

## Clasificación de objetos usando percepción bimodal de palpación única en acciones de agarre robótico

E. Velasco<sup>a</sup>, B. S. Zapata-Impata<sup>b</sup>, P. Gil<sup>b,c,\*</sup>, F. Torres<sup>b,c</sup>

<sup>a</sup>Universidad de las Fuerzas Armadas ESPE, Av. General Rumiñahui s/n y Ambato, 171103, Sangolquí, Ecuador

<sup>b</sup>Departamento de Física, Ingeniería de Sistemas y Teoría de la Señal, Universidad de Alicante, Campus de San Vicente del Raspeig s/n, 03690, Alicante, España.

<sup>c</sup>Instituto Universitario de Investigación Informática, Universidad de Alicante, Campus de San Vicente del Raspeig s/n, 03690, Alicante, España.

### Resumen

Este trabajo presenta un método para clasificar objetos agarrados con una mano robótica multidedo combinando en un descriptor híbrido datos propioceptivos y táctiles. Los datos propioceptivos se obtienen a partir de las posiciones articulares de la mano y los táctiles se extraen del contacto registrado por células de presión instaladas en las falanges. La aproximación propuesta permite identificar el objeto aprendiendo de forma implícita su geometría y rigidez usando los datos que facilitan los sensores. En este trabajo demostramos que el uso de datos bimodales con técnicas de aprendizaje supervisado mejora la tasa de reconocimiento. En la experimentación, se han llevado a cabo más de 3000 agarres de hasta 7 objetos domésticos distintos, obteniendo clasificaciones correctas del 95 % con métrica  $F_1$ , realizando una única palpación del objeto. Además, la generalización del método se ha verificado entrenando nuestro sistema con unos objetos y posteriormente, clasificando otros nuevos similares.

#### Palabras Clave:

Manipuladores robóticos, Percepción propioceptiva-táctil, Aprendizaje propioceptivo-táctil, Clasificación de objetos, Reconocimiento de objetos.

### Object classification using bimodal perception data extracted from single-touch robotic grasps

#### Abstract

This work presents a method to classify grasped objects with a multi-fingered robotic hand combining proprioceptive and tactile data in a hybrid descriptor. The proprioceptive data are obtained from the joint positions of the hand and the tactile data are obtained from the contact registered by pressure cells installed on the phalanges. The proposed approach allows us to identify the grasped object by learning the contact geometry and stiffness from the readings by sensors. In this work, we show that using bimodal data of different nature along with supervised learning techniques improves the recognition rate. In experimentation, more than 3000 grasps of up to 7 different domestic objects have been carried out, obtaining an average  $F_1$  score around 95 %, performing just a single grasp. In addition, the generalization of the method has been verified by training our system with certain objects and classifying new, similar ones without any prior knowledge.

#### Keywords:

Robotic manipulators, Proprioceptive-tactile perception, Proprioceptive-tactile learning, Objects classification, Objects recognition.

### 1. Introducción

La manipulación robótica es un tema en auge en el ámbito de la robótica industrial y de servicios con un amplio enfoque multidisciplinar, principalmente en el marco de la industria 4.0.

como muestran Sanchez et al. (2018). Características como la adaptabilidad y la reconfigurabilidad que demanda la industria 4.0 requieren de sistemas robóticos cada vez más inteligentes. En tareas de agarre y manipulación en entornos dinámicos, los robots se enfrentan a dificultades como agarrar objetos desco-

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

nocidos, tanto en forma como en tamaño y materiales de fabricación. La variabilidad de objetos, así como las condiciones cambiantes del entorno, tales como oclusiones o falta de iluminación, hacen necesario que los sistemas de visión sean acompañados de sistemas de percepción propioceptivos y/o táctiles que ofrezcan información robusta del objeto que está siendo manipulado, como indican Liu et al. (2017b).

En el estado del arte es posible encontrar técnicas de percepción propioceptiva-táctil, ya sean pasivas o activas. Las técnicas pasivas suelen aplicarse a tareas de reconocimiento de objetos agarrados mientras que las técnicas activas son empleadas para reconocimiento de acciones o eventos de manipulación. La principal diferencia radica en que las técnicas pasivas únicamente consideran datos extraídos de agarres estáticos de objetos, donde no hay información temporal de la acción de agarre. No obstante, durante una tarea de manipulación es posible que los dedos de una pinza o mano robótica cambien su posición para adaptarse a la superficie del objeto, por lo que el control de la mano genera una acción dinámica con múltiples agarres. En este último caso, las técnicas de percepción activa son más adecuadas porque la tarea de manipulación considera datos de múltiples agarres y la relación temporal entre ellos.

### 1.1. Percepción propioceptiva

La percepción propioceptiva se basa en extraer valores de ángulos de las articulaciones de la mano robótica durante la tarea de agarre y manipulación de un objeto. De este modo es posible interpretar la forma y tamaño del objeto en base a la configuración cinemática que adoptan los dedos al agarrarlo.

La percepción *propioceptiva pasiva* para el reconocimiento de objetos, generalmente, tiene dos tipos de enfoque. Por un lado, están los métodos basados en descriptores construidos a partir de valores de posiciones articulares de agarres estáticos. Por ejemplo, Vásquez and Perdereau (2017) proponen un descriptor para reconocer cinco formas geométricas básicas como cono, toroide, esfera, cilindro e hiperboloide. Por otro lado, otros investigadores han propuesto aproximaciones basadas en técnicas de aprendizaje automático, donde la tarea de reconocimiento se reduce a un problema de clasificación de la categoría del objeto. En esta línea, Homberg et al. (2015); Homberg et al. (2019) extrajeron datos propioceptivos de agarres de objetos haciendo uso de una mano robótica flexible. Después, emplearon estas características para entrenar un sistema de reconocimiento de objetos agarrados, usando el método de clasificación supervisada *K vecinos más cercanos* o “K-Nearest Neighbors” (k-NN) y la distancia Euclidea entre posiciones articulares.

La percepción *propioceptiva activa* también se emplea con cierto éxito para reconocer acciones en tareas de manipulación. En esta línea, Bergquist et al. (2009) extrajeron posiciones articulares en distintos instantes de tiempo durante la manipulación con el objetivo de reconocer las acciones que se llevaban a cabo, tales como levantar, sacudir, empujar, soltar y aplastar el objeto agarrado. En particular, la percepción propioceptiva activa requiere recolectar gran cantidad de datos para cada una de las secuencias de manipulación. En ocasiones se ha optado por enriquecer la muestra de datos extraída durante la tarea de manipulación combinando datos procedentes de varias fuentes sensoriales de distinta naturaleza. Sinapov et al. (2011) capturaron secuencias temporales de audio y propioceptivas correspon-

dientes a agarres de objetos, en las que el audio representaba el sonido producido por la interacción entre los dedos robóticos y la superficie del objeto al entrar en contacto.

### 1.2. Percepción táctil

La percepción táctil se emplea para obtener, medir e interpretar los datos que se producen por el contacto entre los dispositivos robóticos y los objetos con los que se trabaja. En la última década, es común encontrar métodos de reconocimiento de objetos basados únicamente en datos táctiles, como en el trabajo de Liu et al. (2017a). Como ocurría con la percepción propioceptiva, la táctil también puede ser pasiva o activa.

La percepción *táctil pasiva* se basa en extraer datos táctiles en distintos instantes de tiempo durante la ejecución de una tarea de manipulación sin registrar la conectividad temporal de la acción. De este modo, se pierde la relación temporal que permite determinar la variación de los valores táctiles conforme se desarrolla la manipulación. Equivaldría a muestrear la secuencia temporal de los datos táctiles de modo que por sí sola cada muestra constituye un dato. La ventaja es que se reduce el tiempo de respuesta en el proceso de clasificación. Este tipo de percepción es usado por Rispal et al. (2017) para aprender a reconocer texturas con redes neuronales y usando características calculadas sobre lecturas de un sensor táctil como entrada. Estas técnicas también se usan en otras tareas, como para determinar la estabilidad del agarre (Zapata-Impata et al., 2018) o la dirección del deslizamiento (Zapata-Impata et al., 2019).

