

.....

Métodos Computacionales para el Reconocimiento de Patrones Mioeléctricos en el Control de Exoesqueletos Robóticos: una Revisión

Alberto López Delis, Andrés F. Ruiz Olaya***

Abstract

Traditionally, human-machine interfaces have been a widely studied research topic in the rehabilitation field. In order to empower the physical rehabilitation processes of motor disabled people, there are growing efforts within the scientific community aimed at developing new robotic devices such as exoskeletons. Myoelectric control is an advanced technique concerning with detection, processing, classification and application of electromyography signals to control external rehabilitation systems and devices. In physical therapies using robotic systems it is fundamental an effective identification of the human motion to command these systems. In literature, surface EMG signals have been widely used, taking into account that they can reflect the movement intention. This work provides a revision of the computational techniques and methods that have been used in literature, based on features extraction and pattern recognition techniques aimed at myoelectric control of robotic exoskeletons. It is considered researches that have used these methods to control robotic devices, and it is presented future trends in this research field.

Keywords: surface electromyography, myoelectric control, features extraction, pattern recognition.

Resumen

El desarrollo de las interfaces hombre-máquina ha representado una línea de investigación interesante y ampliamente estudiada en el cam-

Fecha Recibido: 2012-09-20

Fecha Aprobado: 2012-10-23

* Maestría en Automática, Doctorado en Ingeniería Eléctrica Centro de Biofísica Médica, Universidad de Oriente, Cuba. E-mail: lopez_delis@yahoo.com

** Master en Tecnologías de la Información, Doctorado en Ingeniería Eléctrica, Electrónica y Automática Universidad Antonio Nariño, Grupo de Bioingeniería, Colombia. E-mail: andresru@uan.edu.co



po de la rehabilitación. En este sentido, para potencializar los procesos de rehabilitación física de las personas con discapacidad motora hay un esfuerzo creciente en la comunidad científica hacia el desarrollo de nuevos dispositivos robóticos, como los exoesqueletos. El control mioeléctrico es una técnica avanzada concerniente con la detección, procesamiento, clasificación y aplicación de señales electromiográficas para el control de sistemas externos y dispositivos de rehabilitación. En la terapia física efectuada mediante el uso de sistemas robóticos, es fundamental una identificación efectiva de la intención de los movimientos humanos para comandar tales sistemas. En la literatura se han utilizado ampliamente las señales electromiográficas de superficie, teniendo en cuenta que las mismas pueden reflejar la intención del movimiento. Este artículo proporciona una revisión de las técnicas y métodos computacionales que han sido utilizados, basados en técnicas de extracción de características y reconocimiento de patrones para el control mioeléctrico de exoesqueletos. Se abordan trabajos que hacen uso de estos métodos, para el control de los dispositivos robóticos, y se plantean direcciones futuras en este campo de investigación.

Palabras clave: electromiografía de superficie, control mioeléctrico, extracción de características, reconocimiento de patrones.

1. Introducción

EL control basado en reconocimiento de patrones mioeléctricos ha emergido como una alternativa promisoría en los dispositivos de rehabilitación robótica [1]. El principio de clasificación para este control está enfocado en la detección de la intencionalidad del movimiento a través de las señales mioeléctricas (SME) de superficie.

La SME es la manifestación eléctrica de la activación neuromuscular, asociada con la contracción muscular [2]. La señal representa la corriente generada por el flujo iónico a través de la membrana de las fibras musculares, que se propagan a través de los tejidos para alcanzar la superficie de detección de un electrodo, localizado en el músculo [2]. Las SME contienen abundante información a partir de la cual la intención de movimiento del usuario en la forma de una contracción muscular puede ser detectada, usando electrodos de superficie. Las personas con algún tipo de discapacidad motora o amputación, son capaces de generar señales mioeléctricas con patrones repetibles, que gradualmente varían du-

rante diferentes niveles de contracción muscular estática o dinámica. Estos patrones pueden ser usados en sistemas de control, conocidos como sistemas de control mioeléctricos para controlar dispositivos robóticos asistidos [3].

Una de las aplicaciones más extendidas que hace uso de señales SME para el control son las prótesis mioeléctricas, que buscan reemplazar el miembro superior o inferior de personas amputadas. La primera prótesis mioeléctrica para aplicaciones clínicas fue presentada por expertos rusos en 1960, representando un incremento evolutivo en estas tecnologías. Durante los últimos 40 años, importantes aportes científicos se han logrado por diversos grupos de investigación en diferentes universidades del mundo [3]. Recientemente, otro tipo de sistemas robóticos denominados exoesqueletos robóticos ha emergido, los cuales también pueden beneficiarse del control mioeléctrico. Un exoesqueleto robótico es un mecanismo estructural externo cuyos segmentos y articulaciones se corresponden con las del cuerpo humano (estructura antropomórfica). Se adapta o acopla a una persona de modo

que el contacto físico entre el operador y el exoesqueleto permite una transmisión directa de potencia mecánica y señales de información, [4]. Por tanto, el exoesqueleto debe ser ajustable, adaptable con el fin de alinear sus articulaciones con los centros de rotación de las articulaciones del cuerpo humano tales como hombro, codo y muñeca. En la literatura existen múltiples trabajos sobre el desarrollo de exoesqueletos robóticos para aplicaciones de rehabilitación. El hecho de que el progreso de la rehabilitación física de una persona afectada en su sistema neuromotor depende de un entrenamiento intensivo principalmente de carácter mecánico, soporta la aplicación de la terapia ayudada con dispositivos robóticos. En este contexto el control mioeléctrico proporciona un efectivo canal de comunicación para controlar tales sistemas.

La ventaja más importante del control mioeléctrico para los dispositivos asistidos con respecto a otros sistemas, tales como las ortésis y prótesis pasivas, es que el control se realiza acorde a la intención del usuario. Las señales mioeléctricas son detectadas de forma no-invasiva sobre la superficie de la piel y pueden ser adaptadas de forma proporcional a la fuerza o al control de velocidad en los dispositivos robóticos asistidos [3]. Sin embargo, a pesar de sus capacidades y potencialidades, el control mioeléctrico aún presenta

una distancia significativa entre sus aplicaciones científicas y comerciales. Aunque se ha conseguido una gran efectividad en el reconocimiento de los patrones mioeléctricos para el control de exoesqueletos y otros dispositivos externos, aún se perciben dificultades en el proceso de estimación. Un exoesqueleto mioeléctrico activo debe tener la capacidad de presentar, de la forma más natural posible, los movimientos de los músculos de acuerdo con su proceso de aprendizaje. Estos precisan de una adecuada robustez contra las condiciones de variación durante la operación del mismo, sin largos períodos de entrenamiento, mediante algoritmos que detecten de forma eficaz la intencionalidad del usuario y la utilización de nuevos canales en la interfaz [1].

Las implementaciones del control mioeléctrico pueden ser divididas en tres generaciones. La primera generación contiene esquemas de control ON/OFF con simple velocidad o simple cambios de actuación. La segunda generación incluye máquinas de estados, manipulación de niveles umbrales en grandes escalas, ajustes de la razón de contracción de los músculos y control proporcional. La tercera generación incorpora microprocesadores programables que permiten un ajuste ilimitado del rango en las características del controlador mioeléctrico [3]. Las aplicaciones de esta tercera generación en el control mioeléctrico presentan un notable crecimiento en la actualidad, con beneficios en funcionalidad y costo. Las aplicaciones con microprocesadores emplean métodos de procesamiento avanzados para el procesamiento de la señal mioeléctrica e inteligencia artificial (IA), como parte del sistema de control. En este sentido, los esquemas de control basados en reconocimiento de patrones desempeñan funciones importantes, incrementando la variedad de funciones de control y mejorando la robustez [5].

