

Manipulación visual-táctil para la recogida de residuos domésticos en exteriores

Julio Castaño-Amorós^{a,c}, Ignacio de Loyola Páez-Ubieta^{a,c}, Pablo Gil^{a,b,*}, Santiago Timoteo Puente^{a,b}

^aInstituto Universitario de Investigación Informática, Universidad de Alicante, Campus de San Vicente del Raspeig s/n, 03690, Alicante, España.

^bDepartamento de Física, Ingeniería de Sistemas y Teoría de la Señal, Universidad de Alicante, Campus de San Vicente del Raspeig s/n, 03690, Alicante, España.

^cUniversidad Miguel Hernández, 03202, Elche, España.

To cite this article: Castaño-Amorós, J., Páez-Ubieta, I. de L., Gil, P., Puente, S. 2023. Visual-tactile manipulation to collect household waste in outdoor. Revista Iberoamericana de Automática e Informática Industrial 20, 163-174. <https://doi.org/10.4995/riai.2022.18534>

Resumen

Este artículo presenta un sistema de percepción orientado a la manipulación robótica, capaz de asistir en tareas de navegación, clasificación y recogida de residuos domésticos en exterior. El sistema está compuesto de sensores táctiles ópticos, cámaras RGBD y un LiDAR. Éstos se integran en una plataforma móvil que transporta un robot manipulador con pinza. El sistema consta de tres módulos software, dos visuales y uno táctil. Los módulos visuales implementan arquitecturas Convolutional Neural Networks (CNNs) para la localización y reconocimiento de residuos sólidos, además de estimar puntos de agarre. El módulo táctil, también basado en CNNs y procesamiento de imagen, regula la apertura de la pinza para controlar el agarre a partir de información de contacto. Nuestra propuesta tiene errores de localización entorno al 6 %, una precisión de reconocimiento del 98 %, y garantiza estabilidad de agarre el 91 % de las veces. Los tres módulos trabajan en tiempos inferiores a los 750 ms.

Palabras clave: Detección visual, Reconocimiento de objetos, Localización de objetos, Percepción táctil, Manipulación robótica

Visual-tactile manipulation to collect household waste in outdoor

Abstract

This work presents a perception system applied to robotic manipulation, that is able to assist in navigation, household waste classification and collection in outdoor environments. This system is made up of optical tactile sensors, RGBD cameras and a LiDAR. These sensors are integrated on a mobile platform with a robot manipulator and a robotic gripper. Our system is divided in three software modules, two of them are vision-based and the last one is tactile-based. The vision-based modules use CNNs to localize and recognize solid household waste, together with the grasping points estimation. The tactile-based module, which also uses CNNs and image processing, adjusts the gripper opening to control the grasping from touch data. Our proposal achieves localization errors around 6 %, a recognition accuracy of 98 % and ensures the grasping stability the 91 % of the attempts. The sum of runtimes of the three modules is less than 750 ms.

Keywords: Visual detection, Object recognition, Object location, Tactile perception, Robotic manipulation

1. Introducción

En la actualidad, uno de los desafíos mundiales está relacionado con la digitalización en el cuidado de nuestro entorno, y más en concreto en su aplicación en áreas municipalizadas. Basta hacer notar que, en los últimos años, en España se generaron una media de 483,7 Kilos/hab en 2019, último año registrado según el Instituto Nacional de Estadística (INE), es decir

17.764 toneladas. Solamente entre residuos urbanos no peligrosos y recuperables de vidrio, cartón y plástico se generaron 2.3 millones en el territorio nacional, siendo una tendencia al alza el número de residuos procedentes de basura doméstica. Muchos de estos residuos acaban fuera de sus depósitos de recolección, en parques, recintos abiertos y calles de áreas urbanizadas. En este trabajo se expone una solución robotizada que trata de pa-

*Autor para correspondencia: pablo.gil@ua.es

liar la acumulación de residuos domésticos en exteriores, fuera de los lugares y depósitos de recolección destinados para ello. En concreto, se presenta un sistema sensorial enfocado a facilitar la recogida automatizada y organizada de desechos no orgánicos y no peligrosos, como botellas de plástico, latas, cajas, etc.

Este artículo se organiza de la siguiente manera. En la Sección 2, se exponen trabajos previos relacionados con el reconocimiento de residuos para su manipulación en distintos escenarios. Posteriormente, en la Sección 3, se describe la plataforma robótica empleada para percibir el entorno, los objetos presentes en él y ejecutar así, las tareas de manipulación y recogida de residuos en exteriores. A continuación, en la Sección 4, se presentan los métodos y algoritmos implementados para detección, localización y cálculo de agarre a partir de información visual. Y en la Sección 5, se describen los métodos y algoritmos táctiles desarrollados para llevar a cabo un agarre estable y exitoso en tareas de levantar y soltar. Finalmente, en la última sección, se muestran y discuten resultados experimentales llevados a cabo en escenarios reales.

2. Trabajos relacionados

Los avances en procesadores gráficos y en técnicas computacionales que se han producido recientemente han repercutido directamente en mejorar el procesamiento e interpretación de imágenes de objetos, tanto en escenarios de interior como de exterior, con condiciones de iluminación cambiantes y con factores de incertidumbre en pose, forma, textura, etc. Los métodos de aprendizaje máquina, y especialmente aquellos basados en redes neuronales, son los grandes beneficiados, ya que han visto reducir drásticamente los tiempos de entrenamiento e inferencia, permitiendo manejar grandes volúmenes de datos y muchas casuísticas distintas de objetos y escenarios. Este boom computacional está permitiendo, por un lado, tratar de abordar el reconocimiento de residuos en la industria de reciclado como un problema de clasificación automática de imágenes. Así en (Bircanoglu et al., 2018), (Patrizi et al., 2021) y (Vo et al., 2019) se evalúa, para esa tarea, el uso de distintas versiones de conocidas CNNs (ResNet, Inception, Xception, MobileNet, etc.) y, se proponen ligeras modificaciones en las últimas capas para clasificar objetos, que generalmente se presentan aislados, apoyados sobre superficies totalmente planas, homogéneas, y sin oclusiones. Por ejemplo, en (Bircanoglu et al., 2018) se clasifican las imágenes en muestras de papel, vidrio y metal, mientras que en (Vo et al., 2019) se clasifican representaciones orgánicas, inorgánicas o residuos médicos. En (Patrizi et al., 2021) se generan nuevas muestras de residuos a partir de las bases de datos empleadas en los anteriores trabajos. Para hacerlo, los autores aplican técnicas de aumento de datos por sustitución del fondo de las imágenes de los objetos con el objetivo de mejorar la generalización en la clasificación.

También, ha habido intentos de implementar CNNs más ligeras con pocas capas para reducir tiempos de entrenamiento e inferencia como en (Altikat et al., 2022) con bastante peor tasa de reconocimiento, o incluso de embeber este tipo de CNNs en sistemas de CPU integrada del tipo Raspberry Pi 4 como en (Fu et al., 2021), para así diseñar sistemas portables y poder controlar actuadores desde la salida del reconocimiento.

Por otro lado, en el estado del arte, también se ha tratado de enfocar el problema de reconocimiento de residuos como una tarea de detección de objetos, como muestran trabajos como (Feng et al., 2021) y (Kiyokawa et al., 2021). A diferencia de abordarlo como un problema de clasificación, hacerlo como uno de detección ayuda a extraer características que permiten determinar la pose (localización y orientación en la imagen) del objeto o residuo, lo que facilita después implementar métodos para llevar a cabo tareas de coger, levantar y soltar con robots manipuladores. Por ejemplo, en (Feng et al., 2021) se hace uso de una red MobileNet como base para implementar una R-CNN de segmentación de regiones (Minaee et al., 2020), a partir de las características que extrae MobileNet. Así, la nueva MobileNet + Mask-RCNN consigue mantener altos valores de precisión en la detección, superiores al noventa por ciento sobre una Raspberry Pi, permitiendo además la detección de múltiples instancias de objetos en una misma imagen. Y en (Kiyokawa et al., 2021) se presenta un sistema robótico basado en un KUKA LBR iiwa 14 R820 con cámara RGBD que implementa un sistema de percepción visual basado en una red neuronal SSD para la localización, reconocimiento, recogida y clasificación de residuos domésticos en entornos de interior. Es en este tipo de aproximaciones en las que se basa la idea de nuestro trabajo.

