

## RECONOCIMIENTO DE OBJETOS AGARRADOS CON SENSORIZADO HIBRIDO PROPIOCEPTIVO-TÁCTIL

E. Velasco-Sánchez<sup>1</sup>, B.S. Zapata-Impata<sup>1,2</sup>, P. Gil<sup>1,2</sup>

<sup>1</sup>Física, Ingeniería de Sistemas y Teoría de la Señal, Universidad de Alicante, 03690, Alicante, Spain

<sup>2</sup>Instituto Universitario de Investigación Informática, Universidad de Alicante, 03690, Alicante, Spain  
epvelasco1912@gmail.com, {brayan.impata, pablo.gil}@ua.es

### Resumen

*Este trabajo se presenta una aproximación híbrida propioceptiva-táctil para reconocer objetos agarrados. La información propioceptiva de una mano robótica es usada para estimar la geometría de contacto y así, distinguir la forma de cada uno de los objetos que están siendo agarrados. La geometría de contacto viene determinada por los datos articulares de la mano robótica cuando ésta lleva a cabo un agarre en configuración de cierre sobre la superficie del objeto. Además, la información táctil permite determinar propiedades de rigidez y flexibilidad del objeto agarrado, mejorando el proceso de reconocimiento cuando la geometría de contacto y por lo tanto, la forma de los objetos es similar. El método propuesto emplea técnicas de clasificación de aprendizaje supervisado para combinar los datos de ambos tipos de sensores e identificar el tipo de objeto con un porcentaje de acierto medio del 95,5% con métrica 'accuracy' y 95.3% con F1(F-score) aun en presencia de incertidumbre de medida y ambigüedad. Estas ratios de acierto se han alcanzado experimentando con 7 objetos domésticos y llevando a cabo más de 3000 agarres.*

**Palabras clave:** Agarre de objetos, manipulación dextrógrira, reconocimiento de objetos, aprendizaje propioceptivo y táctil, reconocimiento propioceptivo y táctil

### 1 INTRODUCCION

Tradicionalmente, el reconocimiento de objetos en sistemas de manipulación robótica se lleva a cabo con información procedente de sensores visuales, [10,17,18]. En estos casos, el objeto es identificado antes de ser agarrado y el conocimiento de la geometría del objeto suele ser empleado para determinar una configuración de agarre (posición y orientación) de unas pinzas o mano robótica. En otras ocasiones, es posible llevar a cabo agarres robóticos sin necesidad de reconocer visualmente el objeto, únicamente en base a la estimación algorítmica de puntos de agarre sobre la superficie del objeto a priori desconocido [25].

Otras veces, no se dispone de sensores visuales o la información visual es insuficiente para reconocer el objeto, pero si se conoce su localización espacial en la escena. En estas situaciones, es posible llevar a cabo un agarre con configuración en cierre ('*clousure grasping*') que es un agarre intuitivo y simple de ejecutar por una mano robótica. No obstante, este tipo de agarre genera incertidumbre y puede causar cierta ambigüedad [2]. Es decir, se puede dar que, para dos objetos geoméricamente distintos, la mano adopte similar configuración de agarre; también, que un mismo objeto, en instantes de tiempo distintos, adopte poses distintas produciéndose agarres distintos. Esto implica que, si se quiere llevar a cabo un reconocimiento del objeto una vez agarrado, se requiere un sistema robusto que permita soliviantar tanto la incertidumbre de medida como la ambigüedad de configuración del agarre. Para ello, en este trabajo se propone una aproximación de sensorizado híbrida propioceptiva-táctil para reconocer objetos agarrados en configuración de cierre, que permita determinar geometría del objeto agarrado.

En el estado de la técnica, el sensorizado propioceptivo sin combinarse con táctil, se ha usado, habitualmente, tanto para reconocimiento de la clase de objeto que se está agarrando, como de la acción que se está llevando a cabo con la mano robótica. Y en ambos casos, hay dos tipos de aproximaciones, las basadas en descriptores ángulo/par como en [22] donde Vasquez y Perdereau propusieron una firma propioceptiva para reconocer la forma de 5 objetos distintos (cono, toroide, esfera, cilindro e hiperboloide) y aquellas que emplean técnicas de aprendizaje máquina. Por ejemplo, Homberg et al. en [6, 7] desarrollaron una mano robótica flexible que usan para extraer información propioceptiva del agarre de objetos, y luego empleaban un clasificador de los  $k$  vecinos más próximos ('*k-NN: k-Nearest Neighbors*'), basado en distancia Euclídea, entre posiciones articulares para identificar el objeto agarrado. Bergquist [1] et al. extrajeron secuencias temporales de posiciones articulares de una mano Barret de 3 dedos y luego emplearon técnicas para reducir la alta dimensionalidad de las características extraídas con mapas auto organizados ('*SOM: Self-Organizing Maps*') y de este modo poder emplear

como técnica de clasificación un k-NN para reconocer así, acciones sobre el objeto agarrado como levantar, sacudir, soltar, aplastar o empujar. Más recientemente, en [21] se amplió el trabajo anterior combinando datos propioceptivos con secuencias de audio que registraba el sonido producido durante la interacción entre mano robótica y objeto durante la acción de agarre.