El control mioeléctrico puede ser dividido en dos grupos, basados en técnicas que utilizan métodos de reconocimiento de patrones y aquellas que no utilizan estas técnicas. En el primer grupo, las clases de funciones deseadas son discriminadas a partir de patrones de señales y la variedad de funciones depende de forma directa del desempeño del clasificador. En contraste, las técnicas



que no utilizan reconocimientos de patrones están soportadas en el control de niveles umbrales y/o máquinas de estados finitos, en las cuales la respuesta está limitada a partir de comandos de control pre-definidos, basados en una secuencia de patrones de la señal de entrada [3]. El primer grupo será objeto de análisis en este trabajo.

La efectividad de los algoritmos de reconocimientos de patrones basados en SME esta soportado en la implementación de tres módulos que deben ser considerados en la selección de un óptimo vector de características. Los módulos consisten de tres etapas: pre-procesamiento, extracción de características y clasificación de patrones [6], [7]. En la evaluación cuantitativa de estos algoritmos es importante la obtención de parámetros que permitan la caracterización de la separación de clases, robustez y complejidad. Adicionalmente, en las aplicaciones de control mioeléctrico, es imperativo una ejecución de tiempo-real, así que el costo computacional de los algoritmos no deba ser muy alto [3].

Este artículo realiza una revisión de los métodos computacionales basados en reconocimiento de patrones mioeléctricos encontrados en la literatura, en lo relacionado al estado del arte para el control mioeléctrico de exoesqueletos. El trabajo describe las estructuras que conforman el sistema, analizando los diferentes métodos utilizados en la extracción de características y reconocimientos de patrones. El artículo es organizado de la siguiente forma: la estructura de los sistemas basados en reconocimiento de patrones para el control mioeléctrico se aborda

en la sección 2. Se realiza una descripción y análisis de sus componentes, definidas a partir de los módulos de segmentación de datos, extracción de características y clasificación de patrones. La sección 3 presenta una revisión de los trabajos con aplicaciones potenciales de control mioeléctrico orientado a exoesqueletos. Finalmente las conclusiones y direcciones futuras son presentadas en la sección 4.

2. Reconocimientos de patrones enfocados al control mioeléctrico

Las SME son adquiridas por electrodos de superficie en una zona muscular determinada sobre la superficie de la piel. Los electrodos son acompañados de amplificadores para discriminar las señales de interés con baja amplitud. Las señales son amplificadas, filtradas y digitalizadas a partir de sistemas de bioinstrumentación, siendo posteriormente transferidas hacia un controlador [8]. La Figura 1 presenta las etapas principales de un algoritmo para control mioeléctrico basado en reconocimientos de patrones. Las funciones generales del algoritmo se describen a continuación:

Segmentación de los datos: Debido a los requerimientos de tiempo real en el accionamiento de la prótesis, la SME se divide en segmentos de datos. Adicionalmente, este segmento debe ser lo suficientemente adecuado para reducir la varianza entre los vectores característicos con el objetivo de aumentar la exactitud en la clasificación.

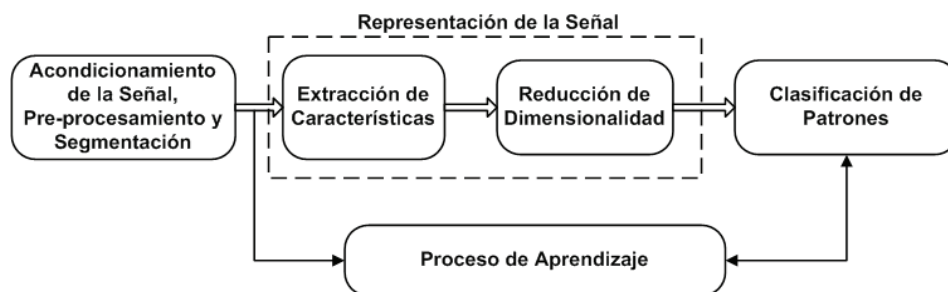


Figura 1: Etapas de un algoritmo para el control mioeléctrico basado en reconocimiento de patrones.

Extracción de características: Transforma el segmento de la SME a analizar para obtener un número reducido de características, a partir de transformaciones lineales y no-lineales.

Reducción de dimensionalidad: Optimiza las características extraídas. En algunos casos esta etapa se utiliza para disminuir la dimensionalidad del espacio característico, es decir el crecimiento exponencial del mismo con la adición de nuevas variables de entrada.

Clasificación: Efectúa el reconocimiento de los patrones de señales clasificando los mismos en categorías predefinidas.

Cada una de estas etapas será analizada a continuación, abordando aquellos métodos que han sido aplicados en el control mioeléctrico de exoesqueletos.

A. Segmentación de los Datos

Previo a la etapa de extracción de características, es de vital importancia el proceso de segmentación de los datos. Este proceso se define como el intervalo de adquisición de los datos mioeléctricos, sobre el cual posteriormente será efectuada la realización del proceso de extracción de características [3]. Teniendo en cuenta las restricciones de tiempo real, el tiempo de procesamiento y la generación de los comandos de control deben ser menores o iguales a 300 ms [3]. De igual forma, la longitud del segmento debe ser adecuada para evitar que la varianza de las características se acumule degradando el desempeño de la clasificación. Por consiguiente, existe un compromiso entre el tiempo de respuesta y la precisión del clasificador. En este contexto en [9], se demuestra que la segmentación continua de la señal en estado estacionario permite reducir el largo del segmento a 128 ms, sin un decremento considerable del desempeño del clasificador.

Las señales mioeléctricas contienen dos estados, un estado transitorio, donde se produce la activación de las fibras cuando el músculo va de reposo a un nivel de contracción voluntario y un estado permanente, que es aquel donde se produce una contracción la cual se mantiene constante en el músculo, sostenida en el tiempo [3]. En [10], se

demuestra que los datos en estado permanente son clasificados con mayor exactitud que los datos en estado transitorio y sufren de menor degradación en segmentos cortos. Los segmentos de datos con duración de 128 ms en estados permanentes presentan mayor confiabilidad cuando se precisa de una rápida respuesta del sistema, aspecto crucial en el control mioeléctrico de exoesqueletos. Esto se debe a que la SME presenta estados indeterminados durante el período de transición, entre diferentes niveles de contracción, lo que provoca que la mayoría de los errores en la clasificación se produzcan cuando se realiza la conmutación entre clases [3].

Para la segmentación de los datos son utilizados dos métodos clásicos a través de ventanas adyacentes y superpuestas [3]. La primera técnica utiliza segmentos disjuntos de largo prefijado para la extracción de características y la intención de movimiento se obtiene luego de un cierto retraso correspondiente al procesamiento. En la segunda variante, la más utilizada en el control mioeléctrico de los dispositivos asistidos robóticos, el nuevo segmento se desliza sobre el anterior, con un incremento de tiempo menor que el largo total, pero mayor que el tiempo de procesamiento, teniendo en cuenta que el sistema debe procesar el conjunto de vectores característicos, realizar la estimación de la clase de movimiento y generar un comando antes de la llegada del próximo segmento de datos. De esta forma, los segmentos




Figura 2: Técnicas de ventanas superpuestas, adaptado de [3].

más cortos producen un arreglo de comandos más denso y redundante, lo que puede mejorar el tiempo de respuesta y precisión. Sin embargo, segmentos demasiados cortos pueden conducir a fluctuaciones de varianza que afectan el proceso de estimación y clasificación de los patrones mioeléctricos. La Fig. 2 presenta un ejemplo de ventanas superpuestas. Con la segmentación continua se produce un flujo denso de decisiones usando segmentos superpuestos, que involucran tanto al estado estacionario como al transitorio. Por este motivo, es importante incluir un mecanismo de post-procesamiento para manejar la salida con excesivas clases y mejorar el desempeño del sistema, este método será abordado posteriormente.

