para implementar una funcionalidad específica, incluyendo controladores, servicios, acceso a datos y modelos asociados. Particularmente, el módulo *scan* concentra la lógica vinculada al registro y validación de residuos. Cuando un usuario envía una imagen para su análisis, este módulo coordina la comunicación con el servicio de visión artificial, recibe los resultados de detección y clasificación y registra la información obtenida dentro del sistema. A partir de estos datos se generan las solicitudes de recolección y se calcula la estimación de puntos asociada a los materiales detectados.

La separación entre la lógica de negocio y el procesamiento de imágenes permite mantener un bajo nivel de acoplamiento entre componentes. Como consecuencia, el modelo de visión artificial puede ser actualizado o reemplazado sin requerir modificaciones significativas en el resto del sistema. Asimismo, esta decisión arquitectónica facilita la incorporación futura de nuevos mecanismos de clasificación, diferentes estrategias de validación o incluso servicios externos especializados, favoreciendo la evolución de la solución a medida que aumenten sus requerimientos funcionales y operativos.




Figura 2: Arquitectura de ReEasy. Vista paquetes.

## 2.2. Modelo de Visión Artificial

Para validar automáticamente el tipo de residuo PET que desea desechar el usuario, se diseñó un modelo de visión artificial basado en un enfoque de procesamiento en dos etapas, que permitió desacoplar la detección espacial de los

objetos, de su posterior clasificación. Las dos etapas del flujo de procesamiento son:

- **Detección de objetos:** Se utiliza un modelo YOLOv26m (Jocher et al., 2026)<sup>3</sup> para identificar y localizar las botellas presentes en la imagen capturada por el usuario. El modelo genera un conjunto de regiones de interés correspondientes a las botellas detectadas.
- **Clasificación de material:** Cada región detectada es recortada y procesada individualmente mediante un modelo YOLOv26n-cls (Jocher et al., 2026), encargado de determinar si el envase corresponde a la categoría PET o NoPET.

Este enfoque permite reducir el impacto del ruido visual del entorno, ya que el modelo clasificador opera sobre imágenes previamente segmentadas, enfocándose exclusivamente en las características del objeto.

**2.2.1. Construcción del dataset** Para el entrenamiento y evaluación del modelo, se construyó un dataset<sup>4</sup> para la clasificación binaria de envases PET y NoPET. La mayor parte de las imágenes del dataset fueron obtenidas mediante búsquedas en Internet. Posteriormente, se realizó un proceso manual de selección y depuración, descartando imágenes de baja calidad, fotografías sin relación con envases o representaciones artificiales que no resultaban consistentes con escenarios reales de utilización. Además, se incorporaron fotografías capturadas por los autores del proyecto, con el objetivo de representar situaciones similares a las que podrían encontrarse durante el uso cotidiano de la aplicación.

Para incrementar la diversidad de ejemplos disponibles y mejorar la capacidad de generalización del modelo, se aplicaron técnicas de aumento de datos (*data augmentation*), incluyendo rotaciones, variaciones de perspectiva, deformaciones leves y modificaciones de iluminación.

**2.2.2. Distribución de clases y categorías consideradas** El problema de identificar el tipo de botella que el usuario escanea, fue abordado como una tarea de clasificación binaria compuesta por dos categorías: PET y NoPET.

La categoría PET incluye principalmente botellas plásticas de agua, gaseosas, aceite, vinagre y alcohol. Por otra parte, la categoría NoPET contempla envases que no forman parte del circuito de recuperación considerado por la solución, incluyendo botellas de vidrio, recipientes metálicos, bidones de agua, botellas reutilizables y otros recipientes plásticos rígidos.

La distribución de imágenes del dataset utilizado durante el entrenamiento presenta la siguiente estructura:

<sup>3</sup> <https://github.com/ultralytics/ultralytics>

<sup>4</sup> El dataset completo se encuentra disponible públicamente para fines académicos y de investigación: <https://drive.google.com/file/d/10hLtp08N7NsF8PeELiUm2qplqKDNA3KW/view?usp=sharing>

```

dataset
train
    PET      (1031 imágenes)
    NoPET    (1277 imágenes)
test
    PET      (126 imágenes)
    NoPET    (177 imágenes)
val
    PET      (120 imágenes)
    NoPET    (159 imágenes)

```

En ella se observa que ambas categorías de envases presentan una distribución relativamente equilibrada, reduciendo el riesgo de sesgos asociados al desbalance extremo entre clases. Las imágenes se estructuran como datos de entrenamiento (*train*), prueba (*test*) y validación (*val*).

