

Detección de la Intención de Movimiento Durante la Marcha a Partir de Señales Electromiográficas

J. Villarejo^a, E. Caicedo^b, O. Campo^b.

(a) Universidad del Valle/ Grupo de Percepción y Sistemas Inteligentes, Colombia.

(b) Universidad Autónoma de Occidente/ Grupo de Investigaciones en Bioingeniería, Colombia.

(Recibido: Abril 24 de 2008- Aceptado: Noviembre 24 de 2008)

RESUMEN

En este trabajo se presenta el desarrollo de un sistema software para el procesamiento, caracterización y clasificación de señales electromiográficas de superficie aplicando técnicas de inteligencia computacional, a fin de detectar intencionalidad en cambios repentinos de movimiento durante la marcha y determinar la función que debe realizar una prótesis transfemoral basada en un sistema de control mioeléctrico en tiempo real, que sea adaptable al usuario y al terreno.

Las señales adquiridas en individuos no amputados de diferente sexo y edad, son segmentadas para realizar un proceso de extracción de características en tiempo real combinando estimativos temporales y frecuenciales conformando un conjunto de patrones característicos aplicando reducción de dimensionalidad con análisis de componentes principales (PCA). Se realizó un reconocimiento de patrones relacionados con seis clases de movimientos, con redes neuronales perceptrón multicapa, redes de base radial y redes probabilísticas, obteniendo resultados de clasificación muy similares entre ellos.

PALABRAS CLAVE: EMG, Prótesis Transfemoral, Reconocimiento de Patrones, Redes Neuronales, Inteligencia Computacional.

Detección de la Intención de Movimiento Durante la Marcha a Partir de Señales Electromiográficas

RESUMEN

En este trabajo se presenta el desarrollo de un sistema software para el procesamiento, caracterización y clasificación de señales electromiográficas de superficie aplicando técnicas de inteligencia computacional, a fin de detectar intencionalidad en cambios repentinos de movimiento durante la marcha y determinar la función que debe realizar una prótesis transfemoral basada en un sistema de control mioeléctrico en tiempo real, que sea adaptable al usuario y al terreno.

Las señales adquiridas en individuos no amputados de diferente sexo y edad, son segmentadas para realizar un proceso de extracción de características en tiempo real combinando estimativos temporales y frecuenciales conformando un conjunto de patrones característicos aplicando reducción de dimensionalidad con análisis de componentes principales (PCA). Se realizó un reconocimiento de patrones relacionados con seis clases de movimientos, con redes neuronales perceptrón multicapa, redes de base radial y redes probabilísticas, obteniendo resultados de clasificación muy similares entre ellos.

PALABRAS CLAVE: EMG, Prótesis Transfemoral, Reconocimiento de Patrones, Redes Neuronales, Inteligencia Computacional.

1. INTRODUCCIÓN

Uno de los factores más importantes para el control de prótesis y órtesis es la capacidad de descubrir la intención de la persona al realizar cierta actividad como levantarse, permanecer quieto, caminar y sentarse. La detección de la intención de una persona al realizar una de estas actividades los releva del esfuerzo consciente del funcionamiento del sistema. El uso de la electromiografía ha sido extenso en este estudio [1].

Los patrones de la señal Electromiografía (EMG) varían entre diferentes individuos. Más aún, los cambios fisiológicos en los músculos, cambios en el contacto electrodo-piel, la impedancia eléctrica de la piel, la ubicación de los electrodos, variaciones en el tiempo causadas por fatiga, sudor, etc., difieren entre usuarios y en diferentes instantes. El problema de modificaciones relacionadas con estas variaciones entre diferentes personas y diferentes momentos de captura son los principales aspectos a resolver. Por lo tanto es necesario que un procesamiento de la señal EMG se adapte a esos cambios con el fin de minimizar las clasificaciones erróneas.

Un amputado puede poseer los músculos del muñón intactos, aunque incapaces de realizar cualquier función [2] [3]. En la figura 1 se muestra el diagrama general de control de una prótesis transfemoral mioeléctrica. Las prótesis mioeléctricas recogen la señal EMG de estos músculos residuales durante el movimiento del individuo en diferentes entornos, la procesan y la utilizan como señal de control para gobernar unos actuadores que pueden hacer las funciones del

miembro original, de manera que se logre la interacción con el medio. Por tanto, el amputado puede recuperar parte de las funcionalidades de su antiguo miembro mediante la contracción o reposo de unos músculos que, en otro caso, habrían de serle inútiles.