B. Extracción de Características

Presentar una señal mioeléctrica directamente a un clasificador resulta poco práctico dado la dimensión y las características aleatorias de la misma. Es necesario que la SME sea representada por un vector de dimensiones reducidas, denominado vector característico [11]. La extracción de características es un aspecto esencial en el éxito de cualquier problema de reconocimiento de patrones, dependiendo enteramente de la calidad y optimización con que se implementa esta primera etapa [3]. La extracción de características es un método útil para extraer información oculta en las SME permitiendo eliminar información indeseada relacionada a interferencia y ruido [12].

La extracción de características posee tres categorías de análisis en los dominios del tiempo, frecuencia (espectral) y tiempo-frecuencia o tiempo-escala [3], [8]. Los primeros dos grupos de categorías son los más utilizados en el control mioeléctrico de dispositivos asistidos, debido a que las características en el dominio tiempo-frecuencia no pueden ser usadas directamente por su alta dimensión. Las características extraídas, necesitan ser reducidas a través del uso de clasificadores. Este trabajo abordará los métodos frecuentemente utilizados en la literatura sobre el control mioeléctricos de exoesqueletos en las categorías que se subdivide el proceso de extracción de categoría.

B.1 Características en el dominio del tiempo.

Debido a su simplicidad y bajo costo computacional, las características en el dominio temporal son las más utilizadas en la clasificación mioeléctrica. Estas características son calculadas, basadas en la amplitud de las series de tiempo de la señal mioeléctrica [3]. La amplitud de la señal mioeléctrica es proporcional al número de unidades motoras y su frecuencia de activación representa la energía de la señal, los niveles de activación y la fuerza [8]. La principal desventaja de este grupo de características está dada por las propiedades no-estacionarias de la señal mioeléctrica de superficie, cambiando sus propiedades estadísticas en el tiempo. Sin embargo, las características en el dominio del tiempo asumen la estacionalidad de la señal en intervalos de tiempo [13]. Entre las características utilizadas en el dominio del tiempo, se encuentran las descritas a continuación:

Integral de la señal electromiográfica (IEMG):

Este método es frecuentemente utilizado como índice de detección del inicio de la contracción muscular en el reconocimiento de patrones mioeléctricos. Se define como la suma de los valores absolutos de la amplitud de la señal y viene expresado como [14], [15]:

$$IEMG = \sum_{i=1}^N |x_i|, \quad (1)$$

donde X_i representa la señal mioeléctrica en un segmento i y N denota la longitud de la señal.

Valor absoluto medio (VAM):

Es una de las técnicas más populares utilizadas en el análisis de las señales mioeléctricas, especialmente en la detección de las SME para el control de prótesis y exoesqueletos [16]. Este se define como el valor absoluto promedio de la señal mioeléctrica en un segmento i de longitud N , y se define como:

$$VAM = \frac{1}{N} \sum_{i=1}^N |x_i|, \quad (2)$$

Valor absoluto medio modificado tipo 1:

El valor absoluto medio modificado del tipo 1 es una extensión del valor absoluto medio [17]. Para mejorar la robustez de la característica, una función ventana con peso w_i es asignada a la ecuación. La expresión viene dada por:

$$VAM1 = \frac{1}{N} \sum_{i=1}^N w_i |x_i|, \quad (3)$$

$$w_i = \begin{cases} 1, & \text{si } 0.25N \leq i \leq 0.75N \\ 0.5, & \text{en caso contrario} \end{cases}$$

Valor absoluto medio modificado tipo 2:

El valor absoluto medio modificado del tipo 2 es una extensión del valor absoluto medio, el cual es similar al MAV1 [17]. Sin embargo, la función ventana con peso w_i es una función continua, que permite suavizar el peso de la función. La expresión es definida como:

$$VAM2 = \frac{1}{N} \sum_{i=1}^N w_i |x_i|, \quad (4)$$

$$w_i = \begin{cases} 1, & \text{si } 0.25N \leq i \leq 0.75N \\ \frac{4i}{N}, & \text{si } i \leq 0.25N \\ \frac{4(i-N)}{N}, & \text{en caso contrario} \end{cases}$$

Variancia de la señal electromiográfica (VAR):

La variancia de la señal electromiográfica es un índice de potencia [12]. Se define como un promedio del valor cuadrático de la desviación estándar de la variable. Sin embargo, el valor medio de la señal mioeléctrica es cercano a 0 ($\sim 10^{-10}$). Por consiguiente la variancia de la señal electromiográfica puede definirse como:

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2, \quad (5)$$

Raíz Media Cuadrática (RMC):

La raíz media cuadrática es otra de las técnicas muy utilizadas en el análisis de las señales

mioeléctricas [18]. Este parámetro permite caracterizar la señal de acuerdo con el estimado de energía, relacionada con la amplitud en cierto intervalo de tiempo. Su expresión viene definida por:

$$RMC = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}, \quad (6)$$

Longitud de la señal (LS):

La longitud de la señal es una medida de la complejidad de la señal mioeléctrica [17]. Es una variación acumulativa de la SME que puede indicar su grado de transición. Su expresión viene definida por:

$$LS = \sum_{i=1}^{N-1} |x_{i+1} - x_i|, \quad (7)$$

Cambio de la amplitud promediada (CAP):

El parámetro de cambio en la amplitud promediada, es equivalente al parámetro LS, con la diferencia de que el parámetro LS es promediado [19]. Su expresión viene definida por:

$$CAP = \frac{1}{N} \sum_{i=1}^{N-1} |x_{i+1} - x_i|, \quad (8)$$

Cruce por cero (CC):

El parámetro del cruce por cero es una medida de la frecuencia de información de la señal mioeléctrica y es definido en el dominio del tiempo [19]. Este calcula el número de veces en que la señal cruza por cero. Para evitar las pequeñas fluctuaciones de voltaje y el ruido inducido, una condición de referencia debe ser incorporada a la expresión, definida por:

$$CC = \sum_{i=1}^{N-1} [\text{sgn}(x_i \times x_{i+1}) \cap |x_i - x_{i+1}|] \geq \text{nivel umbral}, \quad (9)$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{si } x \geq \text{nivel umbral} \\ 0, & \text{en caso contrario} \end{cases}$$

Amplitud de Willison:

La amplitud de Willison (AW) es otra medida de la información en frecuencia de la señal mioeléctrica [12]. Este parámetro calcula el número de veces en que la diferencia resultante en amplitud

de la señal mioeléctrica, entre dos segmentos consecutivos, exceden un umbral predefinido. El parámetro es un indicador de la activación de los potenciales de acción de las unidades motoras, y por consiguiente de los niveles de contracción muscular. El cálculo es formulado por:

$$AW = \sum_{i=1}^{N-1} [f(|x_n - x_{n+1}|)],$$

$$f(x) = \begin{cases} 1, & \text{si } x \geq \text{nivel umbral} \\ 0, & \text{en caso contrario} \end{cases} \quad (10)$$

Cambios en el signo de la señal (CSS):

Este es otro parámetro que representa la información en frecuencia de la señal mioeléctrica [12]. Su cálculo cuantifica el número de veces que la pendiente de la señal SME cambia de signo. El número de cambios entre las pendientes positivas y negativas, entre tres segmentos secuenciales es realizado con un nivel umbral para evitar el ruido inducido. Su expresión matemática viene definida por:

$$CSS = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) \times (x_i - x_{i+1})]],$$

$$f(x) = \begin{cases} 1, & \text{si } x \geq \text{nivel umbral} \\ 0, & \text{en caso contrario} \end{cases} \quad (11)$$

El valor de umbral disponible es normalmente escogido entre 50 μ V y 100 mV [12], [18], dependiendo de la configuración del valor de ganancia del sistema de instrumentación y del nivel de ruido inducido.