En cuanto a la tarea de estimación de poses de agarre, se han aplicado diversos enfoques que pueden clasificarse en dos categorías: basados en datos, como propusieron en (Sahbani et al., 2012) y (Liu et al., 2021), y basados en modelo como hicieron en (Jiang et al., 2021) y (Shaw-Cortez et al., 2018). Los trabajos basados en datos analizan datos muestreados de las tareas de agarre y/o manipulación con técnicas de aprendizaje (Newbury et al., 2022). En los basados en modelo, se emplean características del manipulador y se extraen descriptores del objeto a manipular para crear un modelo físico (Bohg et al., 2013). Además, es posible calcular la pose para realizar el agarre, tal y como propone (Guo et al., 2020) o el cálculo de los puntos de agarre en los objetos (Kim et al., 2021), siendo este último tipo de método el que se empleará.

Con respecto a la manipulación de objetos, se han realizado numerosos trabajos en el estado del arte con el fin de incluir los robots manipuladores en ámbitos como el social o el industrial. Tradicionalmente, se han empleado sensores capaces de medir la fuerza producida por un objeto sobre el extremo del robot durante la manipulación. Estos sensores permiten desarrollar estrategias de control para llevar a cabo tareas complejas de manipulación. Más recientemente, se han desarrollado trabajos con sensores táctiles con diferentes tecnologías como piezo-resistiva, capacitiva, óptica, magnética o barométrica, que devuelven valores de presión ejercidos sobre el objeto manipulado, como por ejemplo (Yao et al., 2020), (Zapata-Impata et al., 2019b) y (Velasco et al., 2020). En (Yao et al., 2020), los autores diseñan un sensor capacitivo tridimensional para la detección de contacto y deslizamiento obteniendo notables resultados gracias a la alta sensibilidad, bajo tiempo de respuesta y baja histéresis de estos sensores. En (Zapata-Impata et al., 2019b) se utilizan los sensores BiotacSP acoplados a la mano robótica Shadow con el objetivo de detectar deslizamiento de objetos mediante redes neuronales. Por otro lado, en (Velasco et al., 2020) los autores utilizaban técnicas clásicas de aprendizaje automático para clasificar objetos según los valores ar-

ticulares de una mano Allegro y los valores de presión de los sensores resistivos colocados sobre los dedos. La tendencia actual se centra más en sensores táctiles de tipo óptico (basados en imagen) como Gelsight (Yuan et al., 2017), GelSlim (Donlon et al., 2018), Tactip (Ward-Cherrier et al., 2018) o Digit (Lambeta et al., 2020). A diferencia de los sensores mencionados anteriormente (fuerza/presión), este tipo de sensores no proporcionan valores de fuerza o presión, sino una imagen en color donde se produce el contacto entre el sensor y el objeto. De esta manera, se pueden aplicar las técnicas más novedosas en el campo de visión por computador y deep learning para tareas de manipulación y agarre basadas en imagen. Por ejemplo, en (Kolamuri et al., 2021) realizan un estudio para compensar la rotación indeseada de un objeto a partir de las imágenes táctiles de sensores Gelsight, mediante técnicas tradicionales de visión por computador. Otro ejemplo sería el trabajo de (Lin et al., 2022) donde aplican técnicas de aprendizaje por refuerzo para llevar a cabo diferentes tareas de manipulación con sensores táctiles como Gelsight, Digit o Tactip. En este trabajo se pretende continuar con la tendencia de uso de los sensores táctiles de bajo coste basados en imagen, ya que aportan más información sobre las características de los objetos que los sensores de fuerza o presión, ya que tienen una resolución espacial mayor.

Las principales novedades de nuestra propuesta son varias. Primero, se ha mejorado el proceso de reconocimiento, empleando una arquitectura Yolact para segmentación (Liu et al., 2020), la cual pertenece a la misma familia de redes que MaskRCNN o SDD (Minaee et al., 2020), para así conseguir más rapidez de detección sin sacrificar tasa de precisión. Después, se mejora el sistema visual incorporando un sistema de estimación de los puntos de agarre a partir de la detección del objeto-basura, extendiendo el trabajo que empezó a desarrollarse en (De Gea et al., 2021). Y finalmente, se ha incorporado un sistema táctil basado en CNNs y sensores táctiles Digit, para controlar la manipulación durante la tarea de agarrar y levantar los residuos, a partir de desarrollos previos mostrados en (Castaño-Amoros et al., 2021). Todo esto se ha empezado a testar, funcionando en situaciones similares a las reales en entornos de exterior.

3. Plataforma robótica de manipulación

Nuestro sistema robótico para la recogida de residuos domésticos consta de una plataforma móvil de fabricación propia, conocida como BLUE (Del Pino et al., 2020), similar a otras plataformas de manipulación móvil como la presente en (Suárez et al., 2020). Esta plataforma recientemente ha sido modificada para transportar un manipulador UR5e de 6 grados de libertad, dotado de una pinza de 2 dedos ROBOTIQ-2F140. Mientras la plataforma móvil se emplea para la navegación en busca de residuos, éste último se emplea para las tareas de recogida.

A parte de estos dispositivos robóticos, el sistema consta de un subsistema de percepción visual y otro táctil, ambos constituidos por una serie de sensores externos y por los algoritmos que permiten adquirir datos, procesarlos, e interpretar tanto el escenario como la interacción del robot con el entorno. Los sensores visuales empleados son cámaras RealSense D435i, adquiriendo imágenes RGBD a 640x480 a una velocidad de 30

Frames Per Second (FPS). También, se emplea un 3D LiDAR Velodyne VLP16 que trabaja a 10Hz y es capaz de medir distancias hasta 100 m, frente al rango de distancias de uso de 0,3–3m que proporcionan las cámaras. Por otro lado, el subsistema táctil consta de dos sensores ópticos de bajo coste, DIGIT (Lambeta et al., 2020), colocados en el interior de los dedos de la pinza. Cada uno de estos sensores captura imágenes RGB con una frecuencia de hasta 30 FPS y una resolución de 240x320 píxeles. En la Figura 1 se muestran la plataforma robótica y los sensores empleados en este trabajo.




Figura 1: Plataforma robótica y sensores

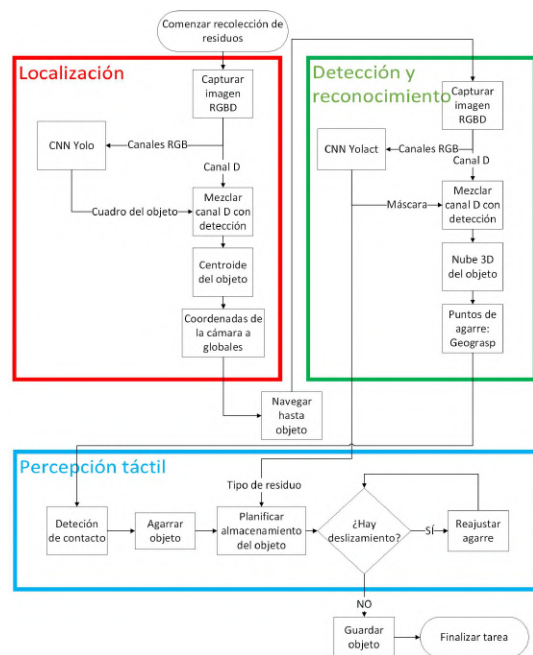


Figura 2: Arquitectura del sistema de percepción visual-táctil para la recolección robótica de residuos

Los dispositivos robóticos, tanto los de desarrollo propio (BLUE), comerciales (UR5e y pinza), como los sensores (RGBD, LiDAR), etc. se han integrado en ROS corriendo sobre Ubuntu Melodic Morenia para facilitar el intercambio de información y la comunicación. Así, sobre ROS se han implementado todos los métodos y algoritmos que forman parte de

los módulos software de los subsistemas de percepción visual y táctil. En concreto, estos métodos y algoritmos se ejecutan en una Jetson AGX Xavier. En la Figura 2 se muestra la arquitectura general del sistema. El sistema presentado está orientado a la recogida de diferente tipología de residuos domésticos no orgánicos y sólidos, como botes, botellas, latas o tetrabricks, en ambientes exteriores, con un manipulador móvil. Éste se encuentra dividido en tres partes diferenciadas, siendo éstas la localización de los residuos y la navegación para su recogida (Sección 4.2), la detección de estos residuos una vez estamos cerca de los mismos y el reconocimiento para su categorización (Sección 4.1) y finalmente, la manipulación de los mismos para agarrarlos y subirlos a bordo de la plataforma robótica (Sección 5).