También, es habitual encontrar métodos de reconocimiento de objetos basados sólo en información táctil [9]. Generalmente, los métodos de reconocimiento táctil consisten en generar secuencias temporales de datos táctiles previamente planificadas a base de ejecutar múltiples toques y/o agarres sobre el objeto y así generar mapas de apariencia de la superficie del objeto que luego es comparada mediante métodos estadísticos de probabilidad bayesiana como en [14] o empleando la técnica de diccionario de palabras (*'Bag-of-Word'*) como en [19] para aprender características a partir de las observaciones táctiles y así, luego poder clasificar los objetos por comparación. En otras ocasiones, es frecuente emplear el sensorizado táctil para determinar la calidad del agarre, es decir si es robusto (no hay deslizamiento del objeto) como se hizo en [12, 16] y en [5] con aprendizaje basado en redes neuronales convolucionales (*'CNN: Convolutional Neural Networks'*) o si el agarre deforma o daña el objeto [3].

El trabajo que aquí se describe no tiene como finalidad centrarse en la estimación de la calidad del agarre sino en presentar un método para reconocimiento de objetos, basado en aprendizaje supervisado, que como novedad combina información propioceptiva y táctil de agarres estáticos (y no secuencias temporales dinámicas) de objetos en configuración de cierre, adoptada de modo arbitraria. Además, el método analiza y compara los clasificadores más habituales usados en reconocimiento propioceptivo y táctil. El método es probado con diversos objetos domésticos de manera exitosa con tasas de acierto del 95.47%.

El artículo se organiza de la siguiente manera. En la sección 2 se presenta la arquitectura de la mano robótica y de los sensores empleados para obtener datos propioceptivo-táctiles. En la sección 3 se describen brevemente los fundamentos de las técnicas de aprendizaje clasificación que se han analizado y las métricas de evaluación empleadas para determinar la robustez y tasa de éxito en el proceso de reconocimiento. La sección 4, se detalla la metodología experimental para ejecutar los agarres y crear una base de datos de agarre de objetos. Finalmente, en la sección 5 se analizan y discuten los resultados obtenidos, y en la sección 6 se muestran las conclusiones de este trabajo.

## 2 SISTEMA ROBOTICO DE MANIPULACION

### 2.1 MANO ROBOTICA MULTIDEDO

Se ha usado una mano robótica multidedo Allegro Hand [23], la cual consta de 4 dedos que poseen 4 articulaciones cada uno, controladas por un motor de corriente continua alimentado con tensiones entre 7.0 y 8.1V a 5A, lo que le permite sostener hasta 1,5 kg. Esta mano usa el protocolo de comunicación CAN (*Controller Area Network*) con una frecuencia de 333Hz. Una de las ventajas de la Allegro Hand es su integración en ROS (*Robot Operating System*).



Figura 1: Allegro Hand del laboratorio AUROVA de la Universidad de Alicante

Para obtener los datos propioceptivos se debe establecer el enlace de comunicación entre ROS y la mano robótica Allegro Hand. La Figura 2 muestra el flujo de datos y comandos de la mano, dónde `/keyboard_0` envía poses de agarre a la mano por teclado y `/jointState2tf_0` devuelve la posición angular de las articulaciones de cada dedo.

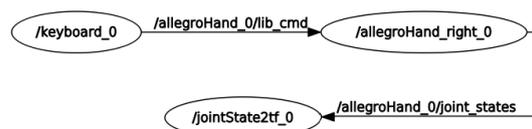


Figura 2. Nodos involucrados para el manejo de la mano robótica Allegro Hand.

### 2.2 SENSOR TÁCTIL

Los sensores Tekscan [24], mostrados en la figura 3, constan de 18 celdas resistivas, cada una de ellas sensibles a la presión/fuerza. Estas matrices se distribuyen de tal manera que se pueden colocar en la superficie de agarre de una mano humana. Las celdas que componen este sensor están distribuidas de modo que se evita el contacto entre ellas y es posible ajustarlas para que no puedan moverse libremente y causen medidas erróneas en agarres.

Para poder tener los datos de presión del sensor Tekscan se ha empleado un nodo ROS que reciba los datos por TCP (*'Transmission Control Protocol'*) que son enviados por un ordenador donde está

conectado el sensor, para luego publicarlos en el entorno ROS mediante los topics necesarios.

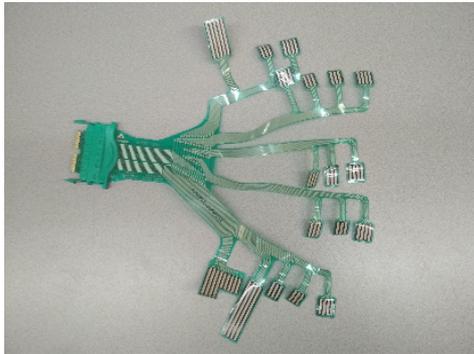


Figura 3: Sensor táctil 'Tekscan'

La Figura 4 muestra la interacción de estos nodos, donde /teckscan\_TCP recibe datos de presión del controlador de Teckscan de todas las celdas y /teckscan\_node devuelve, únicamente, los datos de presión de las celdas de las matrices escogidas /teckscan\_indice de acuerdo a la configuración que se mostrará en la sección 4.

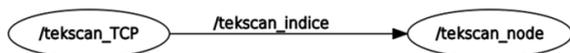


Figura 4: Nodos involucrados para el manejo del sensor Teckscan.