Histograma de la señal electromiográfica (HIST):

El histograma de la SME es una extensión de las características del cruce por cero y de la amplitud de Willison, por lo tanto esta característica también suministra información en frecuencias sobre la señal mioeléctrica. Los dos métodos anteriormente citados aplican un simple nivel de umbral para la SME. Sin embargo, el histograma divide los elementos en la SME en B segmentos espaciados equidistantes y retorna el número de elementos de la señal para cada segmento. En [12], el número recomendado de segmentos B es 9.

B.2 Características en el dominio de la frecuencia

El espectro de la señal mioeléctrica refleja la razón de activación de las unidades motoras por debajo de 40 Hz y la morfología de los potenciales de acción que viajan a lo largo de la fibra muscular por encima de 40 Hz [20]. La señal mioeléctrica en bajos niveles de 20% a 30% de las contracciones máximas voluntarias es asumida como estacionaria en el sentido amplio. De igual forma, para contracciones de tiempo corto de 20 s a 40 s. Para altos niveles de 50% a 80% de contracciones máximas voluntarias, su comportamiento es localmente estacionario por un período de 500 ms a 1500 ms [20]. Las características en el dominio de la frecuencia se derivan de métodos de estimación paramétricos y no paramétricos, a continuación, se revisan brevemente los más utilizados en el control mioeléctrico de exoesqueletos:

Coefficientes de los Modelos Autoregresivos (AR):

El modelo auto-regresivo es un modelo de predicción que describe cada muestra de la señal mioeléctrica como una combinación lineal de las muestras previas x_{i-p} más un término de error con ruido blanco [12], [18]. En la clasificación de las SME, los coeficientes del modelo AR a_p han sido utilizados como un vector característico. El modelo es básicamente expresado de la siguiente forma:

$$x_i = \sum_{p=1}^p a_p x_{i-p} + w_i, \quad (12)$$

donde p es el orden del modelo AR. Los parámetros auto-regresivos contienen la información que permite modelar los datos y el modo de contracción muscular [21]. Los métodos adaptativos más utilizados para la determinación de los modelos auto-regresivos, son los de mínimo cuadrado y el de mínimo cuadrado recursivo. El método de mínimos cuadrados no sufre de inestabilidad numérica y es relativamente simple de ser implementado, siendo ampliamente utilizado [21]. Sin embargo, para señales con amplio rango dinámico espectral, presenta una razón de convergencia lenta [21]. El método de míni-

mos cuadrado recursivos presenta mejor razón de convergencia que el de mínimos cuadrados, pero puede sufrir de inestabilidades numéricas. Para adecuar la implementación en tiempo real del método de mínimos cuadrados recursivos, los valores de los coeficientes del filtro son calculados de forma recursiva [22]. Los trabajos desarrollados en [21] corroboran que un modelo auto-regresivo de cuarto a sexto orden es adecuado para representar la señal mioeléctrica como una serie temporal.

Coefficientes Ceptrales:

El análisis cepstral o cepstrum es definido como la transformada de Fourier inversa del logaritmo de la magnitud del espectro de potencia de la señal [18]. Al igual que los coeficientes auto-regresivos, los coeficientes del análisis cepstral (CC) han sido utilizados como vectores característicos. Para una función de transferencia, compuesta por polos, el primer coeficiente cepstral puede ser obtenido directamente a partir de los coeficientes AR ($a_1 \dots a_p$) de un modelo de orden p -ésimo. Teniendo en cuenta lo anterior, se pueden derivar el resto, utilizando la siguiente expresión [18]:

$$c_1 = -a_1; \\ c_p = -a_p - \sum_{l=1}^{p-1} \left(1 - \frac{l}{p}\right) a_p c_{p-l}, \quad (13)$$

donde c_p es el orden p -ésimo de los coeficientes del análisis cepstral y $1 \leq l \leq P$. Teniendo en cuenta esta definición, estas características pueden ser consideradas como características en el dominio del tiempo y no requieren de la transformada de Fourier para su implementación. Los criterios de selección del orden de los coeficientes AR, pueden ser aplicables para la implementación del análisis cepstral [18].

B.3 Características en el dominio tiempo-frecuencia

Las señales mioeléctricas contienen numerosas propiedades no estacionarias o transitorias. La transformada discreta de Fourier de tiempo corto mapea una señal como una función de dos dimensiones, pero solamente se obtiene infor-

mación con exactitud limitada, determinada por el tamaño del segmento de análisis [3].

La transformada wavelet es uno de los métodos más utilizados en el dominio tiempo-escala, que a partir de los coeficientes en el dominio transformado permiten extraer información característica [23]. Adicionalmente, el análisis wavelet puede comprimir y eliminar ruido en la señal sin una apreciable degradación [24]. Una generalización de la transformada wavelet es el paquete wavelet, que permite una mejor adaptación de la señal en el dominio tiempo-escala [3].

Estas técnicas suelen ser más robusta y precisas debido a su proceso de descomposición que puede efectivamente eliminar ruidos potenciales generados en la señal mioeléctrica. Sin embargo, los mismos presentan alto costo computacional, siendo una limitante para las implementaciones en tiempo real.

Generalmente, en el proceso de extracción de características, los parámetros temporales son mezclados con otros métodos, del mismo dominio temporal y frecuencial, con el objetivo de aumentar la separabilidad de las clases, exactitud y robustez en el proceso de reconocimiento de patrones. Los resultados en lo relacionado al desempeño obtenido en la clasificación de patrones mioeléctricos, recomiendan la combinación de parámetros como el valor absoluto medio, la longitud de la señal, la amplitud de Willison y los modelos de predicción, basados en modelos auto-regresivos.

C. Clasificación de Patrones

Los vectores característicos extraídos necesitan ser organizados en clases para el reconocimiento de patrones del movimiento deseado [12]. El clasificador debe ser capaz de lidiar con patrones de variación de forma óptima, teniendo en cuenta factores externos, tales como el desplazamiento de la posición de los electrodos, fatiga y sudor. El clasificador debe adecuarse para cumplir con las restricciones de tiempo real y la eficiencia en el reconocimiento de los nuevos patrones [12]. Existen numerosas técnicas para clasificar las SME, orientadas al control mioeléctrico del



exoesqueleto. A continuación se describirán algunas de las más utilizadas:

Redes Neuronales:

Es el tipo de clasificación más usado por su facilidad de implementación y el excelente desempeño obtenido [18]. Para el diseño de la red se debe establecer el tipo de conexión de las unidades entre sí y determinar adecuadamente los pesos de estas conexiones. Convencionalmente se disponen las unidades en forma de capas, por lo que se habla de redes de una, dos o multicapas. De forma usual se suelen desarrollar redes con al menos tres capas, donde la primera actúa como un buffer de entrada, luego se encuentra las capas intermedias que extraen, procesan y memorizan la información. Finalmente, está la capa de salida donde se presenta la información clasificada. Todas las redes tienen una fase de aprendizaje, una de validación y luego una fase de aplicación. Dentro de las más utilizadas en el control mioeléctrico se encuentran las redes perceptrón multicapas con algoritmos de entrenamiento *back-propagation* [18].