4. Sistema de percepción visual

4.1. Detección y reconocimiento en exteriores

Una vez se han detectado potenciales residuos a partir de las imágenes de una de las cámaras RGBD y calculado las coordenadas 3D de cada uno de ellos (se detallará en la sección siguiente), tal como se muestra en el procedimiento resaltado en color rojo en la Figura 2, el robot se aproxima navegando hasta ellos para tratar de reconocer el objeto con mayor exactitud. Este proceso se detalla en verde en la misma Figura 2. Para ello, se ha implementado un módulo software específico para esta tarea. El módulo hace uso de una CNN de tipo Yolact (Bolya et al., 2019) mostrada en la Figura 3. Esta red neuronal fue escogida ya que fue la que mejores resultados obtuvo en comparación con otros métodos en el estado del arte en la tarea de segmentación de objetos como la segmentación binaria o la asistida o semiautomática. Yolact es un detector monoetapa que realiza el proceso de segmentación en un solo paso y en tiempo casi real. Además, la familia Yolact permite emplear distintas arquitecturas de red, tales como ResNet (He et al., 2021) con distinto número de capas, DarkNet (Redmon, 2014), etc. En todas esas arquitecturas base se incluye una red de extracción de características, conocida como Feature Pyramid Network (FPN) o red piramidal de extracción de características, la cual consiste en variar el tamaño de la imagen para obtener varios niveles de características semánticas.

La detección monocapa M se divide en dos subtareas paralelas T_1 y T_2 , marcadas en verde y azul en la Figura 3. A partir de P_3 de la FPN, T_1 crea un conjunto de regiones candidatas en las que pueden existir objetos de interés, generando k máscaras. Y haciendo uso de todas las capas FPN, T_2 genera c coeficientes de acierto, 4 regresores de *BoundingBox* (BB) o cuadro delimitador y a coeficientes de máscara, uno por cada prototipo ($4 + c + a$). Una vez finalizado el proceso en paralelo, se fusionan ambas subtareas usando una combinación lineal de la primera tarea T_1 y la transpuesta de la segunda T_2^T , seguido por un proceso sigmoide no lineal σ , como se indica en (1).

$$M = \sigma(T_1 T_2^T) \quad (1)$$

La función de pérdida de esta CNNs viene definida por la suma ponderada de tres funciones de pérdida como se indica en (2), donde L_{cls} representa la pérdida de la clase, L_{box} la del cuadro delimitador y L_{mask} la de la máscara.

$$L_{yolact} = 1,0 L_{cls} + 1,5 L_{box} + 6,125 L_{mask} \quad (2)$$

La pérdida de la clase L_{cls} , como se muestra en (3), representa la suma de las coincidencias positivas y negativas del cuadro delimitador, ambas calculadas con una función softmax.

$$L_{cls} = - \left(\frac{1}{N} \right) \sum_{i \in Pos} x_{i,j}^p \log(\widehat{c}_i^p) - \sum_{i \in Neg} \log(\widehat{c}_i^p) \quad (3)$$

siendo $\widehat{c}_i^p = \frac{e^{c_i^p}}{\sum_p e^{c_i^p}}$

donde N representa el número de cuadros delimitadores detectados, $x_{i,j}^p = \{1, 0\}$ indica la coincidencia entre el cuadro delimitador detectado i y el real j para cada categoría p , siendo c_i^p la confianza de las múltiples clases c y \widehat{c}_i^p la función softmax para cada cuadro delimitador i para cada categoría p .

Por otro lado, L_{box} representa la diferencia entre el cuadro delimitador predicho l y el real g cuando hay coincidencia positiva en la detección, y se define como en (4). Cada cuadro delimitador viene definido por su centro (cx, cy) y dimensiones en anchura y altura (w, h) en píxeles.

$$L_{box} = \left(\frac{1}{N} \right) \sum_{i \in Pos} \sum_{m \in \{cx, cy, w, h\}} x_{i,j}^k \text{smooth}_{L1} (l_i^m - \widehat{g}_j^m) \quad (4)$$

siendo $\widehat{g}_j^{cx} = \frac{(g_j^{cx} - d_i^{cx})}{d_i^w}$ $\widehat{g}_j^{cy} = \frac{(g_j^{cy} - d_i^{cy})}{d_i^h}$

$\widehat{g}_j^w = \log \left(\frac{g_j^w}{d_i^w} \right)$ $\widehat{g}_j^h = \log \left(\frac{g_j^h}{d_i^h} \right)$

donde $x_{i,j}^k$ vuelve a representar nuevamente la coincidencia entre el cuadro delimitador detectado.

Finalmente, L_{mask} es la pérdida de máscara, que se define como una función de entropía cruzada binaria para cada píxel entre la máscara predicha y la real, tal y como se muestra en (5).

$$L_{mask} = - \left(\frac{1}{N} \right) \sum_{i=1}^N y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i)) \quad (5)$$

donde y representa la categoría, siendo $p(y)$ la probabilidad predicha de tener la categoría.

Tras realizar un análisis de porcentajes de acierto y tiempos de ejecución, se decidió emplear Yolact con la arquitectura DarkNet de 53 capas. Esta arquitectura fue entrenada durante 30000 iteraciones empleando SGD (Descenso por gradiente estocástico), comenzando con una tasa de aprendizaje de 0.001, un decaimiento del peso de 0.0005 y un impulso de 0.9. Con ella se consiguió la mejor tasa de reconocimiento, medida en términos de precisión media, mAP , además de usar menor tiempo de inferencia. En la Figura 4 se muestran varios ejemplos de reconocimiento de basura doméstica en distintas condiciones de luz y entornos.

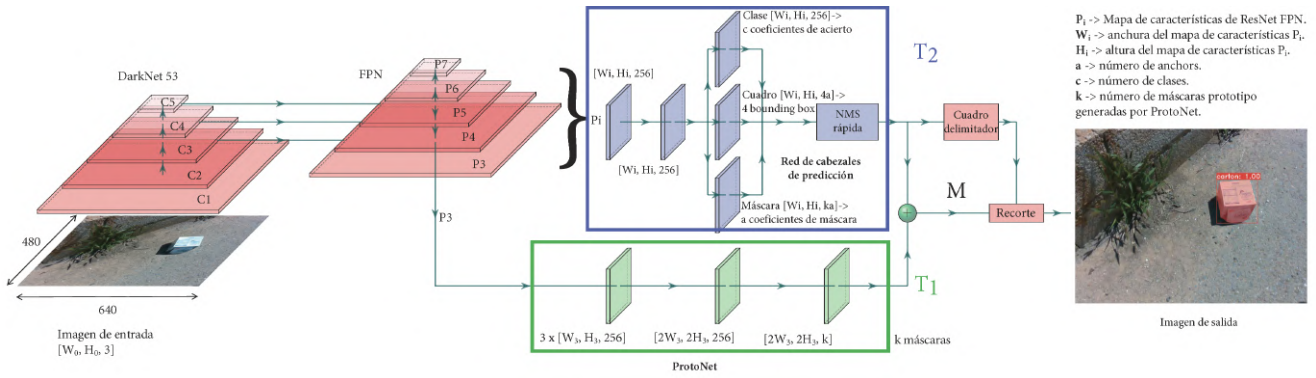


Figura 3: Yolact: red neuronal empleada para realizar la segmentación de objetos



Figura 4: Ejemplos de reconocimiento de basura doméstica (botellas, tetra-bricks, latas) en entornos de exterior

