Jornadas Nacionales de Robótica
Spanish Robotics Conference
13-14 Junio 2019 http://jnr2019.ua.es

Predicción de la Estabilidad en Tareas de Agarre Robótico con Información Táctil

Brayan S. Zapata-Impata[a], Pablo Gil[a,b,*], Fernando Torres[a,b]

[a] *Departamento de Física, Ingeniería de Sistemas y Teoría de la Señal, Universidad de Alicante, Campus de San Vicente del Raspeig, Alicante, España*
[b] *Instituto Universitario de Investigación Informática, Universidad de Alicante, Campus de San Vicente del Raspeig, Alicante, España*

Resumen

En tareas de manipulación robótica es de especial interés detectar si un agarre es estable o por el contrario, el objeto agarrado se desliza entre los dedos debido a un contacto inadecuado. Con frecuencia, la inestabilidad en el agarre puede ser como consecuencia de una mala pose de la mano o pinza robótica durante su ejecución y/o una presión de contacto insuficiente a la hora de ejercer la tarea. El empleo de información táctil y la representación de ésta es vital para llevar a cabo la predicción de estabilidad en el agarre. En este trabajo, se presentan y comparan distintas metodologías para representar la información táctil, así como los métodos de aprendizaje más adecuados en función de la representación táctil escogida.*Copyright © CEA.*

Palabras Clave:
Manipuladores robóticos, percepción táctil, agarre robótico, manipulación inteligente, estabilidad en el agarre, aprendizaje, clasificación

1. Introducción

Los sensores táctiles se usan generalmente para aplicaciones robóticas de agarre y manipulación de objetos en las que se requiere disponer de sentido del tacto que emule la capacidad táctil de los humanos. Los sensores táctiles suelen instalarse en los dedos y/o palma de manos y pinzas robóticas para ayudar a los robots a comprender el entorno que los rodea. Kappassov et al. (2015) llevaron a cabo una revisión del estado de las aplicaciones de manipulación y agarre robótico en las que se hace necesario el sentido del tacto. Éstas se suelen emplear, principalmente, para detectar propiedades de objetos que se están agarrando, así como para determinar la postura y la configuración del objeto durante la ejecución de tareas de agarre o manipulación. En esta línea, Luo et al. (2017) presentaron una revisión de métodos para el reconocimiento de propiedades de objetos usando datos táctiles, centrándose en aquellos que están orientados a reconocimiento de forma del objeto, del tipo de material de fabricación y de la obtención de la posición del objeto. Los sensores táctiles pueden proporcionar información de presión y fuerza en los puntos de contacto con la superficie del objeto y estos a su vez pueden ser empleados para determinar propiedades de éste como el tipo de textura (Kaboli et al., 2015), dureza (Spiers et al., 2016), geometría (Luo et al., 2015), entre otras tantas. En los últimos años, ha proliferado el uso de sensores táctiles en aplicaciones robóticas (Yi et al., 2018), y estos a su vez están basados en una gran variedad de tecnologías distintas, como son, lo sensores: piezo-resistivos (Stassi et al., 2014), capacitivos (Tiwana et al., 2011), ópticos (Johnson et al., 2011), ultrasónicos, barométricos (Su et al., 2012), basado en materiales piezo-eléctricos, basados en transducción magnética (Alfadhel y Kosel, 2015), etc. En general, las lecturas de un sensor se pueden representar como una señal, es decir como un conjunto de medidas discretas extraídas de células táctiles, organizadas en un vector de valores de presión o como imágenes táctiles como se describe por Delgado et al. (2017) y Zapata-Impata et al. (2018). Una imagen táctil es una matriz de datos en la que cada píxel representa un valor de presión de una célula táctil en un instante de tiempo dado. Generalmente, si el sensor táctil proporciona un único valor, por ejemplo un valor de presión promedio, la mejor representación es una señal que muestre la variación de ese valor en cada momento. Sin embargo, si el sensor consta de un conjunto de celdas, y cada una de ellas proporciona un valor, entonces la mejor representación es una imagen táctil. En cualquier caso, tanto si se usan señales como imágenes táctiles, es necesario extraer características estadísticas que representen los cambios temporales en la presión durante las lecturas del sensor. Y después, las características extraídas pueden ser procesadas aplicando técnicas tradicionales de reconocimiento basadas en descriptores y/o en aprendizaje automático (Schmitz et al., 2014), para así encontrar una solución a problemas de reconocimiento del entorno en tareas de manipulación y agarre robótico, tales como reconocimiento de objetos desconocidos (Velasco et al., 2019), reconocer la estabilidad del agarre mediante la detección de deslizamiento del objeto agarrado (Veiga et al., 2015), detección de la dirección del deslizamiento (Meier et al., 2016), etc.

En este trabajo, exploramos diferentes formas de interpretar lecturas táctiles, obtenidas con un sensor cuya superficie no es plana y cuyas celdas de medida no están organizadas como una matriz. Además, evaluamos el impacto del uso de datos táctiles

*Autor en correspondencia.
Correos electrónicos: `brayan.impata@ua.es` (Brayan S. Zapata-Impata), `pablo.gil@ua.es` (Pablo Gil), `fernando.torres@ua.es` (Fernando Torres)
URL: `www.aurova.ua.es` (Pablo Gil)

en la predicción de la estabilidad del agarre y en la detección de la dirección de deslizamiento en situaciones de falta de estabilidad, ambos problemas son frecuentes en las tareas de manipulación robótica. La Sección 2 presenta el problema que se aborda, la estabilidad del agarre. En la Sección 3 se describe el sensor usado y en la Sección 4 como se organizan e interpretan las medidas obtenidas. Posteriormente, se presentan las técnicas de procesamiento para analizar los datos táctiles en la Sección 5 y los resultados alcanzados en la Sección 6. Finalmente, en la Sección 7 se detallan las conclusiones.