La percepción *táctil activa* consiste en generar secuencias temporales de datos táctiles obtenidos a partir de múltiples contactos de los sensores táctiles con la superficie del objeto, cada uno de ellos en distintos instantes de tiempo. Estos contactos múltiples pueden tener como origen múltiples acciones de agarre o una única acción. Se emplean múltiples acciones de agarre cuando se requiere reconocer un objeto mediante la palpación con múltiples toques de la superficie del objeto. De este modo, es posible generar un mapa de apariencia de la superficie del objeto. Después, técnicas probabilísticas como la presentada por Pezzementi et al. (2011) o técnicas como los modelos de bolsas de palabras “Bag-of-Words” (Schneider et al., 2009) aprenden las características de las observaciones táctiles.

En algunas ocasiones, las secuencias temporales representan una única acción de agarre. Es decir, la secuencia temporal es una colección de datos táctiles obtenidos durante el cierre de la mano o pinza hasta envolver la superficie del objeto, registrando los valores de presión generados por el contacto hasta alcanzar un agarre considerado como estable (un agarre capaz de sujetar el objeto sin que este se deslice). Por lo general, las secuencias de datos táctiles de este tipo se emplean para el reconocimiento del objeto en base a características de rigidez y flexibilidad del material con el que está fabricado, como hicieron Baishya and Bäuml (2016), o para controlar la deformación, como demuestran Delgado et al. (2017). No obstante, durante la acción de cierre de la mano y aun cuando la mano no cambie su configuración, es posible que el objeto cambie su posición dentro de la mano. También, es habitual que agarres que parece que sujetan correctamente el objeto no sean estables, por lo que el objeto podría deslizarse de la mano. En estos casos, la percepción táctil se usa para determinar la estabilidad del agarre, como investigaron Reinecke et al. (2014) y Guo et al. (2016).

### 1.3. Percepción propioceptiva-táctil

En relación a los trabajos donde se emplea percepción bimodal propioceptiva-táctil para reconocer objetos, destacan el trabajo de Navarro et al. (2012) en el que los autores preprocesan lecturas táctiles y después las combinan con valores articulares obtenidos desde múltiples palpaciones del objeto a reconocer. Por otro lado, Montano and Suárez (2013) realizan palpaciones de figuras geométricas que reconstruyen combinando información propioceptiva y táctil. Posteriormente, usando modelos de una base de datos reconocen estos objetos con nuevos agarres por comparación de los puntos contactados.

Más adelante, Schmitz et al. (2014) combinaron en un descriptor más de 300 valores datos procedentes de posiciones articulares y presiones táctiles y, posteriormente, aplican técnicas de aprendizaje profundo para aprender a reconocer los objetos. En la línea del uso de técnicas de aprendizaje automático, también está el trabajo de Spiers et al. (2016). Los autores reconocieron objetos cotidianos sin necesidad de realizar varios agarres exploratorios y usando como información los valores articulares de una pinza más los valores de presión medidos por sensores táctiles en sus dedos. Esta información la pasan a un "Random Forest" que predice la clase del objeto.

Recientemente, Velasco-Sanchez et al. (2018) compararon el reconocimiento de objetos empleando sólo datos propioceptivos, sólo datos táctiles o juntando ambos tipos de datos, y demostraron que sistemas de clasificación como k-NN ofrecen mejores resultados cuando se emplean ambos tipos conjuntamente. En esta línea se centra este trabajo, que supone una ampliación de los trabajos realizados por Velasco-Sanchez et al. (2018), investigando el reconocimiento de objetos agarrados con manos robóticas multidedo. La complejidad articular de estas manos posibilita la extracción de más información propioceptiva. Por ello, se presenta un método de reconocimiento basado en aprendizaje supervisado que emplea datos bimodales propioceptivos y táctiles obtenidos por percepción pasiva, es decir, por acciones de agarre estable y de palpación única. El método propuesto ha sido probado con éxito con siete objetos domésticos distintos, logrando tasas de acierto entre 95 % y 96 % y una desviación estándar entre 0.3 % y 0.5 % con nuestro conjunto de datos. Posteriormente, el método propuesto fue verificado reconociendo tres objetos nunca vistos anteriormente, a partir de un preaprendizaje con otros siete objetos distintos.

Las principales contribuciones se pueden resumir de la siguiente manera: se ha implementado un paquete software en ROS capaz de registrar de un modo semi-automático datos bimodales de presión y cinemáticos a partir de agarres estables ejecutados con una mano robótica equipada con sensores táctiles en sus falanges, creando así una base de datos de agarres propia disponible en Velasco-Sanchez (2018). Por otra parte, se ha llevado a cabo una extensa comparativa entre reconocimiento de objetos usando una única fuente de información o combinando varias fuentes (táctil y propioceptivo), cuyo análisis muestra que la combinación bimodal es aconsejable en la mayoría de los casos. Finalmente, se ha diseñado y probado también un descriptor diferencial propioceptivo que combinado con los datos táctiles ofrece una solución eficaz para reconocer objetos por su forma, siendo además invariante a la escala.

Aunque nuestro trabajo se construye en la misma línea que el trabajo de Spiers et al. (2016), existen diferencias significa-

tivas. En primer lugar, en lugar de utilizar una pinza robótica para llevar a cabo los agarres, se propone el uso de manos multidedo. Este tipo de manos aportan durante el agarre mayor información sobre la geometría del objeto que la que proporciona una pinza. En una pinza, se producen dos puntos de contacto que forman un segmento contenido en un plano perpendicular a la superficie del objeto, mientras que en una mano se producen varios puntos de contacto que constituyen varios planos de corte a la superficie. Además, se propone el uso de clasificadores basados en redes neuronales para aprender a reconocer los objetos usando la información bimodal, en lugar de clasificadores basados en árboles como Spiers et al. (2016). Finalmente, este trabajo aporta, también, un descriptor diferencial para abordar los problemas de detectar objetos a distintas escalas, que Spiers et al. (2016) abordan muy brevemente y solo con dos formas geométricas básicas.

El artículo está organizado de la siguiente manera. La sección 2 presenta la arquitectura del paquete software implementado, así como una descripción de los sensores y sistemas robóticos empleados en este trabajo. La sección 3 presenta el descriptor bimodal y la sección 4 la metodología de aprendizaje propuesta, así como las métricas de evaluación utilizadas para medir la tasa de éxito del sistema de reconocimiento propuesto. La sección 5 describe la base de datos de agarres creada y usada en la experimentación y, discute los experimentos y resultados obtenidos. Finalmente, las conclusiones de este trabajo son presentadas en la sección 6.

## 2. Arquitectura del sistema bimodal propioceptivo-táctil

### 2.1. Hardware

La dimensionalidad de los datos que proporciona el sistema propioceptivo-táctil depende tanto del tipo de pinza o mano robótica usada como del sensor táctil que tenga instalado. Para la obtención de datos propioceptivos, se ha empleado una mano diestra Allegro del fabricante Wonik Robotics presentada por Bae et al. (2012) y que proporciona una carga útil de 1.5 Kg, lo que garantiza la capacidad para levantar gran variedad de objetos de ámbito doméstico. La mano Allegro está compuesta de cuatro dedos articulados con cuatro articulaciones cada uno de ellos que proporcionan hasta 16 valores articulares (Figura 1). La comunicación para el control de la mano se lleva a cabo mediante el protocolo "Controller Area Network" (CAN) con una frecuencia de 333 Hz. Además, la mano puede ser controlada a través de la conocida plataforma software "Robot Operating System" (ROS), presentada por Quigley et al. (2009). La mano se fijó para los experimentos en una estructura, así que en lugar de mover la mano alrededor de los objetos para adquirir distintas posturas, los objetos se colocaban en diferentes orientaciones para generar dicha variabilidad.

En concreto, en este trabajo los datos propioceptivos se han combinado con datos táctiles procedentes de una malla con sensores de presión 4256E fabricado por Tekscan (2018). Esta malla sensorial está compuesta de 18 áreas sensitivas. Cada una de estas áreas a su vez se organiza como una matriz de datos que registra la presión de múltiples puntos de contacto en la superficie. La comunicación con los sensores de presión se lleva a cabo mediante "Transmission Control Protocol" (TCP) con una frecuencia de hasta 750 Hz que garantiza lectura en tiempo real.




Figura 1: Direcciones de las 16 articulaciones de la mano Allegro.