El reconocimiento de patrones electromiográficos ha sido aplicado para controlar dispositivos protésicos para amputados. Este control es posible debido al hecho de que los amputados mantienen un patrón repetible EMG en los músculos remanentes del miembro amputado, correspondiente a características funcionales durante la marcha, específicamente la flexo extensión de la cadera [4].

Se pretende entonces implementar un sistema software de detección de intención de movimiento a partir de señales biológicas aplicando técnicas de inteligencia computacional. A partir de la captura de señales EMG, producidas en músculos específicos durante la marcha, se pretende realizar un análisis de reconocimiento e interpretación de patrones con el fin de obtener una caracterización de la intención de movimiento en la pierna para amputados transfemorales. El propósito de obtener una identificación de la intención de movimiento durante la marcha en una prótesis por encima de rodilla (AKP) representa una gran ventaja sobre otras debido a que puede hacer mucho más fácil el proceso de aprendizaje, de adaptación y uso de la misma. Conforme a lo anterior, es interesante aplicar técnicas de inteligencia computacional para tal fin buscando obtener resultados superiores a los obtenidos con las técnicas tradicionales utilizadas para la identificación de movimiento.

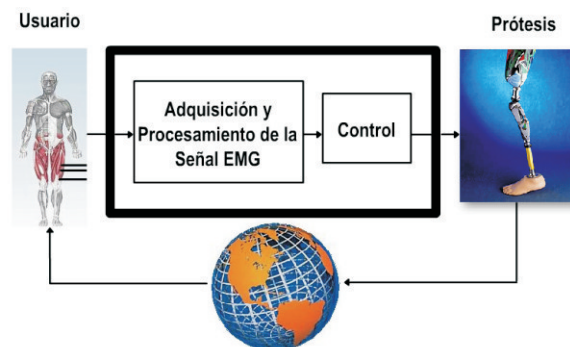


Fig. 1. Diagrama general del control de una prótesis transfemoral mioeléctrica

2. METODOLOGÍA

2.1. Adquisición de la Señal

Para diferenciar la actividad muscular durante el ciclo de la marcha en las etapas de apoyo y balanceo se propone el registro de dos músculos que realicen funciones antagónicas, por lo que se deben capturar dos señales de forma simultánea. Experimentalmente se seleccionaron los músculos capaces de ser medidos por electromiografía superficial y que respondieron de mejor manera a las dinámicas propuestas. Éstos son el recto anterior (RA) y semi-membranoso (SM). La captura de la señal EMG de los músculos se realizó en diferentes actividades de marcha con un amplificador con dos canales en configuración diferencial, a través de 5 electrodos. Dos electrodos para cada canal y uno común a ambos canales ubicado sobre un tejido aislado del movimiento. Es importante asociar con precisión cada segmento de la señal a las distintas fases y eventos durante la marcha, por lo que se realizó un análisis biomecánico para cada prueba por medio de registros filmográficos obteniendo información sobre el contacto y despegue del talón, y los instantes en que ocurría el cambio de dinámica para así identificar y relacionar los eventos a clasificar.

2.2 Diseño Experimental

La base de datos se obtuvo mediante un conjunto de pruebas para el registro de señales EMG, relacionadas con cada uno de los gestos de marcha que se desean identificar: bajando/subiendo gradas, bajando/subiendo rampa (dos ángulos diferentes) y cambios de velocidad. A partir de estas dinámicas se determinan cada una de las clases dentro del clasificador. Las pruebas se realizaron con 10 personas sanas teniendo en cuenta que las señales de las personas amputadas no difieren significativamente con las de un sujeto no amputado [5] de ambos sexos, entre los 22 y 50 años de edad. Cada prueba se realizó 5 veces para cada paciente con un registro de señal de aproximadamente 8 segundos.

El esquema formal para la adquisición y análisis de la señal EMG para el control de dispositivos protésicos está compuesto de varios módulos:

- Acondicionamiento y procesamiento de la señal.
- Extracción de características.
- Reducción de dimensionalidad.
- Reconocimiento de patrones.

Para esto se desarrolló una herramienta software que permite al usuario realizar las diferentes tareas de procesamiento, extracción de características y clasificación.

