

Decodificación de Movimientos Individuales de los Dedos y Agarre a Partir de Señales Mioeléctricas de Baja Densidad

John J. Villarejo Mayor ^{a,*}, Regina Mamede Costa ^b, Anselmo Frizzera-Neto ^a, Teodiano Freire Bastos ^{a,b}

^a Departamento de Ingeniería Eléctrica, Programa de Doctorado en Ingeniería Eléctrica, Universidad Federal de Espírito Santo, Vitória, Brasil.

^b Departamento de Biotecnología, Red del Nordeste en Biotecnología (RENORBIO), Universidad Federal de Espírito Santo, Vitória, Brasil

Resumen

Uno de los principales retos en el diseño de prótesis de mano es poder establecer un control intuitivo que reduzca el esfuerzo del usuario durante su entrenamiento. Este trabajo presenta un esquema para identificar tareas de motricidad fina de la mano, agrupadas en movimientos de los dedos individuales y gestos para el agarre de objetos el cual se ha validado con sujetos amputados. Se han comparado diferentes métodos de selección de características y clasificadores para el reconocimiento de patrones mioeléctricos, utilizando cuatro electrodos superficiales. Las características de las señales en el dominio del tiempo y la frecuencia se han combinado con métodos no lineales basados en análisis de fractales, mostrando una diferencia significativa en comparación con los métodos expuestos en la literatura para clasificar tareas de fuerza. Los resultados con amputados mostraron una exactitud de hasta 99,4% en los movimientos individuales de los dedos, superior a la obtenida con los gestos de agarre, de hasta 93,3%. El sistema ha obtenido una tasa de acierto promedio de 86,3% utilizando máquinas de soporte vectorial (SVM), seguido muy de cerca por K-vecinos más cercanos (KNN) con 83,4%. Sin embargo, KNN ha obtenido un mejor rendimiento global, debido a que es más rápido que SVM, lo que representa una ventaja para aplicaciones en tiempo real. El método aquí propuesto ofrece una mayor funcionalidad en el control de prótesis de mano, lo que mejoraría su aceptación por parte de los amputados.

Palabras Clave:

Señales electromiográficas, prótesis de miembro superior, reconocimiento de patrones, tareas de destreza de la mano.

1. Introducción

Una prótesis ideal debería reconocerse como una parte natural del cuerpo, reemplazando todas las funciones motoras y sensoriales del miembro amputado. Sin embargo, deficiencias en la apariencia, el confort y sobre todo la funcionalidad son las principales causas del rechazo de las prótesis por los usuarios (Peerdeman *et al.* 2011). En relación a la funcionalidad, Sensinger *et al.* (2009) han estudiado algunas tareas comunes de la vida diaria, como tender la cama, el agarre de objetos, el uso de un cierre y de cubiertos, entre otros, son de gran relevancia para los amputados. Dicho estudio ha indicado que los agarres lateral, cilíndrico y trípode son considerados más importantes que los movimientos de la muñeca. Por otra parte, Zecca *et al.* (2002) han reportado que entre los usuarios de prótesis consultados en su estudio, el 100% ha considerado importante apuntar con el dedo índice, el 90% desearía tener movimiento individual de los dedos y el 70% ha encontrado que los movimientos de flexión y extensión de la muñeca son de gran utilidad.

Algunas prótesis existentes, como AR III *Hands System* (Yang *et al.* 2009) y *Cyberhand* (Matrone *et al.* 2012a), proporcionan un control individual de los dedos. Otras, como *MANUS* (Pons *et al.* 2005, Ceres *et al.* 2008), *Fluidhand* (Matrone *et al.* 2012a) y *Southampton hybrid* (Light *et al.* 2002), seleccionan diferentes agarres de forma discreta. En todas ellas el control individual de los dedos es cercano al natural, pero es más complejo y menos intuitivo. Este último aspecto es uno de los desafíos más importantes para los investigadores y se relaciona con el esfuerzo de los usuarios en el aprendizaje del uso del miembro artificial. Las prótesis mioeléctricas son las más adecuadas para alcanzar una interfaz hombre-máquina más intuitiva, sin embargo, su dificultad en el control, la falta de realimentación y la necesidad de entrenamiento hacen que sean poco aceptadas. Algunas prótesis modernas como *i-Limb (Touch Bionics)*, Escocia) y *Kinetic Human Hand S1 (Dainichi)*, Japón) ofrecen un movimiento individual de los dedos, pero su control es limitado para el usuario. Otros proyectos como *DARPA* (Burck *et al.* 2011), *Smart Hand* (Kanitz *et al.* 2011) y *UNB hand* (Losier *et al.* 2011) permiten que los usuarios realicen agarres con todos los dedos, sin embargo, aún requieren de una detección de la intención del movimiento individual de los dedos más confiable.

La mayoría de las técnicas tradicionalmente usadas para el modelado de las señales electromiográficas de superficie (sEMG)

* Autor en correspondencia.

Correos electrónicos: jvimayor@gmail.com (John J. Villarejo Mayor), anselmo@ele.ufes.br (Anselmo Frizzera-Neto), teodiano.bastos@ufes.br (Teodiano Freire Bastos)

son lineales y se enfocan en aplicaciones con una actividad muscular de potencia, además de que son poco sensibles a la actividad de otros músculos. En el caso de tareas de motricidad fina, como el movimiento individual de los dedos y gestos de agarre con la mano, el modelado con técnicas lineales es insuficiente (Phinyomark et al. 2012a). En el caso de amputados, el control de una prótesis resulta difícil y agotador debido a que se requiere de un alto grado de activación muscular (Phinyomark et al. 2012a) y una selectividad de los músculos bajo la influencia del efecto de “*crosstalk*”, que aparece en las señales sEMG capturadas en la superficie de la piel (Kumar et al. 2013). Además, los movimientos de motricidad fina de la mano exigen una localización precisa de los electrodos y una calibración adecuada para cada usuario (Cipriani et al. 2011). Así, una configuración de señales sEMG de baja densidad (con menos de seis canales), reduce problemas de fijación de los electrodos, la necesidad de un experto para su montaje y, además, disminuye la complejidad y el tiempo de procesamiento.

En la literatura, varios estudios se han enfocado en el control de los movimientos de los dedos. Peleg et al. (2002) han obtenido una exactitud del 93% en la identificación del movimiento individual de los cinco dedos de la mano usando dos electrodos en el antebrazo. Por su parte, Tsenov et al. (2006) han utilizado características temporales (valor medio absoluto - MAV, varianza - VAR, longitud de onda - WL, cruces por cero - ZC, entre otras) y redes neuronales artificiales (RNA) para identificar el movimiento de los tres primeros dedos y el cierre de la mano, con procesamiento en los modos *off-line* y *on-line*. Otro estudio, realizado por Oskoei y Hu (2008), ha comparado diferentes grupos de características en el dominio del tiempo y la frecuencia para identificar cinco gestos de la mano en sujetos sin amputación. Se han utilizado clasificadores del tipo máquinas de soporte vectorial (SVM, del inglés *Support Vector Machine*), análisis discriminante lineal (LDA, del inglés *Linear Discriminant Analysis*) y perceptrón multicapa (MLP, del inglés *Multilayer Perceptron*). Los resultados han sido superiores al 95%, aunque se ha requerido un entrenamiento para cada sesión y se ha limitado a algunas acciones del usuario. Además, no se incluyeron tareas de motricidad fina. Posteriormente, Tenore et al. (2009) han reportado un esquema de señales sEMG de alta densidad con 19-32 electrodos para la identificación de 12 movimientos relativos a la flexión y extensión de todos los dedos. Este estudio, que incluyó cinco voluntarios con sus extremidades intactas y un amputado transradial, ha obtenido aciertos por encima del 82,3% en modo *off-line*, usando características temporales. Sin embargo, el número de canales utilizado representa un alto costo computacional. Sin embargo, todos estos trabajos no han evaluado el uso de dichos sistemas para el reconocimiento de tareas de motricidad fina.