El sensor táctil Tekscan está expresamente diseñado para emplazarse en una mano humana usando un guante, de modo que las áreas sensitivas se adaptan a la anatomía de los dedos y palma humanas, pero son de difícil adaptación a pinzas o manos robóticas cuyo tamaño y distribución de falanges no es anatómica. Por lo tanto, para adaptar el sensor a la mano Allegro, se ha tenido que prescindir de 12 de las 18 áreas sensitivas porque no se podían situar sobre las zonas de la mano que generan contactos, sin que se dificultara el movimiento de las falanges en tareas de agarre. Como consecuencia, sólo 6 áreas sensitivas se han habilitado en 3 de los dedos de la mano Allegro, permitiendo que las 12 restantes no interfieran ni perjudiquen el movimiento de la mano. Nótese que a pesar de la disposición del sensor en sólo tres dedos, son cuatro los dedos de la mano que se emplean para llevar a cabo la tarea de agarre de objetos y en consecuencia obtener datos propioceptivos, aunque sólo tres de ellos tienen correspondencia táctil.

## 2.2. Integración a nivel de software

El sensor Tekscan no dispone de integración en ROS por parte del fabricante, ya que sólo es posible ejecutar su driver en el sistema operativo Windows. Por lo tanto, ha sido necesaria la implementación de un módulo software en LabVIEW (National Instruments, 2018) como puente para comunicarlo con el controlador de la mano en ROS. De este modo, se puede interactuar tanto con la mano robótica como con los sensores táctiles al mismo tiempo en ROS, garantizando una correcta transmisión de datos en el sistema bimodal propioceptivo-táctil (Figura 2).

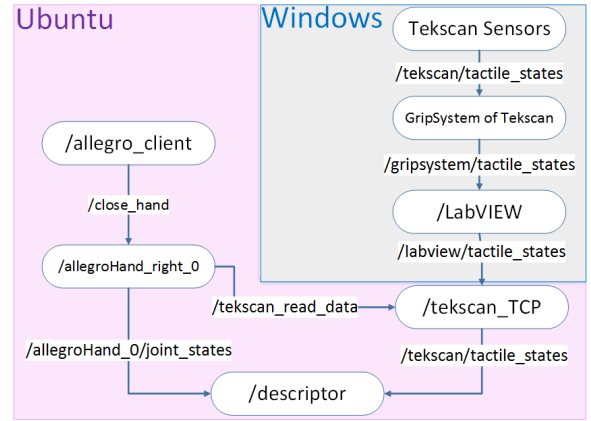


Figura 2: Integración software del sensor táctil y la mano robótica.

## 3. Descriptor propuesto

El objetivo de este trabajo es reconocer objetos domésticos aplicando una técnica de percepción pasiva en la que se ejecutan acciones de agarre de palpación única. Para aumentar y enriquecer los datos registrados durante la acción de toque único, se emplea percepción bimodal combinando datos propioceptivos y táctiles, extraídos de las lecturas de los servomotores de las falanges y de las áreas sensitivas del sensor táctil, respectivamente. Posteriormente, los datos registrados se emplean como datos de entrada para entrenar arquitecturas de aprendizaje supervisado.

### 3.1. Extracción de características propioceptivas-táctiles

Dado  $O = \{O_1, \dots, O_n\}$  un conjunto de  $n$  objetos candidatos sobre los que realizar acciones de agarre con un robot, se asume que sobre cada objeto  $O_i$  es posible llevar a cabo varios agarres distintos en función de su postura, como se muestra en la Figura 3. Si se denota cada postura como  $j$ , y esta viene determinada por los grados de giro respecto a los ejes de coordenadas cartesianas  $x$ ,  $y$  y  $z$ , entonces la configuración de agarre para cada  $O_i \in O$  puede ser denotada como  $O_{ij}$ . Además, cada configuración de agarre  $O_{ij}$  puede ser ejecutada  $k$  veces y por lo tanto, en cada agarre se registra una tupla  $(O_{ij}, P_k, T_k)$  donde  $P_k$  y  $T_k$  son los datos propioceptivos y táctiles obtenidos después de agarrar un objeto  $O_i$  en la postura  $j$  en la iteración  $k$ .

Los datos propioceptivos  $P_k$  obtenidos para cada agarre  $k$  son representados como  $f^k = \{f_1^k, \dots, f_m^k\}$  siendo  $m$  el número de dedos que tiene la mano. Además, cada dedo  $f_i^k = \{\theta_{i1}^k, \dots, \theta_{in}^k\}$  está compuesto de  $n$  falanges, cada una de las cuales puede ser rotada un ángulo distinto  $\theta_{ij}^k$  por cada articulación  $j$  en cada iteración de agarre  $k$ . En el caso que nos ocupa, la dimensionalidad se reduce a  $m = 4$  que son los cuatro dedos de la mano Allegro y a  $n = 4$  que son las cuatro articulaciones de las que se componen las falanges de estos (distal, medial, proximal y metacarpiano). Así pues, tenemos:

$$f^k = \{f_1^k, f_2^k, f_3^k, f_4^k\} \quad (1)$$

siendo cada dedo  $f_i^k$ , una tupla como:

$$f_i^k = \{\theta_{i1}^k, \theta_{i2}^k, \theta_{i3}^k, \theta_{i4}^k\}, \forall i \in [1..4] \quad (2)$$




Figura 3: Capturas de varios agarres en distintas posturas de un objeto.

Las restricciones cinemáticas de la mano Allegro vienen dadas por los valores angulares que pueden tomar las articulaciones de cada dedo  $f_i^k$ , limitados a:  $\theta_{i1} \in [-16,9^\circ, 98^\circ]$  y  $\theta_{i2} \in [-15,7^\circ, 103,6^\circ]$  para las articulaciones metacarpofalangiana,  $\theta_{i3} \in [-18,7^\circ, 98,4^\circ]$  para la proximal y  $\theta_{i4} \in [-34^\circ, 32,6^\circ]$  para la distal. La diferencia cinemática entre el dedo pulgar  $f_4^k$  y el resto de dedos es que este no dispone de articulación metacarpofalangiana  $\theta_{41}$  y, además, el eje de giro tanto de la articulación proximal  $\theta_{43}$  como la distal  $\theta_{44}$  es distinto al fijado para esas dos mismas articulaciones en otros dedos. Esto se debe a la localización del dedo pulgar en la mano, como se observa en la Figura 1. A pesar de ello, el rango de movimiento del giro sí coincide con el del resto de dedos.

Por otro lado, es posible representar la posición articular para cada dedo  $f_i^k$  como una variación relativa y no absoluta como ocurría en la notación anterior. Así, la posición articular se puede notar como un gradiente angular  $f_i^k = \{\theta_{i1}^k, \dots, \theta_{in-1}^k\}$  donde  $\theta_{ij}^k$  es la rotación relativa entre dos articulaciones consecutivas, siempre que en ambas articulaciones los giros se realicen respecto al mismo eje (ver Figura 1). De este modo, para un dedo  $f_i^k$  se puede calcular como:

$$f_i^k = \{\theta_{i4}^k - \theta_{i3}^k, \theta_{i3}^k - \theta_{i2}^k, \theta_{i1}^k - 0\}, \forall i \leq 3 \quad (3)$$

Y puesto que las articulaciones usan diferentes ejes en el dedo pulgar  $f_4$  (ver Figura 1) para este se calcula como:

$$f_4^k = \{\theta_{44}^k - \theta_{43}^k, \theta_{42}^k - 0, \theta_{41}^k - 0\} \quad (4)$$

En cuanto a los datos táctiles  $T_k$  para cada acción de agarre  $k$ , estos se representan como una secuencia de valores de presión  $T_k = \{t_1^k, \dots, t_s^k\}$  donde  $s$  indica el número de áreas sensitivas, siendo  $s = 6$ . Además cada área sensitiva  $t_i^k$  se define como una matriz elementos sensitivos capaces de registrar una

presión máxima de  $21 \text{ N/cm}^2$ . Las áreas  $t_1, t_3, t_5$  son matrices de  $4 \times 4$  elementos sensitivos, mientras que las áreas  $t_2, t_4, t_6$  son de  $3 \times 4$ .

Basándonos en la notación presentada, la distribución final de las áreas sensitivas en la mano Allegro quedó de la siguiente manera: las áreas  $t = 1, 3, 5$  se instalaron en las yemas de los dedos mientras que  $t = 2, 4, 6$  se instalaron entre las articulaciones distales  $\theta_{i4}$  y proximales  $\theta_{i3}$ , siendo  $i$  cualquiera de los dedos. En particular  $t_1$  y  $t_2$  se instalaron en el pulgar  $f_4$ ,  $t_3$  y  $t_4$  en el índice  $f_1$  y  $t_5$  y  $t_6$  en el corazón  $f_2$  (Figura 4).