2.3 Acondicionamiento y Procesamiento de la Señal.

Las señales obtenidas por medio de las pruebas fueron pre-procesadas y adecuadas para la clasificación. Para ello se remuestreó la señal digital a una frecuencia de muestreo de 4KHz, se normalizó con valores entre 1 y -1 para reducir las diferencias de las magnitudes de la señal entre las personas, y finalmente se filtró por medio de dos filtros digitales, un filtro paso bajo IIR elíptico de orden 9 con frecuencia de corte 500Hz, y un filtro paso alto IIR Butherworth de orden 6 con frecuencia de corte de 25Hz. Para lograr procesar la señal en tiempo real, se tomaron segmentos suficientemente cortos de señal adecuados, de tal forma que el sistema sea capaz de procesarlos y responder ante un evento de forma acertada. Estudios realizados han determinado el tiempo mínimo que se requiere para detectar la intención de movimiento [6] [7] (Lee., 1998), y el retardo máximo aceptable antes de que el paciente se sienta frustrado por una respuesta lenta de la prótesis [8]. Basado en estos estudios se determinó que los segmentos de tiempo apropiados para procesar la señal fueran de 200ms. Cada uno de estos segmentos corresponde a un patrón.

2.4 Extracción de Características

En esta fase la señal EMG medida es procesada a fin de acentuar la información más relevante en los datos que permita lograr una clasificación y rechazar tanto ruido como datos irrelevantes, produciendo un conjunto de características que reduce la dimensionalidad del problema de reconocimiento de patrones. Las características extraídas deben contener suficiente información para representar el patrón EMG de forma adecuada, y ser bastante simples para el clasificador.

Considerando trabajos anteriores [6] [7] [9] [10] [11] [12] [13] [14], los siguientes parámetros característicos basados en el tiempo, la frecuencia y estadística espectral, fueron escogidos para representar los patrones mioeléctricos.

1) Características en el Dominio del Tiempo:

- Valor Medio Absoluto
- Valor Absoluto Medio Diferencial
- Valor Medio Absoluto en Pendiente
- Amplitud Willison
- Varianza de la señal EMG
- Cruces por Cero
- Cambio de Signo en Pendiente
- Valor RMS, Momentos de Orden Superior

2) Características con Modelos Autorregresivos:

- Coeficientes del Modelo AR:
Se aplicó el modelo AR de orden 5 y se tomaron los primeros 3 coeficientes.

3) Características en el Dominio de la Frecuencia:

- Potencia Promedio
- Potencia Máxima
- Frecuencia de la Máxima Potencia
- Análisis Cepstrum (Coeficientes Cepstrales): Se tomaron los primeros 20 coeficientes.

4) Características en tiempo-frecuencia.

- Descomposición con Wavelet Packet: La base de la WPD es escogida usando una función de costo basada en entropía. Para la extracción de características por medio de WPD, se utilizó una wavelet del tipo Daubechies de orden 6 con 5 niveles de descomposición, y una función de costo, tipo shannon, correspondiente a la función de entropía mínima.

Las características son extraídas de cada segmento de tiempo de cada señal. A todas estas características se les aplicó un proceso de selección escogiendo sólo aquellas características que realmente aportaran información para el reconocimiento.

Luego de la selección de las características se aplicó un proceso de proyección con el método de Análisis de Componentes Principales (PCA) tomando el 40% de los componentes principales conservando el 96% de la información completa.

2.5 Clasificación

A partir de las características extraídas se conformó una matriz de patrones característicos para cada señal. Estos patrones también fueron normalizados debido a los niveles de magnitud que se encontraban en ellas y que no se relacionan entre sí. Se conformó entonces una base de datos con todos los patrones asociando cada uno de ellos a un gesto marcha respectivo; se tomó el 60% de los patrones de forma aleatoria para entrenamiento y los restantes para validación.

Se implementaron tres clasificadores basados en la familia de Redes Neuronales Artificiales feed-forward: Una red Perceptrón Multicapa (MLP) y una red Función Base Radial (RBF). El número de neuronas de la capa de entrada depende del número de elementos del vector característico de los patrones y en la capa de salida se tiene una neurona para cada clase de tal forma que la neurona con mayor peso corresponde a la salida de la red.

El clasificador MLP diseñado consiste de una capa oculta con 15 neuronas, una capa de entrada y otra de salida. Se asumió el algoritmo Levenberg - Marquardt backpropagation como función de entrenamiento y como función de activación para la capa oculta y la capa de salida se tomó la función sigmoideal tangente hiperbólica y sigmoideal logística respectivamente. Previos trabajos han mostrado que sólo una capa oculta es suficiente para esta aplicación[15][16].

El diseño del clasificador RBF es más simple y consistió de una red de 3 capas con un número máximo de neuronas ocultas igual a 70 y el valor de la dispersión con un valor de 25. El diseño de la red PNN tan sólo requiere configurar el parámetro de dispersión teniendo que con 1.8 se obtiene el mejor resultado.