Por otra parte, las características presentadas por Hudgins et al. (1993), basadas en la magnitud de las señales sEMG, no son confiables en contracciones musculares de bajo nivel (Naik et al. 2010), debido a la relación no lineal entre la fuerza y la actividad eléctrica de los músculos bajo dichas condiciones. Como solución, se han propuesto otros métodos más complejos basados en dominios de tiempo-escala como transformada wavelet (*Discrete Wavelet Transform* - DWT y *Wavelet Packet* - WP) (Englehart et al. 2001), y en dimensión de fractales (*Higuchi's fractal dimension* - HFD y *Detrended Fluctuation Analysis* - DFA) (Phinyomark et al. 2012a, Naik et al. 2010). Se ha demostrado que las características basadas en la dimensión de fractales presentan sensibilidad a la frecuencia y magnitud de la

fuerza de las contracciones musculares (Arjunan y Kumar 2010). Algunos trabajos han aplicado estas técnicas para medir la fuerza muscular (Kumar et al. 2013, Hu et al. 2001). Phinyomark et al. (2012a), por su parte, han utilizado una combinación de DFA con características en el dominio del tiempo y la frecuencia para reconocer cuatro movimientos bifuncionales: pronación/supinación del antebrazo, flexión/extensión y desviación radial/ulnar de la muñeca, abrir/cerrar la mano, además del estado de reposo. Dicho trabajo ha incluido un estudio de cinco canales de señales sEMG, con señales de bajo nivel de contracción de 20 sujetos sin amputación. Se ha analizado la combinación de las características DFA, HFD, RMS, WL y MFL (*Maximum Fractal Length*), siendo la combinación de DFA con otras características basadas en la magnitud de la señal la más adecuada para este problema. Los resultados de clasificación han mostrado exactitud desde 77,71% hasta 90,67%. Sin embargo, este estudio no ha incluido gestos de agarre ni ha sido validado con sujetos amputados.

Otros estudios como el realizado por Khushaba et al. 2012 han propuesto un sistema para clasificar diez movimientos, incluyendo la flexión de los dedos individuales y el contacto del pulgar con cada uno de los otros dedos. Se ha alcanzado una exactitud de 90,3%. Sin embargo, aunque este estudio ha reconocido movimiento de los dedos usando únicamente dos canales, no ha incluido sujetos amputados. Estudios como el de Matrone et al. (2012b) han realizado experimentos con procesamiento en tiempo real con cinco amputados, utilizando ocho canales de señales sEMG para identificar siete movimientos con los dedos, dos de ellos movimientos en pares. Se ha utilizado MAV, alcanzando 89% de exactitud para el grupo control y 79% para amputados. Posteriormente, Al-Timemy et al. (2013) han reportado un estudio con 6 sujetos con amputación traumática por debajo del codo para el reconocimiento de 5, 9, 12 y 15 gestos basados en movimientos de los dedos, con un número de electrodos variable hasta 12, combinando características autorregresivas con características en el tiempo. Los resultados han alcanzado exactitud del 90% para los amputados, con seis canales de señales sEMG y 12 movimientos individuales. Una limitante de estos estudios anteriores ha sido que no se han considerado tareas de agarre en sus experimentos.

Más recientemente, Guo et al. (2015) han comparado diferentes métodos de características como WP, DFA y MM (Modelos Musculares) combinados con los clasificadores SVM y ANN, del inglés *Artificial Neural Network*, usando seis canales de datos de señales sEMG. Sin embargo, su estudio no ha incluido tareas de destreza de la mano ni ha incluido sujetos amputados. Castro et al. (2015) han propuesto una técnica de selección de las tareas más adecuadas para su clasificación, incluyendo agarres, abrir/cerrar la mano y el movimiento individual de los dedos. Se han evaluado conjuntos reducidos desde diez hasta seis tareas, obteniendo una tasa de acierto desde 80,0% hasta 96,5%, respectivamente. Sin embargo, este estudio ha considerado únicamente sujetos sin amputación. Finalmente, los autores han investigado el reconocimiento de los movimientos individuales de los dedos con sujetos sin amputación (Villarejo et al. 2013, 2014a, 2014b).

En resumen, muchos trabajos han utilizado señales sEMG para lograr identificar con exactitud diferentes gestos de la mano. Sin embargo, pocos trabajos han incluido tareas agarre y su validación con amputados no ha sido ampliamente estudiada. Adicionalmente, el análisis de las características utilizadas en el reconocimiento de este tipo de movimientos, no ha sido realizado

Tabla 1: Información demográfica del grupo de amputados que ha participado en el estudio.

ID	Género/ Edad	Miembro amputado	Miembro dominante	Nivel	Tiempo Amp.	Prótesis usada
A1	F / 35	I	D	DM	3	Estética
A2	F / 23	D	D	TP	4	No
A3	F / 48	D	D	DM	1,5	No
A4	F / 50	I	D	TP	10	No
A5	M / 34	B	D	DM	2	No
A6	M / 19	I	D	DM	2	Estética

D: derecho; I: izquierdo; B: bilateral; DM: desarticulación de la muñeca; TP: un tercio proximal

considerando tareas de motricidad fina (Tenore *et al.* 2009, Cipriani *et al.* 2011, Al-Timemy *et al.* 2013). Por último, pocos trabajos han combinado el uso de señales sEMG de baja densidad para el reconocimiento de tareas de motricidad fina, lo que facilitaría la funcionalidad y disminuiría el rechazo al uso de las prótesis mioeléctricas. El objetivo de este trabajo es proponer un método para reconocer tareas de motricidad fina con la mano, basado en señales sEMG de baja densidad, validado en sujetos amputados. El método propuesto ofrece una mayor funcionalidad en el control de prótesis de mano y facilita la interfaz con el usuario mediante un número reducido de canales y un control más intuitivo.

Este trabajo se organiza de la siguiente manera. La sección 2 incluye la descripción del protocolo y del equipo que se ha utilizado en los experimentos, seguido por la descripción de las técnicas que se han utilizado para el procesamiento de los datos. La sección 3 se dedica a los resultados, mientras que la sección 4 aborda la discusión así como una comparación de los resultados de este trabajo con otros de la literatura. Para terminar, en la sección 5 se presentan las conclusiones más relevantes del trabajo.

