

Análisis de Señales EMG Superficiales y su Aplicación en Control de Prótesis de Mano

Surface EMG Signals Analysis and Its Applications in Hand Prosthesis Control

Harold A. Romo, Esp., Judy C. Realpe, Ing., Pablo E. Jojoa, PhD.

Universidad del Cauca

hromo@unicauca.edu.co , jcrealpe@unicauca.edu.co , pjojoa@unicauca.edu.co

Recibido para revisión 26 de Marzo de 2007, aceptado 15 de Junio de 2007, versión final 18 de junio de 2007

Resumen—Las señales Electromiográficas Superficiales (EMGS) son fuente de información muy apropiada para el control de dispositivos virtuales como las prótesis de mano. Las razones para utilizar estas señales obedecen a diferentes aspectos tales como: facilidad para recolectar muestras, respeto por la integridad de la persona quien utiliza la prótesis, reutilización de una persona a otra, y fácil remoción para efectos de mantenimiento y calibración. En este artículo, se presenta una revisión de las técnicas más utilizadas en análisis y extracción de características discriminantes de las señales motoras EMGs con fines de aplicación en el control de prótesis virtuales de mano; haciendo énfasis en la evolución de las técnicas temporales clásicas a las técnicas espectrales más recientes basadas en transformadas *wavelets*, y su aceptación para procesar este tipo de señales según su desempeño en la clasificación y ejecución de movimientos sobre la prótesis. Así mismo, se hace referencia de los trabajos más recientes de desarrollo e investigación en el campo del procesamiento de señales biomédicas EMGs y sus aplicaciones en control mioeléctrico.

Palabras Clave—Análisis Wavelets, Control Mioeléctrico, Prótesis de Mano, Señales EMGS.

Abstract—The surface Electromyographic signals (EMGS) are appropriate source of information to virtual devices control as the hand prosthesis. The reasons to use this signals obey to different aspects as: the simplicity to collect samples of the signal, the respect for the integrity of the person who uses the prosthesis, the reusability of the device from one person to another, and the easiness to remove it for maintenance or calibration purposes. This article presents a review of the most used techniques in analysis and extraction of discriminant features from the EMGs driving signals in order to apply them in virtual hand prosthesis control, emphasizing in the evolution from the classic temporal techniques to the most recent spectral techniques based on the wavelets transformed and, its acceptance to process this kind of signals according to their performance in the classification and carrying out of movements

over the prosthesis. As well, it makes reference to the most recent works on development and research in the biomedical signals EMGs processing field and its applications in myoelectric control.

Key words—Wavelets Analysis, Myoelectric Control, Hand Prosthesis, EMGs Signals.

I. INTRODUCCIÓN

CON el avance tecnológico, cada vez se logra mejorar la construcción de sistemas de prótesis como extensiones de algún miembro del cuerpo humano con características esenciales como: flexibilidad, estética cosmética, peso ligero y multifuncionalidad. Igualmente, la ciencia y la ingeniería han realizado grandes avances en el área de procesamiento digital de señales biomédicas como las señales *electromiográficas superficiales* (EMGS) y sus aplicaciones en el control de dispositivos activos como las prótesis mioeléctricas.

Una prótesis mioeléctrica es un sistema accionado por servomotores que se gobierna a partir de señales EMG, bien sean intramusculares, capturadas mediante agujas o superficiales, recogidas en el muñón del paciente mediante electrodos [1]. Su desempeño, sin importar que tipo de señal se utilice es igualmente aceptable como lo muestran Hargrove L. et al. en [2]. Este tipo de prótesis son cada vez más aceptadas por personas con amputación de mano, por que permite a la persona quien la utiliza su rehabilitación para desempeñarse activamente en su campo laboral. Para lograr esto se requiere también del acompañamiento continuo de un grupo de profesionales en el área médica, de la disponibilidad y esfuerzo mental y físico del paciente para obtener los mejores resultados.

El éxito de una prótesis mioeléctrica será medido por su

desempeño en la ejecución de movimientos prácticos, con la naturalidad de los ejecutados por la mano humana, la menor complejidad de operación como sistema y con el menor esfuerzo físico-mental por parte del paciente. Para esto, es esencial un adecuado proceso de análisis de las señales motoras EMGS.

La evolución en las técnicas de procesamiento de las señales de naturaleza transitoria y no periódica como las EMGS ha jugado un papel importante en los últimos años, partiendo de técnicas básicas y sencillas como el análisis temporal, pasando por el análisis espectral mediante la transformada de Fourier hasta llegar al análisis espectral multiresolución mediante la “*transformada wavelet*” [3]. Esta última técnica adquiere cada vez mayor importancia en muchas áreas de la ciencia y en particular en análisis de señales biomédicas para las cuales se ha comprobado un mejor desempeño que las técnicas basadas en la transformada de Fourier [4].

II. LAS SEÑALES EMGS

Las señales EMG superficiales (EMGS), son esencialmente un patrón unidimensional, por lo que cualquier técnica de procesamiento de señales para extracción de características y reconocimiento de patrones se puede aplicar a este tipo de señales. La información extraída de las señales EMGS, es seleccionada de tal manera que se minimice el error en el control de los sistemas de prótesis mioeléctricas. La necesidad de una rápida respuesta de la prótesis limita la longitud de las muestras de la señal sobre las cuales se extraen las características. La tendencia en el control de prótesis a partir de señales EMGS obedece a que se constituye en la técnica más sencilla de implementar por su facilidad en la recolección sin intromisión directa sobre el organismo del usuario, remoción de electrodos y equipo para efectos de mantenimiento y/o calibración y su reutilización de una persona a otra.

A. Adquisición de Señales EMGS

Las señales EMGS, son colectadas típicamente mediante electrodos bipolares de superficie, ubicados sobre la piel. Estas han sido utilizadas para el control de prótesis de miembros superiores desde 1948 [5]. Estas señales proveen información sobre la actividad neuromuscular que las origina, siendo esencial esta información en: diagnóstico clínico, rehabilitación y como fuente de control para dispositivos activos y esquemas de estimulación eléctrica funcional [4]. Hargrove L. et al. [2], realizaron un trabajo comparativo de clasificación con señales EMG superficiales e intramusculares, concluyendo que la información extraída en las dos clases de señales es igualmente valiosa, sin encontrar diferencias significativas en su capacidad de clasificación. Este resultado es importante, ya que brinda la seguridad de continuar utilizando las señales EMGS en futuros trabajos de investigación aplicada.

Las señales EMGS son generadas por la contracción muscular, por lo que su adquisición requiere de una correcta identificación de las regiones musculares comprometidas en la ejecución de los movimientos a clasificar. Debido a la elevada resistencia eléctrica natural de la piel, se recomienda la aplicación de un gel que mejore la conductividad además de lograrse una buena superficie de contacto y adherencia con los electrodos. A pesar de estas disposiciones, las señales recogidas serán demasiado débiles, por lo que se hace necesario un procesamiento previo de filtraje y amplificación antes de su análisis. Así mismo, según la complejidad de las prótesis será necesario disponer de un mayor o menor número de canales o electrodos de recolección. Estos aspectos se detallan a continuación.