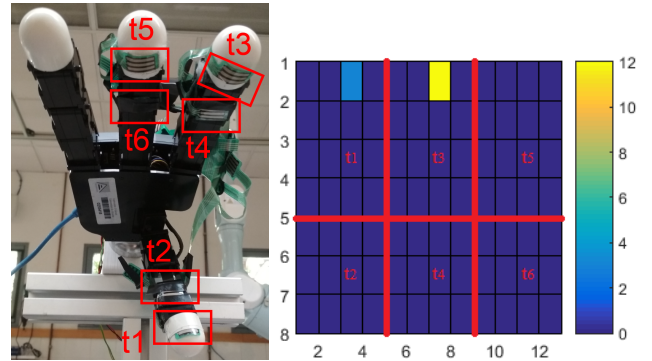


Figura 4: Distribución de las áreas sensitivas en la mano Allegro y muestra de sus lecturas en un agarre.

### 3.2. Descriptor bimodal propioceptivo-táctil

Puesto que el movimiento de un dedo cualquiera no está acoplado al movimiento de los otros dedos que componen la mano, no existe dependencia entre los valores articulares de un dedo con los de otros dedos. Por este motivo, lo más recomendable es organizar los datos propioceptivos como un vector cuya representación no introduce información de dependencia con sus vecinos. No obstante, hay que tener en cuenta que en un mismo dedo los valores que componen el área sensitiva de presión tienen una organización matricial. Por lo tanto, los datos táctiles sí tienen cierta información de vecindad.

La mejor manera de combinar ambos tipos de datos para emplearlos en un clasificador es transformar la organización matricial de las 6 áreas sensitivas en una organización lineal como un vector. Posteriormente, se pueden concatenar ambas representaciones vectoriales en un descriptor único, como se muestra en los dos descriptores propuestos: el descriptor *raw*, dado por

$$(P_k, T_k) = (f_1^k, f_2^k, f_3^k, f_4^k, t_1^k, t_2^k, t_3^k, t_4^k, t_5^k, t_6^k) \quad (5)$$

y el descriptor *diferencial*, dado por

$$(\dot{P}_k, T_k) = (f_1^k, f_2^k, f_3^k, f_4^k, t_1^k, t_2^k, t_3^k, t_4^k, t_5^k, t_6^k) \quad (6)$$

Aparte de estos dos descriptores, se probaron varias representaciones vectoriales organizando los datos propioceptivos y táctiles de distintas maneras. Por ejemplo, se probó a concatenar los datos propioceptivos primero y los táctiles después, alternar datos propioceptivos con táctiles agrupándolos por dedos u organizando los datos por índices crecientes y decrecientes. Al final, los mejores resultados se consiguieron organizando los datos como en los descriptores *raw* y *diferencial*.



La ventaja de un descriptor simple con forma vectorial es que ofrece la posibilidad de usarlo en una amplia gama de diversos clasificadores, desde modelos simples como regresión lineal o logística y k-NN, hasta otros más complejos como "Support Vector Machine"(SVM) y arquitecturas de redes neuronales, como hicieron Cervantes et al. (2017). En este trabajo, hemos preferido evitar la combinación de clasificadores, por ejemplo, el empleo de una red neuronal para clasificar el agarre usando como entrada  $P_k$  y otra red usando  $T_k$ , para luego emplear un tercer clasificador que combina las salidas de ambas redes. Aunque el uso de clasificadores en cascada o combinados generalmente suele funcionar mejor que un solo modelo por separado, esto requeriría el entrenamiento de varios modelos para unirlos por lo que la comparación con otro modelo como un k-NN no se podría realizar en igualdad de condiciones (un modelo contra otro modelo). Además, se ha buscado que la técnica de clasificación utilizada pueda entrenarse con datos bimodales a la entrada sin necesidad de tener que dividirlos en dos entradas.

Finalmente, los datos de los descriptores  $M$ , tanto *raw* (5) como *diferencial* (5), son normalizados a la entrada de los clasificadores. Para ello, se aplican dos conocidas normalizaciones presentadas por Shalabi et al. (2006), como son el reescalado,

$$Z_{rc} = (M - \min(M)) / (\max(M) - \min(M)) \quad (7)$$

y el estandarizado,

$$Z_{st} = M - \text{mean}(M) / \text{std}(M) \quad (8)$$

## 4. Metodología de aprendizaje propuesta

### 4.1. Modelos de referencia

Para analizar los resultados que el método de aprendizaje propuesto ofrece, es necesario compararlo con otros métodos de referencia. En este trabajo se ajustaron los parámetros de varios métodos basados en técnicas tradicionales de aprendizaje automático, descritas por Nasrabadi (2007) y Hastie et al. (2009), para usarlos como métodos de referencia. Concretamente, se emplearon los siguientes métodos:

- *Regresión logística* o "Logistic Regression"(LR): configurado para clasificación multiclase con un máximo de 100 iteraciones. Se seleccionó una función de optimización de gradiente conjugado de Newton en aras de obtener un grado de convergencia óptimo y rápido. El valor de tolerancia para el criterio de parada se escogió en 0.0001.
- *Árbol de decisión* o "Decision Tree"(DT): expandido hasta que todas las hojas tienen una única muestra. Además, se consideró que todas las categorías de objetos a clasificar tienen el mismo peso, pues se emplea similar número de muestras de cada objeto para el entrenamiento del clasificador. Por lo tanto, las clases están balanceadas.
- *K Vecinos más cercanos* o "K-Nearest Neighbors"(k-NN): configurado con pesos uniformes, independientemente del tamaño del entorno de vecindad escogido. Se probaron 5 valores de  $k$  distintos para evaluar su comportamiento. Después, se escogió como método de referencia el k-NN que proporcionaba el valor más alto de acuerdo con varias métricas de evaluación comparadas en base a su distancia Euclídea o  $L_2$ .

### 4.2. Modelo propuesto

Se diseñaron y analizaron varios modelos de arquitecturas de redes neuronales para aprender los descriptores propuestos, *raw* y *diferencial*. Los métodos de clasificación basados en redes neuronales son más complejos pero también más potentes y por lo tanto, son capaces de ofrecer mejores resultados de aprendizaje en tareas de clasificación que otras técnicas tradicionales.

Se puede afirmar que no hay una regla general que facilite la elección de la arquitectura de red neuronal más adecuada para un problema de clasificación dado. Pascanu et al. (2014) justifican como regla general que, cuanto más difícil es el problema de clasificación a resolver, mayor es el número de capas y neuronas requeridas para aprender a resolver el problema, aunque el coste computacional aumenta. Por lo tanto, llevamos a cabo un estudio del comportamiento de distintas configuraciones de redes neuronales en nuestro problema. Así, el número de capas, su tipo y el número de neuronas por cada capa se fue ajustando empíricamente para encontrar el número más adecuado para nuestro problema de reconocimiento de objetos en base a los descriptores propuestos.

El descriptor *raw* contiene 16 valores articulares, 4 por cada dedo, más 84 valores de presión, 16 por cada una de las 3 áreas sensitivas de 4x4 y 12 por cada una de las 3 áreas sensitivas de 3x4, lo que supone un vector de 100 características. De acuerdo al tamaño del vector y a la disposición secuencial escogida, se propone una arquitectura neuronal para datos de tipo secuencial. Así, se ha escogido un modelo perceptrón multicapa o "Multi-Layer Perceptron" (MLP) en vez de otros modelos como las redes neuronales convolucionales o "Convolutional Neural Networks" (CNN), frecuentemente usadas en clasificación de imágenes. Los parámetros del MLP en la etapa de experimentación se presentan en la Tabla 1.

Tabla 1: Parámetros del método propuesto basado en modelos de arquitectura de red neuronal.