2. Materiales y Métodos

2.1. Protocolo de Adquisición de Datos

Las señales sEMG se han capturado en el brazo dominante de diez sujetos voluntarios con el miembro intacto, pertenecientes al grupo control (S1-S10), siendo cinco hombres y cinco mujeres con edades entre los 22 y 35 años, sin historia de desórdenes neurológicos o neuromusculares. Adicionalmente, se han convocado seis sujetos con amputación en el antebrazo (A1-A6) a través del Centro de Rehabilitación Física de Espírito Santo – CREFES. Solo se han considerado sujetos que han sufrido de amputación traumática, siendo cuatro mujeres y dos hombres con edades entre 19 y 50 años, relacionados en la Tabla 1 y Figura 1. El nivel de amputación ha sido de desarticulación de muñeca para los sujetos A1, A3, A5 y A6, mientras que los sujetos A2 y A4 han tenido amputación de un tercio proximal del antebrazo. En el caso del sujeto A5, con una amputación bilateral, el estudio ha sido realizado sobre su miembro amputado dominante. Todos los voluntarios han sido evaluados previamente por un fisioterapeuta e informado acerca de los objetivos y la metodología del estudio. La lateralidad de los voluntarios ha sido consultada directamente con el sujeto durante dicha evaluación, basada en su auto-definición.




Figura 1: Grupo de voluntarios amputados participantes del estudio.

Como criterios de inclusión se ha determinado la no evidencia de neuropatías periféricas, enfermedades del sistema nervioso central o restricción de movilidad. Cada participante ha firmado un formulario de libre consentimiento, siguiendo los principios establecidos según el protocolo número 214/10, aprobado por el comité de ética de la Universidad Federal de Espírito Santo (UFES/Brasil).

2.2. Equipamiento y ubicación de los electrodos

Para la captura de las señales sEMG se han utilizado cuatro electrodos superficiales, activos, bipolares y reutilizables (PL091060A – 60 Hz) fabricados por *Touch Bionics*, con un sistema embebido con un filtro *notch* de 60 Hz y un circuito de acondicionamiento y pre-amplificación con ganancia ajustable. Las señales se han digitalizado con un sistema de adquisición de datos NI USB-6009 (1 KHz). La ubicación de los electrodos ha seguido las recomendaciones descritas en las normas de SENIAM (Hermens *et al.* 2000). Para la preparación de la piel, las zonas de colocación de los electrodos se han rasurado y limpiado con alcohol 70%. Se ha utilizado gel conductor para reducir la impedancia de la piel. Los electrodos se han ubicado en los siguientes músculos: flexor pollicis longus - canal 1; flexor digitorum superficialis - canal 2; flexor carpi radialis y flexor carpi ulnaris - canal 3; y extensor carpi radialis longus, extensor carpi radialis brevis y extensor carpi ulnaris - canal 4. La configuración de los electrodos ha sido la misma para los sujetos amputados y para el grupo control.

2.3. Protocolo Experimental

Los voluntarios han realizado cada tarea motora por separado. Un total de 13 gestos se han considerado en este estudio, reunidos en dos grupos independientes. El grupo A (GA) incluye la flexión de cada uno de los dedos: dedo pulgar (F1), dedo índice (F2), dedo medio (F3), dedo anular (F4) y dedo meñique (F5); y cerrar la mano (HC) y abrir la mano (HO). El grupo B (GB) considera tareas motoras de precisión o destreza, las cuales incluyen agarres de diferentes tipos de objetos: cilindro grande (CL), cilindro mediano (CM), trípode lateral (LT), trípode esférico (ST), pinza (TP). El estado de reposo (RT) se ha incluido en ambos grupos como una tarea motora adicional. Dicha tarea se ha registrado de forma independiente, mientras que los estados de reposo entre cada repetición de las otras tareas no se han tenido en cuenta para el estudio.

Durante los experimentos, cada voluntario se ha sentado en una silla con ambos brazos apoyados en una mesa. Antes del registro de los datos, los participantes se han familiarizado con el protocolo experimental y con los movimientos a realizar. Cada amputado ha tenido un tiempo previo para familiarizarse e imaginar cada una de las tareas, buscando contraer los músculos

del miembro amputado como lo hacía naturalmente antes de su amputación. Se ha sugerido a los sujetos amputados (excepto A5 que ha sufrido amputación bilateral) que imaginaran la tarea con su miembro amputado y ejecutaran un movimiento bilateral en modo espejo usando su miembro contralateral, de modo que se facilitara la contracción en el lado afectado. Los gestos se han realizado en la misma secuencia por cada sujeto. Durante la realización de cada tarea se ha pedido mantener una fuerza constante por un periodo de tiempo de 6 segundos, seguido por un periodo de descanso de 4 segundos para evitar fatiga muscular. Se han realizado 5 repeticiones continuas, alternando entre la contracción estática y la relajación. Cada contracción se ha dividido en la fase de inicio de la contracción (*onset*), seguido por una fase de estado estable, en el que se mantiene una contracción isométrica y, finalmente, el fin de la contracción (*offset*). Se han dado órdenes visuales y verbales para el inicio y el fin de cada repetición, que sirven para la sincronización de los datos y asignación de las clases correspondientes. Los experimentos se han repetido durante 3 días diferentes, con el fin de mejorar la capacidad de generalización, debido a la fluctuación de las señales sEMG por su naturaleza estocástica.

2.4. Procesamiento de los Datos

El procesamiento de los datos se ha compuesto de las fases de pre-procesamiento, extracción de características y clasificación, las cuales se han realizado de modo *off-line*, después de la captura de los datos. En la primera fase, se elimina el nivel de *DC* de cada canal, restando el valor promedio de cada señal. Además, se extrae la parte isométrica de cada repetición y se descartan las transiciones (*onset* y *offset*), tomando segmentos fijos de tres segundos a partir de dos segundos después de haber dado la orden para iniciar la tarea. Posteriormente, los datos se segmentan usando ventanas deslizantes de 200 ms con superposición de 100 ms entre ventanas adyacentes. Este procedimiento cumple con el criterio definido en (Englehart *et al.* 2001), en el que se establece que el tiempo de respuesta máximo de un sistema de control mioeléctrico en tiempo real debe ser inferior a 300 ms, con el fin de no introducir una sensación de retraso percibida por el usuario, lo cual genera frustración.

2.4.1. Extracción de Características

Las características en el dominio del tiempo (DT) son rápidas y fáciles de implementar. Están basadas en la amplitud de la señal, por lo que contienen información acerca de la energía de la señal, así como el nivel, duración y fuerza de la activación muscular. Por otra parte, las características en el dominio de la frecuencia (DF) son principalmente usadas para analizar fatiga y extraer información acerca de los cambios involucrados durante la innervación de las fibras musculares. Diferentes propiedades estadísticas han sido aplicadas sobre el espectro de potencia de la señal sEMG. Información más detallada sobre cada característica puede ser consultada en (Phinyomark *et al.* 2012b). En este estudio se han considerado 17 características basadas en el DT, DF y el estudio de fractales, resumidas en la Tabla 2. Para su análisis, las características se han distribuido en cuatro grupos, de acuerdo al trabajo propuesto en (Phinyomark *et al.* 2012b). El primer grupo reúne las características que están asociadas con la energía (VAR, RMS, MAV, y dos variaciones del valor medio absoluto: MAV1 y MAV2) y complejidad de la información (WL). El segundo grupo está asociado con características temporales que contienen información de frecuencia y modelos

Tabla 2: Características implementadas y analizadas en el estudio.