3. RESULTADOS

Tomando el conjunto de patrones obtenido, el porcentaje de acierto de clasificación para la red

Tabla 1. Porcentaje de acierto por clase

Clasificador	Porc. Acierto [%]	Clase con Mayor Acierto	Porc. Acierto Mayor [%]
MLP	59.2	Marcha Normal	77.6
RBF	52.7	Marcha Normal	57.0
PNN	50.0	Subir Gradadas	54.9

MLP entrenada fue del 59.2%, teniendo como mejor clasificación la clase correspondiente a marcha normal con un 77.6%. El porcentaje de acierto de clasificación para la red RBF fue de 52.7%, teniendo como mejor clasificación la clase correspondiente a marcha normal con un porcentaje de 57% de clasificaciones correctas. El porcentaje de acierto para la red PNN fue del 50%, y la clase que obtuvo la mejor clasificación fue subir gradadas con un porcentaje de 54.93%. Estos datos se reúnen en la Tabla 1.

Además, se aplicó un comité de clasificadores que actúan en paralelo, donde se creó un clasificador para cada una de las clases que sólo se encarga de determinar si un patrón pertenece a una clase específica ó a cualquiera de las otras. Finalmente el

clasificador que mayor acierto presenta determina la salida del comité. Los resultados obtenidos mediante esta metodología muestran que existe una mejora en el número de patrones clasificados de modo correcto con un 61.3% de acierto en la clasificación, donde la clase que tuvo el mayor acierto de clasificación corresponde a marcha normal con un porcentaje del 77.6% de acierto. Los resultados de la clasificación, se presentan como una matriz de confusión, que indica el porcentaje de confusión al clasificar de forma equivocada un patrón como una clase distinta a la que pertenece.

Se conformaron otras bases de datos variando el número de dinámicas para clasificar, tomando en cuenta, en primera medida el estado de reposo como una clase adicional y en otros casos eliminando los patrones correspondientes a la marcha normal,

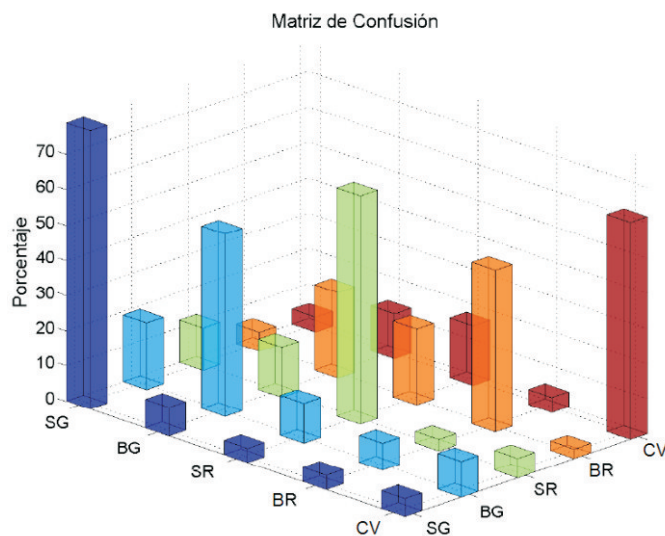


Fig. 2. Matriz de confusión con comité de clasificadores MLP para 5 clases.

donde el clasificador debe diferenciar hasta 7 clases de patrones EMG. Con un comité de clasificadores MLP el porcentaje de acierto de clasificación para estas 7 clases fue de 52.72%, con el acierto más alto del 76.22% para marcha normal. Los resultados obtenidos, con sólo 5 clases, muestran un mejoramiento notable al clasificar de forma correcta el 63.5% de los patrones de validación, con un 78.8% de acierto para la clase *subir gradas*, siendo ésta la más alta, presentando los porcentajes más altos con lo que se observa que entre estas clases hay una mayor separabilidad. En la figura 2 se muestra la matriz de confusión obtenida para la clasificación con 5 dinámicas.

4. CONCLUSIONES

El periodo de tiempo de segmentación de la señal influye considerablemente en los resultados y en el funcionamiento del sistema de clasificación. El sistema desarrollado permite la aplicación en tiempo real, lo que constituye un aspecto fundamental en este tipo de aplicaciones. Esto se compara frente a otros sistemas de clasificación en donde se obtienen resultados muy superiores pero que no pueden ser aplicados en tiempo real, lo cual impide su aplicación directa en un dispositivo real. El número de canales empleados para capturar la señal indica el nivel de complejidad que puede tener el clasificador, lo que influye en el peso computacional y el tiempo de procesamiento y de respuesta de la prótesis.