puntos de agarre candidatos empleando nubes de puntos, pero en esta ocasión acometiendo variaciones como las propuestas previamente en (De Gea et al., 2021). En concreto, tras realizar con la cámara RealSense D435i la captura de la imagen RGBD, se obtiene la nube de puntos $N = \{p_1, p_2, \dots, p_m\}$, formada por los puntos $p_i = \{x, y, z\}$ con colores r, g, b y siendo $i \in \mathbb{N}$, $1 < i < m$. Tras ello, se analiza con Yolact (ver Figura 3) obteniendo la máscara del objeto. Al tener dicha máscara se escogen los píxeles de la imagen de profundidad en los que se encuentra el objeto, obteniendo una nube de puntos tridimensional a color $N_p = \{p_1, p_2, \dots, p_n\} \subseteq N$, siendo $m > n$. Esta nube de puntos se envía al algoritmo GeoGrasp, obteniendo sobre ella los puntos de agarre del objeto $G = \{p_a, p_b\} \subseteq N_p$ que se empleará para manipular el objeto. Estos puntos p_a y p_b cumplen las siguientes condiciones: se encuentran más cerca del plano de grasping, poseen la menor curvatura, son opuestos y no son paralelos con el plano de corte. Todo este procedimiento puede verse en la parte inferior de la Figura 5.

4.2. Localización y estimación de agarre

Para llevar a cabo la recogida de residuos, es necesario determinar las coordenadas de localización de todos ellos respecto a la plataforma móvil y, después determinar su ubicación en el mundo con respecto al UR5e que transporta. Por un lado, para poder determinar su ubicación y poder así navegar hasta ellos, y por otro lado, para determinar las coordenadas sobre la superficie de éstos para llevar a cabo el agarre y recogida.

Para el primer paso, se emplea una CNN de tipo Yolo. La selección de esta arquitectura de red está fundamentada en el rendimiento que ofrece a nivel de detección de objetos frente a otras del estado del arte como los métodos de dos etapas. Su arquitectura se muestra en la Figura 6 y se encuentra formada por tres partes diferenciadas. El backbone (en rojo) es usado para extraer características importantes que den información a partir de la imagen de entrada dada. El neck (en verde) se emplea para generar pirámides de características. Éstas ayudan a generalizar la escala, permitiendo identificar el mismo objeto en imágenes de distinto tamaño. Por último, la salida (en azul) proporciona el resultado que se obtiene tras procesar la imagen por las capas anteriores. La función de pérdida de esta CNN viene dada por el sumatorio de tres funciones de pérdida (6):

$$L_{yolo} = L_{box} + L_{cls} + L_{obj} \quad (6)$$

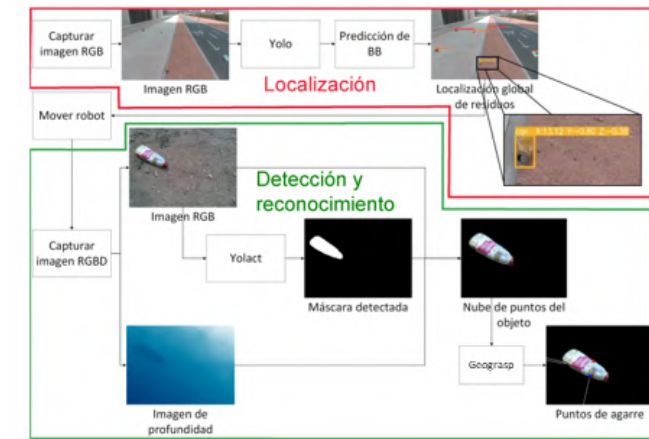


Figura 5: Esquema del proceso de localización, reconocimiento y estimación de puntos de agarre del residuo.

Después de reconocer con exactitud el tipo de residuo doméstico, el siguiente paso consiste en estimar por dónde llevar a cabo el agarre para recogerlo. Para hacerlo, se ha optado por emplear el método propio conocido como Geograsp (Zapata-Impata et al., 2019a), que se basa en la detección de

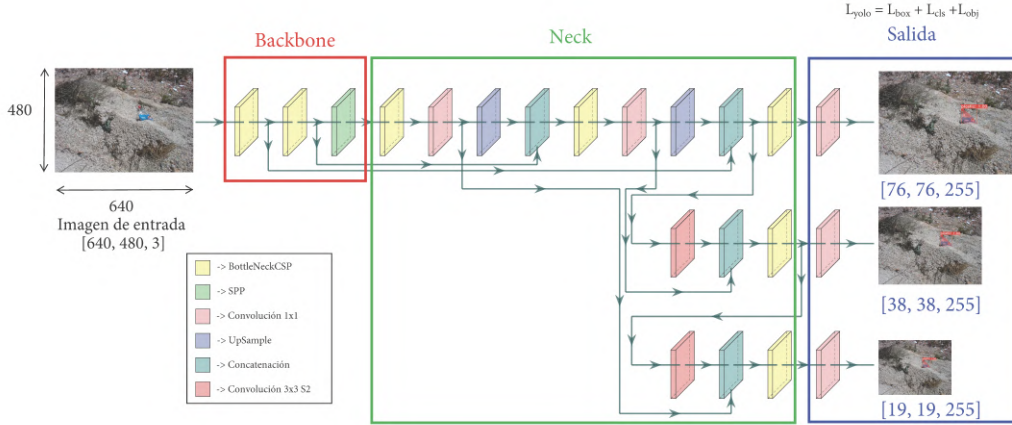


Figura 6: Yolo: red neuronal empleada para realizar la localización de objetos

donde L_{box} representa la pérdida del cuadro delimitador, L_{cls} la de la clase y L_{obj} la de la confianza o seguridad de la detección, que se estiman como (7), (8) y (9) respectivamente.

$$L_{box} = \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{obj} (2 - w_i h_i) \left[(x_i - \hat{x}_i^j)^2 + (y_i - \hat{y}_i^j)^2 + (w_i - \hat{w}_i^j)^2 + (h_i - \hat{h}_i^j)^2 \right] \quad (7)$$

Los términos λ_{coord} representan los coeficientes de pérdida de posición (peso que tiene respecto a los otros elementos en (6)), siendo S cada una de las porciones de búsqueda en las que se divide la imagen de entrada, B los anchors o cuadro delimitador predefinido de cierta altura y anchura para cada S e $I_{i,j}^{obj}$ el cuadro delimitador en (i, j) que contiene al objetivo, que toma el valor 1 si lo contiene o 0 en caso contrario.

Además, la región del cuadro delimitador está definida como $(\hat{x}, \hat{y}, \hat{w}, \hat{h})$ que representan las coordenadas del centro, así como su anchura y altura; mientras que (x, y, w, h) son los valores estimados para el cuadro delimitador por la CNN en cada búsqueda.

Por otro lado, L_{cls} y L_{obj} se calculan como (8) y (9).

$$L_{cls} = \lambda_{class} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{obj} \sum_{c \in classes} p_i(c) \widehat{p}_l(c) \quad (8)$$

$$L_{obj} = \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{noobj} (c_i - \widehat{c}_l)^2 + \lambda_{obj} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{obj} (c_i - \widehat{c}_l)^2 \quad (9)$$

donde λ_{class} son los coeficientes de pérdida de categoría, c el número total de clases, $p_i(c)$ la probabilidad de la categoría del elemento analizado y $\widehat{p}_l(c)$ es el valor real de la categoría. Siendo, además, λ_{noobj} y λ_{obj} los pesos de la confianza cuando no existe y existe un objeto en el cuadro delimitador y c_i, \widehat{c}_l las confianzas real y predicha del cuadro delimitador.