1. **Preprocesamiento.** La amplitud típica de las señales EMGS es de 0-6 mV por lo que se requiere pasarlas por un amplificador diferencial de alta ganancia (unas 5000 veces), evitando distorsiones de la información contenida en la señal. Una vez amplificada la señal, se debe considerar la eliminación de las componentes de ruido de alta frecuencia y las provenientes de fuentes del entorno, como la componente típica de ruido de baja frecuencia introducida por la red de distribución eléctrica de 60 Hz. Para eliminar esta última componente de ruido, lo más común es utilizar un filtro tipo “*notch*” aunque no sea lo más recomendable, ya que este podría eliminar o atenuar también componentes de frecuencia con información útil dada la mayor concentración de energía en las señales EMGS entre los 50 Hz y 150 Hz, aunque su canal de información va de los 20 Hz a los 500 Hz [6].
2. **Posición y número de electrodos.** La posición de los electrodos es muy importante en la recolección de registros EMGS con propósitos de control mioeléctrico. Por ello, se recomienda la asistencia de personal médico especializado, quienes pueden identificar con mayor precisión las regiones musculares con mayor compromiso en la ejecución de los movimientos de interés. Hargrove L. et al. [2], demuestran que unas regiones son mejores que otras para la ubicación de los electrodos; disponiendo para ello de 16 electrodos alrededor del antebrazo y por comparación en la precisión de clasificación se identifican posiciones de los electrodos con los mejores resultados de discriminación para el conjunto de movimientos estudiados. Sin embargo, la generalización de dichas posiciones no es recomendable para todos los pacientes, así que el procedimiento de identificación de las regiones musculares debe realizarse particularmente con cada paciente.

El número de electrodos corresponde al número de canales a procesar y este es un parámetro esencial en el desempeño del clasificador y en el número de movimientos diferentes a identificar. Para desarrollar una prótesis bioeléctrica multifuncional, es necesario extraer la mayor cantidad de información de cada canal, o asignar una función de control a una combinación específica de señales del sistema multicanal [6]. De esta forma, es posible aumentar el número de movimientos diferentes a ejecutar en un sistema de prótesis a partir de la disposición de un mayor número de canales.

Englehart K., et al. [7], muestran en sus resultados que la precisión en la clasificación de patrones EMG para el control mioeléctrico multifuncional es mayor con cuatro canales que con solo dos canales o uno. Sin embargo, entre mayor sea el número de canales mayor será el retardo en la respuesta de la prótesis, debido a la gran cantidad de información a procesar y mayor será también la interferencia entre canales por la cantidad significativa de “*crosstalk*” entre los músculos debido a factores como: el arreglo geométrico de los músculos y la propagación dispersiva de la señal en el volumen conductor entre otros [8],[9]. Estos podrían ser fenómenos que en lugar de mejorar la clasificación podrían empeorarla, obligando a buscar adecuado compromiso entre precisión, multifuncionalidad y velocidad de respuesta.

B. Estados de las Señales EMGS

En la generación de señales EMGS, durante la contracción muscular, se identifican dos fases o estados; uno, *el estado transiente*, correspondiente a los instantes de la ráfaga de actividad mioeléctrica que acompaña al esfuerzo muscular repentino en la ejecución de un movimiento; y dos, *el estado estacionario*, correspondiente al tiempo del esfuerzo muscular realizado durante un movimiento el cual es sostenido [4]. Algunos de los trabajos de investigación como en [6],[7],[10] y [11], se han enfocado en la clasificación de acciones discretas generadas por la muñeca, los dedos o el codo, analizando el estado transiente de las señales EMGS, comprobando la existencia de una estructura determinística en estas señales durante la fase inicial de una contracción muscular, con un valioso contenido de información discriminante. Así mismo, se han realizado trabajos en los que se ha utilizado el estado estacionario las señales EMGS como en [4],[7] y [12], técnica con la cual se simplificó el control de los dispositivos de prótesis, a pesar de que cierta cantidad de información de la señal es ignorada y que esta fase estacionaria tiene una estructura temporal muy corta debida a los cambios dinámicos en el reclutamiento de unidades motoras y en el patrón de los impulsos eléctricos necesarios para una contracción sostenida [4]. Sin embargo

sus resultados son concluyentes al demostrar que se puede lograr un desempeño excepcionalmente bueno en la clasificación continua de patrones mioeléctricos de movimientos, usando el estado estacionario de las señales EMGS [7].

III. PROCESAMIENTO DE LAS SEÑALES EMGS

La introducción del procesamiento digital en el análisis de señales EMGS sugiere su digitalización mediante un proceso de muestreo. La tasa de muestreo en la práctica puede ser de 1000 Hz con el fin de registrar componentes de frecuencia en la señal hasta los 500 Hz según el teorema de Nyquist, o muestrear a una frecuencia de 500 Hz para registrar componentes de frecuencia hasta los 250 Hz. No se requiere de mayores tasas, puesto que la mayor concentración de energía se encuentra entre los 50 y 150 Hz [6]. De cualquier manera, se debe tener en cuenta que la tasa de muestreo incidirá directamente en la longitud de las muestras de la señal a procesar, implicando mayor o menor tiempo de cómputo sobre cada registro EMG y comprometiendo con ello el retardo en la respuesta del sistema de prótesis.

Para el análisis de las señales, lo más común es segmentar los registros en segmentos de longitud 256 muestras (256 ms de grabación), y aplicar las técnicas de extracción de características a cada segmento [2],[4],[7],[13],[14]. Por su parte, Englehart K., et al. [7] comparan el desempeño de clasificación con seis movimientos diferentes de la mano, variando para esto la longitud de los segmentos en 256, 128, 64 y 32 muestras en cada ensayo. Así, mostraron que el desempeño en la clasificación se degrada rápidamente a medida que disminuye la longitud de los segmentos. Otros trabajos como en [15],[16] y [17] utilizan secuencias de 200 y 400 muestras (200 y 400 ms), igualmente con resultados satisfactorios, pero cabe anotar que longitudes mayores de 256 muestras impondrá mayor tiempo de procesamiento y en consecuencia mayor retardo en la respuesta de la prótesis.

A. Extracción de Características

Todo sistema de control mioeléctrico parte del hecho de que el valor instantáneo de las señales EMGS no contiene información [6]. Y según los modelos aceptados para su representación, estas son estocásticas [18]. Hudgins B. et al. [6], encontraron en las señales EMGS una estructura inherente para cada tipo de contracción, que a pesar de mostrar una componente determinística, también contiene una componente aleatoria. Una forma de retener esta información estructural es segmentando la forma de onda transiente y determinar el conjunto de características a partir de estadísticos evaluados en cada segmento. Sin embargo esta naturaleza estocástica no estacionaria de la señal, justificó la investigación y aplicación de nuevas técnicas de análisis de señales. Así fue como el análisis espectral empezó a considerarse como un complemento al análisis temporal clásico.