Dominio	Gr.	Abr	Características	Parámetros
Tiempo	1	MAV	Mean absolute value	
		MAV1	Modified MAV 1	
		MAV2	Modified MAV 2	
		VAR	Variance of sEMG	
		RMS	Root mean square	
		WL	Waveform length	
		ZC	Zero crossing	$U=0.0005$
Frecuencia	2	SSC	Slope sign change	$U=0.001$
		AR	Autoregressive model	4º orden
	3	MNF	Mean frequency	
		MDF	Median frequency	
		PKF	Peak frequency	
Fractales	4	MNP	Mean power	
		TTP	Total power	
		PSR	Power spectrum ratio	$N=20$
		DFA	Detrended Fluctuation Analysis	$L=10$
		HFD	Higuchi Fractal Dimension	$K_{max}=10$

U: umbral

predictivos (ZC, SSC y coeficientes autorregresivos de cuarto orden – AR). Los modelos AR describen cada muestra de la señal sEMG como una combinación lineal de las muestras previas. El tercer grupo reúne todas las características calculadas en el DF. Finalmente, el cuarto grupo incluye los métodos basados en el análisis de fractales (DFA y HFD) calculados en el dominio del tiempo. Cada característica se ha normalizado con base en su promedio y desviación estándar.

Es común utilizar vectores de múltiples características para conseguir una mayor exactitud en la clasificación. Sin embargo, el uso conjunto de todas las características mencionadas anteriormente puede generar redundancia y su cálculo implicaría un alto costo computacional. Por lo tanto, se hace necesario encontrar un número pequeño de características que optimice la clasificación desde el punto de vista de la separabilidad.

Se han propuesto entonces cuatro criterios diferentes para definir el conjunto de características que mejor representarían los patrones para su discriminación. Dicho análisis se ha realizado como un proceso independiente para ambos grupos de tareas, GA y GB. El primer método (M1) se ha basado en las características comúnmente usadas en el estado del arte para el reconocimiento de las tareas objeto de este estudio. Para conformar el segundo grupo (M2) se ha realizado un estudio usando cada característica individualmente como único parámetro para entrenar el clasificador. El porcentaje de acierto se ha utilizado como criterio de selección. Los dos últimos métodos se han basado en el algoritmo de selección secuencial hacia adelante (SFS del inglés *Sequential Forward Selection*) para la búsqueda sistemática de las características más apropiadas (Theodoridis y Koutroumbas 2008), estableciendo un ranking de acuerdo al criterio adoptado para la selección. En el tercer método (M3), el criterio de evaluación se ha basado en los resultados de clasificación mediante la tasa de acierto. En el cuarto método (M4), el criterio se ha basado en el indicador Davies-Bouldin (DB), el cual evalúa la distribución de los datos en el espacio de características (*clusters*) entre las clases.

2.4.2. Clasificación

Para la clasificación de las tareas se han implementado tres diferentes esquemas para su comparación: LDA, KNN ($k = 9$) y Multi-clase SVM (topología uno contra uno, kernel polinomial de tercer orden). Dichos clasificadores se han seleccionado debido a su buen desempeño en la clasificación y su bajo coste computacional (Chowdhury *et al.* 2013). Se ha utilizado el esquema de validación cruzada con 5 conjuntos aleatorios diferentes (*5-fold crossvalidation*) de igual tamaño, seleccionando 4 conjuntos de forma iterativa para ser usados para el entrenamiento, y el restante para validación. Dicho proceso se ha repetido 3 veces, incluyendo la definición de los conjuntos aleatorios. Finalmente, se ha obtenido el porcentaje de acierto promedio con todos los resultados.

2.5. Evaluación

Los indicadores usados para evaluar el desempeño de cada clasificador han sido especificidad (Esp), acierto (Ac) y el coeficiente Kappa de Cohen (K) (Japkowicz y Shah 2014). El coeficiente K representa la concordancia entre las respuestas esperadas y los valores predictivos. Los valores entre 0,61 y 0,80 indican una concordancia sustancial, mientras que valores mayores a 0,81 indican una concordancia casi perfecta. Además, se ha calculado la matriz de confusión para obtener la tasa de acierto promedio para todas las clases. Se ha evaluado la diferencia estadística entre las tasas de acierto de los diferentes métodos para selección de características por medio de las pruebas de Friedman y Bonferroni. La diferencia entre los sujetos del grupo control y el grupo de amputados se ha evaluado usando la prueba de suma de rangos de Wilcoxon. En ambas pruebas se han determinado los niveles de significancia para valores de $p < 0,05$.

2.6. Experimentos

Inicialmente, se ha definido una propuesta para el sistema de reconocimiento de patrones a partir de las técnicas propuestas en este estudio, tomando en cuenta el grupo control. Posteriormente, dicho sistema se ha validado con el grupo de amputados. Para la selección de características, se ha evaluado el desempeño de los cuatro métodos propuestos, para seleccionar el conjunto más adecuado. Este estudio se ha realizado únicamente con el clasificador KNN, debido a su eficiencia en tiempo de procesamiento. Una vez se ha definido dicho conjunto de

características, se ha comparado el desempeño de todos los clasificadores implementados. Finalmente, se ha definido un esquema para el reconocimiento de los gestos, para ambos grupos de tareas, el cual se ha validado con el grupo de amputados para determinar su validez.

3. Resultados

Inicialmente, se ha definido el número de características para la selección. A partir de los resultados con los cuatro métodos presentados, a continuación se ha obtenido una relación entre el número de características seleccionadas y los resultados de clasificación. En general, se ha definido que el número adecuado de características es seis, ya que para valores superiores no se observaba una mejora sustancial en el desempeño de la clasificación. Los resultados se han presentado en dos partes, de acuerdo a los grupos de tareas definidos anteriormente.

Para el grupo GA, se han identificado las características comúnmente usadas para este tipo de movimientos según la revisión del estado del arte. Para AR se ha determinado un modelo de cuarto orden usando todos los coeficientes. Por otro lado, para el método M2, se ha obtenido la clasificación promedio usando cada una de las características como único parámetro de entrada para el clasificador. Los resultados, resumidos en la Tabla 3, se han organizado según los grupos de características definidos en la sección de metodología, escogiendo al menos una característica por grupo. Finalmente, para los métodos M3 y M4 se ha realizado una búsqueda de las características más relevantes utilizando SFS. A partir de los resultados se ha establecido un ranking tomando en cuenta ambos grupos de voluntarios, control y amputados. Para M3, usando la tasa de acierto como criterio para la selección, y para M4, usando el indicador de DB.

Para las tareas del grupo GB, la selección de características para cada método ha seguido la metodología empleada para el GA. En el método M1 se ha definido el mismo conjunto de características que para GA. La Tabla 4 resume los conjuntos definidos para cada método en ambos grupos de tareas. El orden de las características no está relacionado con la prioridad que tienen en relación a la tasa de acierto. Con base en los resultados previos se ha observado que las características WL y TTP se han seleccionado en todos los métodos en ambos grupos de tareas. Otras características como SSC, MAV y AR se han incluido también en la mayoría de los conjuntos.

Tabla 3: Resultados de clasificación con la tasa de acierto promedio porcentual (Ac) y desviación estándar con características individuales, para los grupos de tareas GA y GB, con el grupo control. Los valores resaltados corresponden a las características seleccionadas en el métodos 2.