Ajustes	MLP <sub>1</sub>	MLP <sub>2</sub>	MLP <sub>3rc</sub>	MLP <sub>3st</sub>
Entrada	100	100	100	100
Capas ocultas	1	2	3	3
Nº neuronas/capa	100	100/1000	100/1000/50	100/1000/50
Lotes	32	32	32	32
Normalización	$Z_{rc}$	$Z_{rc}$	$Z_{rc}$	$Z_{st}$
Nº iteraciones	50	50	50	20
Reducción Dim.	NO	NO	NO	NO
"Dropout"	NO	NO	NO	NO

En todas las capas se emplea "Batch Normalization" (Ioffe and Szegedy, 2015) y se usa como función de activación "Rectified Linear Unit" (ReLU) (Glorot et al., 2011). En la última capa se ha escogido la función "Softmax" (Bishop, 2006) que permite definir múltiples límites de decisión y dar de salida una distribución de probabilidad multiclase mutuamente excluyente. No se ha requerido aplicar técnicas de regularización como "Dropout" (Srivastava et al., 2014), que son frecuentemente usadas para prevenir el sobreajuste típico en redes complejas. El rendimiento y resultados no mejoraron aplicando "Dropout", ya que




Figura 5: (Izquierda) Evolución de la tasa de aprendizaje. (Derecha) Evolución de la convergencia de la función de pérdida.

las dimensiones y simplicidad de las redes propuestas se adecuan al tamaño del descriptor de entrada y a la complejidad de la tarea llevada a cabo. Por todo esto, se demuestra que no se requiere emplear arquitecturas más complejas para esta tarea. Además, la Figura 5 muestra la velocidad del aprendizaje de los modelos propuestos y cómo convergen a un mínimo local para el número de iteraciones escogido en cada caso. Esto demuestra el correcto ajuste de los pesos de la red neuronal. El resultado de nuestro modelo muestra como a medida que aumenta la velocidad de aprendizaje, el coste disminuye hasta estabilizarse en 0.01 con 20 iteraciones para MLP<sub>3st</sub>, siendo este modelo propuesto el que mejor tasa de aprendizaje nos ofrece.

#### 4.3. Evaluación del modelo

Para evaluar el modelo propuesto y compararlo con los de referencia se han empleado algunas de las métricas de evaluación sugeridas por Powers (2011), tales como: Exactitud/Acierto o "Accuracy" ( $Acc$ ), Precisión o "Precision" ( $P$ ), Sensibilidad o "Recall" ( $R$ ) y "F-score" ( $F_1$ ). Estas métricas son ampliamente usadas en tareas de aprendizaje automático para medir el rendimiento en tareas de clasificación.

- $Acc$  es una medida que determina la capacidad del método para predecir correctamente. Proporciona el ratio de reconocimientos correctos, tanto de objeto específico como de la ausencia de este, de entre todas las predicciones que se hacen.
- $P$  indica la capacidad del método para reconocer un objeto específico sin confundirlo con instancias de otros objetos.
- $R$  indica la bondad que tiene el método para reconocer un objeto específico de entre todas las instancias que representan ese objeto.

- $F_1$  es una medida que combina  $P$  y  $R$  mediante una media armónica de ambas métricas, por lo que cuando ambas métricas tienen valores similares  $F_1$  coincide con la media aritmética.

$$\begin{aligned}
 Acc &= (TP + TN)/(TP + FP + FN + TN) \\
 P &= TP/(TP + FP) \\
 R &= TP/(TP + FN) \\
 F1 &= 2 * (P * R)/(P + R)
 \end{aligned}
 \tag{9}$$

donde TP: "True Positives" son los verdaderos positivos y denota el número de instancias correctamente detectadas como el objeto buscado; FN: "False Negatives" son los falsos negativos y denota el número de instancias que aun presentando el objeto buscado se han perdido en el proceso de búsqueda y detección; FP: "False Positives" son los falsos positivos e indican el número de instancias que han sido detectadas incorrectamente, por ejemplo porque la instancia representa un objeto que es parecido al buscado y se genera una confusión que proporciona un incorrecto reconocimiento; TN "True Negatives" son los verdaderos negativos, es decir las instancias que correctamente se ha reconocido que no pertenecen a la clase del objeto buscado.

## 5. Experimentación

### 5.1. Base de datos de agarres

Si se quiere implementar un sistema de reconocimiento de objetos, que están siendo agarrados por un robot, y para ello se pretende hacer uso de técnicas de aprendizaje supervisado, es necesario disponer de datos de agarre que tomados como entrada permitan enseñar al sistema a reconocer correctamente el objeto. Es importante destacar que la base de datos debe disponer de suficientes muestras de cada objeto a reconocer. Además,

deben ser representativas y mostrar la variabilidad del problema, por ejemplo cada objeto debe tener un número suficiente de instancias de agarres que representen distintas posturas. En este trabajo, empleando la mano robótica descrita en la sección 2, se ha construido una base de datos de agarres pasivos de objetos domésticos disponible en Velasco-Sanchez (2018).

Como resultado, se ha creado el conjunto de datos DS-I compuesto de 3064 agarres de 7 objetos distintos (Figura 6). Los datos propioceptivo-táctiles fueron adquiridos con distintas posturas de agarre para cada objeto, emulando situaciones reales que se pueden dar en tareas de manipulación. Para ello, se colocaron los objetos uno a uno sobre una plataforma de forma que presentaban una nueva postura cada vez. Se grabaron agarres distintos de los mismos objetos haciendo girar la plataforma ( $0^\circ$ ,  $30^\circ$ ,  $45^\circ$  y  $90^\circ$ ) de cada postura inicial, usando los ejes en la Figura 6, para añadir mayor variabilidad a las posturas. Los objetos que se emplearon tienen al menos un eje de simetría por lo que no fue necesario considerar giros mayores a  $90^\circ$  sobre dicho eje. Objetos cilíndricos como  $O_1$  solamente se giraron en dos ejes, pues los ejes  $X$  e  $Y$  presentan el objeto en posturas similares, al ser éste simétrico con respecto al eje  $Z$ . Así mismo, objetos esféricos como  $O_6$  solamente se giraron en el eje  $Z$ . La Tabla 2 muestra la composición del conjunto DS-I.



Figura 6: Objetos de la base de datos DS-I (de izquierda a derecha y de arriba a abajo):  $O_1$  Botella de leche,  $O_2$  Envase de gel,  $O_3$  Caja de cartón,  $O_4$  Lata,  $O_5$  Pelota de espuma,  $O_6$  Bola de plástico,  $O_7$  Copa de plástico. Arriba se muestra el sistema de coordenadas tomado para realizar los giros de los objetos.

Tabla 2: Número de agarres para cada objeto en la base de datos propuesta DS-I.

Objeto	eje - x	eje - y	eje - z	Nº agarres
$O_1$	347	67	0	414
$O_2$	136	267	0	403
$O_3$	163	246	40	449
$O_4$	192	210	0	402
$O_5$	0	0	404	404
$O_6$	0	0	384	384
$O_7$	198	319	91	608

Para validar el aprendizaje del modelo propuesto, se ha usado la técnica de validación cruzada o "n-fold cross validation" que garantiza la independencia de cómo se escojan los datos para entrenamiento y prueba. En nuestro caso, la validación cruzada consiste en emplear diferentes particiones de DS-I, dividiéndola en  $n = 5$  conjuntos disjuntos que mantienen el por-

centaje de muestras para cada categoría de objetos a reconocer. Uno de los subconjuntos es usado para la prueba de validación (20 % de DS-I) y los otros cuatro (80 % de DS-I) como datos de entrenamiento. Estos conjuntos rotan de forma que el proceso se repite 5 veces. De este modo, es posible obtener mejores estimaciones de Monte-Carlo que cuando las muestras se escogen aleatoriamente y se van asociando al subconjunto de prueba o al de entrenamiento, tal y como demuestra Kohavi (1995). La técnica de validación cruzada nos permite comparar los modelos de referencia y los propuestos bajo similares condiciones.

Cabe indicar que no se ha aplicado la técnica de aumento de datos descrita por Kang et al. (2014) y Krizhevsky et al. (2012), muy frecuente en el aprendizaje profundo, para evitar la representación de datos articulares y táctiles irreales. Los datos aumentados artificiales podrían haber representado valores articulares que incumplen las restricciones cinemáticas de la mano robótica, así como podrían generarse valores táctiles fuera de rango o de difícil ocurrencia real.