**2.2.3. Aprendizaje por transferencia** Para el entrenamiento del modelo clasificador se empleó la técnica de aprendizaje por transferencia (*transfer learning*) (Pan and Yang, 2010; Goodfellow et al., 2016). Este enfoque consiste en reutilizar un modelo previamente entrenado sobre grandes volúmenes de datos generales y adaptarlo a una tarea específica mediante el ajuste de sus capas finales. En particular, se conservaron las capas encargadas de la extracción de características visuales generales, tales como bordes, texturas y patrones. Posteriormente, se ajustaron las capas finales utilizando el dataset propio construido para discriminar entre las categorías PET y NoPET. La Figura 3 ilustra la implementación del entrenamiento considerando los datasets explicados anteriormente.

La utilización de la técnica de aprendizaje por transferencia permitió reducir la cantidad de datos necesarios para el entrenamiento, acelerar la convergencia del modelo y mejorar su capacidad de generalización.




Figura 3: Proceso de implementación de aprendizaje supervisado aplicado para clasificar botellas como PET/NoPET. Fuente: Generada por ChatGPT.

**2.2.4. Configuración del entrenamiento** El modelo de visión artificial fue implementado utilizando Ultralytics YOLO26 (Jocher et al., 2026), en su versión

más reciente disponible al momento del desarrollo de este trabajo, que es la lanzada oficialmente en enero de 2026.

Para la etapa de detección de objetos se empleó el modelo YOLOv26m<sup>5</sup> (Jocher et al., 2026) utilizando los pesos preentrenados provistos por sus desarrolladores, sin realizar modificaciones adicionales. Este modelo fue utilizado exclusivamente para localizar las botellas presentes en las imágenes que escanea el usuario.

Para la etapa de clasificación de materiales se utilizó un modelo YOLO26n-cls, correspondiente a la variante de clasificación de imágenes de la familia YOLO26. El modelo fue adaptado mediante aprendizaje por transferencia utilizando el conjunto de datos construido específicamente para este trabajo, permitiendo ajustar los pesos preentrenados a las categorías de materiales de interés.

Respecto a la configuración del entrenamiento, se utilizó un entorno de Google Colaboratory con aceleración mediante una GPU NVIDIA T4. Las imágenes fueron normalizadas a una resolución de  $640 \times 640$  píxeles y el proceso de ajuste se ejecutó durante 100 épocas utilizando un tamaño de lote (*batch size*) de 16 imágenes. La elección de un modelo de clasificación de tamaño reducido permitió mantener bajos tiempos de inferencia, facilitando su integración dentro de una aplicación interactiva orientada a dispositivos móviles.

**2.2.5. Entrenamiento y evaluación** El modelo clasificador fue entrenado utilizando el dataset descrito anteriormente. Los datos fueron divididos en subconjuntos de entrenamiento, prueba y validación, permitiendo evaluar la capacidad de generalización del modelo sobre imágenes no utilizadas durante el proceso de aprendizaje <sup>6</sup>.

Para evaluar el desempeño del modelo se analizaron las métricas de pérdida sobre entrenamiento (*train loss*) y validación (*validation loss*), así como la precisión Top-1 y Top-5. Dado que el problema de clasificación contempla únicamente dos categorías (PET y NoPET), la métrica más representativa es la precisión Top-1, que alcanzó aproximadamente un 95 % al finalizar el entrenamiento. La Figura 4a presenta las métricas obtenidas durante el entrenamiento del modelo YOLO26n-cls para la tarea de clasificación de materiales PET y NoPET a lo largo de 100 épocas.


- *Train Loss* (arriba izquierda en la figura): la función de pérdida del conjunto de entrenamiento disminuye de manera sostenida desde aproximadamente 0.50 hasta valores cercanos a 0.03, indicando que el modelo aprende progresivamente los patrones presentes en los datos de entrenamiento.
- *Accuracy Top-1* (arriba derecha en la figura): la precisión de clasificación aumenta rápidamente durante las primeras épocas y luego se estabiliza alrededor del 95 %, alcanzando valores máximos cercanos al 96 %. Esto sugiere una adecuada convergencia del modelo.

<sup>5</sup> <https://github.com/ultralytics/ultralytics>. Fecha acceso: Junio 2026.