Máquinas de Soporte Vectorial:

Las máquinas de soporte vectorial son muy utilizadas en el reconocimiento de patrones mioeléctricos, debido a su alta capacidad de generalización, la capacidad de clasificar patrones linealmente inseparables con baja complejidad computacional, aspecto que permite su implementación en tiempo real [25]. El principio de funcionamiento se sustenta en teorías estadísticas de aprendizaje, específicamente en el

principio de minimización de riesgo estructural [25]. Este sistema garantiza buena capacidad de generalización, debido a que el subconjunto de funciones encontradas en el proceso de optimización minimiza el riesgo actual del problema. En el diseño de las máquinas de vectores de soporte para la clasificación es importante tener en cuenta algunos aspectos como: la capacidad de generalización, ya que las máquinas de soporte no minimizan una superficie de error, sino un margen que mide la separación entre las clases, con la existencia de un mínimo global; la función núcleo que constituye una función de decisión no debe ser linealmente dependiente del espacio de entrada; otros elementos a considerar son los algoritmos de optimización y el costo computacional para mejorar el rendimiento, así como la validación del error, por pruebas simples independientes y por validación cruzada.

Sistemas de Inferencias Adaptativos (modelos neuro-difusos):

En el estado del arte de la Inteligencia Artificial se menciona que los sistemas híbridos que combinan lógica difusa, redes neuronales, algoritmos genéticos y sistemas expertos proporcionan los métodos más eficientes para resolver una gran variedad de aplicaciones. Uno de estos sistemas híbridos corresponde a los sistemas neuro-difusos, que combinan las técnicas de redes neuronales artificiales y las técnicas de inferencia difusa [26]. En la actualidad, es uno de los métodos más utilizados en el control mioeléctrico de exoesqueletos [27]-[29]. Estos sistemas propor-



cionan un mecanismo sobre la incertidumbre y las redes neuronales, ofrecen grandes ventajas computacionales, tales como el aprendizaje, adaptación, tolerancia a fallas, el paralelismo y la generalización.

Los sistemas de inferencia difusa basadas en redes neuronales adaptativas, están soportadas en el tipo de reglas si-entonces del tipo Takagi-Sugeno [30]. Estos sistemas utilizan la representación de reglas difusas mediante una topología neuronal, de tal forma que una red de neuronas se traduce en series de reglas difusas y viceversa. Los antecedentes y consecuentes de las reglas difusas son representados por neuronas distribuidas en cinco capas de la topología neuronal [26].

Los modelos neuro-difusos contienen dos conjuntos de parámetros asociados al antecedente y consecuente que deben ser entrenados. El paradigma de aprendizaje emplea algoritmos de gradiente descendiente para optimizar los parámetros del antecedente y el algoritmo de mínimos cuadrados para determinar los parámetros lineales del consecuente. Debido a esta combinación de métodos de aprendizaje se le denomina regla de aprendizaje híbrido.

D. Post-procesamiento de los Datos

La segmentación y clasificación continua utiliza completamente la capacidad del sistema de procesamiento produciendo un flujo denso de decisiones, usando segmentos superpuestos, que involucran a los estados estacionarios y transitorios. Esto trae consigo, la inclusión de un mecanismo de post-procesamiento para el manejo de la salida con excesivas clases que permitan mejorar el desempeño del sistema. El método de post-procesamiento Voto mayoritario (VM) [3], provee un mecanismo de decisión suavizado y confiable, que permite eliminar las clasificaciones espurias. En este método se incluyen la última y las siguientes m -decisiones alrededor de un punto dado para generar una nueva decisión. La decisión final en cada punto estará dada por la combinación del mayor número de ocurrencias en $2m+1$ puntos de decisión. El número de decisiones usado dependerá del tiempo de procesamiento y del retardo aceptable por el sistema [3].

E. Aplicaciones del Control Mioeléctrico en Exoesqueletos

A continuación se describen algunos trabajos relevantes reportados en la literatura, que abordan el problema de extraer información proveniente de las SME para el control de exoesqueletos robóticos.

Existen diversos exoesqueletos que se han enfocado a nivel de la mano, utilizando SME para su control, [31]-[35]. El trabajo en [31] describe un prototipo ortésico que incorpora actuadores neumáticos para apoyar la acción de agarre de la mano (ver figura 3). El dispositivo utiliza información de la SME residual para activar el movimiento asistido.

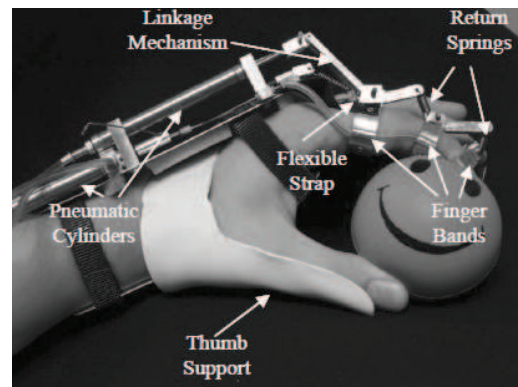


Figura 3. Dispositivo controlado por SME presentado por DiCicco, adaptado de [31].

El trabajo en [32] presenta un dispositivo robótico que permite asistir en la rehabilitación de la mano a personas que han perdido parcialmente su movilidad. La información proveniente de la SME de 2 músculos permite comandar el exoesqueleto. En el trabajo se definió un umbral, basado en la SME para controlar el sistema.

Wege describe en [33] un dispositivo robótico a nivel de la mano para apoyar la rehabilitación física de personas afectadas por apoplejía. El dispositivo en forma de exoesqueleto tiene un total de 20 GdL, permite el control de las articulaciones de los dedos y se controla mediante SME provenientes de 10 músculos del brazo y antebrazo, en combinación con información de otros sensores de fuerza y de posición.

En [34] se presenta el uso de reconocimiento de patrones basados en SME para estimar el par aplicado por la muñeca del usuario a un exoesqueleto robótico para comandarlo, y la implementación en tiempo real del controlador del dispositivo de 2 Grados de libertad (GdL) (ver figura 4).

Un exoesqueleto robótico a nivel de la mano, para el entrenamiento motor de personas afectadas por apoplejía se propuso en [35]. Este sistema determina la intención de movimiento del usuario a partir de las señales mioeléctricas del lado hemipléjico y asiste en la tarea funcional de apertura y cierre de la mano.

A nivel del miembro superior también se han reportado múltiples trabajos [36]-[44]. El trabajo presentado por Kiguchi en [36] describe un controlador neuro-borroso jerárquico para un exoesqueleto robótico y su método de adaptación. El dispositivo robótico fue concebido para asistir en el movimiento a nivel del miembro superior. El controlador propuesto utiliza SME.

El trabajo presentado en [37] propone algoritmos de control para un exoesqueleto actuado de 1 GdL, usado en procesos de fisioterapia y rehabilitación física del miembro superior. Tales algoritmos hacen uso de las SME provenientes de los músculos agonista y antagonista como información de control.

La propuesta presentada en [38] describe un nuevo método de clasificación de señales mioeléctricas provenientes de los músculos asociados a la flexión y extensión del codo. Utilizaron un modelo autoregresivo multivariable (MVAR) para los músculos de bíceps y tríceps. Los coeficientes MVAR fueron utilizados para definir la función de transferencia directa (*Directed Transfer Function – DTF*) la cual estima la intensidad de la dirección de las señales entre los canales. La máxima intensidad de la DTF fue usado como la características en el dominio de la frecuencia para la clasificación mediante máquinas de vectores de soporte.