El éxito que se tenga en el control de un sistema de prótesis está fuertemente influenciado por la etapa de procesamiento de las señales motoras EMGS. Esta etapa consiste en extraer la información más relevante, necesaria y suficiente para discriminar con el mínimo de error los diferentes movimientos requeridos en el sistema de prótesis. Esta información se obtiene de la aplicación de las llamadas **técnicas de extracción de características**, dentro de las cuales se destacan como pioneras las basadas en análisis temporal por su sencillez y facilidad de evaluación, debido a que no requieren ningún tipo de transformación de la señal. También están las basadas en análisis espectral, para las cuales se requiere de la transformación de la señal, como la transformada de Fourier de tiempo corto (STFT- *short time Fourier transform*) con la cual se obtiene información de la señal en el dominio tiempo-frecuencia [5],[19],[20], aunque esta técnica asume la condición de estacionariedad en la señal, lo cual no se cumple para las señales EMGS. A pesar de haberse conseguido con esta transformada un desempeño aceptablemente bueno en el análisis de este tipo de señales para efectos de clasificación de patrones de movimientos, su naturaleza estocástica no estacionaria ha hecho necesario explorar técnicas alternativas que ayuden a mejorar el proceso de extracción de características. Una solución a este inconveniente se refleja en los últimos trabajos de investigación en el área de procesamiento de señales con la técnica de análisis espectral basada en la “**teoría de wavelets**”, mediante las **transformadas wavelets**. CWT (*Continuos Wavelet Transform*), DWT (*Discrete Wavelet Transform*) y WPT (*Wavelet Packet Transform*). Con esta técnica se consigue una representación de la señal en los dominios tiempo-frecuencia mucho más compacta que la conseguida por transformada de Fourier STFT, puesto que permite disponer de información de la señal en sus dominios original y transformado de manera simultánea [19].

1) **Características Temporales:** Las características basadas en estadísticos temporales se evalúan rápidamente, y son extraídas de cada segmento de tiempo para crear un conjunto de características que representan el patrón de la señal EMGS. Entre ellas se pueden mencionar como las más importantes (utilizadas en [2],[4],[6],[7],[13] y [21]), las siguientes:

- Valor medio absoluto. Estima el valor medio absoluto \overline{X}_i , sobre cada segmento i de N muestras de la señal, mediante la expresión:

$$\overline{X}_i = \frac{1}{N} \sum_{k=1}^N |x_k|, \quad i=1,2,\dots,I, \quad (1)$$

donde x_k es la $k^{\text{ésima}}$ muestra en el segmento i , e I es el número total de segmentos.

- **Valor medio absoluto de pendientes.** Este es simplemente la diferencia entre sumas de segmentos adyacentes, i e $i+1$, definido por:

$$\Delta \overline{X}_i = \overline{X}_{i+1} - \overline{X}_i, \quad i=1,2,\dots,I-1 \quad (2)$$

- **Cruces por cero:** Es una forma simple de medir la frecuencia de la señal, puede determinarse contando el número de veces que la forma de onda cruza por cero. Se requiere un umbral para reducir el número de cruces por cero inducidos por ruido, y se selecciona con respecto al voltaje de la señal V . El contador de cruces por cero se incrementa según la comparación entre dos muestras consecutivas x_k y x_{k+1} así:

$$\begin{aligned} x_k > 0 \text{ y } x_{k+1} < 0, \text{ o } x_k < 0 \text{ y } x_{k+1} > 0, \\ \text{y } |x_k - x_{k+1}| \geq 0,01 \text{ V} \end{aligned} \quad (3)$$

- **Cambios de signo de pendiente.** Provee otra forma de medir el contenido de frecuencia en la señal mediante el conteo del número de veces que la pendiente de la forma de onda cambia de signo. Igualmente requiere de un umbral para reducir los cambios de signo de pendiente inducidos por el ruido. El contador de cambios de signo en la pendiente se incrementa según las relaciones:

$$\begin{aligned} x_k > x_{k-1} \text{ y } x_k > x_{k+1} \text{ o } \\ x_k < x_{k-1} \text{ y } x_k < x_{k+1} \text{ y } \\ |x_k - x_{k+1}| \geq 0,01 \text{ V} \text{ o } |x_k - x_{k-1}| \geq 0,01 \text{ V} \end{aligned} \quad (4)$$

- **Longitud de la Forma de Onda.** Provee información de la complejidad de la forma de onda en cada segmento, está dada por la siguiente expresión:

$$lo = \sum_{k=1}^N |\Delta x_k|, \quad (5)$$

donde, $\Delta x_k = x_k - x_{k-1}$ (diferencia entre valores de muestras consecutivas). El valor resultante da una medida de la amplitud de la forma de onda, su frecuencia y duración en un solo parámetro.

Otra técnica de análisis temporal de señales, utilizada en [2],[14],[22],[17] y [21], se basa en el **modelado paramétrico Auto Regresivo** (AR), el cual permite modelar series de tiempo mediante la expresión:

$$x(k) = - \sum_{i=1}^P a_i x(k-i) + \epsilon(k), \quad (6)$$

donde a_i son los coeficientes AR, P el orden del modelo, y $\epsilon(k)$ un término de error. En este caso los coeficientes forman el conjunto de características requeridas. Graupe y Cline [10], fueron los primeros en clasificar señales EMG, utilizando coeficientes AR como características para clasificación a partir de un solo canal. Sin embargo, este parámetro tiene el inconveniente de suponer la condición de estacionariedad en la señal, lo cual no se cumple para las señales EMGS.

2) **Características Espectrales:** La representación tiempo-frecuencia de la señal provee información de la distribución

de su energía en los dos dominios, lográndose una descripción más completa del fenómeno físico [5]. Sin embargo, una transformación de la señal implica un costo computacional adicional y un espacio de características de mayor dimensión. Las técnicas más utilizadas en la extracción de características espectrales han sido: *la transformada de Fourier STFT (Short Time Fourier Transform)*, *la transformada wavelet continua CWT*, *la transformada wavelet discreta DWT* y *la transformada de paquetes wavelet WPT*, como veremos a continuación.