	Dominio del Tiempo									Dominio de la Frecuencia		
	Gr. 1	Ac	DE	Gr. 2	Ac	DE	Gr. 3	Ac	DE	Gr. 4	Ac	DE
Grupo A	RMS	92,7	3,9	SSC	82,5	9,3	DFA	54,1	6,4	MNF	94,1	3,2
	WL	94,0	3,2	ZC	70,8	8,9	HFD	55,2	4,3	MDF	94,1	3,2
	VAR	88,7	4,0	AR	87,5	4,1				PKF	44,9	4,1
	MAV	92,3	3,9							MNP	94,1	3,2
	MAV1	91,7	3,9							TTP	94,1	3,2
	MAV2	87,7	5,6							PSR	30,8	4,6
Grupo B	RMS	87,9	4,0	SSC	75,4	7,4	DFA	48,2	15,6	MNF	89,5	3,3
	WL	88,9	3,5	ZC	63,4	11,1	HFD	43,2	17,1	MDF	89,4	3,3
	VAR	84,0	5,0	AR	70,5	14,2				PKF	37,2	19,1
	MAV	87,4	4,1							MNP	89,5	3,3
	MAV1	86,7	4,3							TTP	89,4	3,3
	MAV2	82,0	5,5							PSR	26,9	22,2

Tabla 4: Características seleccionadas con los cuatro métodos de selección de características, para los grupos de tareas GA y GB.

Mét.	Grupo	1	2	3	4	5	6
M1	GA/GB	WL	RMS	MAV	SSC	ZC	AR
M2	GA	WL	AR	HFD	MNP	TTP	RMS
	GB	WL	SSC	DFA	MNF	MNP	MDF
M3	GA	WL	SSC	TTP	AR	MNP	MAV
	GB	WL	MDF	TTP	MAV	MNF	SSC
M4	GA	WL	MAV	SSC	TTP	DFA	AR
	GB	WL	MAV	SSC	ZC	TTP	HFD

A partir de los conjuntos de características conformados, se ha propuesto definir un conjunto único para cada grupo de tareas. En el método M2 se ha observado que las características basadas en el DF han tenido los resultados más altos, seguido muy de cerca por las características que representan la energía de la señal (Grupo 1). Asimismo, se ha observado que las características basadas en el análisis de fractales por sí solas tienen resultados muy pobres en la clasificación. Por otra parte, los métodos M3 y M4, usando SFS, han tenido resultados muy similares, siendo que se han seleccionado 4 características iguales en ambos grupos (WL, MAV, SSC y TTP). En el caso de SFS, para el método M3 basado en el criterio de la clasificación, las características en la frecuencia han tenido prioridad frente a los fractales, debido que son seleccionadas en secuencia y a su buen desempeño individualmente. Por el contrario, para el método M4, cuyo criterio de selección se basa en la distribución de los clusters en el espacio de características, se han tenido en cuenta las características basadas en fractales.

Posteriormente, se han comparado los resultados de clasificación con los métodos para el grupo control. Según los resultados de clasificación promedio, M4 alcanzó el mejor desempeño seguido muy de cerca por los otros métodos. Para establecer la significancia de los resultados, se ha aplicado la prueba de Friedman, la cual ha señalado una diferencia significativa entre los cuatro métodos para ambos grupos de tareas (GA, $p = 0,024$; GB, $p = 0,038$). Debido a que se requiere de una comparación múltiple, se realizó un análisis estadístico usando la prueba de Bonferroni. Se ha encontrado una diferencia significativa entre el método M4 con los métodos M3 y M1 en ambos grupos. Con base en lo anterior, se han seleccionado las características de M4 para el sistema de clasificación.

El estudio se ha realizado con el grupo control y, posteriormente, se ha extendido para su validación con amputados. Por tanto, se ha pretendido verificar la aproximación entre los resultados obtenidos con ambos grupos de voluntarios. En el caso de GA, la prueba de suma de rangos de Wilcoxon ha indicado que hubo una diferencia significativa en el desempeño entre el grupo control y el grupo de amputados ($p = 0,021$). Para entender esta diferencia, se ha realizado un análisis adicional en el que se han excluido el sujeto amputado cuyo desempeño ha sido el más bajo de todos (A4), siendo considerado como un caso

atípico de la muestra. En este caso, se ha encontrado que al comparar todos los demás sujetos (A1, A2, A3, A5 y A6) con el grupo control, no ha habido diferencia significativa en los resultados ($p = 0,0519$). Asimismo, se ha realizado un análisis similar con el grupo GB, en el cual se ha encontrado que no ha habido diferencia significativa entre ambos grupos de voluntarios, ($p = 0,053$).

Para los dos grupos de tareas, comparando los clasificadores, SVM ha tenido un mejor desempeño en relación a KNN y LDA. Para el grupo GA, la exactitud promedio (y la desviación estándar) ha sido de 98,1% (0,5) con el grupo control, y 88,5% (1,0) con el grupo de amputados. Para el grupo GB, la exactitud promedio ha sido de 91,5% (1,4), y 84,5% (1,3), para el grupo control y el grupo amputados, respectivamente. El coeficiente Kappa ha sido superior a 0,8 en todos los casos, lo que indica una concordancia significativa entre las clases esperada y predictiva. La especificidad, por su parte, ha estado por encima de 98,0% para SVM, y 96,3% para KNN, lo que indica la habilidad de ambos clasificadores para rechazar falsos positivos. La exactitud promedio, la especificidad y el coeficiente Kappa para ambos grupos de voluntarios, control y amputados, y para ambos grupos de tareas, se resumen en la Tabla 5. A partir de los resultados con los tres clasificadores, se ha encontrado una diferencia significativa entre SVM y LDA ($p < 0,024$). Comparando SVM con KNN, ha habido una diferencia significativa en los resultados de las tareas de agarre (GB) para el grupo control ($p < 0,022$). En la matriz de confusión se ha podido evidenciar la discriminación de cada tarea en relación a las restantes, tal como se observa en la Figura 2, para el caso del sujeto A5.

Tomando en cuenta los resultados con SVM, el grupo de tareas GA ha presentado una tasa de acierto entre 97,1% y 99,5% con el grupo control. Para el grupo de amputados, la tasa de acierto ha estado entre 73,0% y 99,4%, siendo A4 el sujeto con el porcentaje más bajo, seguido por A2 con un acierto del 84%, y todos los restantes con tasas de acierto por encima del 91%. A5 ha tenido el más alto desempeño. Con respecto al grupo de tareas GB, los resultados han estado entre 86,7% y 97,5% para el grupo control, y entre 77,4% y 93,3% para los amputados. En este caso, A5 ha logrado igualmente el más alto desempeño, mientras que todos los demás sujetos han estado por debajo del 87%, donde A3 y A4 han tenido los más bajos desempeños, cercanos al 77%.

4. Discusión

De acuerdo con los resultados del análisis para la selección de las características usando SFS, se ha encontrado que la clasificación de las tareas del grupo GA, que incluye flexión individual de los dedos y tareas de abrir y cerrar la mano, ha alcanzado un mejor desempeño cuando se combinan las características de los dos grupos en el dominio del tiempo.

Tabla 5: Resultados de clasificación con el método de características seleccionado, con la tasa de acierto promedio (Ac), especificidad (Esp) y coeficiente de Kappa para los grupos de tareas GA y GB, comparando los resultados con el grupo control y los sujetos amputados. Se incluyen los resultados para los 3 clasificadores SVM, LDA y KNN.