### 3 TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

#### 3.1 METODOS DE CLASIFICACION

El aprendizaje automático o máquina (*machine learning*) contempla el desarrollo de algoritmos para que un ordenador pueda aprender y hacer predicciones de reconocimiento mediante el uso de técnicas de clasificación [13]. La clasificación suele hacerse empleando una metodología supervisada o no supervisada. En la supervisada se obtiene un conjunto de elementos de entrenamiento y se busca identificar de un segundo conjunto de reconocimiento, elementos con similitud con los del entrenamiento. En la no supervisada, no se dispone de conjunto de entrenamiento, y únicamente se realiza la identificación en base a la comparativa con unos parámetros que describen cada elemento del conjunto de reconocimiento.

Existen varios tipos de clasificadores para aprendizaje supervisado que facilitan el aprendizaje automático entre ellos arboles de decisión, clasificación bayesiana, regresión línea, regresión logística, máquina de soporte vectorial (*SVM: Support Vector Machines*), etc. Los clasificadores que se han escogido y usado en este trabajo son: regresión lineal [12], árbol de decisión [4] y k vecinos cercanos [8]. La elección se ha

fundamentado en que por la distribución y cantidad de datos que describen un agarre, no se requiere clasificadores excesivamente complejos, para evitar el sobreajuste (*“overfitting”*) del proceso de reconocimiento. La descripción de los datos del agarre será presentada en la sección 4.

#### 3.2 METRICAS DE EVALUACION

La manera de evaluar los clasificadores es mediante métricas [15], las cuales definen el rendimiento de cada uno de ellos. En este caso se calcularon las tasas de éxito empleando las métricas de *Accuracy* (ecuación 1), *Precision* (ecuación 2), *Recall* (ecuación 3) y *F1 score* (ecuación 4) en cada experimento, para luego comparar cada técnica empleada y determinar el clasificador más adecuado para el problema de reconocimiento propioceptivo-táctil.

$$accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$precision = \frac{TP}{TP + FP} \quad (2)$$

$$recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1\ score = 2 * \frac{precision * recall}{precision + recall} \quad (4)$$

Donde los valores de *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) y *False Negative* (FN) se representan mediante la figura 5.

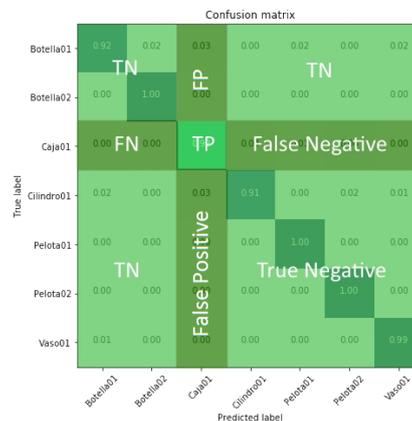


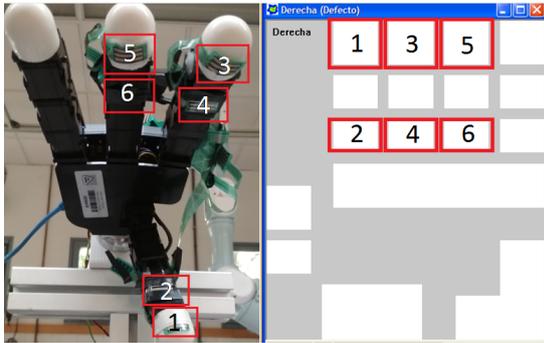
Figura 5: Valores de TP, TN, FP y FN sobre una matriz de confusión con los objetos empleados en el reconocimiento

### 4 METODOLOGIA

#### 4.1 ESTRATEGIAS DE AGARRE

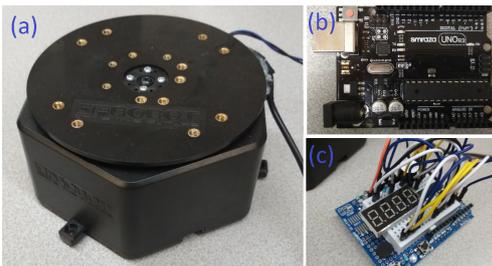
Para generar el descriptor de agarre conformado por los datos propioceptivos y del sensor táctil, se ha instalado el sensor Tekscan sobre la mano Allegro Hand. Debido a que el sensor Tekscan está diseñado específicamente para ser colocada en una mano

humana, existen inconvenientes al querer adaptarlo a la mano Allegro Hand, de mayor tamaño y con distinta morfología. Como se muestra en la figura 6, sólo se logran ubicar, en la mano, 6 de las 18 celdas que dispone este sensor. Para el presente caso se utilizó los sensores de los dedos índice, corazón y meñique en los dedos pulgar, índice y corazón de la Allegro Hand respectivamente.



**Figura 6.** Ubicación de los array Sensels del sensor Tekscan en la mano Allegro Hand.

Ya que se van a llevar a cabo diferentes agarres en distintos ángulos y posiciones del objeto con respecto a la mano robótica, se ha optado por tener una base mecánica (Figura 7) cuyo movimiento rotacional ha sido automatizado. De este modo, es posible cambiar la orientación del objeto, sin necesidad de modificar la orientación de la mano robótica y sensor de presión que se encuentran fijos durante la experimentación. La base giratoria está compuesta por un servomotor, una plataforma giratoria de plástico, un Arduino UNO como parte de control de giro del servomotor y 3 displays de 7 segmentos para poder visualizar el ángulo de giro de la base.