2. El problema de la estabilidad en el agarre

En manipulación robótica es primordial un agarre correcto de los objetos. Roa y Suárez (2015) presentaron una revisión de medidas de calidad de agarre para determinar la bondad de éste. Nosotros consideramos que un agarre es estable, cuando la mano o pinza robótica contacta con el objeto que tiene que ser agarrado, adoptando la pose y fuerza que se requiere para poder levantarlo sin que éste se desplace dentro de la mano. Si dada una pose de agarre, la fuerza ejercida no es suficiente para que el objeto no se deslice entre los dedos de la mano, entonces el agarre se considera inestable (ver Figura 1). La detección de la falta de estabilidad en el agarre es útil para que el robot pueda activar alguna estrategia de control que mejore la calidad del agarre ejecutado.

En este trabajo, se abordan dos metodologías específicas en relación a los problemas que subyacen en la estabilidad del agarre en tareas de manipulación. Por un lado, la predicción de la estabilidad del agarre, se puede llevar a cabo utilizando como fuente principal de información una única instantánea del estado del conjunto de sensores táctiles. Es decir, el sistema debe aprender a partir de un conjunto de lecturas táctiles estáticas adquiridas en un momento dado, que es cuando el robot ha contactado con el objeto pero aún no lo ha levantado. Por lo tanto, el sistema debe predecir que el agarre será inestable en aquellos casos en los que el objeto al levantarse, desliza entre los dedos. Nuestro sistema debe ser capaz de dado un conjunto de lecturas táctiles en un instante de tiempo, distinguir entre *agarre estable* y *agarre inestable*.

Por otro lado, otro problema vinculado a la estabilidad hace referencia a la detección de la dirección de deslizamiento por la falta de contacto o por valores de presión insuficientes cuando se llevan a cabo tareas de manipulación, por ejemplo cuando una pinza o mano robótica transporta un objeto de un lado a otro. En estos casos, los movimientos de la mano pueden causar perturbaciones que a su vez generen movimientos no deseados en el objeto que sujeta, haciendo que éste pueda deslizar dentro de la mano y por lo tanto, produciendo un agarre inestable. Nuestro sistema debe ser capaz de dado un conjunto de lecturas táctiles en un instante de tiempo, que identifican que el agarre es inestable, distinguir entonces entre dos tipos de deslizamiento *traslacional* y *rotacional*. Y a su vez, identificar dirección traslacional (*norte, este, sur y oeste*) y rotacional (*sentido horario o antihorario*) (ver Figura 2).

Aunque ambas problemáticas, tanto la predicción de estabilidad como la predicción de la dirección deslizamiento, tienen una componente temporal. La primera de ellas se puede abordar sin considerar la variación de las lecturas táctiles a lo largo del tiempo como se ha mostrado exitosamente en trabajos como

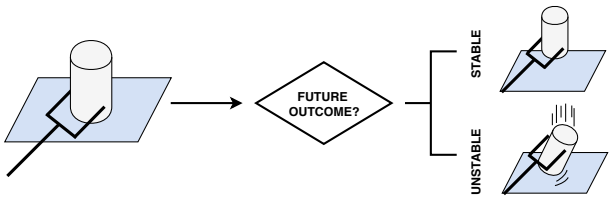

Figura 1: Problema de estabilidad en el agarre cuando se levanta un objeto en una tarea de manipulación robótica.

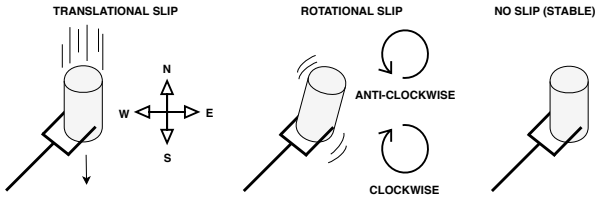

Figura 2: Dirección de deslizamiento en tareas de agarre inestable.

Zapata-Impata et al. (2018). Por el contrario, la identificación de la dirección de deslizamiento requiere que el sistema aprenda a detectar cómo los datos táctiles varían a lo largo del tiempo mientras se experimenta algún tipo de deslizamiento como se mostró (Zhang et al., 2018) y (Zapata-Impata et al., 2019b). Por lo tanto, se hace imprescindible para una detección exitosa que el sistema disponga de secuencias temporal de lecturas táctiles, y no sólo de las lecturas táctiles en un instante dado, ya que una sola instantánea podría no proporcionar al sistema información suficiente para distinguir la dirección del deslizamiento.

3. Descripción del sensor táctil

En este trabajo, empleamos dispositivos BioTac SP (BioTac® de SynTouch LLC) que son una versión mejorada del dispositivo BioTac. El primer BioTac fue presentado por Wettels et al. (2008). BioTac SP se diferencia de BioTac en su geometría y en su frecuencia de muestreo para la obtención de los datos táctiles. El primero tiene una forma elíptica y cambia el número de electrodos para obtener medidas, 24 frente a 19 de la versión anterior. (Figure 3).

Ambos dispositivos están formados por un conjunto de sensores que se encuentran dentro de un cuerpo rígido que está envuelto por una piel elastomérica que a su vez está rellena de un liquido conductivo. Además, bajo la superficie de esta piel y por encima del líquido hay un conjunto de electrodos que son usados para medir la distribución de las fuerzas que se aplican en la superficie. La superficie de la piel imita la rugosidad de la huella humana para producir fricción y vibraciones por contacto cuando el dispositivo se desliza sobre otra superficie haciendo movimientos de exploración.

También, en ambas versiones, los BioTac son capaces de detectar la posición de los puntos de contacto sobre su superficie, las fuerzas de contacto normales y tangenciales en esos puntos, así como algunos rangos de variaciones de temperatura gracias a que disponen de un conjunto de receptores de calor en combinación con un termistor.