- **La transformada de Fourier de tiempo corto STFT** [5]. Asumiendo estacionariedad de la señal EMGs en períodos cortos de tiempo, la STFT para un segmento de longitud finita X_i , $i \in [0, \dots, L-1]$, consiste en una serie de transformadas de Fourier discretas DFT's, indexadas con respecto a T_s y F , de la forma:

$$\begin{aligned} STFT[k, m] &\equiv STFT[kT_s, mF] \\ &= \sum_{i=1}^{L-1} x[i]g[i-k]e^{-j2\pi m_i/L}, \end{aligned} \quad (7)$$

donde $g[i]$ es la función de la ventana de observación de tamaño fijo sobre la señal original, L la longitud del segmento y $T = kT_s$ el tamaño de paso de muestreo temporal. Si $k=1$, la STFT se evaluará sobre cada muestra temporal, si $k=L$, las ventanas sucesivas de análisis no se traslanan. Una ventana tipo Gaussiana brinda una buena resolución tiempo - frecuencia. Sin embargo, esta resolución siempre estará acotada inferiormente por la desigualdad conocida como *principio de incertidumbre de Heisenberg*, dada por la expresión:

$$\Delta t \cdot \Delta f = \frac{1}{4\pi}. \quad (8)$$

Esta transformada se utilizó en [19] como técnica de análisis de señales EMGS para clasificación de patrones de movimientos y en otros trabajos como en [4],[7],[13],[14] y [23] para comparar su desempeño en el análisis y clasificación de señales EMGS con técnicas más recientes como las basadas en *transformadas wavelet*.

- **La transformada wavelet continua CWT** [3],[24]. Al igual que la STFT, la CWT hace uso de ventanas de observación en su transformación, pero ahora son ventanas de tamaño variable. La CWT expresa una señal $x(t)$ continua en el tiempo, mediante una expansión de términos con coeficientes que son proporcionales al producto interno entre, la señal $x(t)$ y versiones escaladas y trasladadas de una función prototipo $\psi(t)$ conocida como “*wavelet madre*”. Partiendo de que tanto la señal $x(t)$ como la función

“*wavelet madre*” $\psi(t)$ son de energía finita, se define la CWT de una señal como:

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t)\psi\left(\frac{t-b}{a}\right)dt \quad a, b \in \mathbb{R}, \quad (9)$$

con $a, b \in \mathbb{R}$, $a \neq 0$ y donde “ a ” es una *variable de escala*, que permite comprimir o dilatar la función $\psi(t)$ y establece el grado de resolución con el cual se analiza la señal $x(t)$; “ b ” es una *variable de traslación* que permite desplazar la función $\psi(t)$ y determina su ubicación sobre la señal analizada. Acorde a la definición de la CWT puede concluirse que más que una representación tiempo-frecuencia, es una representación tiempo-escala. Así, una descripción global de la señal quedaría de la siguiente manera: las bajas frecuencias de la señal, se analizan con altas escalas y se obtiene buena resolución en frecuencia, mientras que los detalles de la señal, correspondientes a las altas frecuencias, se analizan con bajas escalas, con lo que se obtiene buena resolución en tiempo. Su aplicación en análisis de señales EMGS se puede encontrar en [21] y [25].

- La transformada *wavelet* discreta DWT [3],[24]. A nivel práctico y computacional, se prefiere la discretización de la CWT, y la forma más adecuada es discretizando los valores de las variables “ a ” y “ b ” mediante una escala diádica, esto se logra haciendo $a = 2^{-j}$ y $b = k2^{-j}$ de tal manera que una función *wavelet madre* de la forma:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}}\psi\left(\frac{t-b}{a}\right); \quad a, b \in \mathbb{R}, \quad a \neq 0 \quad (10)$$

adquiere la forma:

$$\psi_{j,k}(t) = 2^{\frac{j}{2}}\psi\left(2^j t - k\right); \quad j, k \in \mathbb{Z} \quad (11)$$

Este conjunto de funciones se conoce como la *versión diádica discretizada* de la función *wavelet*. El factor $2^{j/2}$ se denomina *constante de normalización* y garantiza la condición de ortonormalidad. A su vez, una función *wavelet madre* $\psi(t)$ lleva asociada consigo una función *escala* $\phi(t)$, de tal manera que ahora es posible aproximar cualquier función $x(t) \in L^2(\mathbb{R})$ con una de estas funciones o con ambas, mediante la siguiente expresión:

$$x(t) = \sum_k \sum_j c_{j,k} \phi(t) + \sum_k \sum_j d_{j,k} \psi(t); \quad j, k \in \mathbb{Z} \quad (12)$$

donde $c_{j,k}$ son los *coeficientes de escala* o de

aproximación y $d_{j,k}$ son los *coeficientes wavelet* o de *detalle* de la señal original $x(t)$, con respecto a las funciones de escala $\phi(t)$ y *wavelet* $\psi(t)$ respectivamente.

El desarrollo de algoritmos rápidos para evaluar la DWT, llevó a implementar los llamados "bancos de filtros" [3]. Así, estos algoritmos no se relacionan directamente con las funciones de escala $\phi(t)$ y *wavelets* $\psi(t)$, sino con los coeficientes de los filtros que las representan. Estos filtros corresponden a un filtro pasa-bajas y un filtro pasa-altas, tales que al hacer pasar la señal original por este banco de filtros se obtiene a su salida los coeficientes $c_{j,k}$ y $d_{j,k}$ respectivamente. Este proceso de filtrado puede iterarse y así obtener una descomposición a diferentes niveles. Basta hacer pasar los coeficientes de escala obtenidos del proceso de filtrado anterior por un par idéntico de filtros y así obtener los coeficientes del siguiente nivel. Así se obtienen los coeficientes $c_{n-1,k}$ y $d_{n-1,k}$, a partir de los coeficientes $c_{n,k}$. La idea es, bien sea utilizar directamente los coeficientes que resultan de la descomposición como características del vector descriptor, o realizar algún tipo de manipulación sobre estos y así obtener las características descriptoras de los patrones EMGS. Esta técnica de análisis aún siendo relativamente nueva, ha sido ampliamente utilizada en señales EMGS como lo muestran los trabajos de

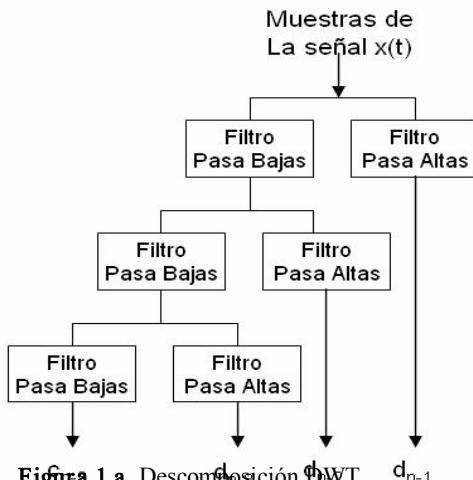


Figura 1 a Descomposición DWT. d_{n-1}

[4],[7],[11],[13],[14],[15],[17],[23] y [26].