<sup>6</sup> El código del entrenamiento del modelo se encuentra disponible públicamente en: <https://colab.research.google.com/drive/1gvdvvDBpXsy6TvwkMMnBatv068bQIGNP?usp=sharing>. Fecha acceso: Junio 2026.

- *Validation Loss* (abajo izquierda en la figura): la pérdida sobre el conjunto de validación presenta una disminución inicial importante y posteriormente oscila entre 0.15 y 0.25. Aunque existe cierta variabilidad entre épocas, no se observa un incremento sostenido que indique un sobreajuste significativo.
- *Accuracy Top-5* (abajo derecha en la figura): permanece constante en 1.0 (100 %) durante todo el entrenamiento. Dado que el problema contempla únicamente dos clases (PET y NoPET), esta métrica resulta poco informativa, ya que la clase correcta siempre se encuentra entre las cinco predicciones más probables.

En conjunto, los resultados muestran que el modelo logra una convergencia estable y alcanza un elevado nivel de precisión en la tarea de clasificación. La Figura 4b muestra un conjunto de imágenes reales clasificadas por el modelo entrenado y evaluado.



(a) Curvas de entrenamiento y validación del modelo YOLO26n-cls.



(b) Conjunto de imágenes clasificadas por el modelo.

Figura 4: Resultados del entrenamiento.

**2.2.6. Análisis de resultados** La Figura 5 presenta la matriz de confusión obtenida durante la evaluación del modelo clasificador. En la misma, puede observarse que la mayor parte de las imágenes fue clasificada correctamente. En particular, el modelo identificó correctamente 51 ejemplos pertenecientes a la categoría NoPET y 39 ejemplos correspondientes a la categoría PET. Los errores observados se resumen en los siguientes: únicamente una imagen PET fue clasificada como NoPET y dos imágenes NoPET fueron clasificadas erróneamente como PET, representando tres clasificaciones incorrectas sobre un total de 93 muestras evaluadas. Estos resultados muestran que el modelo posee una adecuada capacidad para discriminar entre ambas categorías. No obstante, algunos errores pueden atribuirse a las limitaciones identificadas en el dataset, particularmente la escasa representación de determinados tipos de envases o perspectivas de captura poco frecuentes.

En conjunto, los resultados experimentales indican que el modelo constituye una alternativa viable para asistir en el proceso de validación automática de residuos propuesto por ReEasy.




Figura 5: Matriz de confusión obtenida para la clasificación PET/NoPET.

**2.2.7. Limitaciones y posibles sesgos** Si bien los resultados obtenidos muestran un desempeño satisfactorio, durante la construcción y evaluación del dataset se identificaron algunas limitaciones que podrían afectar el comportamiento del modelo en determinados escenarios.

En primer lugar, existe una menor representación de imágenes capturadas desde perspectivas superiores o inferiores de los envases. Como consecuencia, la detección y clasificación puede resultar menos precisa cuando las botellas son fotografiadas desde estos ángulos poco frecuentes.

Por otro lado, el conjunto de datos no incluye ejemplos representativos de botellas retornables. En consecuencia, este tipo de envases puede clasificarse erróneamente como PET, aun cuando su tratamiento dentro de la cadena de recuperación difiere del considerado por la solución propuesta.

Estas limitaciones constituyen oportunidades de mejora para futuras versiones del modelo, mediante la incorporación de nuevas categorías y una mayor diversidad de imágenes durante el proceso de entrenamiento.

### 2.3. Implementación del prototipo de ReEasy

Una vez finalizadas las etapas de análisis, diseño y definición de la arquitectura, se procedió a la construcción de un prototipo funcional de ReEasy. El objetivo de esta etapa fue materializar los principales casos de uso identificados durante el relevamiento y validar la factibilidad técnica de integrar servicios web, visión artificial y mecanismos de incentivo dentro de una misma solución.

Los aspectos relacionados con el entrenamiento, la evaluación y las limitaciones del modelo de visión artificial, fueron presentados en la subsección 2.2. Por este motivo, en esta sección se describen principalmente los aspectos vinculados con la

integración de dichos componentes y las tecnologías utilizadas para la construcción del prototipo.