La salida de la CNN, por lo tanto, proporciona un cuadro delimitador en la imagen RGBD de entrada, según el procedimiento de localización mostrado en la Figura 2. Después, se extraen las coordenadas en píxeles (u, v) del centro del cuadro delimitador del objeto-basura, y se transforman a coordenadas 3D respecto de la cámara con la que se obtuvo su detección.

Para ello, se emplean los parámetros intrínsecos K de la matriz de calibración de la cámara y la distancia d obtenida a partir del canal de profundidad D , operando tal y como se indica en (10).

$$(x_c, y_c, z_c) = K \cdot (d, u, v) \quad (10)$$

Después, se transforman las coordenadas obtenidas a coordenadas con respecto al LiDAR como se expresa en (11).

$$\begin{bmatrix} x_l \\ y_l \\ z_l \\ 1 \end{bmatrix} = T_{cl}^l \begin{bmatrix} x_c \\ y_c \\ z_c \\ 1 \end{bmatrix} \quad (11)$$

donde T_{cl}^l representa la transformación entre la cámara y el LiDAR. Una vez obtenidas las coordenadas respecto del LiDAR se transforman a coordenadas respecto de la plataforma móvil mediante la transformación fija (T_l^r) como se indica en (12). Esta transformación refleja la relación entre la ubicación del LiDAR y el sistema GPS de la plataforma móvil. Además, teniendo en cuenta la posición de la plataforma móvil, según el GPS y la odometría, se obtiene un *offset* como la diferencia entre la posición de partida y su posición actual. Así, es posible referenciar con coordenadas relativas a la zona de trabajo actual en vez de con coordenadas GPS globales.

$$\begin{bmatrix} x_m \\ y_m \\ z_m \\ 1 \end{bmatrix} = T_l^r \begin{bmatrix} x_l \\ y_l \\ z_l \\ 1 \end{bmatrix} + offset \quad (12)$$

Un ejemplo del resultado de este procedimiento se puede observar en la parte superior de la Figura 5. En él se muestra la detección y localización de varias instancias de dos tipos de objetos distintos en una misma vista, así como el detalle de las coordenadas obtenidas para uno de ellos con respecto a la plataforma móvil.

En el segundo paso, una vez que el robot BLUE está cerca, y dentro del alcance del manipulador UR5e, es necesario calcular la pose con respecto a éste para llevar a cabo el agarre. Para ello, se procede como se comentó previamente en la Sección 4.1. Es decir, se hace uso de Yolact para reconocer con mayor exactitud el tipo de objeto. Después, se predicen los puntos de agarre (p_a, p_b) sobre su superficie como se comentó anteriormente y muestra la parte inferior de la Figura 5. Por lo tanto, para este caso en vez de utilizar las coordenadas del centro del cuadro delimitador del objeto, se usan las coordenadas imagen de esos dos puntos de agarre (p_a, p_b) . Para cada uno de estos dos puntos se transforman del mismo modo a como se procedió para el centro del cuadro delimitador. Esto se hace así, porque como herramienta de agarre se emplea una pinza, y el agarre por un único punto como el centroide solo sería factible si en el efector del UR5e llevara una ventosa.

Finalmente, una vez computados (p_a, p_b) , es posible determinar la posición 3D de dichos puntos de agarre con respecto al UR5e, como $T = T_r^p \cdot T_p^c$. Ya que es conocida la transformación entre la pinza y la cámara situada en el extremo T_p^c y además, se puede obtener la transformación entre el UR5e y la pinza como $T_r^p = T_r^e \cdot T_e^p$, donde T_e^p es la transformación del efector a los dedos de la pinza y T_r^e de la base del robot al efector obtenida mediante el método de Denavit-Hartenberg. Un esquema de la posición de cada uno de los sistemas de coordenadas y transformaciones descritas se puede observar en la Figura 7.




Figura 7: Configuración de los sistemas de coordenadas a bordo de BLUE en la tarea de navegación y estimación del agarre

5. Sistema de percepción táctil

Para llevar a cabo la tarea de manipulación, que consiste en coger un objeto y dejarlo en una posición final, el robot debe combinar diferentes acciones. Primero, se deberá agarrar el objeto a partir de los puntos de agarre y las trayectorias calculadas previamente. Una vez se ha agarrado el objeto, este es levantado y llevado a la posición de destino donde será depositado. Antes de levantar el objeto, se debe garantizar que su agarre es estable. Después, el robot podrá transportar el objeto reaccionando ante cualquier movimiento indeseado entre el objeto y la pinza robótica. Ambas operaciones, el agarre del objeto y su levantamiento para transportarlo hasta su almacén de destino, deben ser controladas en tiempo real para garantizar una manipulación estable y exitosa (ver proceso en azul en la Figura 2). Para ello, se ha hecho uso de información táctil obtenida a partir de un sensor óptico de bajo coste, como DIGIT (Lambeta et al., 2020) que se ha incorporado como parte

de un control táctil realimentado. Estos sensores fueron acoplados a los dedos de la pinza ROBOTIQ-2F140 del robot UR5e. Al no requerir una manipulación diestra para agarrar los residuos, la forma más económica, sencilla y eficaz de realizar esta manipulación es mediante una pinza robótica de dos dedos. El subsistema de percepción táctil para controlar el agarre robótico se ha diseñado e implementado para adaptar la tarea de agarre en función de dos algoritmos de detección táctil: uno para la detección de contacto entre objeto y dedos de la pinza, y otro para la detección de deslizamiento que evite que el objeto resbale y caiga. El controlador de agarre hace uso del algoritmo propuesto para la detección de contacto y de las imágenes extraídas de los sensores táctiles. Esta tarea se formula como una clasificación de imagen de tipo binario, donde el resultado de la predicción será 0 o 1, donde la etiqueta 0 significa que no existe contacto, y 1 significa que sí existe contacto. Para realizar esta predicción se utilizan CNNs debido a su alta capacidad para extraer y aprender características a partir de imágenes. En (Castaño-Amorós et al., 2021), ya realizamos una extensa experimentación entrenando diferentes arquitecturas de CNNs para esta tarea, tales como las basadas en la familia VGG (Simonyan and Zisserman, 2015) e Inception (Szegedy et al., 2016) u otras de arquitectura más ligera y portable como MobileNet Sandler et al. (2018). Los resultados mostraron que la arquitectura InceptionV3 obtenía un tiempo de inferencia 50 ms menor que otras, manteniendo los mismos porcentajes de acierto. Por lo que, aquí se ha optado por utilizar esta arquitectura pero, esta vez, aplicándole una serie de modificaciones para acelerar el tiempo de inferencia para trabajar embebida en la Jetson AGX Xavier. En primer lugar, se extraen características de la capa "mixed5", reduciendo así el número de filtros y parámetros. En segundo lugar, se añaden a continuación las siguientes capas neuronales: una capa de agrupación de promedio global, dos bloques formados por una capa de normalización por lotes, una capa totalmente conexa y una técnica de regularización conocida como "dropout". Finalmente, se añade una última capa totalmente conexa con una neurona y una función de activación sigmoide que devuelve un valor entre 0 y 1. De forma empírica se establece un umbral para redondear estos valores a 0 (no contacto) o 1 (contacto). La función de pérdida utilizada es la entropía cruzada binaria, que ya se definió en (5).