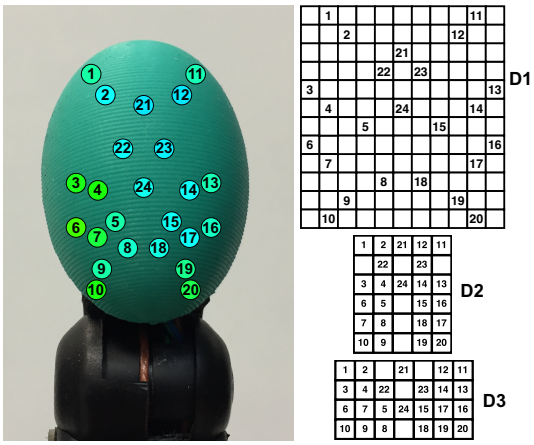

Figura 3: (Izq.) BioTac SP en el dedo de una mano Shadow. (Der.) Distribuciones de mapeado en imagen táctil

4. La representación de los datos táctiles

4.1. Imágenes táctiles

Los datos de presión táctil obtenidos en un BioTac SP se podrían organizar para su procesamiento como una imagen táctil I (ver Figura 3), donde I es una representación matricial de los valores de presión medidos por los 24 electrodos que lo componen. El principal problema de esta representación está relacionada en cómo se organiza la distribución de esos valores. Esto se debe a que el BioTac SP no dispone de una superficie plana, sino elíptica, así que los electrodos se distribuyen en un espacio tridimensional determinado por la forma elíptica de la superficie. Por lo tanto, para crear una matriz táctil hay que proyectar las coordenadas 3D $p_i = (x_i, y_i, z_i)$ de cada electrodo, en un plano 2D con coordenadas píxel (u_i, v_i), siendo $i = \{1..,24\}$. Por consiguiente, habrá píxeles de la matriz I que no tengan asignado un valor numérico, ya que habrá más píxeles que electrodos, lo que puede suponer a priori un problema añadido que generará *huecos* o píxeles sin valor. No obstante, este tipo de representación tiene como ventaja que mantiene la información de conectividad local entre cada uno de sus electrodos y su entorno de vecindad.

Para solucionar el problema de los *huecos* conviene explorar distintos tamaños de imágenes táctiles, ya que el número de filas y columnas determina las dimensiones del plano de proyección, y por consiguiente la proyección de 3D a 2D variará, consiguiendo que las distribuciones sean más o menos compactas. Así, en la Figura 3 se muestra como la distribución $D1$ es más compacta que $D2$. Este tipo de distribuciones fue estudiada en trabajos previos como (Zapata-Impata et al., 2018).

Por lo general, contra más compacta se la distribución menos *huecos* habrá que rellenar. Para introducir un valor en estos píxeles, que no tienen asignado un valor directo desde los electrodos, se puede proceder de varias maneras. Nosotros hemos definido dos posibles estrategias. La primera consiste en rellenar los *huecos* con el valor de presión más pequeño medido por los electrodos para que de ese modo, esos píxeles tengan la menor influencia posible en la interpretación de los datos sin que tengan un valor nulo. La segunda consiste en rellenar esos *huecos* a partir de los valores de los k electrodos que caen en un cierto entorno de vecindad de un radio previamente definido. Ambos ejemplos se pueden observar en la Figura 4.

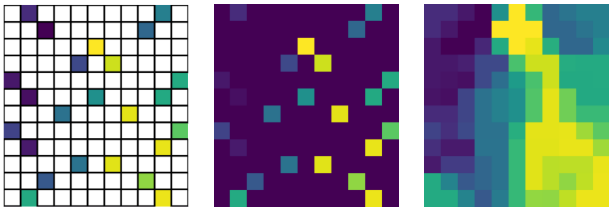

Figura 4: Imágenes táctiles. (Izq.) Mapeado de los electrodos. (Cen.) Rellenado de *huecos* con el mínimo valor de contacto. (Der.) Rellenado de *huecos* considerando k-electrodos vecinos

En nuestro caso, como se mostrará en las próximas secciones se experimentará con la información táctil procedente de tres dedos, cada uno montando un BioTac SP, habrá que considerar tres matrices táctiles $I = (I_1, I_2, I_3)$.

4.2. Grafos táctiles

Otra posible representación del estado del sensor en cada momento que además permite preservar la conectividad es una estructura de tipo grafo. Garcia-Garcia et al. (2019) y Zapata-Impata et al. (2019a) presentaron con éxito los grafos táctiles para predicción de estabilidad en el agarre.

Definimos un grafo táctil como una tripleta $G = (N, E, Y)$, donde $N = \{n_1, n_2, ..., n_{24}\}$ es un conjunto de nodos, y cada nodo n_i representa cada uno de los 24 electrodos, E es un conjunto de aristas, donde cada arista conecta dos nodos entre sí, e Y es la categoría o etiqueta del grafo para clasificar la tarea. Cada uno de los nodos del grafo $n \in N$ se caracterizan por tener una posición 3D, $p_n = (x_n, y_n, z_n)$ y un vector de características $f_n = (f_{n1}, f_{n2}, ..., f_{nm})$ de tamaño m. Las coordenadas 3D de p_n fueron definidas por el fabricante de los BioTac SP con respecto al centro del cuerpo rígido que está envuelto por la piel elastomérica.

Al igual que ocurría con la imagen táctil, puesto que en la experimentación se dispondrá de tres dispositivos táctiles BioTac SP, se definen tres vectores de características, uno por cada dispositivo. Así, cada nodo n tendrá en realidad una tripleta como características $f_n = (f_{n1}, f_{n2}, f_{n3})$, donde f_{n1} es el vector de características con las n-th lecturas de presión obtenidas desde el dedo índice, f_{n2} los valores de presión desde el dedo corazón y f_{n3} desde el pulgar.

Respecto al conjunto de aristas E que conectan los nodos (electrodos), lo hemos generado empleando dos estrategias. La primera de ellas consiste en especificar manualmente qué nodos están conectados siguiendo un criterio de simetría. La segunda consiste en hacer las conexiones usando un criterio de vecindad, en nuestro caso los k vecinos más cercanos (k-NN). Estas conexiones puede ser dirigidas, si cada arista $\{n_i, n_j\}$ conecta un nodo n_i con un nodo n_j pero no al contrario, es decir no hay camino entre n_j y n_i. También, pueden ser no dirigidas, si cada arista $\{n_i, n_j\}$ conecta ambos nodos en ambas direcciones, es decir hay camino de n_i a n_j pero también hay camino de n_j a n_i. En este trabajo hemos probado ambas representaciones, tanto empleando grafos no dirigidos, como empleando grafos dirigidos haciendo uso de los k vecinos más cercanos. La Figura 5 muestra un ejemplo de dos grafos, uno no dirigido y otro dirigido con $k = 4$.