- **La transformada de paquetes wavelet WPT** [3],[24]. El concepto de la WPT se fundamenta en que mientras la transformada DWT reitera el proceso de filtrado únicamente sobre los coeficientes de escala $c_{j,k}$ para llevarlos a niveles de menor resolución y

conservando los coeficientes de detalle $d_{j,k}$ en cada nivel de descomposición tal como se muestra en la figura 1.a; la transformada WPT reitera el proceso de filtraje de igual manera sobre los coeficientes de detalle $d_{j,k}$, tal como se muestra en la figura 1.b.

La diferencia que se encuentra al comparar la transformada WPT con las transformadas STFT y DWT es su capacidad de análisis multiresolución en los dominios tiempo-frecuencia de la señal como se muestra en la figura 2. sin embargo esta ventaja de la WPT sobre las otras dos técnicas implica un mayor costo computacional y una mayor dimensionalidad del espacio transformado. Siendo quizás esta la razón por la cual no ha sido tan utilizada como la DWT. Algunos de los trabajos donde se encuentra su aplicación están en [4],[7] y [21].

B. Reducción de Dimensionalidad

El inconveniente que se presenta en la técnica de extracción de características mediante la aplicación de transformaciones de la señal es la alta dimensionalidad del espacio resultante, lo que implicaría conformar vectores de descripción muy grandes. Ante esto, las técnicas de reducción de dimensionalidad permiten preservar la información más relevante al tiempo que se reduce la dimensión del espacio transformado [5]; procedimiento esencial para incrementar el desempeño de la clasificación. La reducción de dimensionalidad se puede lograr de dos maneras: por *proyección de características* o por *selección de*

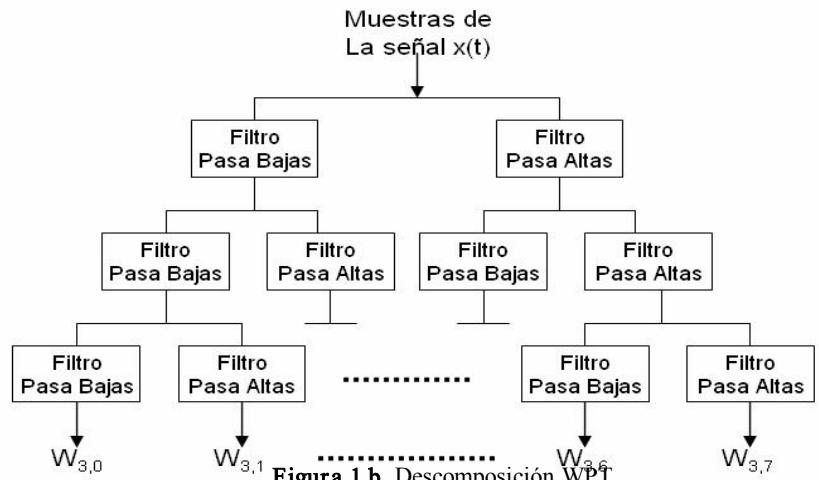


Figura 1 b Descomposición WPT

características.

En general se prefiere trabajar la técnica de *proyección de características*, pues de esta manera se conserva en el conjunto reducido la información contenida en cada una de las características del conjunto original. Este es un procedimiento automático que no requiere de la intervención humana para la selección de las características finales. Dentro

de esta técnica el método más utilizado es el *análisis de componente principal* (PCA – *Principal Component Analysis*), también conocido como transformada de *Karhunen-Loeve* o *descomposición de valores singulares* (SVD- *Singular Value Decomposition*), que consiste en un mapeo lineal del conjunto original de características en un conjunto reducido de características decorrelacionadas, a la vez que se minimiza el error cuadrático medio entre los dos conjuntos [7],[28], pues la proyección se realiza sobre bases ortonormales que son los autovectores de la matriz de covarianzas del conjunto original. Las características transformadas son ordenadas de acuerdo a sus varianzas, reflejado su decreciente efectividad en la represen-

función de las probabilidades *a priori* de cada clase y la probabilidad condicional, resultante de la distribución de las *muestras de entrenamiento* en cada clase y evaluada según el teorema de Bayes. Su aplicación en clasificación de señales EMGS se encuentra en [14].

- **Análisis discriminante lineal** (LDA-*Lineal discriminant analysis*). Es otro método estadístico que discrimina la separabilidad de clases en forma lineal, lo cual no se ajusta de manera eficiente a los patrones EMGS por su dinámica estocástica. Sin embargo, ha

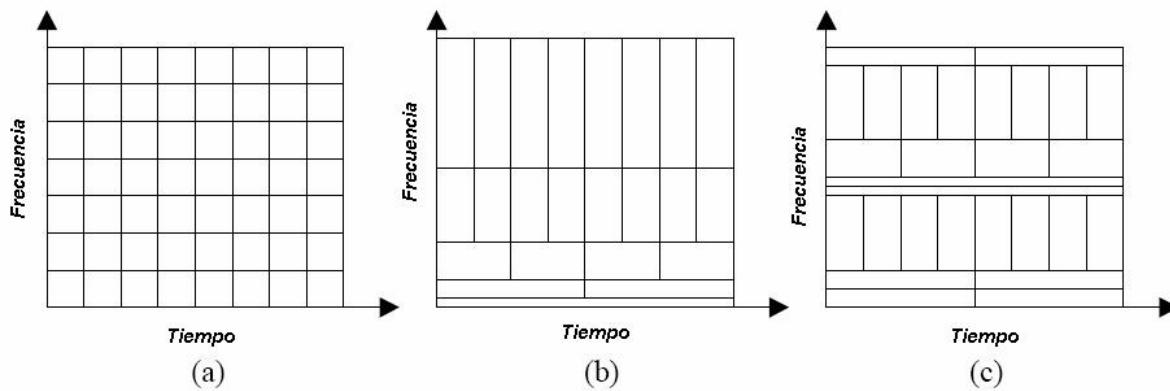


Figura 2. Resoluciones de análisis espectral. a) STFT, b) DWT y c) WPT.

ción del conjunto original. El análisis PCA es uno de los métodos más efectivos en aplicaciones de reconocimiento de patrones y ampliamente utilizado con señales EMGS como se muestra en [7],[13],[17] y [23]. Por su parte, la técnica de *selección de características* se busca conformar el mejor subconjunto de características a partir de la selección de las mejores características del conjunto original. Su inconveniente es que parte de la información contenida en el conjunto original se pierde definitivamente por el descarte de algunas de sus características, además requiere de la intervención humana para el proceso de selección o descarte.

C. Clasificación de Patrones [5],[20]

Incrementar la precisión en el control de una prótesis requiere también mejorar en las *técnicas de clasificación de patrones*, parte complementaria y no menos importante en el diseño de un sistema de prótesis completo. Existen una variedad de clasificadores, de los cuales se pueden destacar: el clasificadores Bayesiano y los basados en redes neuronales, lógica difusa y redes neuro-fuzzy.