En [39] se presenta un prototipo robótico para permitir la rehabilitación de la extremidad superior en personas afectadas por lesiones a




Figura 4. Prototipo de un exoesqueleto de mano controlado por SME, adaptado de [34].

nivel cervical, lesiones cerebrales adquiridas o apoplejía. El sistema de control del prototipo se basa en información de las SME y proporciona terapias mediante una resistencia apropiada para fomentar el progreso de la recuperación motora.

En el trabajo presentado por Gopura [40] se describen diversas técnicas para la utilización de las SME en el control de exoesqueletos robóticos.

Los estudios realizados en [41] permiten determinar la factibilidad de usar las SME para comandar una órtesis activa, para terapia física a nivel de la mano, para personas afectadas por apoplejía. El dispositivo asiste en el movimiento de flexión del dedo para realizar la función de prensión.

Con el objetivo de cancelar el temblor esencial, el trabajo en [43] presenta un exoesqueleto robótico a nivel del codo que realiza tal función, extrayendo la información de movimiento voluntario mediante las SME. Los autores proponen un método mediante redes neuronales para discriminar el movimiento voluntario tembloroso de las señales bioeléctricas.

Una revisión sobre el estado del arte de los exoesqueletos robóticos a nivel del miembro superior se presenta en [1], en el cual también se aborda el control mediante información mioeléctrica.

En la literatura también se han reportado múltiples trabajos de exoesqueletos robóticos a nivel del miembro superior y para asistir en la locomoción [44-50].

Ferris propone en [44] un prototipo robótico a nivel de la articulación del tobillo para asistir en el proceso de locomoción. El prototipo utiliza como información de control las señales

mioeléctricas provenientes de dos músculos, lo que permite implementar los movimientos de flexión plantar y la dorsi-flexión.

Fleischer reporta en [45] un estudio en el cual se presenta una interface humano-máquina que utiliza la electromiografía como principal fuente de información. Así mismo, presentan un modelo biomecánico para usar con la interface. Ellos evaluaron tal interface mediante un exoesqueleto robótico a nivel de rodilla, el cual diseñaron y construyeron. La figura 5 presenta la estructura que los autores del estudio proponen. El estudio reporta la utilización de seis canales mioeléctricos: tres del músculo extensor y tres del músculo flexor. Tal información fue implementada en un modelo que estima el par resultante en la articulación de la rodilla.

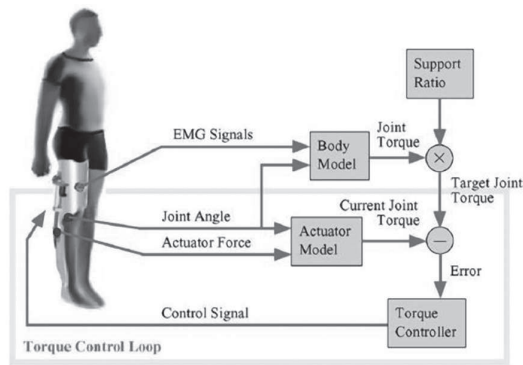


Figura 5. Estructura presentada por Fleischer, adaptado de [45].

Otro trabajo enfocado a controlar un robot exoesquelético mediante información de las SME fue propuesto en [46]. Este dispositivo estuvo dirigido para asistir en el movimiento del miembro inferior de personas afectadas en su sistema motriz.

El trabajo en [47] describe una interface basada en SME para el control de un exoesqueleto robótico (ver figura 6). Los autores utilizaron dos características extraídas de las señales mioeléctricas: los coeficientes extraídos de la Transformada de Fourier de Tiempo Corto y los coeficientes de un modelo autoregresivo de cuarto orden. El proceso de clasificación lo rea-

lizaron mediante una red neuronal. Los autores reportan que obtuvieron buen desempeño, pero no existe evidencia cuantitativa.

El trabajo presentado por Zhang [48] describe un esquema de control para un exoesqueleto robótico de tobillo que utiliza señales mioeléctricas. Los autores utilizan ocho canales de SME, a partir de los cuales se calculó el valor RMS como característica de las señales. Así mismo, se utilizó una red neuronal *back-propagation* como clasificador, y específicamente se estableció una relación entre las características de las señales mioeléctricas y los ángulos de la articulación. Posteriormente, la información extraída relacionada con el ángulo estimado se envía al controlador del exoesqueleto.

LOPES es el nombre dado a un exoesqueleto de rehabilitación de la marcha presentado en [49]. El dispositivo contiene tres articulaciones rotacionales actuadas, dos para el control de la cadera y una para el control de la rodilla.

El trabajo reportado en [50] determina la posibilidad de utilizar clasificadores basados en Máquina de Soporte Vectorial para identificar la intencionalidad de la locomoción desde señales mioeléctricas. El trabajo describe el uso de una máquina de estados, mediante sensores de contacto.




Figura 6. Exoesqueleto de rodilla controlado por SME presentado por Yan, adaptado de [47]).




Figura 7. Exoesqueleto robótico de tobillo presentado por Zhang, adaptado de [48].

Finalmente, en [51] se propone una nueva característica, extraída de las SME, mediante la transformada discreta wavelet para usarse en robots de rehabilitación. El trabajo además comparó la nueva característica propuesta con características típicas extraídas de las SME en el dominio del tiempo.

Conclusiones

En general, el problema de controlar un exoesqueleto robótico mediante señales mioeléctricas de superficie se puede abordar desde dos enfoques. Uno es el método basado en un modelo mioeléctrico en el cual es requerido establecer una relación entre el par muscular o articular y la actividad electromiográfica. El otro enfoque es el que se describe en este artículo y se basa en la caracterización de las SME y la identificación de la intencionalidad del movimiento.

En la literatura se han presentado múltiples trabajos relacionados a exoesqueletos robóticos para diferentes partes del cuerpo y controlados mediante SME. Sin embargo, la mayoría de esos trabajos se han restringido a nivel del laboratorio. Existen diversos factores que limitan el uso a nivel comercial de los dispositivos exoesqueléticos;

Tales factores son principalmente de tipo tecnológico, aunque también existen factores asociados al control. Respecto al control mioeléctrico, un futuro prometedor es el intercambio directo de información entre el sistema nervioso del usuario y el dispositivo. De esta forma, sensores periféricos colocados al interior del músculo pueden medir la información electromiográfica para la predicción de movimiento [52]. Además, tales implantes permitirían incorporar realimentación sensorial a nivel del sistema nervioso.

En la literatura, se reportan múltiples trabajos sobre exoesqueletos robóticos controlados mediante señales SME para el movimiento de simples articulaciones, pero existe muy poco sobre tales dispositivos con múltiples GdL. Se pueden establecer algunas razones:

- La obtención de la señal mioeléctrica para múltiples movimientos alcanza mayor nivel de complejidad, incluso con la misma persona.
- La predicción del movimiento en tiempo real para múltiples grados de libertad podría aumentar el costo computacional.
- La sinergia que se produce en el proceso de contracción, entre los músculos puede afectar el control de múltiples de grado de libertad.
- El rol de cada músculo en un cierto movimiento varía de acuerdo con el ángulo articular.
- Las incompatibilidades cinemáticas entre los segmentos y articulaciones del cuerpo humano y los segmentos y ejes de rotación del exoesqueleto robótico generan fuerzas indeseables que aumentan con los sistemas poli-articulados.

Apéndices

A. Aplicaciones de Control Mediante el Reconocimiento de Patrones Mioeléctricos.

El control de sistemas externos basado en el reconocimiento de patrones mioeléctricos ha sido reportado en múltiples trabajos en la literatura. La Tabla 1 recopila diversas aplicaciones del control mioeléctrico.