Como se puede observar en la Figura 8, tras activarse los sensores táctiles (ver letra A en Figura 8), el controlador recibe una orden del sistema de visión, indicando si se tiene que agarrar o soltar el objeto. En primer lugar, se deberá agarrar el objeto, por lo que el sistema utilizará la imagen en color de los sensores. Para el control de agarre se ejecuta el algoritmo de detección de contacto (ver letra B en Figura 8) mencionado en el párrafo anterior, que enviará la orden de cerrar mediante un registro al controlador de la pinza (ver letra D en Figura 8) hasta que el algoritmo detecte que el objeto ya se encuentra agarrado. El propio controlador, internamente, cambiará el modo de detección de contacto a deslizamiento mientras el robot levanta y traslada el objeto. Durante este proceso se pueden producir movimientos indeseados como, por ejemplo, deslizamientos que hagan que el objeto resbale. El robot debe ser capaz de ajustar la apertura de la pinza para evitar una caída del objeto no deseada. Para esta, se propone un segundo algoritmo de detección de deslizamientos (ver letra C en Figura 8). Este algoritmo, tam-

empleó todo el dataset con la siguiente división aleatoria 70 %, 20 %, 10 % para entrenamiento, validación y prueba offline, asegurando muestras distintas en cada subconjunto. Sin embargo para el sistema de percepción táctil se usó un número más reducido de objetos. Concretamente, se emplearon 11 de los 50 objetos con un total de 24607 muestras táctiles de contacto y 3540 muestras táctiles de secuencias de deslizamiento (cada una consta de 4 imágenes táctiles). La elección se realizó atendiendo a características de geometría, dureza y fricción del material de estos, para tener un subconjunto de objetos con comportamientos distintos desde el punto de vista del sentido del tacto. En este caso, la división para entrenamiento, validación y prueba, no se llevo a cabo separando muestras sino utilizando para entrenar el 72 % de los objetos y para evaluar el 28 % restante. Los conjuntos disjuntos de objetos de entrenamiento y prueba, permiten comprobar la capacidad de genericidad de los algoritmos.

Una vez entrenada la CNN mostrada en Figura 3 (módulo de visión), se ha evaluado su rendimiento en las tareas que implica la actividad de agarre robótico. Para medir los resultados de la detección y reconocimiento visual, se utiliza la métrica de Average Precision (AP) o precisión media como en (15), de todas las categorías de objetos, haciendo uso de umbrales de confianza de Intersection over Union (IoU) o intersección sobre unión, fijados en 0.5, 0.75 y 0.90. En concreto, AP se estima como el área bajo la curva Precision-Recall (PR-AUC) que queda segmentada en i regiones, calculando el Recall y la Precisión para cada región dada como en (16).

$$AP_{IoU} = \sum_{i \in \tilde{R}} (R_{i+1} - R_i) \cdot \max_{\tilde{R} \geq R_{i+1}} P(\tilde{R}) \quad (15)$$

$$R = \frac{TP}{TP + FP} \quad P = \frac{TP}{TP + FN} \quad (16)$$

El comportamiento obtenido en cuanto precisión para el módulo de reconocimiento visual es: $AP_{50} = 0,998$, $AP_{75} = 0,980$ y $AP_{90} = 0,696$. Además, el error medio obtenido por el módulo de localización es de $0,178 \pm 0,06$ m. para objetos situados a distancias inferiores a 3 m.

Del mismo modo, la arquitectura InceptionV3 empleada en el módulo de percepción táctil ha permitido alcanzar valores de rendimiento de $A = 0,98$ y $A = 0,91$ en las tareas de detección de agarre y deslizamiento, respectivamente. Para el módulo táctil se ha escogido la métrica tradicional de precisión (Accuracy) (17).

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

donde TP denota que el contacto o deslizamiento detectado es correcto, TN que el sistema está detectando ausencia de contacto o deslizamiento correctamente, mientras que FP y FN indican incorrectas detecciones, es decir se detecta el evento contrario al que realmente se produce.

Con estos resultados demostramos que los métodos implementados de nuestro sistema visual-táctil son adecuados para las tareas de recogida de residuos en exteriores que implican localización, reconocimiento y manipulación estable.

6.2. Evaluación conjunta del sistema visual-táctil

Después de la evaluación del sistema visual-táctil en modo offline, se ha procedido a evaluarlo en entornos realistas de exteriores y en modo online. Para ello, se realizaron dos experimentos de campo en los que se ejecuta el proceso completo de navegación, detección, reconocimiento y agarre, de 4 objetos y en 2 entornos nunca vistos antes por nuestro sistema visual-táctil. La columna de la izquierda representa el escenario A y la de la derecha el escenario B (Figura 10). La metodología para cada experimento es la siguiente: se colocan 2 objetos en el suelo simulando que hay residuos. Nuestro robot BLUE, de manera completamente autónoma, detecta los objetos desde la lejanía y navega hacia ellos, realizando una maniobra para situarlos dentro del rango de acción del brazo manipulador. Entonces, se ejecuta el módulo de visión encargado del reconocimiento de los objetos, que los clasifica según el tipo de residuo. Este módulo estima puntos de agarre a partir de la representación de nube de puntos segmentada de los objetos en la escena y determina la pose de agarre para la pinza del manipulador.



Figura 10: Localización y navegación (arriba), detección y clasificación (en medio) y estimación de puntos de agarre en residuos (abajo)

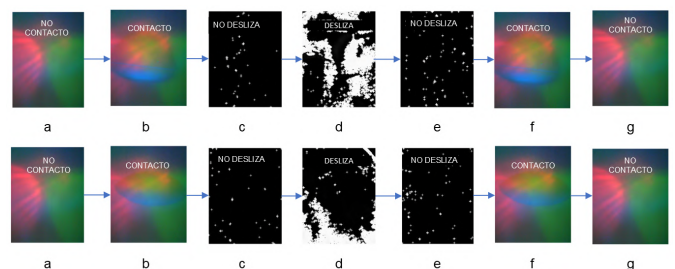


Figura 11: Secuencias táctiles durante la tarea de manipulación de residuos. (a, b) corresponden al agarre y detección de contacto. (c, d, e) se obtienen en la detección de deslizamiento y reajuste del cierre de la pinza, y, (f, g) se producen cuando se abre la pinza para depositar el residuo

Después, el manipulador recibe la orden de moverse hasta la posición de agarre y cerrar la pinza hasta que el módulo de percepción táctil, a través del algoritmo de detección de contacto, indica que el objeto ya se encuentra agarrado. Entonces, el brazo manipulador recibe la orden del módulo táctil de levantar y transportar el objeto hacia el depósito de destino (según el tipo de residuo) mientras el algoritmo de deslizamiento corrige la apertura de la pinza en caso de producirse un deslizamiento (Figura 11).

Finalmente, el brazo manipulador deposita el residuo y vuelve a la posición inicial para volver a ejecutar el proceso de recogida de objetos restantes. Las trayectorias completas de navegación y de manipulación se ilustran en la Figura 12. Como se observa, el error cometido durante la fase de navegación (puntos rojo y verde) es corregido durante la tarea de manipulación (estrellas roja y azul), consiguiendo así su eliminación. En este ejemplo en particular, se cometió un error de $0,175 \pm 0,06$ m, el cual es un poco menor que el cometido de media en el resto de experimentos realizados únicamente con el módulo de navegación.

La trayectoria cartesiana seguida por el extremo del robot durante la tarea de detección y agarre para el escenario A, se muestra en la Figura 13. En esta figura se muestra, por etapas (zonas de color), el movimiento cartesiano de la pinza durante todo el proceso de posicionamiento para agarre. Las líneas discontinuas indican posiciones deseadas, que vienen dadas por la localización estimada de los objetos por el módulo de visión descrito en secciones previas. Tal y como se observa, el error cometido durante la tarea de navegación llega a anularse, corregido en la fase de estimación de puntos agarre y recogida del objeto.

Todos estos procesos, tanto visuales como táctiles, han sido ejecutados en tiempo real, con tiempos de cómputo medios en el rango [30, 40] ms. en la tarea de localización, [200, 300] ms. en la tarea de reconocimiento, y [300, 400], [7, 10] ms. en detección de contacto y deslizamiento táctil. Esto favorece que todos los métodos y algoritmos puedan ser empleados sin provocar latencia en otros procedimientos embebidos en nuestra plataforma de manipulación móvil.