**Figura 7** (a) Base conformada por un servomotor y una plataforma giratoria. (b) Placa Arduino UNO genérica (smrza UNOR3). (c) Displays de 7 segmentos.

#### 4.2 OBTENCION DE INFORMACION TACTIL Y PROPRIOCEPTIVA

Para obtener los datos propioceptivos y táctiles de cada agarre se ha creado el nodo `/allegro_cliente` descrito en la figura 8, el cual obtiene los datos de los nodos ROS de las figuras 2 y 4, ángulos de las articulaciones y presiones de las celdas táctiles.

La información del descriptor que define un agarre está constituida por los datos de la mano Allegro

Hand que constan de 16 posiciones articulares y los 84 datos entregados por las 6 celdas del sensor táctil Tekscan. La disposición de vector del descriptor se muestra en la ecuación (5)



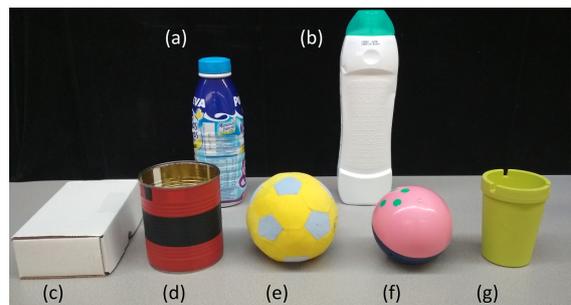
**Figura 8** Arquitectura de la interacción de todos los nodos en ROS (nodos de Allegro Hand, nodos de Tekscan y nodo suscrito a ambos nodos)

$$v_{desc} = \left\{ \overbrace{[\theta_{11}, \theta_{12}, \theta_{13}, \theta_{14}]}^{f_1} \dots \overbrace{[\theta_{i1}, \theta_{i1}, \theta_{i3}, \theta_{i4}]}^{f_i}, t_1, t_2, \dots, t_{84} \right\} \quad (5)$$

donde  $\theta_{iN}$  son los ángulos de las posiciones articulares por cada uno de los dedos de la mano Allegro, siendo  $i$  el identificador del dedo  $f$  y  $N$  el identificador de la articulación comenzado por la palma. Y donde  $t_n \in [0, 255]$  son los datos táctiles del sensor Tekscan, siendo  $t_1$  a  $t_{16}$  para la celda 1,  $t_{17}$  a  $t_{29}$  para la celda 2 (Figura 6), y así sucesivamente; teniendo en cuenta que las celdas 1, 3 y 5 tienen 16 elementos de presión y las celdas 2, 4 y 6 tienen 12.

#### 4.3 BASE DE DATOS DE AGARRES

Nuestra base de datos consta de 7 objetos domésticos (Figura 9) con distintas formas, tamaños y texturas que nos permitirá recolectar datos propioceptivos y táctiles y poder así generar un dataset de agarres de todos ellos.



**Figura 9.** Objetos domésticos de nuestra base de datos. (a) Botella01 (b) Botella02. (c) Caja01. (d) Cilindro01 (e) Pelota01 (f) Pelota02 (g) Vaso01

Además, en la Tabla 1 se puede apreciar la distribución de la base datos atendiendo al número de agarres por objeto y a la tipología del agarre, de acuerdo a diferentes ángulos y ejes de referencia. El número de agarres por clase de objeto tiende a ser próximo, con poca variación, con el objetivo de tener un conjunto de clases lo más balanceada posible. Todo esto con la finalidad de no tener un sistema viciado que pueda producir un sobreajuste (“overfitting”) en la clasificación durante la etapa de reconocimiento.

Objetos	Ejes y ángulos								Cantidad de Agarres
	X				Y	Z			
	0°	30°	45°	90°	0°	0°	45°	90°	
Botella01	67					85	87	175	414
Botella02	64		136	67		69		67	403
Caja01	50	52	51	93	40	49	50	64	449
Cilindro01	141		69			192			402
Pelota01						404			404
Pelota02						384			384
Vaso01	111		104	104	91	198			608
<b>Total</b>									<b>3064</b>

Tabla 1. Distribución de agarres con diferentes ejes y ángulos de referencia entre la mano robótica y el objeto.

Por un lado, en la figura 10 se puede observar algunos ejemplos de los agarres generados para el objeto Caja01 (Tabla 1) mediante el movimiento de la base giratoria en 4 ángulos distintos. Notar que la mano está fija y no modifica su orientación, es el objeto quien modifica la orientación y obliga a la mano a modificar el agarre.

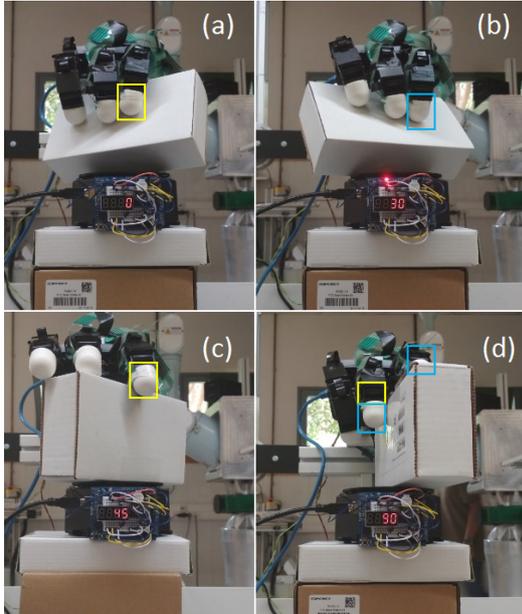


Figura 10 Agarres del Objeto Caja01 posicionado a 0, 30, 45, 90 grados con respecto a la mano Allegro Hand.