Al aumentar el número de clases a diferenciar con la red neuronal existe mayor probabilidad de confusión como se pudo comprobar con los resultados obtenidos para 5, 6 y 7 clases. En la actualidad el número de movimientos a diferenciar ha aumentado mejorando el funcionamiento de la prótesis para las necesidades de los usuarios y para tratar de reproducir los movimientos lo más cercano posible a como lo hace un miembro natural. El número de clases que se plantean en este trabajo es muestra de una mejoría en algunos estudios realizados recientemente como el trabajo realizado por [17] en donde sólo identifican el tipo de terreno entre plano, pendiente o escalera, sin distinguir entre subir o bajar, ni cambios de velocidad.

Los resultados obtenidos por los distintos métodos de clasificación muestran que es posible diferenciar el terreno cuando se trata de una escalera y un plano inclinado, y diferenciar cuando se está bajando y cuando se está subiendo. Además, se logró reducir en cierta medida las variaciones que existen en los patrones, relacionadas con diferencias de sexo, edad, con una condición física distinta y con la naturaleza aleatoria de la señal.

La reducción de dimensionalidad en el conjunto del espacio de características permite resultados similares a los obtenidos con el conjunto completo, significando ésto una ventaja para reducir el costo computacional y el tiempo de procesamiento. La transformada Wavelet Packet proporciona el mejor resultado en la clasificación con características individuales. La clasificación, empleando un comité de clasificadores en paralelo, obtuvo un mejor desempeño que con un sólo clasificador para todas las clases.

5. REFERENCIAS

- [1] S. Hussein & M. Granat. *Intention Detection Using a Neuro-Fuzzy EMG Classifier*, Engineering in Medicine and Biology Magazine IEEE, 21, pp. 123-129. 2002.
- [2] S. L. Saridis., *The control of a prosthetic arm by EMG pattern recognition*, IEEE Trans. Automat. Contr., AC-29, pp. 290-302. 1984.
- [3] M. K. Morin., *Parallel cascade classification of myoelectric*. IEEE Conf. Eng. Med. Biol., pp. 1399-1400. 1995.
- [4] Y. Y. Chan, *Fuzzy EMG Classification for Prosthesis Control*. IEEE Transactions on Rehabilitation Engineering, 8(3):305-311. 2000.
- [5] E. M. P. O'Neill, (1995). *Myoelectric Signal Characteristics from Muscles in Residual Upper Limbs*. IEEE Transactions on Rehabilitation Engineering, 2(4).
- [6] B. Hudgins, *A new strategy for multifunction myoelectric control*. IEEE Transactions on Biomedical and Engineering, BME- 40:82-94. 1993.

- [7] S. P. Lee., (1998). EMG Pattern Recognition Based on Artificial Intelligence Techniques. *IEEE Transactions on Rehabilitation Engineering* , 6(4):400–405.
- [8] O, Campo, Detección de Cambios Repentinos de Velocidad en Marcha Normal. *II Congreso Colombiano de Bioingeniería e Ingeniería*, 2005
- [9] SENIAM PROJECT. *Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles*. (n.d.). Retrieved from www.seniam.org.
- [10] G. G. Betancourt, *Reconocimiento de Patrones de Movimiento a Partir de Señales Electromiográficas*. Scientia et Technica Año X (26).2004.
- [11] S. M., Zecca, *Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal*. *Critical Reviews in Biomedical Engineering*, 30:459–485, 2002.
- [12] A. S. Lamounier, *A virtual prosthesis control based on neural networks For emg parttern classification*. Brazil., Federal University of Uberlândia/ Faculty of Electrical Engineering, Biomedical and Computer Graphics Laboratories, 2002.
- [13] R. Barea., *Tema5: Electromiografía*. Instrumentación Biomédica. Departamento Electrónica. Universidad Alcalá.
- [14] DAY, S. (n.d.). *Bortec Biomedical*. Retrieved from www.bortec.ca
- [15] J. L., Barrero, *Determinación de la Arquitectura óptima de una Red Neuronal Tipo Perceptrón Multicapa Para la Extracción de Características Relevantes y Reconocimiento de Señales Mioeléctricas (Parte 1)*. *Noticiero, Revista Bimestral de la Región 9 - America Larina y el Caribe* (41), 2003.
- [16] A. Z. Chaiyaratana, *Myoelectric signals pattern recognition for intelligent functional operation of upper-limb prosthesis..* In *Inf. téc. Department of Automatic Control and Systems Engineering*. University of Sheffield, 1996.
- [17] X. Guo, P. Y., *Study of the Control Mechanism of Robot-Prosthesis Based-on the EMG Processed*. *Proceedings of the 6th World Congress on Intelligent Control and Automation*, (pp. 9490–9493), 2006