7. Conclusiones

En este artículo, se ha propuesto un sistema de percepción visual-táctil para la recogida de basura o residuos domésticos no orgánicos, tales como botes, botellas, latas, tetrabricks, tetrapacks, etc. Nuestro sistema de percepción visual-táctil consta de tres módulos software, dos de ellos con enfoque visual y un tercero con enfoque táctil pero basado en sensores ópticos. Todos los métodos y algoritmos propuestos en el sistema de percepción han sido implementados combinando técnicas de visión por computador y aprendizaje profundo con varias CNNs.

La contribución principal se puede resumir de la siguiente manera. Por un lado, se ha diseñado e implementado un método visual para la localización y reconocimiento de residuos sólidos en entorno de exterior. El método combina dos etapas algorítmicas en cascada. En la primera de ellas, se combina una 2D-CNN y datos de geolocalización de un robot móvil para obtener coordenadas geométricas 3D de posición de objetos en la escena. En la segunda, se combina otra 2D-CNN y datos geométricos 3D

de la superficie de los objetos para su reconocimiento y posterior estimación del agarre de pinzas de 2 dedos, sin necesidad de una reconstrucción del objeto. El método es flexible y modular, es decir permite sustituir los modelos de 2D-CNN parametrizados, lo que facilita una arquitectura del sistema de percepción escalable a diferentes robots y entornos. Además, para llevar a cabo estas tareas, se ha creado un dataset específico de residuos domésticos en entornos de exterior. Por otro lado, se ha construido sensores táctiles basados en imagen para controlar el agarre con pinzas robóticas. Este tipo de sensores no dispone de una relación matemática para mapear píxeles a valores de fuerza en N, ni tampoco marcadores que faciliten la estimación de movimiento. Por lo tanto, se han diseñado e implementado algoritmos de detección táctil que nos han permitido desarrollar una estrategia de control para el agarre y reajuste del cierre de la pinza.

En general nuestro sistema de percepción visual-táctil ofrece buenos resultados, sin embargo también adolece de ciertas limitaciones. Por un lado, el empleo de una única vista RGBD genera en algunos casos, por ejemplo en residuos de vidrio transparente, nubes de puntos 3D sin la necesaria calidad para estimar puntos de agarre adecuados. En estos casos, se puede estudiar el empleo de nubes de puntos más densas obtenidas a partir de la reconstrucción de varias vistas RGBD. Además, se pretende incorporar una cámara multispectral para analizar como responden los diferentes objetos a diferentes longitudes de onda en aras de favorecer el reconocimiento de nuevos residuos y de mejorar la estimación de puntos de agarre. La cámara multispectral puede ayudar también a mejorar la precisión en la etapa de localización, ya que es posible que nos permita modificar la detección mediante cuadros delimitadores añadiendo una detección por regiones de segmentación en función de longitudes de onda. En relación al módulo táctil para controlar el agarre, se está trabajando en incorporar técnicas de aprendizaje por refuerzo empleando tanto los datos de los sensores táctiles como datos de orientación y apertura de la pinza, para corregir la pose de agarre en caso de detectarse deslizamiento.

Agradecimientos

Este trabajo ha sido financiado con Fondos Europeos de Desarrollo Regional (FEDER), el gobierno de la Generalitat Valenciana a través del proyecto PROMETEO/2021/075, y los recursos computacionales fueron financiados a través de la ayuda IDIFEDER/2020/003.

Referencias

- Altikat, A., Gulbe, A., Altikat, S., 2022. Intelligent solid waste classification using deep convolutional neural networks. *Int. J. Environmental Science and Technology* 19, 1285–1292.
DOI: 10.1007/s13762-021-03179-4
- Bircanoglu, C., Atay, M. and Beser, F., Genç, , Kızrak, M. A., 2018. Recyclenet: Intelligent waste sorting using deep neural networks. In: *Innovations in intelligent systems and applications*. pp. 1–7.
DOI: 10.1109/INISTA.2018.8466276
- Bohg, J., Morales, A., Asfour, T., Kragic, D., 2013. Data-driven grasp synthesis—a survey. *IEEE Transactions on robotics* 30 (2), 289–309.
DOI: 10.1109/TR0.2013.2289018
- Bolya, D., Zhou, C., Xiao, F., Lee, Y., 2019. Yolact: Real-time instance segmentation. In: *IEEE/CVF Int. Conf. on Computer Vision*. pp. 9157–9166.
DOI: 10.1109/ICCV.2019.00925




Figura 12: Trayectorias de navegación y manipulación generadas para la tarea de recogida de los objetos del escenario A.

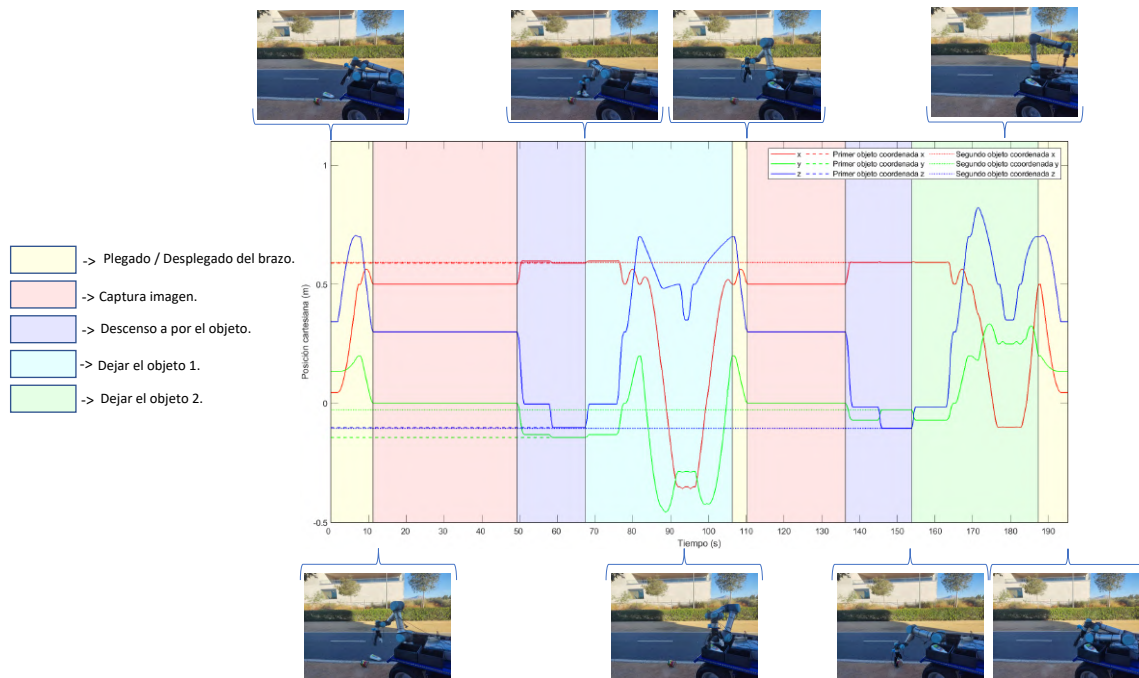


Figura 13: Posición de la pinza durante la manipulación de los residuos del escenario A.