A continuación, se muestran los resultados obtenidos a través de dos experimentos. En el primer experimento, sección 5.2, se han comparado los resultados obtenidos en los modelos de referencia y los propuestos, entrenando y probando con la base de datos DS-I. En el segundo experimento, sección 5.3, se ha escogido el modelo propuesto que mejor rendimiento ha ofrecido en la primera experimentación y se ha reentrenado pero esta vez con el 100 % de los datos de DS-I (los 3064 agarres). De este modo, se ha dispuesto de un 20 % más de datos para afinar en el ajuste de los parámetros de la red neuronal. Después, se ha creado un segundo conjunto de datos completamente nuevo, llamado DS-II, a partir de 140 nuevos agarres de los mismos objetos pero con posturas totalmente distintas a las que se había almacenado en DS-I (rotaciones de ángulos diferentes). Este segundo conjunto se utilizó para verificar el ajuste del modelo propuesto, comprobando si hay variación en los rendimientos al emplear agarres muy distintos a los usados en la etapa de entrenamiento.

Finalmente, se ha realizado una variación adicional que ha consistido en emplear objetos nuevos pero similares a los representados en DS-I en la etapa de prueba. Estos objetos nuevos tienen propiedades físicas similares a algunos de los objetos de DS-I, sin ser idénticos. El objetivo de este experimento es validar la generalización de nuestro sistema para reconocer objetos nunca vistos antes, de modo que el sistema identifique por similitud los objetos nuevos (en DS-III) con las categorías de objetos registrados en DS-I.

## 5.2. Modelo propuesto VS modelos de referencia

El rendimiento del método propuesto basado en MLPs en comparación con los modelos de referencia se presenta en la Tabla 3. Por un lado, se puede concluir que nuestra aproximación tiene un rendimiento estable ya que el rendimiento medio de reconocimiento obtenido no varía en función de la métrica de evaluación empleada, y por lo tanto es independiente de cuál se use. Por otro lado, las arquitecturas basadas en MLP tienen mayor capacidad para discriminar los objetos que los métodos tradicionales para el caso que nos ocupa. El mejor modelo de referencia es el k-NN que alcanza una probabilidad media de acierto del 95 % con una desviación típica del 1 %, mientras que MLP<sub>2</sub> obtiene un resultado similar pero con desviación típica



Tabla 3: Rendimiento de los modelos propuestos frente a los de referencia, usando el descriptor *raw*.

Método	<i>Acc</i>	<i>P</i>	<i>R</i>	<i>F</i> <sub>1</sub>
LR	0,82 ± 0,02	0,82 ± 0,01	0,81 ± 0,01	0,81 ± 0,01
DT	0,89 ± 0,01	0,89 ± 0,02	0,89 ± 0,01	0,89 ± 0,02
k-NN	0,95 ± 0,01	0,95 ± 0,01	0,95 ± 0,01	0,95 ± 0,01
MLP <sub>1</sub>	0,92 ± 0,01	0,92 ± 0,01	0,92 ± 0,009	0,91 ± 0,001
MLP <sub>2</sub>	0,94 ± 0,009	0,94 ± 0,009	0,94 ± 0,008	0,94 ± 0,009
MLP <sub>3<sub>rc</sub></sub>	0,96 ± 0,006	0,96 ± 0,006	0,96 ± 0,005	0,96 ± 0,005
MLP <sub>3<sub>st</sub></sub>	0,97 ± 0,003	0,97 ± 0,003	0,97 ± 0,004	0,96 ± 0,004

menor (94 % ± 0.9 %). Los resultados para MLP<sub>3</sub> son aun significativamente mejores que los de los clasificadores tradicionales, ya que en el caso de MLP<sub>3<sub>st</sub></sub> se alcanza un acierto medio de 97 % con una desviación de tan sólo el 0.3 %.

### 5.3. Comparación de los descriptores propuestos usando el mejor modelo propuesto

La primera parte de los resultados del segundo experimento se muestran en la Tabla 4, en la que se presenta el rendimiento de MLP<sub>3<sub>st</sub></sub> con los dos descriptores propuestos. Los resultados indican una diferencia entre usar el descriptor *raw* y el *diferencial*. El descriptor *diferencial* muestra peor rendimiento que *raw* aplicando el entrenamiento por validación cruzada. Aunque los conjuntos de prueba y entrenamiento son disjuntos, los datos de agarre empleados en las pruebas de rendimiento son obtenidos desde agarres de los mismos objetos situados en las mismas posturas. En estos términos, el comportamiento del descriptor *raw* es siempre mejor que el del *diferencial*.

Tabla 4: Resultados por validación cruzada de MLP<sub>3<sub>st</sub></sub> con DS-I para los descriptores *raw* y *diferencial*.

Descriptor	<i>raw</i>	<i>diferencial</i>
<i>Acc</i>	0,97 ± 0,003	0,94 ± 0,001
<i>P</i>	0,97 ± 0,003	0,94 ± 0,001
<i>R</i>	0,97 ± 0,004	0,94 ± 0,001
<i>F</i> <sub>1</sub>	0,96 ± 0,004	0,94 ± 0,001


La segunda parte del experimento está enfocado a verificar la capacidad de generalización del método propuesto. Para hacer esto, grabamos un nuevo conjunto de datos de agarre, llamado DS-II. Este conjunto consta de 140 nuevos agarres de los mismos objetos  $O = \{O_1, \dots, O_7\}$  pero con nuevas posturas. Se reentrenó el modelo MLP<sub>3<sub>st</sub></sub> con el 100 % de los datos de DS-I para después evaluarlo con DS-II. Los resultados se presentan en la Tabla 5 donde se observa que el rendimiento medio obtenido es ligeramente peor para el descriptor *raw* frente al *diferencial*, si se compara con los resultados de la Tabla 4. Sin embargo, aunque haya aumentado el rendimiento medio del uso del descriptor *diferencial*, la desviación estándar también ha incrementado. En las figuras 7 y 8 se muestra el comportamiento de los dos descriptores propuestos con más detalle. Cuando MLP<sub>3<sub>st</sub></sub> se entrena con el descriptor *diferencial*, se mejora la probabilidad de acierto en el reconocimiento en 7 %, 6 % y 2 %

de los objetos  $O_4$ ,  $O_3$  y  $O_1$ , respectivamente. Mientras que para  $O_6$  y  $O_7$  empeora en un 5 % y un 7 %.

Tabla 5: Resultados de MLP<sub>3<sub>st</sub></sub> entrenado con DS-I y probado con DS-II para los descriptores *raw* y *diferencial*.

Descriptor	<i>raw</i>	<i>diferencial</i>
<i>Acc</i>	0,96 ± 0,003	0,95 ± 0,005
<i>P</i>	0,96 ± 0,003	0,95 ± 0,005
<i>R</i>	0,96 ± 0,004	0,95 ± 0,004
<i>F</i> <sub>1</sub>	0,96 ± 0,006	0,95 ± 0,004

Independientemente del objeto que se escoja, con el descriptor *diferencial* la predicción en el proceso de reconocimiento falla sólo por confusión con un único objeto cuando esta ocurre. Mientras que con el descriptor *raw* la predicción puede fallar hasta con tres y cuatro objetos distintos, aunque con tasa baja. Esto se puede observar comparando los datos para el objeto  $O_4$  en las matrices de confusión de las figuras 7 y 8.

Figura 7: Matriz de confusión para el modelo MLP<sub>3<sub>st</sub></sub> entrenado con DS-I y evaluado con DS-II para el descriptor *raw*.




Figura 8: Matriz de confusión para el modelo MLP<sub>3st</sub> entrenado con DS-I y evaluado con DS-II para el descriptor *diferencial*.

Aunque los descriptores han sido normalizados y con ellos sus datos propioceptivos, el descriptor *raw* no parece ser invariante a escala. Más aun, se puede deducir que para objetos pequeños, aun siendo distintos en forma, la variabilidad en las posiciones articulares que definen parte del agarre puede llegar a asemejarse, generando similitudes en el descriptor y causando confusión en el reconocimiento del agarre. Esto queda atenuado en parte cuando se emplea el descriptor *diferencial*, aunque alcance una tasa de acierto ligeramente inferior en aquellos objetos donde la probabilidad de reconocimiento es muy alta, como es el caso de *O*<sub>6</sub> y *O*<sub>7</sub>.

Finalmente, se ha llevado a cabo una última prueba (Tabla 6) incorporando un conjunto adicional DS-III de nuevos datos de agarre, esta vez de nuevos objetos distintos a los descritos en DS-I, y por lo tanto para los cuales el sistema no ha sido entrenado anteriormente. En particular, se ha añadido el objeto *O*<sub>8</sub> (un vaso de plástico), *O*<sub>9</sub> (una nueva caja de cartón) y *O*<sub>10</sub> (una nueva pelota de espuma) (Figura 9). Los objetos que se han añadido están hechos de materiales similares a los materiales con los que fueron fabricados los de DS-I, aunque las formas y dimensiones no son exactamente las mismas que aquellos objetos de DS-I a los que más se parecen (*O*<sub>7</sub>, *O*<sub>3</sub> y *O*<sub>5</sub>) y que podrían ser catalogados de la misma clase.