Grupo	Sujetos	SVM			LDA			KNN		
		Ac	Esp	k	Ac	Esp	k	Ac	Esp	k
GA	Control	98,1(0,5)	99,7(0,1)	1,0(0,0)	95,4(0,8)	99,3(0,3)	0,9(0,0)	97,5(0,7)	99,6(0,2)	1,0(0,0)
	Amputados	86,3(1,0)	98,0(1,3)	0,8(0,1)	77,6(1,2)	96,8(1,9)	0,7(0,2)	83,4(1,2)	97,6(0,8)	0,8(0,1)
GB	Control	91,6(1,4)	98,3(0,7)	0,9(0,0)	83,5(1,7)	96,7(0,8)	0,8(0,0)	87,7(1,6)	97,5(1,1)	0,9(0,1)
	Amputados	84,5(1,0)	97,0(1,1)	0,8(0,1)	74,0(1,4)	94,9(1,4)	0,7(0,1)	81,3(1,1)	96,3(1,4)	0,8(0,1)

Tabla 6: Comparación de los resultados de este estudio con otros resultados reportados en la literatura, incluyendo número de canales (N.C); número de clases (N.Cl); tipos de tareas estudiadas; grupo de sujetos, grupo control (Ct) o amputados (A); tasa de acierto (Ac); indicador R, como la relación de N.Cl/N.Ch.

Autores	N. C	N. Cl	Tareas	Sujetos	Ac [%]	R
2002, Peleg et al.	2	5	Dedos individ.	4 C	93	2,50
2006, Tsenov et al.	2	4	Dedos y gestos de la mano	1 C	92	2,00
	4	4			98	1,00
2009, Tenore et al.	19	12	Dedos individ.	5 C / 1 A	87,8	0,63
	32	12			94,1	0,38
2008, Oskoei and Hu	4	5	Gestos de la muñeca	11 C	97	1,25
2012, Phinyomark et al.	1	2	Mov. antebrazo, muñeca y mano	20 C	77,7 a 90,7	2,00
2011, Cipriani et al.	8	7	Dedos individ.	5 C / 5 A	48 a 98	0,88
2013, Al-Timemy et al.	6	15	Dedos individ.	10 C	89	2,50
	6	12		6 A	79	2,00
Este estudio	4	8	Dedos y gestos de la mano	10 C / 6 A	98,1	2,00
	4	6	Gestos de agarre	10 C / 6 A	91,6	1,50

Para el grupo GB, que reúne las tareas de agarre, se ha encontrado que para varios voluntarios la selección ha incluido la combinación de características de fractales con otras características relacionadas con la energía de la señal. El esquema que ha mostrado los mejores resultados para el sistema propuesto se ha compuesto del conjunto de características seleccionado en el método M4, y un clasificador SVM. No obstante, es importante destacar que el clasificador KNN ha mostrado un desempeño muy cercano al SVM, y además, tiene ventajas por su bajo coste computacional. Aunque el acierto promedio ha sido similar para todos los métodos, el test de significancia estadística determina la factibilidad para definir un método en relación a la tendencia de los resultados para cada sujeto.

Las características en el dominio de la frecuencia han obtenido las más altas tasas de acierto cuando han sido utilizadas individualmente como parámetros únicos para caracterizar los patrones. Sin embargo, la combinación de estas características no necesariamente conlleva a una mejor clasificación. Se ha encontrado una fuerte correlación entre las características en este

dominio, lo que indica una redundancia en la información para la discriminación de las clases. Esta redundancia también ha sido encontrada entre las características en el dominio del tiempo. Las características de fractales combinadas con otras características, basadas en la energía o la frecuencia de la señal, proporcionan ventajas en cuanto a la generalización de los datos para efectos de repetición a lo largo de diferentes experimentos.

En general, para ambos grupos de voluntarios, los movimientos de agarre han tenido una tasa de reconocimiento más baja en relación a los movimientos individuales de los dedos y de la mano. También, se ha podido notar que la variación de la tasa de acierto entre sujetos amputados para el grupo A (25%) ha sido mayor a la obtenida por el grupo B (16%), contrario a lo encontrado para el grupo control (2% para GA y 11% para GB). Debe resaltarse que los grupos no contienen el mismo número de tareas (8 para GA y 6 para GB), siendo más exigente para un clasificador la discriminación con mayor número de clases. Comparando los grupos de voluntarios que participaron en el estudio, se ha encontrado que los amputados han tenido un desempeño inferior al grupo control, lo que puede relacionarse con la falta de uso habitual de los músculos remanentes asociados con las tareas.

A partir de los experimentos, se ha evidenciado un bajo nivel de contracción muscular durante los registros de tareas de destreza comparado con otros movimientos que incluyen tareas de fuerza. La energía de la señal durante la tarea motora, en muchos casos, ha sido comparable con la actividad de reposo alterna a las repeticiones. Por este motivo, no se han podido aplicar las técnicas para la detección del inicio y fin de la contracción. Por consiguiente, la extracción de los segmentos relacionados con la actividad isométrica se ha realizado manualmente por parte de un experto, descartando los segmentos de cualquier otra actividad. Adicionalmente, se conoce que la relación entre la fuerza de contracción y la amplitud de la señal sEMG es de carácter no lineal para contracciones musculares de bajo nivel, asociadas con las tareas de destreza de la mano (Kumar *et al.* 2013). Dichas condiciones dificultan la diferenciación de las actividades musculares con el estado de reposo. Por otro lado, las señales sEMG de bajo nivel de contracción muscular, asociadas a tareas de destreza en movimientos funcionales de la mano, tienen una pobre relación señal a ruido (SNR), mientras que ocurre lo contrario con contracciones musculares en tareas de fuerza.

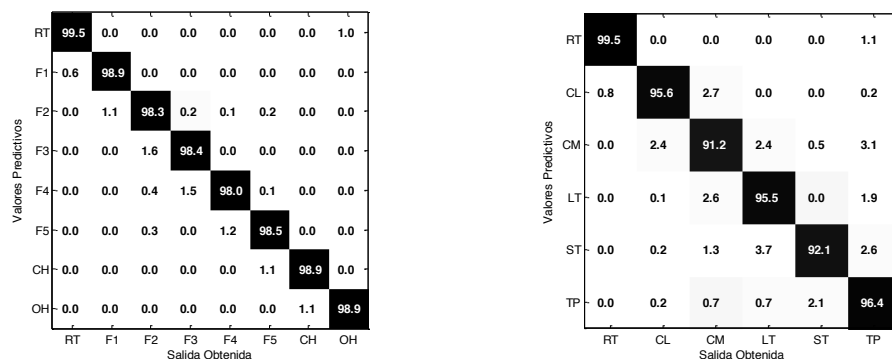


Figure 2: Matriz de confusion para el sujeto amputado A5, con amputación trans-radial. Izquierda, Grupo A, con movimiento individual de los dedos y abrir/cerrar la mano. Derecha, Grupo B, con movimientos de agarre. En cada matriz C, la celda C_{ij} representa el valor porcentual de muestras de valor predictivo de la clase i que se han clasificado como la clase j . El valor máximo, de 100%, se ha representado con el color negro, y el valor mínimo, de 0%, con el color blanco.

Con base en lo anterior, resulta interesante la combinación de características basadas en la magnitud de la señal con otros parámetros no lineales para caracterizar los patrones de las tareas de destreza.