- Castaño-Amoros, J., Gil, P., Puente, S., 2021. Touch detection with low-cost visual-based sensor. In: 2nd Int. Conf. on Robotics, Computer Vision and Intelligent Systems. pp. 136–142.
DOI: 10.5220/0010699800003061
- De Gea, V., Puente, S., Gil, P., 2021. Domestic waste detection and grasping points for robotic picking up. 10.48550/arXiv.2105.06825, IEEE Int. Conf. on Robotics and Automation. Workshop: Emerging paradigms for robotic manipulation: from the lab to the productive world.
- Del Pino, I., Muñoz-Bañón, M., Cova-Rocamora, S., Contreras, M., Candelas, F., Torres, F., 2020. Deeper in blue. Journal of Intelligent & Robotics Systems 98, 207–225.
DOI: 10.1007/s10846-019-00983-6
- Donlon, E., Dong, S., Liu, M., Li, J., Adelson, E., Rodriguez, A., 2018. Gelslim: A high-resolution, compact, robust, and calibrated tactile-sensing finger. In: 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, pp. 1927–1934.
DOI: 10.1109/IR0S.2018.8593661
- Feng, J., Tang, X., Jiang, X., Chen, Q., 2021. Garbage disposal of complex background based on deep learning with limited hardware resources. IEEE Sensors Journal 21(8), 21050–21058.
DOI: 10.1109/JSEN.2021.3100636
- Fu, B., Li, S., Wei, J., Li, Q., Wang, Q., T. J., 2021. A novel intelligent garbage classification system based on deep learning and an embedded linux system. IEEE Access 9), 131134–131146.
DOI: 10.1109/ACCESS.2021.3114496
- Guo, N., Zhang, B., Zhou, J., Zhan, K., Lai, S., 2020. Pose estimation and adaptable grasp configuration with point cloud registration and geometry understanding for fruit grasp planning. Computers and Electronics in Agriculture 179, 105818.
- He, K., Zhang, X., Ren, S., Sun, J., 2021. Deep residual learning for image recognition. In: IEEE Conf. on Computer Vision And Pattern Recognition. DOI: 10.1109/CVPR.2016.90
- Jiang, D., Li, G., Sun, Y., Hu, J., Yun, J., Liu, Y., 2021. Manipulator grabbing position detection with information fusion of color image and depth image using deep learning. Journal of Ambient Intelligence and Humanized Computing 12 (12), 10809–10822.
DOI: 10.1007/s12652-020-02843-w
- Kim, D., Li, A., Lee, J., 2021. Stable robotic grasping of multiple objects using deep neural networks. Robotica 39 (4), 735–748.
DOI: 10.1017/S0263574720000703
- Kiyokawa, T., Katayama, H., Tatsuta, Y., Takamatsu, J., Ogasawara, T., 2021. Robotic waste sorter with agile manipulation and quickly trainable detector. IEEE Access 9), 124616–124631.
DOI: 10.1109/ACCESS.2021.3110795
- Kolamuri, R., Si, Z., Zhang, Y., Agarwal, A., Yuan, W., 2021. Improving grasp stability with rotation measurement from tactile sensing. In: 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, pp. 6809–6816.
DOI: 10.1109/IR0S51168.2021.9636488
- Lambeta, Chou, P.-W., Tian, S., Yang, B., Maloon, B., Most, V., Stroud, D., Santos, R., B.-A., Kammerer, G., Jayaraman, D., Calandra, R., 2020. Digit: A novel design for a low-cost compact high-resolution tactile sensor with application to in-hand manipulation. IEEE Robotics and Automation Letters 5(3), 3838–38451.
DOI: 10.1109/LRA.2020.2977257
- Lin, Y., Lloyd, J., Church, A., Lepora, N. F., 2022. Tactile gym 2.0: Sim-to-real deep reinforcement learning for comparing low-cost high-resolution robot touch. IEEE Robotics and Automation Letters 7 (4), 10754–10761.
DOI: 10.1109/LRA.2022.3195195
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., Pietikainen, M., 2020. Deep learning for generic object detection: A survey. Int. J. of Computer Vision 128, 261–318.
DOI: 10.1007/s11263-019-01247-4
- Liu, Y., Jiang, D., Duan, H., Sun, Y., Li, G., Tao, B., Yun, J., Liu, Y., Chen, B., 2021. Dynamic gesture recognition algorithm based on 3d convolutional neural network. Computational Intelligence and Neuroscience 2021.
DOI: 10.1155/2021/4828102
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., Terzopoulos, D., 2020. Image segmentation using deep learning: A survey. IEEE Trans. on Pattern Analysis and Machine Intelligence. DOI: 10.1109/TPAMI.2021.3059968
- Newbury, R., Gu, M., Chumbley, L., Mousavian, A., Eppner, C., Leitner, J., Bohg, J., Morales, A., Asfour, T., Kragic, D., et al., 2022. Deep learning approaches to grasp synthesis: A review. arXiv preprint arXiv:2207.02556.
- Patrizi, A., Gambosi, G., Zanzotto, F., 2021. Data augmentation using background replacement for automated sorting of littered waste. J. of Imaging 7(8), 144.
DOI: 10.3390/jimaging7080144
- Redmon, J., 2014. Darknet: Open source neural networks in c. <http://pjreddie.com/darknet/>.
- Sahbani, A., El-Khoury, S., Bidaud, P., 2012. An overview of 3d object grasp synthesis algorithms. Robotics and Autonomous Systems 60 (3), 326–336.
DOI: 10.1016/j.robot.2011.07.016
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.-C., 2018. MobileNetV2: Inverted residuals and linear bottlenecks. In: IEEE Conf. on Computer Vision and Pattern Recognition. pp. 4510–4520.
DOI: <https://doi.org/10.1109/CVPR.2018.00474>
- Sandykbayeva, D., Kappassov, Z., Orabayev, B., 2022. Vibrotouch: Active tactile sensor for contact detection and force sensing via vibrations. Sensors 22 (17).
DOI: 10.3390/s22176456
- Shaw-Cortez, W., Oetomo, D., Manzie, C., Choong, P., 2018. Tactile-based blind grasping: A discrete-time object manipulation controller for robotic hands. IEEE Robotics and Automation Letters 3 (2), 1064–1071.
DOI: 10.1109/LRA.2018.2794612
- Simonyan, K., Zisserman, A., 2015. Very deep convolutional networks for large-scale image recognition. In: 3rd Int. Conf. on Learning Representations. DOI: <https://doi.org/10.48550/arXiv.1409.1556>
- Suárez, R., Palomo-Avellaneda, L., Martínez, J., Clos, D., García, N., 2020. Manipulador móvil, bíbrazo y diestro con nuevas ruedas omnidireccionales. Revista Iberoamericana de Automática e Informática industrial 17 (1), 10–21.
DOI: 10.4995/riai.2019.11422
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z., 2016. Rethinking the inception architecture for computer vision. In: IEEE Conf. on Computer Vision and Pattern Recognition. pp. 2818–2826.
DOI: <https://doi.org/10.1109/CVPR.2016.308>
- Velasco, E., Zapata-Impata, B. S., Gil, P., Torres, F., 2020. Clasificación de objetos usando percepción bimodal de palpación única en acciones de agarre robótico. Revista Iberoamericana de Automática e Informática Industrial 17 (1), 44–55.
DOI: 10.4995/riai.2019.10923
- Vo, A. H., Son, L., Vo, M., Le, T., 2019. A novel framework for trash classification using deep transfer learning. IEEE Access 7, 178631–178639.
DOI: 10.1109/ACCESS.2019.2959033
- Ward-Cherrier, B., Pestell, N., Cramphorn, L., Winstone, B., Giannaccini, M. E., Rossiter, J., Lepora, N. F., 2018. The tactip family: Soft optical tactile sensors with 3d-printed biomimetic morphologies. Soft robotics 5 (2), 216–227.
DOI: 10.1089/soro.2017.0052
- Yao, T., Guo, X., Li, C., Qi, H., Lin, H., Liu, L., Dai, Y., Qu, L., Huang, Z., Liu, P., et al., 2020. Highly sensitive capacitive flexible 3d-force tactile sensors for robotic grasping and manipulation. Journal of Physics D: Applied Physics 53 (44), 445109.
DOI: 10.1088/1361-6463/aba5c0
- Yuan, W., Dong, S., Adelson, E. H., 2017. Gelsight: High-resolution robot tactile sensors for estimating geometry and force. Sensors 17 (12), 2762.
DOI: 10.3390/s17122762
- Zapata-Impata, B., Gil, P., Pomares, J., Torres, F., 2019a. Fast geometry-based computation of grasping points on three-dimensional point clouds. Int. J. of Advanced Robotic Systems, 1–18.
DOI: 10.1177/1729881419831846
- Zapata-Impata, B. S., Gil, P., Torres, F., 2019b. Learning spatio temporal tactile features with a convlstm for the direction of slip detection. Sensors 19 (3), 523.
DOI: 10.3390/s19030523