Tabla 6: Resultados de MLP<sub>3st</sub> entrenado con DS-I y probado con nuevos objetos para los descriptores *raw* y *diferencial*.

Descriptor	raw	diferencial
Acc	0,86 ± 0,002	0,97 ± 0,002
P	0,86 ± 0,003	0,97 ± 0,005
R	0,85 ± 0,003	0,98 ± 0,005
F1	0,86 ± 0,005	0,98 ± 0,005



Figura 9: Nuevos objetos DS-III (de izquierda a derecha): *O*<sub>8</sub> Vaso de plástico, *O*<sub>9</sub> Nueva caja de cartón y *O*<sub>10</sub> Pelota de rugby de espuma.

En la Figura 10 y en la Figura 11 se muestra cómo el mejor modelo propuesto MLP<sub>3st</sub> entrenado con DS-I consigue reconocer el 95 % de las veces el objeto *O*<sub>8</sub> (vaso de plástico) con el descriptor *diferencial* como un objeto similar al objeto *O*<sub>7</sub> (copa de plástico), que es el objeto con el que el sistema entrenó. Mientras, el descriptor *raw* únicamente alcanza el 65 % de acierto. Lo mismo ocurre para el caso del objeto *O*<sub>9</sub> (nueva caja de cartón), correctamente reconocido como un objeto similar a *O*<sub>3</sub> (caja de cartón) en el 85 % de los casos haciendo uso del descriptor *diferencial*, mientras que con el descriptor *raw* sólo se alcanza el 73 % de acierto. También ocurre esto con el objeto *O*<sub>10</sub> (pelota de rugby de espuma) que es clasificado correctamente como un objeto similar a *O*<sub>5</sub> (pelota de espuma) con un 95 % de las veces, frente al 88 % que se alcanza con el descriptor *raw*.




Figura 10: Matriz de confusión para el modelo MLP<sub>3st</sub> entrenado con DS-I y evaluado con DS-III usando el descriptor *raw*.

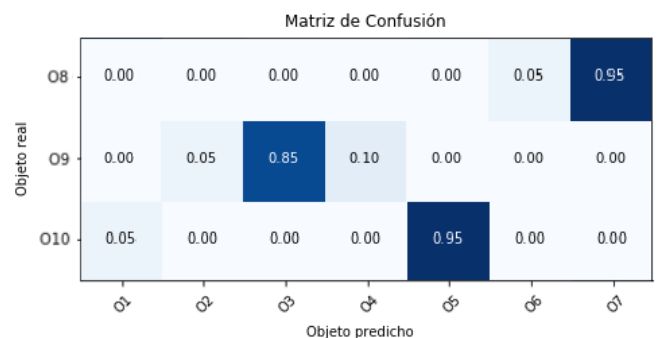


Figura 11: Matriz de confusión para el modelo MLP<sub>3st</sub> entrenado con DS-I y evaluado con DS-III usando el descriptor *diferencial*.

Estos resultados demuestran que aunque en las Tablas 4 y 5 el descriptor *raw* puede tener un comportamiento ligeramente mejor en algunos casos – como en el reconocimiento de *O*<sub>6</sub> y

$O_7$  – esto se debe a que el modelo ha sido evaluado con los mismos objetos con los que fue entrenado, aun cuando las escenas de agarre sean nuevas, por lo que el sistema de reconocimiento no está generalizado para reconocer nuevos objetos distintos de forma y material similares a los aprendidos. Por el contrario, el descriptor *diferencial* sí reconoce los mismos objetos con los que fue entrenando aun cuando se usan nuevos agarres y también reconoce nuevos objetos nunca vistos antes pero con similitudes con los entrenados. Por lo tanto, se demuestra que el descriptor *diferencial* propuesto es un buen punto de partida para generalizar el reconocimiento de objetos agarrados empleando datos propioceptivo-táctiles.

## 6. Conclusiones

Este trabajo ha presentado dos descriptores bimodales que combinan datos propioceptivos y táctiles, obtenidos a partir de sensores reales, utilizados para el reconocimiento de objetos. El comportamiento de ambos descriptores se ha evaluado empleando varios modelos de referencia entrenados con técnicas clásicas de aprendizaje automático y con varios modelos propuestos basados en técnicas de aprendizaje neuronal. Para llevar a cabo la validación de nuestra propuesta se ha creado una base de datos de agarre de objetos domésticos. Además, el mejor modelo propuesto MLP<sub>3st</sub> se ha probado con nuevos agarres de los mismos objetos en nuevas posturas, así como con nuevos objetos nunca vistos antes y para los que el sistema no fue entrenado previamente. Este modelo alcanzó una tasa de reconocimiento de hasta el 96 % independientemente de la métrica de evaluación empleada, ya que se llegó a evaluar con cuatro distintas.

La investigación aquí presentada contribuye al desarrollo de estrategias para el reconocimiento de objetos usando datos híbridos, mezclando datos propioceptivos y táctiles, y tiene como objetivo mejorar la eficacia de las acciones de agarre en tareas de manipulación inteligente. Estos resultados podrían ser aplicados a otros sensores táctiles y manos robóticas de características similares en sistemas de agarre y manipulación.

## Agradecimientos

Este trabajo ha sido financiado con Fondos Europeos de Desarrollo Regional (FEDER), Ministerio de Economía, Industria y Competitividad a través del proyecto DPI2015-68087-R y la ayuda pre-doctoral BES-2016-078290, y también gracias al apoyo de la Comisión Europea y del programa Interreg V. Sudoe a través del proyecto SOE2/P1/F0638.

## Referencias

Bae, J., Park, S., Park, J., Baeg, M., Kim, D., Oh, S., Oct 2012. Development of a low cost anthropomorphic robot hand with high capability. In: 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). pp. 4776–4782.  
DOI: 10.1109/IR0S.2012.6386063

Baishya, S. S., Bäuml, B., Oct 2016. Robust material classification with a tactile skin using deep learning. In: 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). pp. 8–15.  
DOI: 10.1109/IR0S.2016.7758088

Bergquist, T., Schenck, C., Ohiri, U., Sinapov, J., Griffith, S., Stoytchev, E., 2009. Interactive object recognition using proprioceptive feedback. In: IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)-Workshop: Semantic Perception for Robot Manipulation. URL: <http://www.willowgarage.com/iros09spmm>

Bishop, C., 2006. Pattern Recognition and Machine Learning. Springer-Verlag New York.

Cervantes, J., Taltema, J., Lamont, F. G., Castilla, J. S. R., Rendon, A. Y., Jallili, L. D., 2017. Análisis comparativo de las técnicas utilizadas en un sistema de reconocimiento de hojas de planta. Revista Iberoamericana de Automática e Informática Industrial 14 (1), 104–114.  
DOI: 10.1016/j.riai.2016.09.005

Delgado, A., Corrales, J., Mezouar, Y., Lequievre, L., Jara, C., Torres, F., 2017. Tactile control based on gaussian images and its application in bi-manual manipulation of deformable objects. Robotics and Autonomous Systems 94, 148–161.  
DOI: 10.1016/j.robot.2017.04.017

Glorot, X., Bordes, A., Bengio, Y., 11–13 Apr 2011. Deep sparse rectifier neural networks. In: Gordon, G., Dunson, D., Dudík, M. (Eds.), Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. Vol. 15 of Proceedings of Machine Learning Research. PMLR, Fort Lauderdale, FL, USA, pp. 315–323.  
URL: <http://proceedings.mlr.press/v15/glorot11a.html>

Guo, D., Kong, T., Sun, F., Liu, H., May 2016. Object discovery and grasp detection with a shared convolutional neural network. In: 2016 IEEE International Conference on Robotics and Automation (ICRA). pp. 2038–2043.  
DOI: 10.1109/ICRA.2016.7487351

Hastie, T., Tibshirani, R., Friedman, J., 2009. The elements of statistical learning: data mining, inference and prediction. Springer-Verlag New York.  
DOI: 10.1007/978-0-387-84858-7

Homberg, B. S., Katschmann, R. K., Dogar, M. R., Rus, D., Sep. 2015. Haptic identification of objects using a modular soft robotic gripper. In: 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). pp. 1698–1705.  
DOI: 10.1109/IR0S.2015.7353596

Homberg, B. S., Katschmann, R. K., Dogar, M. R., Rus, D., Mar 2019. Robust proprioceptive grasping with a soft robot hand. Autonomous Robots 43 (3), 681–696.  
URL: <https://doi.org/10.1007/s10514-018-9754-1>  
DOI: 10.1007/s10514-018-9754-1

Ioffe, S., Szegedy, C., 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: 32nd International Conference on International Conference on Machine Learning. Vol. 15. JMLR, pp. 448–456.