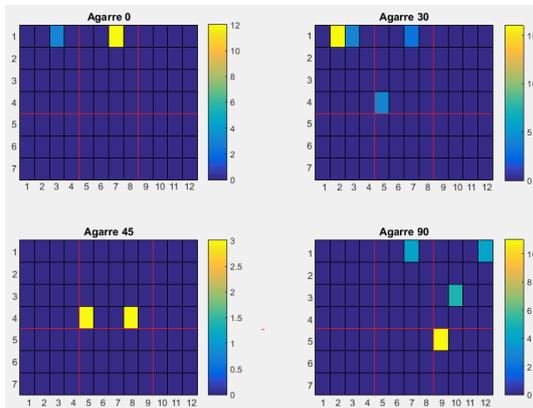


Figura 11 Datos del sensor táctil en los agarres del objeto Caja01 posicionado a 0, 30, 45, 90 grados con respecto a la mano Allegro Hand.

Por otro lado, en la figura 11 se muestra la presión que sufren las 6 celdas (Figura 6) ocupadas del sensor táctil Tekscan en el momento de ejecutar cada uno de los agarres mostrados en la figura 10.

## 5 EXPERIMENTACION Y RESULTADOS

Mediante la implementación de las técnicas de clasificación comentadas en el apartado 3.1, y a partir de la base de datos de la Tabla 1, se llevaron a cabo tres pruebas experimentales. Para todas ellas, se ha dividido la base de datos de agarres en dos grupos, el primer grupo destinado a entrenamiento (80% de las muestras) de los clasificadores empleados, y el segundo grupo al proceso de reconocimiento (20% de las muestras).

En el primero de los experimentos se ha empleado únicamente reconocimiento propioceptivo, es decir los datos del conjunto de entrenamiento y test sólo están compuestos por los datos de las posiciones articulares de la mano Allegro Hand. El segundo grupo contiene, únicamente, los datos de presión del sensor Tekscan. En el tercero se realizaron pruebas de clasificación con el descriptor mostrado en la ecuación 5, con la unión de posiciones y presiones. Los datos de todos y cada uno de los descriptores empleados en las pruebas experimentales han sido normalizados mediante *scaling*, también conocida como técnica *min-max* [20], mostrada en la ecuación 6, de esta manera se consigue que todos los valores estén dentro del rango unidad.

$$M_{norm} = \frac{M - M_{min}}{M_{max} - M_{min}} \quad (6)$$

### 5.1 RECONOCIMIENTO PROPIOCETIVO

Para el caso del entrenamiento sólo con posiciones articulares, se tomaron únicamente los 16 primeros datos de cada descriptor, es decir se toman todos los valores de  $\theta_{iN}$  de la ecuación 5. A continuación, se muestran los resultados de aprendizaje automático alcanzados con cada una de las técnicas de clasificación empleadas, donde se detallan las tasas de éxito de cada métrica de medición.

	Accuracy	Precision	Recall	F1
Regresión Lineal	0.794±0.023	0.799±0.024	0.790±0.020	0.788±0.024
Árbol de decisión	0.898±0.012	0.897±0.012	0.899±0.011	0.897±0.011
K-NN (3)	<b>0.928±0.012</b>	<b>0.924±0.012</b>	<b>0.926±0.012</b>	<b>0.924±0.012</b>

Tabla 2. Resultados promedio por métrica y clasificador usando posiciones articulares en los descriptores.

Como se observa en la Tabla 2, la técnica de clasificación k-NN, empleada con una configuración de 3 vecinos, posee un ratio de éxito en torno a 0.03

y 0.13 mejor que las técnicas de árbol de decisión y regresión lineal respectivamente; esto independientemente de la métrica empleada para evaluar, siendo estas puntuaciones una mejora notable en el campo del aprendizaje automático.

En la Figura 12 se puede apreciar con más detalle el comportamiento del clasificador que mejores resultados proporciona, k-NN, pero mostrando el proceso de reconocimiento por cada clase de objeto. En este caso, se observa que los objetos caja01 y cilindro01 son los objetos donde más falla el proceso de reconocimiento, teniendo una tasa para el objeto caja01 de TP de 0.77, FP de 0.09 y de FN de 0.23, y para el objeto cilindro01 de TP de 0.81, FP de 0.07 y de FN de 0.18. Aunque los valores de FP en ambos casos puedan ser similares a los de otros objetos con TP mucho más elevada, como pelota01 que tiene un TP de 1 y un FP de 0.08, éste destaca por tener un FN de 0. Son, por lo tanto, los valores de FN los que más influyen en los resultados medidos con esas métricas.