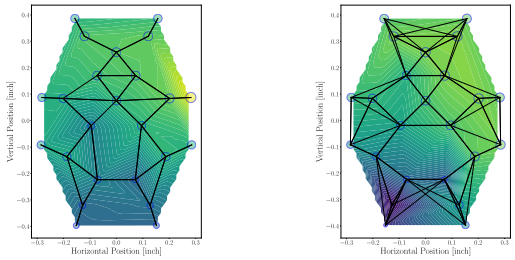

Figura 5: Grafos táctiles. (Izq.) No dirigido. (Der.) Dirigido con $k = 4$

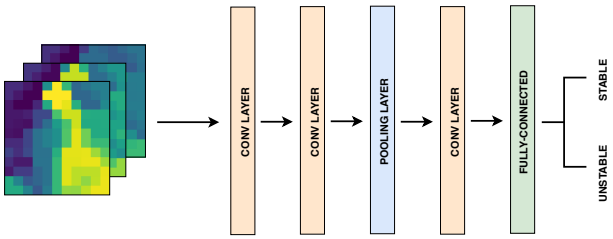

Figura 6: Ejemplo de una CNN para predecir la estabilidad tomando como entrada una imagen compuesta de 3 imágenes táctiles.

5. Procesamiento e interpretación de los datos táctiles

En esta sección, se presentan los métodos implementados para procesar e interpretar los datos táctiles obtenidos desde sensores BioTac SP, en tareas de agarre y manipulación robótica. Se presentan métodos específicos para trabajar con distintas representaciones de datos táctiles como las expuestas en la sección anterior. Además, los métodos que hemos implementado los organizamos en dos tipos, dependiendo de si emplean datos estáticos tomados en un instante de tiempo dado (no hay correlación temporal entre dos muestras) o hacen uso de secuencias temporales (hay correlación temporal). Tanto unos como otros, se emplean para distinguir entre *agarre estable* y *agarre inestable*, reduciendo el problema a una clasificación binaria. Pero además, las secuencias temporales de entrada pueden ser empleadas para detectar el tipo y dirección de deslizamiento en los casos en los que el agarre es inestable.

5.1. *Redes Neuronales profundas para datos estáticos*

En el caso de la detección de deslizamiento, es frecuente emplear lecturas táctiles estáticas de un único contacto de la pinza con la superficie del objeto, en un instante de tiempo dado. Este tipo de datos táctiles se puede procesar empleando distintas técnicas de procesamiento de señal e imagen y aprendizaje máquina. Las tendencias más recientes están más enfocadas a explotar el potencial que las técnicas de aprendizaje profundo ofrecen. En el caso que los datos táctiles se hayan representados como imágenes táctiles, el uso de Redes Neuronales Convolucionales (CNN) (Lecun y Bengio, 1995), ofrecen una buena alternativa como quedó patente en (Calandra et al., 2017) donde los datos táctiles se registraron desde un sensor óptico. Este tipo de redes ha demostrado superar a otros métodos en las tareas de clasificación de imágenes, debido a su capacidad para aprender características de imagen por sí mismas (Krizhevsky et al., 2012).

Básicamente, una CNN es un clasificador que recibe como entrada una imagen I que puede estar compuesta por un único canal, o puede estar compuesto por múltiples canales, como imágenes color RGB. Una capa convolucional procesa I con múltiples filtros, generando una nueva imagen I' que sirve a su vez como entrada de la siguiente capa convolucional, y así se continua a lo largo de todas las capas de la red. Además, es frecuente añadir unas capas de agrupación ('pooling layers') que permiten reducir las dimensiones de las imágenes intermedias I' para mejorar el tiempo de respuesta. Por lo general, al final se usa una capa completamente conectada ('fully connected') que proporciona una probabilidad como resultado. Esta probabilidad indica el nivel de pertenencia de I a un conjunto o categoría

El procesamiento para un sensor como BioTac SP no es muy distinto que para un sensor táctil basado en tecnología óptica, ya que como se mencionó en la sección anterior, las lecturas táctiles pueden ser representadas como imágenes táctiles I. Sólo es necesario un paso de preprocesamiento previo para transformar las lecturas $\theta = \{e_1, e_2, ..., e_{24}\}$ en una imagen táctil $I = \phi$. Una vez que se completa ese paso, la CNN puede aprender a detectar patrones de estabilidad a partir de las lecturas táctiles. La Figura 6 muestra un ejemplo de una CNN que recibe como entrada una imagen múltiple $I = \{\phi_1, \phi_2, \phi_3\}$ donde cada ϕ representa un canal de dimensiones $12x11$ si empleamos la representación $D1$ de la Figura 4. Cada canal ϕ representa una imagen táctil procedente de las lecturas táctiles de cada uno de los tres dedos BioTac SP que hemos instalado en una mano robótica multidedo.

Como se describió anteriormente en este documento, otra forma de interpretar las lecturas táctiles de los sensores BioTac SP es mediante grafos táctiles. Recientemente, las redes neuronales de grafos (GNN) están siendo usadas con éxito como alternativa a las señales y a las imágenes táctiles. Fueron Kipf y Welling (2016) quienes propusieron las redes convolucionales de gráficos (GCN) como una generalización de cómo aplicar convoluciones a grafos.

Una GCN toma como entrada una matriz de características X con tamaño NxF (hay un vector de características f_n para cada nodo n en el grafo G) y una matriz de adyacencia A que da forma al grafo. Como ocurre con las capas convolucionales de una CNN, las capas de la GCN procesan la entrada para aprender características a nivel de nodo y entonces generan una matriz intermedia X' de tamaño NxF'como salida (con un vector de características nuevo f'_n para cada nodo n). Al igual que en las CNN, se dispone de capas de agrupamiento ('pooling layers') para reducir el tamaño de los grafos intermedios y al final hay capas completamente conectadas ('fully connected') para devolver la probabilidad de que el grafo de entrada pertenezca a cada una de las categorías en las que se pretendía clasificarlo.