**2.3.1. Tecnologías utilizadas** El *backend* de ReEasy fue desarrollada utilizando Java y Spring Boot (VMware, Inc., 2026), Para la persistencia de la información se utilizó una base de datos MySQL junto con la biblioteca Sql2o (Sql2o Team, 2025) para el acceso a datos. Por su parte, los modelos de visión artificial fueron implementados utilizando la familia de modelos YOLOv26. La detección de botellas se realizó mediante el modelo YOLOv26m, mientras que la clasificación entre envases PET y NoPET se llevó a cabo utilizando un modelo YOLOv26n-clas ajustado mediante aprendizaje por transferencia.

Finalmente, la solución fue desplegada utilizando contenedores Docker (Docker Inc., 2026), facilitando la portabilidad de los distintos componentes y simplificando su ejecución en diferentes entornos.


**2.3.2. Implementación del flujo principal** La funcionalidad central del prototipo corresponde al registro y validación de envases mediante imágenes capturadas por los usuarios. El proceso comienza cuando el usuario captura una fotografía y la sube a la aplicación. La Figura 6a presenta la interfaz implementada para que el usuario escanee imágenes de las botellas que desea registrar para su posterior recolección. El *backend* de ReEasy recibe esa imagen y coordina el análisis utilizando el servicio de visión artificial previamente descrito.

Una vez obtenido el resultado de la inferencia, el sistema registra los envases detectados y genera una solicitud de recolección asociada al usuario. La Figura 6b muestra la interfaz de los resultados obtenidos luego del procesamiento automático de una imagen subida por el usuario. En ella se observa cómo se informa al usuario el resultado del análisis realizado, indicando la cantidad de envases identificados y los puntos potenciales asociados a la futura recuperación del material.

Cuando el usuario confirma el registro, las botellas quedan incorporadas al carrito de recolección, donde el usuario puede visualizar las botellas pendientes de retiro y realizar el seguimiento de las solicitudes generadas. La Figura 6c presenta la interfaz correspondiente al módulo de recolección.

El usuario dispone además, de un tablero de seguimiento (*dashboard*) que permite visualizar información relacionada con su progreso, incluyendo puntos acumulados, cantidad de envases recuperados y métricas ambientales estimadas. La Figura 6d muestra el panel principal del usuario.

La Figura 6 resume el flujo principal de utilización de ReEasy mediante un ejemplo concreto. En este caso, el usuario registra una botella PET, visualiza el resultado del análisis automático y los puntos potenciales obtenibles, incorpora el envase al carrito de recolección y finalmente puede observar su impacto reflejado en el panel de seguimiento de la aplicación.



(a) Captura de botellas.



(b) Resultados del escaneo de imágenes.



(c) Carrito plástico del usuario.



(d) Dashboard del usuario.

Figura 6: Capturas de las principales interfaces gráficas en ReEasy.

## 2.4. Implementación del mecanismo de validación

Uno de los aspectos considerados durante el desarrollo fue garantizar que las recompensas estuvieran asociadas a la recuperación efectiva de residuos y no únicamente al proceso de escaneo. Por este motivo, los puntos informados durante el análisis de imágenes representan únicamente una estimación potencial. Una vez generada la solicitud de recolección, un recolector debe verificar la cantidad de material efectivamente retirado antes de que los puntos sean acreditados al usuario.

De esta manera, el flujo implementado contempla las siguientes etapas: 1) escaneo y análisis de los envases, 2) registro de los materiales detectados, 3) generación de la solicitud de recolección, 4) validación del retiro por parte del recolector, 5) acreditación definitiva de los puntos correspondientes.

Los puntos son acreditados únicamente sobre los botellas PET efectivamente recuperadas. Posteriormente, estos puntos pueden utilizarse para acceder a descuentos, promociones o productos ofrecidos por entidades adheridas a la iniciativa ReEasy. Así, las recompensas quedan asociadas a la incorporación real de residuos PET al circuito de recuperación y no exclusivamente al registro de imágenes.

## 2.5. Estado actual del prototipo

El prototipo desarrollado permitió implementar y validar los principales casos de uso definidos durante la etapa de análisis <sup>7</sup>. En particular, se construyeron los módulos de gestión de usuarios, escaneo y validación de envases mediante visión artificial, generación de solicitudes de recolección, administración de recompensas y visualización de estadísticas para los usuarios.

Debido al alcance académico del proyecto, algunos aspectos propios de un entorno de producción no fueron abordados. Entre ellos se encuentran los mecanismos avanzados de seguridad, la detección automática de imágenes duplicadas, la prevención de comportamientos fraudulentos, las pruebas de carga y la validación del sistema sobre grandes volúmenes de usuarios y solicitudes. Así como también, todo lo concerniente al trazado y optimización de rutas para la recolección de los residuos.