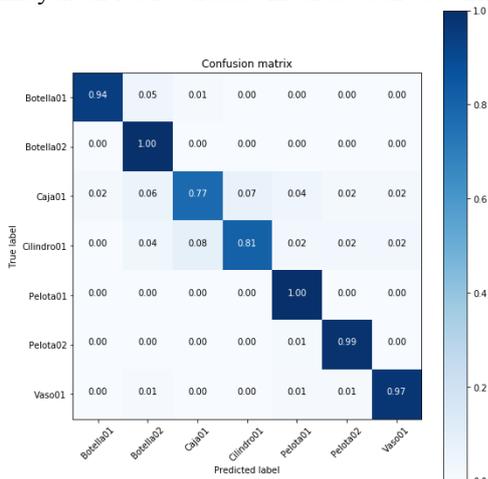


Figura 12 Matriz de confusión del clasificador de K-NN con 3 vecinos únicamente con descriptores de posiciones articulares.

## 5.2 RECONOCIMIENTO TACTIL

Para el caso del entrenamiento sólo con datos táctiles, se tomaron únicamente los 84 últimos datos de cada descriptor, es decir se toman todos los valores de  $t_n$  de la ecuación 5. Así, procediendo de igual manera a como se hizo en la sección anterior, la técnica que mejores resultados obtiene es el árbol de decisión. Aunque como se observa en la tabla 3 los ratios obtenidos son bajos (por debajo de 0.75) y por lo tanto es posible concluir que no son suficientes para reconocer objetos si sólo se emplean datos de presión en agarres. Por lo cual queda justificada que este tipo de descriptor no es el adecuado, si los agarres se llevan a cabo en una metodología estática, donde los agarres no siguen una secuencia temporal.

	Accuracy	Precision	Recall	F1
Regresión Lineal	0.564±0.014	0.619±0.016	0.562±0.012	0.545±0.016
Árbol de decisión	<b>0.648±0.016</b>	<b>0.686±0.022</b>	<b>0.650±0.009</b>	<b>0.641±0.016</b>
K-NN (3)	0.458±0.071	0.535±0.046	0.459±0.081	0.451±0.057

Tabla 3. Resultados promedio por métrica y técnica de clasificación experimentada usando datos de presión del sensor Tekscan.

## 5.3 RECONOCIMIENTO PROPIOCETIVO Y TACTIL

En el siguiente experimento se usaron los datos de posiciones articulares y presiones obteniendo un descriptor completo para el entrenamiento de las técnicas de clasificación, con la finalidad de saber si al añadir datos de sensores táctiles se obtiene una mejora en el reconocimiento, y por lo tanto es posible emplear dicha información para ayudar al reconocimiento propioceptivo de la mano robótica.

	Accuracy	Precision	Recall	F1
Regresión Lineal	0.819±0.017	0.816±0.014	0.813±0.015	0.810±0.014
Árbol de decisión	0.895±0.017	0.895±0.019	0.892±0.014	0.893±0.017
K-NN (3)	<b>0.924±0.002</b>	<b>0.923±0.005</b>	<b>0.920±0.002</b>	<b>0.918±0.002</b>

Tabla 4. Resultados promedio por métrica y técnica de clasificación experimentada con los datos completos del descriptor de la ecuación 5.

De nuevo, el modelo K-NN es el que mejores resultados proporciona. Si además, se comparan las tablas 2 y 4 se observa que tenemos un rendimiento similar en los valores medios de todas las métricas, pero la desviación típica se reduce en un orden de magnitud. Así pues es posible afirmar que los valores obtenidos son más estables y robustos quedando justificado el uso de un descriptor híbrido propioceptivo-táctil para el reconocimiento de objetos domésticos.

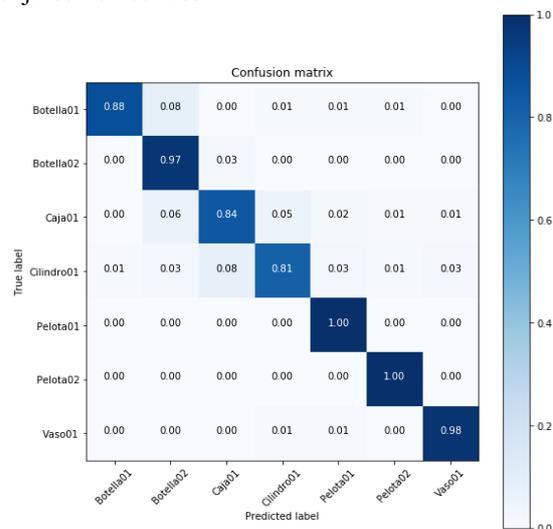


Figura 13 Matriz de confusión del clasificador de K-NN con 3 vecinos y el descriptor propioceptivo-táctil.

Si además, se compara la Figura 12 con la Figura 13, que muestra el reconocimiento por clase de objeto con ambas técnicas, se aprecia que las tasas de acierto de Caja01 mejoran en 0.7, pero empeoran en 0.6 y 0.3 las de los objetos Botella01 y Botella02, respectivamente. Para las demás clases de objetos, las métricas no muestran diferencias significativas; lo que obliga, a buscar un mejor ajuste del clasificador k-NN. Por lo tanto, haciendo una exhaustiva variación de algunos de los parámetros de k-NN, por ejemplo la vecindad y probando con otros valores de k, tales como 1,3,5,7 y 9 (Figura 14), se aprecia que reduciendo el entorno de vecindad a k=1 mejora la clasificación, obteniendo  $0.955\pm 0.010$  tanto de accuracy como de precisión, así como un  $0.952\pm 0.001$  de recall y un  $0.953\pm 0.010$  de F1 (F-score).