Para ambos grupos de tareas, los voluntarios han requerido de concentración para la ejecución de las tareas durante el protocolo. Se ha buscado reducir la posibilidad de fatiga muscular definiendo un bajo número de repeticiones, incluyendo un tiempo de descanso suficiente entre cada prueba y se ha considerado un tiempo límite de una hora para su realización para evitar el estrés mental. Asimismo, el tipo de tareas motoras consideradas en este estudio no requiere de contracciones musculares de potencia que puedan producir fatiga. Al indicar a los amputados para realizar las tareas de una forma similar a la que realizaban naturalmente antes de la amputación, se ha encontrado una mayor dificultad para lograr bajas contracciones al momento de ejecutar las tareas, comparado con los voluntarios sin amputación.

Por otro lado, durante los experimentos, algunos amputados (A3 y A4) han indicado sentir espasmos musculares y dificultad para realizar contracciones selectivas de acuerdo a la tarea solicitada. En estos casos, las pruebas debieron ser interrumpidas por relacionarse con fatiga, debida a la falta de actividad cotidiana de los grupos musculares remanentes, lo cual sería superado con el uso progresivo de una prótesis. Además, el nivel de amputación afecta el desempeño en los resultados, específicamente para los sujetos A2 y A4, quienes también han sufrido cambios en los puntos de inserción de los músculos debido a la altura de la amputación. En relación a la lateralidad, tres sujetos amputados (A2, A3 y A5) han realizado los experimentos con su brazo dominante y tres sujetos (A1, A4 y A6) con su brazo no dominante. Los resultados obtenidos no han mostrado un efecto de la lateralidad sobre el desempeño de los voluntarios, dado que los sujetos A1 y A6 han obtenido un alto desempeño con su lado no dominante.

Asimismo, el sujeto A3 ha obtenido un bajo desempeño en comparación con los otros sujetos, usando su lado dominante. No obstante, un estudio con un número mayor de voluntarios podría generar resultados singificativos. Tomando en cuenta los cuatro amputados con mejor desempeño, la diferencia en las tasas de acierto entre ambos grupos de tareas ha estado en un rango de 3,8% a 6,8%. A pesar de que la validación del sistema se ha realizado en modo *off-line*, el sistema se ha propuesto tomando en cuenta los requerimientos para aplicaciones en tiempo real (Englehart *et al.* 2001). La comparación de los resultados obtenidos con el sistema aquí propuesto con otros resultados de la literatura podría resultar desequilibrada, debido a las diferencias entre el número de canales usados, el número de clases a reconocer, el tipo de tareas considerados en relación al nivel de destreza y motricidad fina, y la inclusión de voluntarios amputados. Sin embargo, se propone un indicador de comparación R, el cual se basa en la relación entre el número de clases y el número de canales. La Tabla 6 resume los trabajos previos con su respectivo valor de R a modo de resaltar la significancia de los resultados presentados en este trabajo. En este sentido, para este estudio se han calculado las relaciones R para los dos grupos de tareas estudiados, siendo igual a 2 para GA y 1,5 para GB. Los resultados de este estudio son relevantes debido que se han validado las técnicas propuestas con amputados y se han considerado distintas funciones de destreza para realizar diferentes gestos de la mano y manipular diferentes objetos, lo cual ha sido abordado por pocos estudios. A su vez, los resultados han superado otros estudios en la literatura.

5. Conclusión

En este trabajo se propone un nuevo método para identificar tareas de destreza fina, divididas en dos grupos, para el control de prótesis de mano con sistema multicanal de baja densidad. Se han analizado diferentes métodos para la selección de características, combinando técnicas no lineales con parámetros estadísticos de amplitud de la señal sEMG. Los resultados han mostrado mejor desempeño a partir de la combinación de análisis de fractales con características temporales y modelos predictivos, para la caracterización de patrones sEMG en tareas de destreza. Se han comparado 3 clasificadores, obteniendo resultados similares entre SVM y KNN. La elección del clasificador dependería del tipo de aplicación, siendo KNN el más indicado para aplicaciones en tiempo real. Los resultados validados con amputados han mostrado tasas de acierto superiores a las de otros trabajos de la literatura. Al final la elección óptima se basa en la búsqueda de un compromiso entre rendimiento del clasificador y la velocidad en relación al coste computacional, dependiendo de lo crítica que sea la aplicación.

English Summary

Decoding of Grasp and Individuated Finger Movements Based on Low-Density Myoelectric Signals

Abstract

Intuitive prosthesis control is one of the most important challenges in order to reduce the user effort in learning to use an artificial hand. This work presents the development of a myoelectric pattern recognition system for myoelectric weak signals able to discriminate dexterous hand movements using a reduced number of electrodes. The system was evaluated in six forearm amputees and the results were compared with the performance of able-bodied subjects. Different methods were analyzed to classify individual fingers flexion, hand gestures and different grasps using four electrodes and considering the low level of muscle contraction in these tasks. Multiple features of sEMG signals were also analyzed considering traditional magnitude-based features and fractal analysis. Statistical significance was computed for all the methods using different set of features, for both groups of subjects (able-bodied and amputees). For amputees, results showed accuracy up to 99.4% for individual finger movements, higher than the achieved by grasp movements, up to 93.3%. Best performance was achieved using support vector machine (SVM), followed very closely by K-nearest neighbors (KNN). However, KNN produces a better global performance because it is faster than SVM, which implies an advantage for real-time applications. The results show that the method here proposed is suitable for accurately controlling dexterous prosthetic hands, providing more functionality and better acceptance for amputees.

Keywords:

Myoelectric signals, upper-limb prosthesis, superficial electromyography low density, dexterous hand gestures, pattern recognition.

Agradecimientos

Este trabajo ha sido patrocinado por CAPES y FAPES/Brasil (Proyecto Número 007/2014: Use of Robotics and Assistive Technology for Children and Adults with Disabilities).