5.2. *Redes Neuronales profundas para secuencias temporales*

La detección de dirección de deslizamiento es un problema que requiere recopilar secuencias temporales de datos táctiles que permitan medir la variación de éstos a través del tiempo. Los métodos presentados en la sección anterior están limitados para llevar a cabo, correctamente, esta tarea. Aunque podrían concatenar secuencias temporales en canales (en una CNN) o más características (en una GCN), no habría una dependencia

temporal de las lecturas táctiles obtenidas y por lo tanto, no existiría el concepto de orden y consecuentemente de memoria como un orden temporal de cuando ocurre cada evento. Por esta razón, hemos recurrido a redes neuronales recurrentes, capaces de simular la memoria de largo plazo, interpretando datos con conexión temporal, como por ejemplo táctiles.

En particular, hemos hecho uso de redes recurrentes de memoria temporal conocidas como LSTM (Long Short-Term Memory), que fueron presentadas por primera vez por Hochreiter y Schmidhuber (1997). Estas redes emplean un tipo de neurona que es capaz de tomar como entrada tanto datos nuevos como procedente de su propia salida. Así en la red, la salida de una capa H_i se conecta tanto a la capa que le precede H_{i+1} como a ella misma H_i. Y durante el procesamiento de una secuencia de entrada $X = \{x_t, x_{t+1}, ..., x_{t+m}\}$, la neurona LSTM toma los valores de x_i uno por uno en cada momento t y mantiene un estado almacenado en una celda de memoria c_t. A través del uso de algunos operadores, la unidad decide si debe acumular la nueva entrada x_{t+1} en la memoria, olvidar el estado anterior que proviene de c_{t-1} y también si debería usar su valor actual de salida c_t. A parte de CNN y GCN, las redes LSTM también incluyen capas completamente conectadas ('Fully connected') para clasificar a la salida.

Este tipo de redes, puede ser empleado para detectar la dirección de deslizamiento, tratando el problema como si fuera un problema de clasificación de categorías de deslizamiento, de entre varias previamente aprendidas. Y para ello, estas redes pueden emplear tanto lecturas temporales táctiles, es decir señales discretas de datos obtenidos desde los electrodos del BioTac SP, como secuencias temporales de imágenes táctiles. Así las LSTM harán uso de señales como entrada y una variante de éstas como las ConvLSTM harán lo propio con secuencias de imágenes.

En el caso de las LSTM, es posible entrenarlas tomando como entrada una secuencia de T señales táctiles dadas por $\Theta = \{\theta^1, \theta^2, ..., \theta^t\}$, donde cada θ^t representa datos en bruto obtenidos en distintos instantes de tiempo manteniendo cada lectura los valores de los 24 electrodos del BioTac SP $\theta^t = \{e_1, e_2, ..., e_{24}\}$. Una vez entrenada la LSTM tiene la capacidad de funcionar como un clasificador aprendiendo a discernir entre distintas categorías buscando cuál se asemeja más una señal de entrada táctil arbitraria. Así, en nuestro caso la hemos entrenado para identificar las siguientes direcciones de deslizamiento: *norte, este, oeste, sur, sentido horario, antihorario, ausencia de deslizamiento*.

Las ConvLSTM son una variación de las LSTM, donde se añaden capas convolucionales a la LSTM, para poder emplear secuencias temporales de imágenes como entrada. En este trabajo, hemos usado un modelo de neurona como la presentada por Shi et al. (2015). La principal diferencia entre una ConvLSTM y una LSTM radica en el tipo de operaciones que se ejecutan en su interior, pero la lógica es la misma. Es decir, la ConvLSTM también tiene una celda memoria c_t que almacena el estado en el momento t, y a través del uso de sus puertas lógicas cada neurona puede determinar qué hacer con cada una de las entradas. No obstante, la ConvLSTM puede operar con tensores 3D en vez de con vectores 1D, como el caso de las señales y por lo tanto, puede aplicar operaciones de convolución con los datos a su paso por las distintas capas, tal y como lo haría una CNN. De ahí que la ventaja de ConvLSTM es que puede usar imágenes táctiles a la entrada para aprender mediante una etapa de entrenamiento tanto características espaciales como temporales. Las características temporales dan información de la variación de los valores de presión en los electrodos con el paso del tiempo durante la ejecución de la tarea. Y las características espaciales proporcionan información sobre qué electrodos se activan y en qué áreas de electrodos se obtienen valores similares o muy distintos.

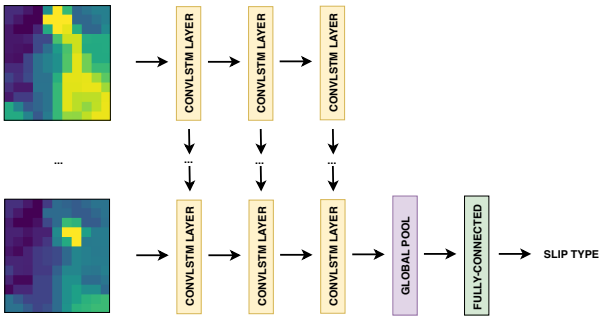

Figura 7: Ejemplo de una ConvLSTM para predecir la estabilidad del agarre y la dirección de desplazamiento tomando como entrada imágenes táctiles.

La Figura 7 representa un ejemplo de la arquitectura de ConvLSTM. Se debe tener en cuenta que las capas ConvLSTM en un instante t reciben como entrada x_t, la lectura del BioTac SP procesada como una secuencia de imágenes táctiles tomada en un intervalo de tiempo. Y su salida se pasa a la siguiente capa, así como a ellas mismas, simbolizadas por las flechas que apuntan hacia abajo, indicando que es la misma capa pero representada en el siguiente instante de tiempo.

6. Resultados

En esta sección analizaremos el rendimiento de los modelos de aprendizaje comentados en la sección anterior y empleados en tareas de agarre y manipulación para predicción de estabilidad y dirección del deslizamiento. Los modelos CCN y GCN para detección binaria de estabilidad, es decir *agarre estable* y *agarre inestable* (ver Tabla 1), y los modelos LSTM y ConvLSTM para la identificación del tipo de deslizamiento en los casos de falta de estabilidad (ver Tabla 2), ya sea traslacional (*norte, este, sur y oeste*) como rotacional (*sentido horario o antihorario*) .