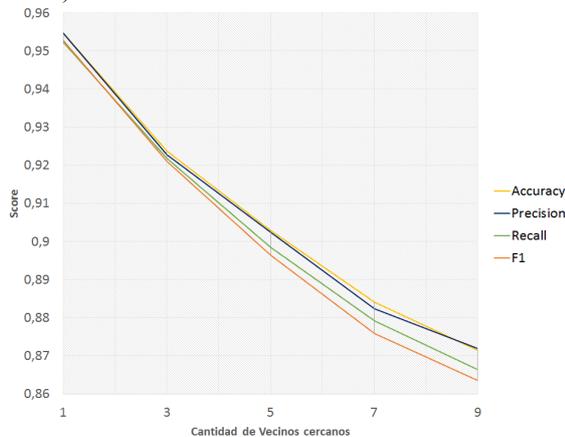


Figura 14 Métricas de puntuación con k-NN variando k.

Obteniendo de nuevo, la matriz de confusión para el reconocimiento por clase de objeto, esta vez con k-NN y vecindad 1, se obtienen los resultados mostrados en la figura 15, donde se consiguen las siguientes mejoras: Botella 01 aumenta un 4%, Botella02 un 3%, Caja01 un 8%, Cilindro01 un 10%, Botella01, Pelota01 y Pelota02 se mantienen y el objeto Vaso01 aumenta en 1%.

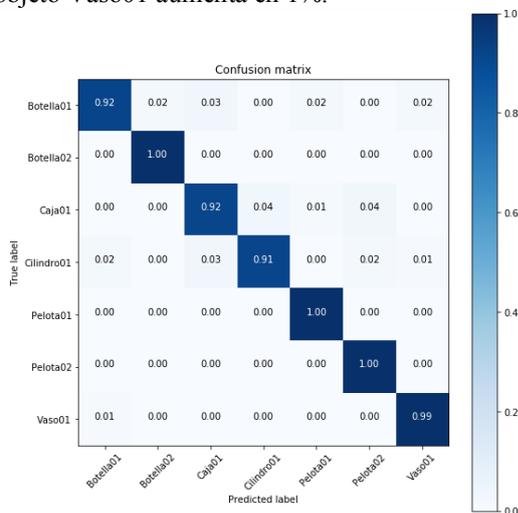


Figura 15 Matriz de confusión del clasificador de K-NN con 1 vecino y el descriptor propioceptivo-táctil.

## 6 CONCLUSIONES

Se ha presentado un método de reconocimiento basado en técnicas supervisadas que emplea información propioceptiva y táctil para reconocer objetos domésticos, alcanzando tasas de éxito del 95.5% con métrica 'accuracy' y 95.3% con F1(F-score) y una desviación típica de los ratios por debajo de 1%. El método presentado se ha probado llevando a cabo más de 3000 agarres de 7 objetos domésticos de geometría distinta, generando así una base de datos propia de agarre de objetos. El tamaño y la variabilidad de esta base de datos son apropiados ya que se ha generado utilizando hasta 8 orientaciones distintas, lo que ayuda a entrenar modelos de aprendizaje automático más generales. Se puede concluir afirmando que una correcta clasificación de objetos de diferentes formas y tamaños por metodología de agarre ('grasping') aconseja hacer uso de un descriptor que combine el uso de datos propioceptivos y táctiles frente a otras aproximaciones donde sólo se emplea una tipología de datos única. En el futuro, se pretende analizar el comportamiento con clasificadores basados en redes neuronales y en probar el método de reconocimiento con agarres de nuevos objetos.

### Agradecimientos

Este trabajo ha sido financiado por el proyecto europeo COMMANDIA (SOE2/P1/F0638) que está cofinanciado por el programa Interreg-V Sudoe y el Fondo Europeo de Desarrollo Regional, así como por el proyecto nacional DPI2015-68087-R.

### English summary

## GRASPED OBJECT RECOGNITION WITH PROPRIOCEPTIVE-TACTILE HYBRID SENSING

### Abstract

This work presents a hybrid proprioceptive-tactile approach to recognize grasped objects. Proprioceptive data of a robotic hand are used to estimate contact geometry and thus, to distinguish the shape of each of the objects that are being grasped. The contact geometry is determined by the joint data of the robotic hand when it carries out a grip in closure grasps configuration on the object surface. In addition, the tactile data allow to robotic hand to determine rigidity and flexibility properties of the grasped object, improving the recognition process when the contact geometry and therefore, the shapes of different objects are similar. The proposed method employs supervised learning classification techniques to combine the data from both types of

sensors and identify the type of object with an average success rate of 95,5% (with accuracy) and 95.3% (with F1 or F-score) even in the presence of measurement with uncertainty and ambiguity of pose. These success ratios have been achieved by experimenting with 7 different objects and performing more than 3000 grasps.

**Keywords:** Object grasping, dextrogyre manipulation, object recognition, proprioceptive and tactile learning, proprioceptive and tactile recognition.