No obstante, los resultados obtenidos permiten demostrar la viabilidad técnica de la propuesta y evidencian el potencial de integrar tecnologías de visión artificial, servicios web y mecanismos de incentivo para asistir los procesos de recuperación de residuos reciclables.

## 3. Conclusiones

En este trabajo se presentó ReEasy, una propuesta orientada a asistir los procesos de recuperación de residuos PET surgida en el marco de las asignaturas

---

<sup>7</sup> El proyecto de ReEasy se encuentra en el repositorio <https://github.com/lauregalan/reeasy-mob>. Fecha de acceso: Junio 2026.

Análisis y Diseño de Sistemas I y II. Comenzó como una iniciativa para abordar una problemática identificada durante el relevamiento realizado sobre el proceso de recuperación de materiales reciclables, en Análisis y Diseño de Sistemas I. A partir de dicho análisis, se observó que una de las dificultades existentes radica en la obtención de material correctamente clasificado desde su origen, situación que motivó el diseño de una solución capaz de asistir a los usuarios durante la etapa inicial del proceso de reciclaje, cuestión abordada en Análisis y Diseño de Sistemas II.

La experiencia desarrollada permitió aplicar de manera integrada conocimientos relacionados con análisis y diseño de sistemas, modelado UML, arquitectura de software, bases de datos, desarrollo de servicios web e incorporar técnicas de visión artificial, que constituye una temática no abordada en las materias mencionadas. Así, se logró una primera aproximación práctica al entrenamiento, evaluación e integración de modelos de aprendizaje profundo dentro de una solución de software completa.

Como líneas de trabajo futuro, se plantea profundizar la evaluación experimental del modelo de visión artificial. Si bien en este trabajo se reportó la precisión global obtenida durante la validación, resultaría valioso incorporar métricas adicionales para caracterizar con mayor detalle el comportamiento del clasificador y analizar los distintos tipos de errores que pueden producirse durante la inferencia.

Asimismo, sería de interés realizar estudios de robustez sobre el sistema en condiciones más cercanas a escenarios reales de utilización. Entre ellos se destacan la evaluación del desempeño frente a variaciones de iluminación, la presencia de envases parcialmente visibles, la incorporación de nuevos tipos de residuos y envases, así como el análisis de situaciones asociadas a errores de captura o escaneo por parte de los usuarios. Estas evaluaciones permitirían determinar con mayor precisión las limitaciones actuales del modelo y orientar futuras mejoras tanto en el dataset como en la estrategia de entrenamiento utilizada.

Vale destacar que ReEasy trasciende el desarrollo de un prototipo académico centrado exclusivamente en aspectos tecnológicos. Y si bien, aún existen aspectos técnicos y operativos por profundizar, el trabajo permitió materializar una solución funcional orientada a una problemática concreta, alineada con los principios de sostenibilidad y economía circular.

*Aclaración: Durante la preparación de este trabajo, los autores utilizaron ChatGPT con el fin de mejorar el lenguaje y la legibilidad del manuscrito. Tras utilizar esta herramienta, los autores revisaron y editaron el contenido según fuera necesario y asumen plena responsabilidad por el contenido de la publicación.*

## Bibliografía

- Booch, G., Rumbaugh, J., and Jacobson, I. (2005). *The Unified Modeling Language User Guide*. Addison-Wesley Professional, Boston, MA, 2nd edition.
- Docker Inc. (2026). Docker documentation. <https://docs.docker.com/>. Recuperado el 11 de junio de 2026.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- Jocher, G., Qiu, J., Liu, M., Lyu, S., Akyon, F. C., and Kalfaoglu, M. E. (2026). Ultralytics yolo26: Unified real-time end-to-end vision models. *arXiv preprint arXiv:2606.03748*.
- Martin, R. C. (2017). *Clean Architecture: A Craftsman's Guide to Software Structure and Design*. Prentice Hall.
- Pan, S. J. and Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10):1345–1359.
- Sql2o Team (2025). Sql2o documentation. <https://www.sql2o.org/>. Recuperado el 11 de junio de 2026.
- United Nations Environment Programme (2023). Turning off the tap: How the world can end plastic pollution and create a circular economy.
- VMware, Inc. (2026). Spring boot reference documentation. <https://docs.spring.io/spring-boot/reference/>. Recuperado el 11 de junio de 2026.