Referencias

- Al-Timemy, A., Bugmann, G., Escudero, J., Outram, N., 2013. Classification of finger movements for the dexterous hand prosthesis control with surface electromyography. *IEEE Journal of Biomedical and Health Informatics* 17(3), 608–618. DOI:10.1109/JBHI.2013.2249590
- Arjunan, S., Kumar, D., 2010. Decoding subtle forearm flexions using fractal features of surface electromyogram from single and multiple sensors. *Journal of Neuroengineering and Rehabilitation* 7(1), 53. DOI: 10.1186/1743-0003-7-53
- Burck, J., Bigelow, J., Harshbarger, S., 2011. Revolutionizing prosthetics: systems engineering challenges and opportunities. *Johns Hopkins APL Tech Dig* 30(3), 186–197.
- Castro, M., Arjunan, S., Kumar, D., 2015. Selection of suitable hand gestures for reliable myoelectric human computer interface. *BioMedical Engineering OnLine* 14(1), 1–11. DOI: 10.1186/s12938-015-0025-5
- Ceres, R., Pons, J., Calderón, L., Moreno, J., 2008. La robótica en la discapacidad. Desarrollo de la prótesis diestra de extremidad inferior manus-hand. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 5(2), 60–68. DOI: 10.1016/S1697-7912(08)70145-6
- Chowdhury, R., Reaz, M., Ali, M., Bakar, A., Chellappan, K., Chang, T., 2013. Surface electromyography signal processing and classification techniques. *Sensors* 13(9), 12431–66. DOI: 10.3390/s130912431
- Cipriani, C., Antfolk, C., Controzzi, M., Lundborg, G., Rosen, B., Carrozza, M., Sebelius, F., 2011. Online myoelectric control of a dexterous hand prosthesis by transradial amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 19(3), 260–270. DOI: 10.1109/TNSRE.2011.2108667
- Englehart, K., Hudgins, B., Parker, P., 2001. A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering* 48(3), 302–311. DOI: 10.1109/10.914793
- Guo, S., Pang, M., Gao, B., Hirata, H., Ishihara, H., 2015. Comparison of sEMG-Based Feature Extraction and Motion Classification Methods for Upper-Limb Movement. *Sensors* 15(4), 9022–38. DOI: 10.3390/s150409022
- Hermens, H. J., Freriks, B., Disselhorst-Klug, C., Rau, G., 2000. Development of recommendations for SEMG sensors and sensor placement procedures. *Journal of Electromyography and Kinesiology* 10(5), 361–374. DOI: 10.1016/S1050-6411(00)00027-4
- Hu, K., Ivanov, P., Chen, Z., Carpena, P., Stanley, H., 2001. Effect of trends on detrended fluctuation analysis. *Physical Review. E* 64, 11114. DOI: 10.1103/PhysRevE.64.011114
- Hudgins, B., Parker, P., Scott, R., 1993. A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering* 40(1), 82–94. DOI: 10.1109/10.204774
- Japkowicz, N., Shah, M., 2014. *Evaluation learning algorithms: a classification perspective*. Cambridge University Press. New York, NY, USA.
- Kanitz, G., Antfolk, C., Cipriani, C., Sebelius, F., Carrozza, M., 2011. Decoding of individuated finger movements using surface EMG and input optimization applying a genetic algorithm. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 33, 1608–11. DOI: 10.1109/IEMBS.2011.6090465
- Khushaba, R., Kodagoda, S., Takruri, M., Dissanayake, G., 2012. Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Systems with Applications* 39(12), 10731–10738. DOI: 10.1016/j.eswa.2012.02.192
- Kumar, D., Arjunan, S., Singh, V., 2013. Towards identification of finger flexions using single channel surface electromyography - able bodied and amputee subjects. *Journal of Neuroengineering and Rehabilitation* 10(1), 50. DOI: 10.1186/1743-0003-10-50
- Light, C., Chappell, P., Hudgins, B., Engelhart, K., 2002. Intelligent multifunction myoelectric control of hand prostheses. *Journal of Medical Engineering & Technology* 26(4), 139–146. DOI: 10.1080/03091900210142459
- Losier, Y., Clawson, A., Wilson, A., Scheme, E., Englehart, K., Kyberd, P., Hudgins, B., 2011. An overview of the UNB hand system. *Proceedings of the 2011 MyoElectric Controls/Powered Prosthetics Symposium* Fredericton, 2–5.
- Matrone, G., Cipriani, C., Carrozza, M., Magenes, G., 2012. Real-time myoelectric control of a multi-fingered hand prosthesis using principal components analysis. *Journal of NeuroEngineering and Rehabilitation* 9(1), 40. DOI: 10.1186/1743-0003-9-40
- Naik, G., Kumar, D., Arjunan, S., 2010. Pattern classification of myoelectrical signal during different maximum voluntary contractions: a study using BSS techniques. *Measurement Science Review* 10(1), 1–6. DOI: 10.2478/v10048-010-0001-y
- Oskoei, M., Hu, H., 2008. Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb. *IEEE Transactions on Biomedical Engineering* 55(8), 1956–1965. DOI: 10.1109/TBME.2008.919734
- Peerdeman, B., Boere, D., Witteveen, H., Huis R., Hermens, H., Stramigioli, S., Misra, S., 2011. Myoelectric forearm prostheses: state of the art from a user-centered perspective. *The Journal of Rehabilitation Research and Development* 48(6), 719. DOI: 10.1682/JRRD.2010.08.0161
- Peleg, D., Braiman, E., Yom-Tov, E., Inbar, G., 2002. Classification of finger activation for use in a robotic prosthesis arm. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 10(4), 290–293. DOI: 10.1109/TNSRE.2002.806831
- Phinyomark, A., Phukpattaranont, P., Limsakul, C., 2012a. Fractal analysis features for weak and single-channel upper-limb EMG signals. *Expert Systems with Applications* 39(12), 11156–11163. DOI: 10.1016/j.eswa.2012.03.039
- Phinyomark, A., Phukpattaranont, P., Limsakul, C., 2012b. Feature reduction and selection for EMG signal classification. *Expert Systems with Applications* 39(8), 7420–7431. DOI: 10.1016/j.eswa.2012.01.102
- Pons, J., Ceres, R., Rocon, E., Levin, S., Markovitz, I., Saro, B., Bueno, L., 2005. Virtual reality training and EMG control of the MANUS hand prosthesis. *Robotica* 23(3), 311–317. DOI: 10.1017/S026357470400133X
- Sensinger, J., Lock, B., Kuiken, T., 2009. Adaptive pattern recognition of myoelectric signals: exploration of conceptual framework and practical algorithms. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 17(3), 270–278. DOI: 10.1109/TNSRE.2009.2023282
- Tenore, F., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R., Thakor, N., 2009. Decoding of individuated finger movements using surface electromyography. *IEEE Transactions on Biomedical Engineering* 56(5), 1427–1434. DOI: 10.1109/TBME.2008.2005485
- Theodoridis, S., Koutroumbas, K., 2008. *Pattern Recognition*. Academic press.
- Tsenov, G., Zeghib, A., Palis, F., Shoylev, N., Mladenov, V., 2006. Neural networks for online classification of hand and finger movements using surface EMG signals. *8th Seminar on Neural Network Applications in Electrical Engineering (NEUREL)*, 167–171. DOI: 10.1109/NEUREL.2006.341203
- Villarejo, J., Costa, R., Bastos, T., Frizera, A., 2014. Identification of low level semg signals for individual finger prosthesis. *Biosignals and Bioinformatics Conference. Biosignals and Robotics for Better and Safer Living (BRC)*, 5th ISSNIP-IEEE. DOI: 10.1109/BRC.2014.6880991
- Villarejo, J., Frizera, A., Bastos, T., Sarmiento, J., 2013. Pattern recognition of hand movements with low density sEMG for prosthesis control purposes. *IEEE International Conference on Rehabilitation Robotics* 1–6. DOI: 10.1109/ICORR.2013.6650361
- Villarejo, J., Mamede, R., Bastos, T., 2014. Movement Identification using weak sEMG signals of low density for upper limb control. *En: Andrade, A., Barbosa, A., Cardoso, A., Lamounier, E. Tecnologias, técnicas e tendências em engenharia biomédica. Canal6 Edi*, p. 280–300.
- Yang, D., Zhao, J., Gu, Y., Wang, X., Li, N., Jiang, L., Zhao, D., 2009. An anthropomorphic robot hand developed based on underactuated mechanism and controlled by EMG signals. *Journal of Bionic Engineering* 6(3), 255–263. DOI: 10.1016/S1672-6529(08)60119-5
- Zecca, M., Micera, S., Carrozza, M., Dario, P., 2002. Control of multifunctional prosthetic hands by processing the electromyographic signal. *Critical Reviews in Biomedical Engineering* 30(4–6), 459–485. DOI: 10.1615/CritRevBiomedEng.v30.i456.80