## Referencias

- [1] Bergquist, T., Schenck, C., Ohiri, U., Sinapov, J., Griffith, S., Stoytchev, A., (2009) "Interactive object recognition using proprioceptive feedback", *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)- Workshop on Semantic Perception for Robot Manipulation*, St Louis, USA.
- [2] Dang, H., Allen, P.K., (2014) "Stable grasping under pose uncertainty using tactile feedback," *Autonomous Robots*, 36(4), pp. 309-330.
- [3] Delgado, A., Corrales, J.A., Mezouar, Y., Lequievre, L., Jara, C. Torres, F. (2017) "Tactile control base on gaussian images and its application in bi-manual manipulation of deformable objects", *Robotics and Autonomous systems*, 94, pp. 148-161, doi: 10.1016/j.robot.2017.04.017
- [4] Frías, I., Ortiz, A., Ramos, G., Morales, R., Caballero, Y. (2010) "Clasificadores y multclasificadores con cambio de concepto basados en árboles de decisión, Inteligencia Artificial", *Revista Iberoamericana de Inteligencia Artificial*, 14 (45), pp. 32-43
- [5] Guo, D., Kong, T., Sun, F., Liu, H., (2016) "Object discovery and grasp detection with a shared convolutional neural network", *International Conference on Robotics and Automation (ICRA)*, pp. 2038–2043, doi: 10.1109/ICRA.2016.7487351
- [6] Homberg, B.S., Katschmann, R.K., Dogar, M.R., Rus, D., (2015) "Haptic identification of objects using a modular soft robotic gripper", *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Hamburg, Germany, doi: 10.1109/IROS.2015.7353596
- [7] Homberg, B.S., Katschmann, R.K., Dogar, M.R., Rus, D., (2018) "Robust proprioceptive grasping with a soft robot hand", *Autonomous Robots*, pp.1-19, doi: 0.1007/s10514-018-9754-1
- [8] Lee, Y., (1991) "Handwritten Digit Recognition Using K Nearest-Neighbor, Radial-Basis Function, and Backpropagation Neural Networks," *Neural Computation*, 3(3), pp, 440-449.
- [9] Liu, H., Wu, Y., Sun, F., Guo, D., (2017). "Recent progress son tactile object recognition", *International Journal of Advanced Robotic Systems*, pp. 1-12, doi: 10.1177/1729881417717056
- [10] Mateo, C.M., Gil, P., Torres, F., (2016). "Visual perception for the 3D recognition of geometric pieces in robotic manipulation", *International Journal of Advanced Manufacturing Technology*, 83(9-12), pp.1999-2013, doi: 10.1007/s00170-015-7708-8
- [11] Meier, M., Walck, G., Haschke, R., Ritter, H., (2016). "Distinguishing sliding from slipping during object pushing", *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Daejeon, South Korea, doi: 10.1109/IROS.2016.7759820
- [12] Mena, C., Montecinos, R. (2006). "Comparación de redes neuronales y regresión lineal para estimar productividad de sitio en plantaciones forestales, utilizando geomática", *Bosque* 27(1), pp. 35–43.
- [13] Nasrabadi, N.M., "Pattern Recognition and Machine Learning," *Journal of Electronic Imaging* 16(4). doi: 10.1117/1.2819119
- [14] Pezzementi, Z., Plaku, E., Reyda, C., Hager, G.D., (2011). "Tactile-object recognition from appearance information". *IEEE Transactions on robotics*, 27(3), pp. 473-487, 10.1109/TRO.2011.2125350.
- [15] Powers, David M W (2011). "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation". *Journal of Machine Learning Technologies*. 2 (1): 37–63.
- [16] Reinecke, J., Dietrich, A., Schmidt, F., Chalon, M., (2014). "Experimental comparison of slip detection strategies by tactile sensing with the BioTac R on the DLR hand arm system," *IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2742–2748.

- [17] Rusu, R.B.: (2010), “Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments”, *KI - Künstliche Intelligenz* 24(4), pp. 345–348, doi: 10.1007/s13218-0100059-6
- [18] Salti, S., Tombari, F., Di-Stefano, L. (2014) “SHOT: Unique signatures of Surface and texture description”. *Computer Vision and Image Understanding*, 125, pp. 251-264, doi:10.1016/j.cviu.2014.04.011
- [19] Schneider, A., Sturm, J., Stachniss, C., Reisert, M., Burkhardt, H., Burgard, W., (2009). “Object identification with tactile sensors using bag-of-features”, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, St Louis, USA.
- [20] Shalabi, L.A., Shaaban, Z., Kasasbeh, B., Data Mining: A Preprocessing Engine. *Journal of Computer Science* .2006, vol 2, pp. 735–739.
- [21] 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), pp. 1250-1262, doi: 10.1177/0278364911408368
- [22] Vasquez, A., Perdereau, V., (2017). “Proprioceptive shape signatures for object manipulation and recognition purposes in robotic hand”, *Robotics and Autonomous Systems*, 98, pp. 135-146, doi: 10.1016/j.robot.2017.06.001
- [23] Wonik Robotics. Wiki Allegro Hand. Accedido el 16-07-2018:  
<http://wiki.wonikrobotics.com/AllegroHandWiki/>
- [24] Tekscan Inc. Accedido el 16-07-2018:  
<https://www.tekscan.com/>
- [25] Zapata-Impata, B.S., Gil, P., Pomares, J., Torres, F., (2017) “Using Geometry to Detect Grasping Points on 3D Unknown PointCloud”, *14th International Conference on Informatics in Control, Automation and Robotics (ICINCO)*,2, pp.154-161, doi: 10.5220/00064707015401



© 2018 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 3.0 license (<https://creativecommons.org/licenses/by-nc/3.0>).