- **Clasificador Bayesiano.** Es el método estadístico clásico. Donde se estima la probabilidad *a posteriori* de la pertenencia de una *muestra de prueba* a una de las clases dadas. Esta probabilidad es evaluada en

sido utilizada en trabajos de investigación para efectos comparación con otras técnicas como en [2],[4] y [7].

- **Redes neuronales artificiales** (ANN *Artificial Neural Network*). Es un sistema computacional inspirado en las características de aprendizaje y estructura de la red neuronal biológica. Las redes ANN tienen características como: generalización y habilidad para aprender de la experiencia sin requerir un modelo matemático a priori de las características de la señal, adaptación a los cambios de condiciones ambientales y habilidad para procesar datos degradados o incompletos, lo que las hace apropiadas para señales críticas como las señales EMGS. Sin embargo, las redes ANN requieren de un gran número de muestras y mucho tiempo de entrenamiento para un aprendizaje adecuado. Su aplicación en clasificación de señales EMGS se puede encontrar en [2],[4],[7],[11],[15],[17], [21] y [26].

- **Lógica difusa.** Son sistemas de inferencia, y al igual que las ANN simulan el comportamiento de decisión humana. Con posibilidad de introducir la experiencia de un experto en la elaboración de reglas de decisión, en un esquema *IF THEN*. Estos sistemas se pueden clasificar en dos categorías: la primera categoría,

incluye modelos lingüísticos basado en colección de reglas *IF THEN*, cuyos antecedentes y consecuentes usan valores fuzzy (modelo Mamdani); y la segunda categoría, esta basada en sistemas tipo Tagagi-Sugeno y usa una estructura de reglas que tienen antecedentes fuzzy y consecuentes funcionales. Consiste en una aproximación no lineal, a partir de una combinación de muchos sistemas lineales mediante la descomposición del espacio completo de entradas en espacios fuzzy parciales y la representación de cada espacio de salida con una ecuación lineal. Su aplicación en clasificación de señales EMGs se encuentra en [2] y [13].

- **Sistemas Neuro-fuzzy.** La combinación de redes neuronales y lógica difusa permite una relación simbiótica en la cual se aprovecha el conocimiento de un experto y la capacidad de aprendizaje y eficiencia computacional de la red neuronal, logrando un sistema de decisiones más inteligentes. Algunos de los trabajos realizados en clasificación de señales EMGs utilizando técnicas neuro-fuzzy se encuentran en [13] y [23].

IV. LAS SEÑALES EMGS Y EL CONTROL DE PRÓTESIS DE MANO

Son muchos los grupos alrededor del mundo que investigan la aplicabilidad de señales EMGS en el control de prótesis de mano. Según Zecca [5], en 1948 Reiter R. fue el primero en utilizar señales EMGS para controlar un dispositivo de prótesis simple. [28], con modelado AR y discriminación Bayesiana, fueron capaces de discriminar seis clases de movimientos con éxito del 99%. Desafortunadamente estos resultados solo se lograban después de muchas horas de entrenamiento. Más tarde, el uso de redes neuronales artificiales (ANN) permitió reducir el tiempo requerido para el entrenamiento.

En 1993, Hudgins et al. [6] propusieron por primera vez una estrategia de control de dispositivos artificiales utilizando el estado transiente de las señales EMGS, logrando discriminar cuatro movimientos diferentes (extensión del codo, flexión de muñeca, y rotación humeral radial/lateral), a partir de un solo electrodo bipolar y con extracción de características temporales y clasificación de movimientos mediante una Red Neuronal ANN de dos capas. A pesar de sus logros, el error de discriminación aún superaba el 10%.

En 1999, Englehart et al. [4] propusieron la clasificación de señales EMGS en su fase transiente, siendo pioneros en introducir la transformada *wavelet* en la representación tiempo-frecuencia de la señal. Analizaron las señales EMGS correspondientes a cuatro patrones de movimientos del codo y antebrazo, extrayendo características espectrales con STFT, DWT y WPT y comparándolas con las características del dominio temporal TD (*Temporal Domain*) propuestas por

Hudgins, concluyeron que la precisión en la clasificación se logra en el orden progresivo TD → STFT → DWT → WPT. En este mismo año, Englehart et al. [13] y [14] propusieron un esquema de clasificación continua basada en *wavelets* para el control mioeléctrico multifuncional usando la transformada WPT en la extracción de características y luego sometidas a una reducción de dimensionalidad con PCA. Sus resultados fueron aplicados en la discriminación de seis movimientos de mano y muñeca (mano cerrada, mano abierta, flexión de muñeca, extensión de muñeca, desviación cubital, y desviación radial). Concluyeron, que con cuatro canales se obtiene mejores resultados que con dos canales o uno, y que se puede lograr una sorprendente precisión en la discriminación utilizando el estado estacionario de las señales EMGS.

En 2002, Ferguson S y Dunlop G. [14] desarrollaron un sistema que permitió identificar cuatro tipos de agarre complejos (esférico, cilíndrico, de pinza y lateral) a partir de señales EMGS utilizando en la extracción de características las técnicas STFT, AR, DWT y la deconvolución. Para la clasificación se probaron métodos estadísticos (Distancias Euclídea y de Mahalanobis) y redes neuronales. Concluyeron que la misma combinación de técnicas tanto de extracción de características como de clasificación de patrones no tiene el mismo desempeño para todos los pacientes, por lo que el dispositivo deberá adaptarse para cada paciente. El hecho de tener que adecuar la prótesis a cada paciente pasó a ser un punto de interés para los investigadores quienes vislumbraron su solución en el uso de redes neuronales y lógica difusa afirmando que las EMGS no son señales estrictamente repetibles y muchas veces aún contradictorias, y que los sistemas con lógica difusa pueden tolerar dichas contradicciones, además de permitir detectar patrones en los datos que con otras técnicas no es tan fácil. En este sentido, Zhang et al. [23] propusieron una técnica de clasificación neuro-fuzzy con la combinación DWT/SVD en extracción de características y fue aplicada al reconocimiento de seis movimientos (extensión de codo, flexión del codo, pronación de muñeca, supinación de muñeca, mano abierta y mano cerrada) con mejores resultados que los obtenidos con métodos tradicionales utilizados hasta entonces. Por su parte, Yucel K. y Mehmet K. [13], propusieron la combinación DWT/PCA y clasificación fuzzy (fuzzy c-means FCM, probabilistic c-means PCM y fuzzy K-nearest FKNN) para señales EMGS. Se aplicó en la ejecución de cuatro movimientos (flexión y extensión de codo, pronación y supinación de antebrazo) sobre un dispositivo de prótesis. Concluyeron que las técnicas por ellos aplicadas daban mejores resultados de clasificación que los logrados con características temporales, coeficientes AR y coeficientes cepstrales utilizadas hasta entonces.