Kang, L., Ye, P., Li, Y., Doermann, D., June 2014. Convolutional neural networks for no-reference image quality assessment. In: 2014 IEEE Conference on Computer Vision and Pattern Recognition. pp. 1733–1740.  
DOI: 10.1109/CVPR.2014.224

Kohavi, R., 1995. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2. IJCAI'95. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, pp. 1137–1143.  
URL: <http://dl.acm.org/citation.cfm?id=1643031.1643047>

Krizhevsky, A., Sutskever, I., Hinton, G. E., 2012. Imagenet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1. NIPS'12. Curran Associates Inc., USA, pp. 1097–1105.  
URL: <http://dl.acm.org/citation.cfm?id=2999134.2999257>

Liu, H., Wu, Y., Sun, F., Guo, D., 2017a. Recent progress on tactile object recognition. International Journal of Advanced Robotic Systems 14 (4), 1729881417717056.  
URL: <https://doi.org/10.1177/1729881417717056>  
DOI: 10.1177/1729881417717056

Liu, H., Yu, Y., Sun, F., Gu, J., 2017b. Visual-tactile fusion for object recognition. IEEE Transactions on Automation Science and Engineering 14 (2), 996–1008.  
DOI: 10.1109/TASE.2016.2549552

Montano, A., Suárez, R., 2013. Object shape reconstruction based on the object manipulation. 2013 16th International Conference on Advanced Robotics, ICAR 2013, 1–6.  
DOI: 10.1109/ICAR.2013.6766571

Nasrabadi, N. M., 2007. Pattern recognition and machine learning. Journal of Electronic Imaging 16 (4).  
URL: <https://doi.org/10.1117/1.2819119>

- DOI: 10.1117/1.2819119  
National Instruments, 2018. The LabView website. <http://www.ni.com/en-us/shop/labview.html>, online; accedido 05 Noviembre 2018.
- Navarro, S. E., Gorges, N., Wörn, H., Schill, J., Asfour, T., Dillmann, R., March 2012. Haptic object recognition for multi-fingered robot hands. In: 2012 IEEE Haptics Symposium (HAPTICS). pp. 497–502.  
DOI: 10.1109/HAPTIC.2012.6183837
- Pascanu, R., Montufar, G., Bengio, Y., April 2014. On the number of inference regions of deep feed forward networks with piece-wise linear activations. In: International Conference on Learning Representations (ICLR).  
URL: <https://arxiv.org/abs/1312.6098>
- Pezementi, Z., Plaku, E., Reyda, C., Hager, G. D., June 2011. Tactile-object recognition from appearance information. IEEE Transactions on Robotics 27 (3), 473–487.  
DOI: 10.1109/TR0.2011.2125350
- Powers, D. M. W., 2011. Evaluation: From precision, recall and f-measure to ROC, informedness, markedness & correlation. Journal of Machine Learning Technologies 2 (1), 37–63.
- Quigley, M., Conley, K., Gerkey, B., Faust, J., Foote, T., Leibs, J., Wheeler, R., Ng, A., May 2009. Ros: an open-source robot operating system. In: IEEE International Conference on Robotics and Automation (ICRA): Workshop on Open Source Software.  
URL: <http://www.willowgarage.com/papers/ros-open-source-robot-operating-system>
- Reinecke, J., Dietrich, A., Schmidt, F., Chalon, M., May 2014. Experimental comparison of slip detection strategies by tactile sensing with the biotac on the dlr hand arm system. In: IEEE International Conference on Robotics and Automation (ICRA). pp. 2742–2748.  
DOI: 10.1109/ICRA.2014.6907252
- Rispaal, S., Rana, A. K., Duchaine, V., 2017. Texture roughness estimation using dynamic tactile sensing. 2017 3rd International Conference on Control, Automation and Robotics, ICCAR 2017, 555–562.  
DOI: 10.1109/ICCAR.2017.7942759
- Sanchez, J., Corrales, J.-A., Bouzgarrou, B.-C., Mezouar, Y., 2018. Robotic manipulation and sensing of deformable objects in domestic and industrial applications: a survey. The International Journal of Robotics Research 37 (7), 688–716.  
DOI: 10.1177/0278364918779698
- Schmitz, A., Bansho, Y., Noda, K., Iwata, H., Ogata, T., Sugano, S., Nov 2014. Tactile object recognition using deep learning and dropout. In: 2014 IEEE-RAS International Conference on Humanoid Robots. pp. 1044–1050.  
DOI: 10.1109/HUMANOIDS.2014.7041493
- Schneider, A., Sturm, J., Stachniss, C., Reisert, M., Burkhardt, H., Burgard, W., Oct 2009. Object identification with tactile sensors using bag-of-features. In: IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). pp. 243–248.  
DOI: 10.1109/IROS.2009.5354648
- Shalabi, L., Shaaban, Z., Kasasbeh, B., David, M., 2006. Data mining: A pre-processing engine. Journal of Computer Science 2 (9), 735–739.  
DOI: 10.3844/jcssp.2006.735.739
- Sinapov, J., Bergquist, T., Schenck, C., Ohiri, U., Griffith, S., Stoytchev, A., 2011. Interactive object recognition using proprioceptive and auditory feedback. The International Journal of Robotics Research 30 (10), 1250–1262.  
URL: <https://doi.org/10.1177/0278364911408368>  
DOI: 10.1177/0278364911408368
- Spiers, A. J., Liarokapis, M. V., Calli, B., Dollar, A. M., apr 2016. Single-Grasp Object Classification and Feature Extraction with Simple Robot Hands and Tactile Sensors. IEEE Transactions on Haptics 9 (2), 207–220.  
URL: <http://ieeexplore.ieee.org/document/7390277/>  
DOI: 10.1109/TOH.2016.2521378
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014. Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research 15, 1929–1958.  
URL: <http://jmlr.org/papers/v15/srivastava14a.html>
- Tekscan, 2018. The Tekscan website. <https://www.tekscan.com>, online; accedido 05 Noviembre 2018.
- Velasco-Sanchez, 2018. Base de datos de agarres con Allegro y Tekscan. [https://github.com/EPVelasco/Descriptores\\_de\\_agarres](https://github.com/EPVelasco/Descriptores_de_agarres), online; accedido 05 Noviembre 2018.
- Velasco-Sanchez, E., Zapata-Impata, B. S., Gil, P., Torres, F., 2018. Reconocimiento de objetos agarrados con sensorizado híbrido propioceptivo-táctil. In: XXXIX Jornadas de Automática. CEA-IFAC, pp. 224–232.  
URL: <https://www.eweb.unex.es/eweb/ja2018/actas.html>
- Vásquez, A., Perdereau, V., 2017. Proprioceptive shape signatures for object manipulation and recognition purposes in a robotic hand. Robotics and Autonomous Systems 98, 135 – 146.  
URL: <http://www.sciencedirect.com/science/article/pii/S092188901630700X>  
DOI: <https://doi.org/10.1016/j.robot.2017.06.001>
- Zapata-Impata, B. S., Gil, P., Torres, F., 2018. Non-matrix tactile sensors: How can be exploited their local connectivity for predicting grasp stability? In: IEEE/RSJ International Conference on Intelligent Robots And Systems (IROS). Workshop on Robotac: New Progress in Tactile Perception And Learning in Robotics. IEEE.  
URL: <https://arxiv.org/abs/1809.05551>
- Zapata-impata, B. S., Gil, P., Torres, F., 2019. Learning Spatio Temporal Tactile Features with a ConvLSTM for the Direction Of Slip Detection. Sensors 19 (3), 1–16.  
URL: <https://www.mdpi.com/1424-8220/19/3/523>  
DOI: 10.3390/s19030523