6.1. *Comparación CNN versus GCN, imagen contra grafo*

Para realizar esta comparativa se han llevado a cabo 5831 agarres de 51 objetos distintos. La mitad de los agarres ejecutados se han etiquetado como estables. Por lo que ambas categorías de detección están balanceadas. Se han empleado 80 % de los agarres para entrenar y el 20 % para determinar su capacidad de detección. Y nos hemos asegurado que los agarres de test se hicieran con objetos totalmente distintos a los objetos agarrados durante el entrenamiento. Ambas redes, GCN y CNN, se han ajustado mediante un estudio hiperparamétrico durante la fase de entrenamiento. Así en la CNN se ha ajustado el número óptimo de capas y filtros por capa. Y en la GCN, se ha escogido el parámetro k de vecindad que mejor rendimiento proporciona. En ambas redes se combina a la entrada los datos generados por tres sensores BioTac SP, uno por cada uno de los dedos sensorizados de una mano robótica multidedo con la que se hacen los agarres.

Así, en relación al problema estático de la predicción de estabilidad (Tabla 1), podemos ver que hay diferencias en el rendimiento entre los dos modelos propuestos, CNN (con imagen táctil) y GNN (con grafo táctil). El aprendizaje de los datos táctiles representados en una imagen parece funcionar muy bien pues alcanza un valor de acierto medio más alto que si se utilizan grafos. Sin embargo, su rendimiento no es igual de estable. La CNN parece ser más sensible cuando cambiamos la orientación del agarre, pues su rendimiento baja de forma considerable cuando se trata de predecir estabilidad en las configuraciones de pose de la palma en 90º y 45º. El motivo de esta bajada podría ser debido a que la CNN aprende unos patrones para detectar la estabilidad que cuando cambiamos la orientación del agarre se desplazan a otras partes de la imagen táctil. Por lo tanto, la CNN aprende unas características que son locales dentro de la imagen y no consigue generalizarlos a otras orientaciones.

Por otro lado, la GCN entrenada con grafos sobre los mismos datos que la CNN entrenada con imágenes tiene un rendimiento mucho más estable entre orientaciones. A pesar de tener un rendimiento medio un poco más bajo al cambiar las orientaciones en los conjuntos de prueba, la GCN continúa obteniendo un rendimiento similar. Así pues, los grafos parecen ser una mejor representación del estado del sensor táctil en un momento dado para esta tarea. Esto queda demostrado con los resultados que ponen en manifiesto que la GCN ha aprendido unas características en los grafos que no se ven afectados por las orientaciones, por lo que generaliza más que la CNN entrenada con imágenes táctiles.

6.2. *Comparación LSTM versus ConvLSTM, señal contra secuencia temporal de imágenes*

Para realizar esta segunda comparativa se han generado contactos entre un sensor BioTac SP y superficies de 11 objetos distintos. Cuatro de esos objetos se han empleado para obtener datos táctiles de deslizamiento que permitieran entrenar los modelos de esta comparativa, LSTM y ConvLSTM. El resto de objetos se han empleado en las pruebas de validación para medir la capacidad de los métodos de generalizar la predicción de tipo de deslizamiento para situaciones no conocidas. En total, hemos empleado 112 secuencias temporales de medidas táctiles obtenidas desde el dispositivo BioTac SP para entrenar ambos modelos. Al igual que en el caso anterior, se ha hecho un estudio hiperparamétrico para ajustar los modelos y obtener el mejor rendimiento posible durante la fase de entrenamiento.

Así, en relación al problema dinámico de la predicción de la dirección de deslizamiento (Tabla 2), los resultados muestran que una LSTM entrenada con la señal táctil que contiene los datos en crudo del sensor puede alcanzar picos de rendimiento más altos que la ConvLSTM que hace uso de secuencias temporales de imágenes. Esto podría ser debido a que la LSTM trabaja con datos 100 % reales mientras que las imágenes táctiles de la ConvLSTM tienen una gran parte de valores que son generados desde los valores de los píxeles vecinos. Así, la ConvLSTM se entrena con una parte de valores de píxeles que son sintéticos, y que corresponden al rellenado de huecos de la matriz. Este hecho puede ser que afecte a la capacidad de aprendizaje de esta red y por ello, su rendimiento sea algo inferior. A pesar de ello, la ConvLSTM tiene una desviación típica menor que la LSTM en sus resultados. Por ejemplo, en el caso de la medida de sensibilidad, la desviación típica es de ±0,067 frente a ±0,028 en el caso de los objetos sólidos, de ±0,079 frente a ±0,021 en el caso de los objetos rugosos o con textura, y de ±0,091 frente a ±0,067 en el caso de los objetos con poca superficie de contacto. Por lo tanto, los patrones espacio-temporales aprendidos por esta red parecen ser más robustos a los diferentes objetos y sus propiedades.

En lo referente a la posible ejecución en tiempo real de ambos modelos, podría discutirse que la ConvLSTM tardará más en su procesamiento ya que debe crear la imagen táctil y realizar más cálculos en el paso por la red de estos datos. No obstante, el tiempo requerido para generar las imágenes es prácticamente despreciable. Por un lado, esto depende directamente del hardware utilizado. Por otro lado, en nuestros experimentos, vimos que estos cálculos no superaban 1 ms. Así pues, la mayor limitación viene realmente de la necesidad de esperar 50 ms. para recolectar los datos táctiles necesarios en el tiempo para así construir la secuencia propuesta.

7. Conclusiones

En este trabajo se han introducido diferentes formas de representar e interpretar los datos táctiles registrados con un sensor táctil de superficie no plana, como el BioTac SP. Además, se han descrito técnicas de aprendizaje profundo para poder aprender desde las representaciones diseñadas a predecir la estabilidad en el agarre robótico y a clasificar la dirección de deslizamiento en caso de falta de estabilidad. Como se ha mostrado en la experimentación, es posible obtener buenas tasas de detección en tareas de agarre robótico con cualquiera de las representaciones y modelos usados para interpretarlas. No obstante, todos ellos tienen ventajas y limitaciones que conviene comentar.