En 2004, Betancourt et al. [21] presentaron una metodología para el reconocimiento de patrones de movimiento a partir de señales EMGS utilizando: análisis

temporal, AR, FFT, STFT y *wavelets*, para construir un conjunto híbrido de características y mediante una red neuronal en configuración “*back-propagation*” probar la clasificación de dichos patrones. Por otra parte, Kilby et al. [30] compararon el desempeño de diferentes *familias wavelets* en el análisis de señales EMGS mediante las transformadas DWT y WPT. Con base en el error de aproximación obtenido tras la descomposición y reconstrucción de una señal concluyeron que las familias *wavelets*: Daubechies, Symmlet y Coiflet son las más adecuadas para el análisis de este tipo de señales.

En 2005, Carreño I. y Vuskovic M. [15] propusieron un método de extracción de características basado en el cálculo de los tres primeros momentos a partir de tres secuencias de *transformadas wavelet*. Su método se aplicó en la clasificación de patrones EMGS de aprehensión o agarre (cilíndrico, esférico, lateral y de precisión), mostrando ser significativamente mejor que el basado en la transformada Thompson de tiempo corto STTT de tres ventanas. En la clasificación utilizaron la distancia Mahalanobis basada en clasificadores ARTMAP (*Adaptive Resonant Theory - based algorithm for supervised incremental learning and classification*). Así mismo, Wang X. y Cui J. [26] usaron la combinaron DWT/ANN en señales EMGS para identificación y clasificación de ocho patrones diferentes de movimientos con una alta tasa de identificación. Carreño I. y Vuskovic M. [16], innovaron también en su trabajo previo, proponiendo ahora la evaluación de los primeros cinco momentos en lugar de aplicar PCA para reducción de dimensionalidad. Su nueva propuesta se aplicó en clasificación de cuatro tipos de agarre (cilíndrico, esférico, de precisión y lateral). Por otra parte, Englehart et al. [2], compara la clasificación de seis patrones de movimientos a partir de señales EMG superficiales y señales EMG intramusculares, asumiendo en las últimas menos crosstalk muscular, lo cual permitiría puntos de control más independientes. Los resultados mostraron que no hay diferencia significativa en la precisión de clasificación. Liu et al. [11], desarrollaron un método de aprendizaje en tiempo real, aplicando la *transformada wavelet* en la extracción de características y una red ANN en la clasificación. El método se aplicó para discriminación de cinco diferentes tipos de movimientos y hacer control en tiempo real de una prótesis. Para esto, analizó tanto la fase transitoria como la estacionaria de la señal. Sus resultados mostraron que la discriminación de movimientos mejorada sustancialmente con esta forma combinada de análisis.

V. CONCLUSIONES

La optimización en el análisis de señales EMGS y su aplicación en el control de prótesis activas seguirá siendo objeto de investigación y futuros desarrollos, usando cada vez técnicas más apropiadas para el análisis de las señales y aprovechando al máximo los avances tecnológicos.

El control de prótesis virtuales mioeléctricas se puede lograr con

resultados altamente satisfactorios bien sea utilizando señales EMG intramusculares o señales EMG superficiales (EMGS), aunque se prefiere las señales EMGS por razones ya descritas. De igual manera se puede utilizar bien sea el estado transiente o el estado estacionario de las señales electromiográficas.

La correcta ubicación de las regiones musculares para recoger las muestras de señales EMGS es esencial en la correcta discriminación de movimientos, así como el número de electrodos o canales implicará disponer de mayor o menor información para su clasificación.

Los resultados de los trabajos más recientes muestran que la conformación de vectores descriptores para una mejor descripción de patrones EMGS se consigue mediante la combinación de características tanto temporales como espectrales, preferiblemente obtenidas mediante transformadas *wavelet*.

Siempre que se tengan características obtenidas mediante alguna transformación de la señal, será muy apropiado aplicar alguna técnica de reducción de dimensionalidad como PCA.

Para concluir, en la etapa de clasificación, se pueden fusionar técnicas como las redes neuro-fuzzy para aprovechar las ventajas de cada una, así como su capacidad de readaptación o reaprendizaje según los cambios dinámicos que se presentan en las señales EMGS debidos a los estados psicofísicos de la persona, y así lograr un mejor desempeño en su sistema de prótesis.

REFERENCIAS

- [1] Alonso A., Sanchez H., Hurtado E., Steinak L., “Entrenador Mioeléctrico de Prótesis Para Amputados de Brazo y Mano”, Hospital clínico Universitario, Universidad de Valladolid. Mapfre Medicina. Vol 13, pp. 11-19, 2002.
- [2] Hargrove L., Englehart K., Hudgins B., “A Comparison of Surface and Intramuscular Myoelectric Signal Classification”, Proc. of the 27th Annual Conf. Int. pag. 5009 - 5012. IEEE EMBS 2005.
- [3] Ali N. Akansu and Paul R. Haddad. Multiresolution signal decomposition Transforms, subbands, and wavelets. Second edition New Jersey Institute of Technology, Newark, NJ.
- [4] Englehart K., Hudgins B., Parker P., Stevenson M., “Classification of the Myoelectric Signal Using Time-frequency Based Representations”. Institute of Biomedical Engineering, University of New Brunswick, Canada. 1999.
- [5] Zecca M., Micera S., Carroza M., Dario P., “Control Of Multifunctional Prosthetic Hands By Processing The Electromyographic Signal”, Critical Reviews™ in Biomedical Engineering. Vol. 30, pp. 459 - 485.2002.
- [6] Hudgins B., Parker P., Scott RN., “New Strategy for Multifunction Myoelectric Control”, IEEE Trans Biomed Eng. Vol. 40, pp. 82 - 94, 1993.
- [7] Englehart K., Hudgins B., and Parker P., “A Wavelet Based Continuous Classification Scheme for Multifunction Myoelectric Control”. Department of Electrical and Computer Engineering and the Institute of Biomedical Engineering. University of New Brunswick, Canada. Vol. 48, pp. 302 - 311, 2001.
- [8] Lowery M., Stoykov N., Taftave A., y Kuiken T., Tesis profesional “A Multiple-Layer Finite-Element Model of the Surface EMG Signal”. IEEE Transactions on Biomedical Engineering, vol. 49, no. 5, pp. 446-454, May 2005.
- [9] Nishikawa D., Yu W., Yokoi H., y Kakazu Y., “EMG prosthetic hand controller discriminating ten motions using realtime learning method”, IEEE/RSJ IROS, 1999.
- [10] Graupe D., y Cline W., “Functional separation of EMG signals via ARMA identification methods for prosthesis control purposes”. In IEEE Trans. Systems Man and Cybernetics, volume 5, 252-259. 1975.
- [11] Liu H., Chen X., Chen Y. “Wavelet Transform and Real - Time Learning Method for Myoelectric Signal in Motion Discrimination”. International Symposium on Measurement Technology and Intelligent Instruments. Conf. Ser. Vol. 13, pp. 25 - 253, 2005.
- [12] Crawford B., Miller K., Shenoy P., y Rao R., “Real-Time Classification of Electromyographic Signals for Robotic Control”. Technical Report No. 2005-03-05, Department of Computer Science, University of Washington, March 2005.
- [13] Yücel K., Mehmet K., “EMG Signal Classification Using Wavelet Transform And Fuzzy Clustering Algorithms”. Istanbul Technical University, Faculty of Electrical and Electronics Engineering, Department of Electronics and Communication Engineering,