Agradecimientos

Este trabajo fue financiado por la Vicerrectoría de Ciencia, Tecnología e Innovación (VCTI) de la Universidad Antonio Nariño de Colombia y el Centro de Biofísica Médica de la Universidad de Oriente de Cuba.

Referencias

- [1] H.S. Lo, S.Q. Xie, “Exoskeleton robots for upper-limb rehabilitation: State of the art and future prospect”, *Medical Engineering & Physics*, 2012, Vol. 34, No. 3, p.p. 261-268.
- [2] C J. De Luca, Electromyography. *Encyclopedia of Medical Devices and Instrumentation*: Editorial John Wiley, 2006.
- [3] M. A. Oskoei y H. Hu, “Myoelectric control systems — A survey”, *Biomedical Signal Processing and Control*, vol. 2, pp. 275-294, 2007.
- [4] J.L. Pons, *Wearable Robots, Biomechatronic Exoskeletons*: Editorial John Wiley, 2008.
- [5] K. Englehart, B. Hudgins y P. Parker, *Intelligent Systems and Technologies in Rehabilitation Engineering*: Editorial CRC Press, 2001.
- [6] M. Zecca, S. Micera, M.C. Carroza, y P. Dario, “Control of multifunctional prosthetic hands by processing the electromyographic signal”, *Critical Reviews in Biomedical Engineering*, vol. 30(4-6), pp. 459-485, 2002.
- [7] P. Angkoon, P. Pornchai y L. Chusak, “Feature reduction and selection for EMG signal classification”, *Expert Systems with Applications*, vol. 39, pp. 7420-7431, 2012.
- [8] R. Merletti, A. Botter, A. Troiano, E. Merlo y M. A. Minetto, “Technology and instrumentation for detection and conditioning of the surface electromyographic: State of the art”, *Clinical Biomechanics*, vol. 24, pp. 122-134, 2009.
- [9] K. Englehart y B. Hudgins, “A robust, real time control scheme for multifunction myoelectric control”, *IEEE Trans. Biomedical Eng.*, vol. 50(7), pp. 848-854, 2003.
- [10] K. Englehart, B. Hudgins y P. A. Parker, “A wavelet-based continuous classification scheme for multifunction control”, *IEEE Trans. Biomedical Eng.*, vol. 48(3), pp. 302-310, 2001.
- [11] R. Merletti y P. Parker, *Electromyography Physiology, Engineering and Noninvasive Applications*: Editorial IEEE Press Engineering in Medicine and Biology Society, 2004.
- [12] M. Zardoshti-Kermani, B.C. Wheeler, K. Badie y R.M. Hashemi, “EMG feature evaluation for movement control of upper extremity prostheses”, *IEEE Transactions on Rehabilitation Engineering*, vol. 3(4), pp. 324-333, 1995.
- [13] M. Lei, Z. Wang y Z. Feng, “Detecting non-linearity of action surface EMG signal”, *Physics Letters A*, 2001, vol. 290(5-6), pp. 297-303.
- [14] H.P. Huang y C.Y. Chen, “Development of a myoelectric discrimination system for a multi-degree prosthetic hand”, en *Proc. of IEEE International Conference on Robotics and Automation* vol. 3, pp. 2392–2397, 1999.
- [15] R. Merletti, “Standards for reporting EMG data”, *Journal of Electromyography and Kinesiology*, vol. 6(1), III-IV, 1996.
- [16] B. Hudgins, P. Parker y R. Scott, “A new strategy for multifunction myoelectric control”, *IEEE Transactions on Biomedical Engineering*, vol. 40(1), pp. 82–94, 1993.
- [17] M. A. Oskoei y H. Hu, “Support vector machine based classification scheme for myoelectric control applied to upper limb”, *IEEE Transactions on Biomedical Engineering*, vol. 55(8), pp. 1956–1965, 2008.
- [18] R. Boostani y H. Moradi, “Evaluation of the forearm EMG signal features for the control of a prosthetic hand”, *Physiological Measurement*, vol. 24(2), pp. 309–319, 2003.
- [19] A. Fougner, *Proportional myoelectric control of a multifunction upper limb prosthesis*: Tesis de Maestría, Norwegian University of Science and Technology, Trondheim, Norway, 2007.
- [20] S. Karlsson, J. Yu y M. Akay, “Enhancement of spectral analysis of myoelectric signals during static contractions using wavelet methods”, *IEEE Trans. Biomed. Eng.*, vol. 46(6), pp. 670–684, 1999.

- [21] S. V. Vaseghi, *Advanced Digital Signal Processing and Noise Reduction*: Editorial Wiley, 2000.
- [22] E. C. Ifeachor y B. W. Jervis, *Digital Signal Processing: A Practical Approach*: Editorial Addison-Wesley, 1993.
- [23] S. Ferguson y G. R. Dunlop, "Grasp Recognition from Myoelectric Signals", *Proc. Australian Conference on Robotics and Automation*, pp. 83-87, 2002.
- [24] A. Phinyomark, Ch. Limsakul Ch. y P. Phukpattaranont, "A Comparative Study of Wavelet Denoising for Multifunction Myoelectric Control", *Proc. International Conference on Computer and Automation Engineering*, pp. 21-25, 2009.
- [25] V. Vapnik, *The Nature of Statistical Learning Theory*: Editorial Springer, 1995.
- [26] T. Takagi y M. Sugeno, "Fuzzy Identification of Systems and its Applications to Modeling and Control", *IEEE Trans. Systems, Man and Cybernetics*, vol15, pp. 116-132, 1985.
- [27] R.A.R.C. Gopuray K. Kiguchi, "Electromyography (EMG)-signal based fuzzy-neuro control of a 3 degrees of freedom (3DO F) exoskeleton robot for human upper-limb motion assist", *Journal of the National Science Foundation of Sri Lanka*, vol. 37(4), pp. 241-248, 2009.
- [28] H-J. Liu y K-Y. Young, "An Adaptive Upper-Arm EMG-Based Robot Control System", *International Journal of Fuzzy Systems*, Vol. 12(3), pp. 181-189, 2010.
- [29] G. W. Favieiro y A. Balbinot, "Adaptive Neuro-Fuzzy Logic Analysis Based on Myoelectric Signals for Multifunction Prosthesis Control", *Proc. 33rd Annual International Conference of the IEEE EMBS*, 2011, pp. 7888-7891.
- [30] J-S. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System", *IEEE Tran. Systems, Man and Cybernetics*, vol. 23, pp. 665-685, 1996.
- [31] M. DiCicco, L. Lucas, Y. Matsuoka, "Comparison of Control Strategies for an EMG Controlled Orthotic Exoskeleton for the Hand", *Proceedings of the 2004 IEEE International Conference on Robotics & Automation*, p.p. 1622- 1627.
- [32] M. Mulas, M. Folgheraiter, G. Gini, "An EMG-controlled Exoskeleton for Hand Rehabilitation", *Proceedings of the 2005 IEEE 9th International Conference on Rehabilitation Robotics*, p.p. 371-374.
- [33] A. Wege, A. Zimmermann, "Electromyography Sensor Based Control for a Hand Exoskeleton", *Proceedings of the 2007 IEEE Int. Conf. on Robotics and Biomimetics*, p.p. 1470-1475.
- [34] Z.O. Khokhar, Z.G. Xiao, C.Menon, "Surface EMG pattern recognition for real-time control of a wrist exoskeleton", *BioMedical Engineering OnLine* 2010, 9:41.
- [35] N.S.K. Ho, K.Y. Tong, X.L. Hu, K.L. Fung, X.J. Wei, W. Rong, and E.A. Susanto, "An EMG-driven Exoskeleton Hand Robotic Training Device on Chronic Stroke Subjects", in *Proc. IEEE Int. Conf. on Rehabilitation Robotics (ICORR)*, 2011, pp. 1 – 5.
- [36] Kazuo Kiguchi, Takakazu Tanaka, and Toshio Fukuda, "Neuro-Fuzzy Control of a Robotic Exoskeleton with EMG Signals", *IEEE Transactions on Fuzzy Systems* Vol. 12, Issue 4, 2004, pp. 481 – 490.
- [37] M.A. Mikulski, "Electromyogram Control Algorithms for the Upper Limb Single-DOF Powered Exoskeleton", in *Proc. IEEE Int. Conf. on Human System Interactions (HSI)*, 2011, pp. 117 – 122.
- [38] R. Latif, S. Sanei, and K. Nazarpour, "Classification of elbow electromyography signals based on directed transfer functions", in *Proc. IEEE Int. Conf. on BioMedical Engineering and Informatics*, 2008, pp. 371 – 374.
- [39] D. S. Andreasen, S.K. Allen, and D.A. Backus, "Exoskeleton with EMG Based Active Assistance for Rehabilitation", in *Proc. IEEE Int. Conf. on Rehabilitation Robotics*, 2005, pp. 333 – 336.
- [40] R.A.R.C. Gopura and Kazuo Kiguchi, "Application of Surface Electromyographic Signals to Control Exoskeleton Robots", en *Applications of EMG in Clinical and Sports Medicine*, 2012,