Por un lado, las imágenes táctiles pueden ser útiles para aprender patrones estáticos de los datos táctiles. Además, con ellas, es posible explotar la potencia de técnicas como las CNN. Sin embargo, se ha visto que son sensibles a las orientaciones de los agarres realizados. En contra, los grafos y las GCN parecen mejor adaptados para representar estos datos y seguir teniendo un rendimiento robusto ante variaciones.

Por otro lado, a la hora de aprender con patrones temporales tanto la representación en imágenes táctiles como los datos en crudo parecen tener un rendimiento similar con la ConvLSTM y la LSTM. Al fin y al cabo ambos son métodos con la misma base (las LSTM). No obstante, se ha visto que las ConvLSTM aprenden unos patrones que hacen más estable la clasificación de secuencias de imágenes táctiles.

En el futuro, queremos explorar la posibilidad de aprender a tratar grafos que varían en el tiempo con técnicas que mezclen las GCN y las LSTM. El uso de grafos para representar este tipo de sensor parece ser la mejor elección para mantener la distribución espacial de los electrodos y las LSTM parecen ser un método adecuado para aprender sobre secuencias temporales de datos táctiles.

English Summary

Stability prediction in robotic grasping tasks using tactile information

Abstract
In tasks of robotic manipulation, it is important to detect if a

Tabla 1: Resultados de detección comparando las metodologías de GCN (grafo táctil) y CNN (imagen táctil)

	Exactitud		Precisión		Sensibilidad		F_1	
Pose	GCN	CNN	GCN	CNN	GCN	CNN	GCN	CNN
Palma (0º)	0,741	0,829	0,741	0,936	0,751	0,717	0,745	0,812
Palma (90º)	0,751	0,708	0,785	0,858	0,709	0,515	0,745	0,643
Palma (45º)	0,774	0,763	0,774	0,860	0,783	0,639	0,778	0,734

Tabla 2: Resultados de detección comparando las metodologías de LSTM (señal táctil) y ConvLSTM (secuencia de imágenes táctiles)

	Exactitud		Precisión		Sensibilidad		F_1	
Superficie	ConvLSTM	LSTM	ConvLSTM	LSTM	ConvLSTM	LSTM	ConvLSTM	LSTM
Sólida y lisa	0,826	0,825	0,809	0,826	0,823	0,827	0,811	0,818
Rugosa o texturizada	0,735	0,738	0,720	0,747	0,737	0,741	0,725	0,735
con poco contacto	0,709	0,724	0,723	0,755	0,707	0,728	0,709	0,727

grasp is stable or on the contrary, the slips of grasped object among the robotic fingers due to inadequate contact. Usually, an unstable grasp can be caused as a consequence of a bad pose of the robotic hand or gripper and/or an insufficient contact pressure while the tasks is being performed. The use of tactile information and its representation is essential to carry out the prediction of stability throughout the grasp task. In this work, different representation of tactile data as well as the most appropiate deep learning methods are presented and compared when they are applied to detection of slipping in grasping tasks.

Keywords:
Robotic manipulators, tactile perception, robotic grasping, intelligent manipulation, stable grasp, learning, classification

Agradecimientos

Este trabajo ha sido financiado con Fondos Europeos de Desarrollo Regional(FEDER), Ministerio de Economía, Industria y Competitividad a través del proyecto RTI2018-094279-B-100 y la ayuda predoctoral 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

Alfadhel, A., Kosel, J., 2015. Magnetic nanocomposite cilia tactile sensor. Advanced Materials 27 (47), 7888–7892.
URL: https://onlinelibrary.wiley.com/doi/abs/10.1002/adma.201504015
DOI: 10.1002/adma.201504015

Calandra, R., Owens, A., Upadhyaya, M., Yuan, W., Lin, J., Adelson, E. H., Levine, S., 2017. The Feeling of Success: Does Touch Sensing Help Predict Grasp Outcomes? En: Proceedings of the 1st Annual Conference on Robot Learning. Vol. 78. pp. 314—-323.

Delgado, A., Corrales, J., Mezouar, Y., Lequievre, L., Jara, C., Torres, F., 2017. Tactile control based on gaussian images and its application in bimanual manipulation of deformable objects. Robotics and Autonomous Systems 94, 148 – 161.
URL: http://www.sciencedirect.com/science/article/pii/S092188901630478X
DOI: https://doi.org/10.1016/j.robot.2017.04.017

Garcia-Garcia, A., Zapata-Impata, B. S., Orts-Escolano, S., Gil, P., Garcia-Rodriguez, J., 2019. TactileGCN: A Graph Convolutional Network for Predicting Grasp Stability with Tactile Sensors. arXiv preprint, 1–8.
URL: http://arxiv.org/abs/1901.06181

Hochreiter, S., Schmidhuber, J., nov 1997. Long Short-Term Memory. Neural Computation 9 (8), 1735–1780.
URL: http://www.mitpressjournals.org/doi/10.1162/neco.1997.9.8.1735
DOI: 10.1162/neco.1997.9.8.1735

Johnson, M. K., Cole, F., Raj, A., Adelson, E. H., Jul. 2011. Microgeometry capture using an elastomeric sensor. ACM Trans. Graph. 30 (4), 46:1–46:8.
URL: http://doi.acm.org/10.1145/2010324.1964941
DOI: 10.1145/2010324.1964941

Kaboli, M., De La Rosa T, A., Walker, R., Cheng, G., Nov 2015. In-hand object recognition via texture properties with robotic hands, artificial skin, and novel tactile descriptors. En: 2015 IEEE-RAS 15th International Conference on Humanoid Robots (Humanoids). pp. 1155–1160.
DOI: 10.1109/HUMANOIDS.2015.7363508

Kappassov, Z., Corrales, J.-A., Perdereau, V., 2015. Tactile sensing in dexterous robot hands — review. Robotics and Autonomous Systems 74, 195 – 220.
URL: http://www.sciencedirect.com/science/article/pii/S0921889015001621
DOI: https://doi.org/10.1016/j.robot.2015.07.015

Kipf, T. N., Welling, M., 2016. Semi-supervised classification with graph convolutional networks. arXiv preprint arXiv:1609.02907.