- Ayazaga, Istanbul, Turkey 2002.[Fecha consulta nov 2006]. Disponible en: <http://eleco.emo.org.tr/eleco2003/ELECO2003/bsession/B8-02.PDF>.
- [14] Ferguson S., Dunlop G Reg, "Grasp Recognition From Myoelectric Signals". Australian conf. on Robotics and Automation, Auckland, 2002.[Fecha de consulta nov 2006]. Disponible en: <http://www.araa.asn.au/aca/aca2002/Papers/Ferguson-Dunlop.pdf>.
- [15] Carreño I. y Vuskovic M., "Wavelet Based Feature Extraction From Prehensile EMG Signals". Universidad Pública de Navarra, Pamplona, Spain. 2005 [fecha de consulta nov. 2006]. Disponible en: http://medusa.sdsu.edu/Robotics/Neuromuscular/Our_publications/Sweeden2005/Sweden.pdf.
- [16] Carreño I. y Vuskovic M., "Wavelet Transform Moments For Feature Extraction From Temporal Signals". Universidad Pública de Navarra, Pamplona, Spain. 2005.[Fecha de consulta nov. 2006]. Disponible en: http://medusa.sdsu.edu/Robotics/Neuromuscular/Our_publications/Barcelona2005/Paper575-Revised.pdf.
- [17] Zhang X., Yang Y., Xu X. Zhang J., Gao Z., Hu T., Chen T., Chen Z. "Clinical Detection and Movement Recognition of Neuro Signal". Journal of Zhenjian University SCIENCE. pp. 272-279. 2004.
- [18] Deluca C., "Physiology and Mathematics of Myoelectric Signals". IEEE Trans. Biomed. Eng. Vol. BME-26, pp:313-325,1079.
- [19] Sijiang D., Thesis profesional "Feature Extraction For Classification of Perhensile Electromyography patterns". Master's Degree of Computer Science San Diego State University, 2003.
- [20] Reaz M., Hussain M., Mohd-Yasin F., "Techniques Of Emg Signal Analysis: Detection, Processing, Classification And Aplications". Faculty of Engineering, Multimedia University, 63100 Cyberjaya, Selangor, Malaysia. Vol. 8, pp. 11 - 35, 2006.
- [21] Betancourt G., Giraldo E., Franco J. "Reconocimiento de Patrones de Movimiento a Partir de Señales Electromiográficas". Grupo de Investigación en Instrumentación y control. Scientia et Técnica. Scientia et Technica. Vol 26, pp. 53 - 58, 2004.
- [22] Birkedal L., Collet T., Dagilis S., Delavemhe G., Emborg J., Jørgensen A. "Pattern Recognition of Upper-body Electromyography For Control of Lower-limb Prostheses". Institute of Electronic Systems Aalborg University, June 2002.
- [23] Zhang X., Yang Y., Xu X. Zhang Ming. "Wavelet Based Neuro-Fuzzy Classification for EMG Control". Department of Automation, Shanghai Jiaotong University, Shanghai 200030, China. Vol 2, pp. 1087 - 1089, 2002.
- [24] Alfred Mertins. Signal Analysis: wavelets , filter banks, Time-frequency transform and applications. Ed. John Wiley & Sons Ltda 1999.
- [25] Ismail A. Y Asfour S., "Continuos Wavelet Transform Application to EMG Signal During Human Gait". Dept. Of Industrial and Biomedical Eng. University of Miami. pp. 325-329. IEEE 1998.
- [26] Wang X. y Cui J., "The Application of Wavelet Transform and Neural Network to Surface Electromyographic Signal for Pattern Recognition". Engineering in Medicine and Biology. Proc. of the 27th Annual Int. Conf. Shanghai, China. pag. 5009 - 5012. IEEE EMBS 2005.
- [27] Micera S., Sabatini A., Dario P., Rossi B., "A hybrid approach for EMG pattern analysis for classification of arm movements using statistical and fuzzy techniques". Med Eng Phys. Vol 21; pp 303-311. 1999.
- [28] Graupe D., Salahi J., Kohn KH., "Multifunctional Prosthesis and Orthosis Control Via Microcomputer identification of temporal pattern differences in single-site myoelectric signals". J Biomed Eng. Vol. 4, pp. 17- 22, 1982.
- [29] Englehart K., Hudgins B., and Parker P., "Improving Myoelectric Signal Classification Using Wavelet Packets and Principal Component Analysis". Proc. Of 21st Annual Int. Conf. of the IEEE on Eng. In Med. And Biol. Soc. Atlanta 1999.
- [30] Kilby J., Hosseini G., "Wavelet Analysis of Surface Electromyography Signals". Electrotechnology Department, Auckland University of Techology, New Zealand. Proc. Of 26th Annual Int. Conf. of the IEEE EMBS, San Francisco, CA. 2004.

Harold A. Romo R. Profesor Asociado, Dpto. de Telecomunicaciones de la Facultad de Ingeniería Electrónica y Telecomunicaciones de Universidad del Cauca. Licenciado en Matemáticas, Universidad de Nariño. Ingeniero en Electrónica y Telecomunicaciones, Universidad del Cauca. Especialista en Redes y Servicios Telemáticos, Universidad del Cauca. Estudiante de Maestría en Ingeniería, Área Electrónica y Telecomunicaciones de la Universidad del Cauca. Áreas de Interés: procesamiento de Señales y comunicaciones digitales

Judy C. Realpe C. Profesora Asistente, Dpto. de Electrónica, Instrumentación y Control de la Universidad del Cauca. Ingeniera en Electrónica y Telecomunicaciones de la Universidad del Cauca. Estudiante de Maestría en Ingeniería, Área Electrónica y Telecomunicaciones de la Universidad del Cauca. Áreas de Interés: procesamiento de Señales y algoritmos adaptativos

Pablo E. Jojoa G. Profesor Asociado, Departamento de Telecomunicaciones de la Facultad de Ingeniería Electrónica y Telecomunicaciones de Universidad del

Cauca. Ingeniero en Electrónica, Universidad del Cauca. Magíster en Ingeniería Área Sistemas Electrónicos, Universidad de São Paulo, Brasil. Doctor en Ingeniería Área Sistemas Electrónicos, Universidad de São Paulo, Brasil. Áreas de Interés: algoritmos adaptativos y procesamiento de Señales