Dr. Catriona Steele (Ed.), ISBN: 978-953-307-798-7.

[41] J.M. Ochoa, M. Listenberger, D.G. Kamper, and S. Wook Lee, "Use of an Electromyographically Driven Hand Orthosis for Training after Stroke", in Proc. IEEE Int. Conf. on Rehabilitation Robotics (ICORR), 2011, pp. 1 – 5.

[42] A.C. Tsai, J.J. Luh, and T.T. Lin, "A Modified Multi-Channel EMG Feature for Upper Limb Motion Pattern Recognition", 34th Annual International Conference of the IEEE EMBS, 2012, pp. 3596-3599.

[43] T. Ando, M. Watanabe, K. Nishimoto, Y. Matsumoto, M. Seki, and M.G. Fujie, "Myoelectric-Controlled Exoskeletal Elbow Robot to Suppress Essential Tremor: Extraction of Elbow Flexion Movement Using STFTs and TDNN", *Journal of Robotics and Mechatronics*, Vol. 24, No. 1, pp. 141-149, 2012.

[44] D.P. Ferris, K.E. Gordon, G.S. Sawicki, A. Peethambaran, "An improved powered ankle-foot orthosis using proportional myoelectric control", *Gait & Posture* 23 (2006) 425–428.

[45] C. Fleischer and G. Hommel, "A Human-Exoskeleton Interface Utilizing Electromyography", *IEEE Transactions on Robotics*, 2008, Vol. 24, No. 4, p.p. 872-882.

[46] H. He and K. Kiguchi, "A Study on EMG-Based Control of Exoskeleton Robots for Human Lower-limb Motion Assist", in Proc. IEEE Int. Conf. on Information Technology Applications in Biomedicine, 2007, pp. 292 – 295.

[47] Hui Yan, Ray P.S. Han, Yu Wang and Jieru Chi, "Controlling a Powered Exoskeleton System

via Electromyographic Signals", Proceedings of the 2009 IEEE International Conference on Robotics and Biomimetics, 2009, p.p. 349-353.

[48] Z. Zhang, J. Jiang, L. Peng, and H. Fan, "A Method to Control Ankle Exoskeleton with Surface Electromyography Signals", In proceeding of: Intelligent Robotics and Applications - Third International Conference, ICIRA 2010, Shanghai, China, November 10-12, 2010, p.p. 390-397.

[49] J.F. Veneman, R. Kruidhof, E.E.G. Hekman, R. Ekkelenkamp, E.H.F. Van Asseldonk, and H. van der Kooij, "Design and Evaluation of the LOPES Exoskeleton Robot for Interactive Gait Rehabilitation", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 15, Issue 3, 2007, pp. 379 – 386.

[50] E. Ceseracciu, M. Reggiani, Z. Sawacha, M. Sartori, F. Spolaor, C. Cobelli, E. Pagell, "SVM classification of locomotion modes using surface electromyography for applications in rehabilitation robotics", *RO-MAN, 2010 IEEE*, pp. 165 – 170.

[51] Feng Zhang, Pengfeng Li, Zeng-Guang Hou, Yixiong Chen, Fei Xu, Jin Hu, Qingling Li, Min Tan, "SEMG Feature Extraction Methods for Pattern Recognition of Upper Limbs", in Proc. IEEE Int. Conf. on Advanced Mechatronic Systems (ICAMechS), 2011, pp. 222 – 227.

[52] X. Navarro, T.B. Krueger, N. Lago, S. Micera, T. Stieglitz, P. Dario, "A critical review of interfaces with the peripheral nervous system for the control of neuroprostheses and hybrid bionic systems", *Journal of Peripheral Nervous Systems*, 2005 Sep;10(3):229-58.

Tabla 1. Múltiples aplicaciones derivadas del control mioeléctrico, adaptada de [3].

Reference	Application	Class	Channel	Classifier	Feature
Hudgins et al. [31]	Upper limb prosthesis	4 Class motion	2-Channel	MLP NN	MAV,MAVS,ZC,SSC,WL
Englehart et al. [1]	Upper limb prosthesis	6-Class motion	4-Channel	PCA/LDA	STFT, WT, WPT
Huang et al. [3]	Upper limb prosthesis	6-Class motion	4-Channel	GMM/MV	RMS, AR
Kiguchi et al [3]	3-DOF assisting exoskeleton	6-Class motion	11-Channel	Neuro-fuzzy network	MAV
Fukuda et al [7,8]	Human-assisting manipulator	8-Class motion	6-Channel	LLGMN/(online training)	-
Vuskovic and Du [15]	Finger joints control	6-Class motion	4-Channel	Simplified fuzzy ARTMAP network	-
Carrozza et al. [35]	Prosthetic hand (1-DOF)	2-State	2-Channel	FSM	-
Felzer and freisleben [29]	Prosthetic Wheelchair	5-State	Forehead muscle	FSM	-
Han et al. [33]	Prosthetic Wheelchair	4-State	Near Neck muscles	Fuzzy min-max Neural networks (FMMNN)	IAV, VAR
Moon et al. [34]	Prosthetic Wheelchair	4 State	Shoulder Elevation gestures	FSM	MAV
Lamounier et al. [11]	Mechanism to train parients To work with myoelectric prosthesis	4-Class motion	5-Channel	MLP NN	AR
Barniu et al. [26]	Virtual environment (VE) to Eliminate latencies		8-Channel	PCA/ICA MLP NN	MA, ZC, etc.
Nilas et al. [28]	Morse code-based commands For human-assisting Or rehabilitating robots	8-Class motion	2-Channel		MA
Ju et al. [25]	User interface for portable Consumer electronics	4-Class gestures	2-Channel	HMM	AR
Au and kirsch [16]	Functional Neuromuscular Stimulation (FNS) in a Paralyzed shoulder and elbow	8-Class motion	6-Channel	TDA NN	
Chris todoulou And patrchis [12]	To diagnose Neuromuscular Disorders		Unsupervised Single-Channer Biceps muscle	ANN SOFM, LVQ	
Khalil and Duchene [23]	Characterizing events in uterine MES for preterm bishth	4-Class events		DCS	WT

• Alberto López Delis • Andrés F. Ruiz Olaya •