Krizhevsky, A., Sutskever, I., Hinton, G. E., 2012. ImageNet Classification with Deep Convolutional Neural Networks. Advances In Neural Information Processing Systems, 1–9.
DOI: http://dx.doi.org/10.1016/j.protcy.2014.09.007

Lecun, Y., Bengio, Y., 1995. Convolutional Networks for Images, Speech, and Time-Series. The handbook of brain theory and neural networks 3361 (10), 1–14.

Luo, S., Bimbo, J., Dahiya, R., Liu, H., 2017. Robotic tactile perception of object properties: A review. Mechatronics 48, 54 – 67.
URL: http://www.sciencedirect.com/science/article/pii/S0957415817301575
DOI: https://doi.org/10.1016/j.mechatronics.2017.11.002

Luo, S., Mou, W., Althoefer, K., Liu, H., 2015. Novel tactile-sift descriptor for object shape recognition. IEEE Sensors Journal 15, 5001–5009.

Meier, M., Patzelt, F., Haschke, R., Ritter, H. J., 2016. Tactile convolutional networks for online slip and rotation detection. En: Villa, A. E., Masulli, P., Pons Rivero, A. J. (Eds.), Artificial Neural Networks and Machine Learning – ICANN 2016. Springer International Publishing, Cham, pp. 12–19.

Roa, M. A., Suárez, R., Jan 2015. Grasp quality measures: review and performance. Autonomous Robots 38 (1), 65–88.
URL: https://doi.org/10.1007/s10514-014-9402-3
DOI: 10.1007/s10514-014-9402-3

Schmitz, A., Bansho, Y., Noda, K., Iwata, H., Ogata, T., Sugano, S., Nov 2014. Tactile object recognition using deep learning and dropout. En: 2014 IEEE-RAS International Conference on Humanoid Robots. pp. 1044–1050.
DOI: 10.1109/HUMANOIDS.2014.7041493

Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-k., Woo, W.-c., 2015.

Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. Advances in Neural Information Processing Systems, 802–810.
URL: http://arxiv.org/abs/1506.04214

Spiers, A. J., Liarokapis, M. V., Calli, B., Dollar, A. M., April 2016. Single-grasp object classification and feature extraction with simple robot hands and tactile sensors. IEEE Transactions on Haptics 9 (2), 207–220.
DOI: 10.1109/TOH.2016.2521378

Stassi, S., Cauda, V., Canavese, G., Pirri, C. F., 2014. Flexible tactile sensing based on piezoresistive composites: A review. Sensors 14 (3), 5296–5332.
URL: http://www.mdpi.com/1424-8220/14/3/5296
DOI: 10.3390/s140305296

Su, Z., Fishel, J., Yamamoto, T., Loeb, G., 2012. Use of tactile feedback to control exploratory movements to characterize object compliance. Frontiers in Neurorobotics 6, 7.
URL: https://www.frontiersin.org/article/10.3389/fnbot.2012.00007
DOI: 10.3389/fnbot.2012.00007

Tiwana, M. I., Shashank, A., Redmond, S. J., Lovell, N. H., 2011. Characterization of a capacitive tactile shear sensor for application in robotic and upper limb prostheses. Sensors and Actuators A: Physical 165 (2), 164 – 172.
URL: http://www.sciencedirect.com/science/article/pii/S0924424710004231
DOI: https://doi.org/10.1016/j.sna.2010.09.012

Veiga, F., van Hoof, H., Peters, J., Hermans, T., Sep. 2015. Stabilizing novel objects by learning to predict tactile slip. En: 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). pp. 5065–5072.
DOI: 10.1109/IROS.2015.7354090

Velasco, E., Zapata-Impata, B. S., Gil, P., Torres, F., 2019. Clasificación de objetos usando percepción bimodal de palpación única en acciones de agarre robótico. Revista Iberoamericana de Automática e Informática industrial 0 (0).
URL: https://polipapers.upv.es/index.php/RIAI/article/view/10923
DOI: 10.4995/riai.2019.10923

Wettels, N., Santos, V. J., Johansson, R. S., Loeb, G. E., 2008. Biomimetic tactile sensor array. Advanced Robotics 22 (8), 829–849.
URL: https://doi.org/10.1163/156855308X314533
DOI: 10.1163/156855308X314533

Yi, Z., Zhang, Y., Peters, J., 2018. Biomimetic tactile sensors and signal processing with spike trains: A review. Sensors and Actuators A: Physical 269, 41 – 52.
URL: http://www.sciencedirect.com/science/article/pii/S0924424717307689
DOI: https://doi.org/10.1016/j.sna.2017.09.035

Zapata-Impata, B. S., Garcia-Garcia, A., Orts-Escolano, S., Garcia-Rodriguez, J., Gil, P., 2019a. Tactile Graphs for Grasp Stability Prediction. En: Seventh International Conference on Learning Representations (ICLR 2019). Workshop on Representation Learning on Graphs and Manifolds. pp. 1–6.
URL: https://rlgm.github.io/papers/7.pdf

Zapata-Impata, B. S., Gil, P., Torres, F., 2018. Non-Matrix Tactile Sensors: How Can Be Exploited Their Local Connectivity For Predicting Grasp Stability? En: IEEE/RSJ IROS 2018 Workshop RoboTac: New Progress in Tactile Perception and Learning in Robotics. pp. 1–4.
URL: http://arxiv.org/abs/1809.05551

Zapata-Impata, B. S., Gil, P., Torres, F., 2019b. Learning Spatio Temporal Tactile Features with a ConvLSTM for the Direction Of Slip Detection. Sensors 19 (3), 1–16.
URL: https://www.mdpi.com/1424-8220/19/3/523
DOI: 10.3390/s19030523

Zhang, Y., Kan, Z., Tse, Y. A., Yang, Y., Wang, M. Y., 2018. Fingervision tactile sensor design and slip detection using convolutional LSTM network. CoRR abs/1810.02653.
URL: http://arxiv.org/abs/1810.02653