

CARACTERIZACIÓN DE SEÑALES ELECTROMIOGRÁFICAS PARA LA DISCRIMINACIÓN DE SEIS MOVIMIENTOS DE LA MANO.

EMG signals characterization for discrimination of six-hand movements

RESUMEN

En este documento se presenta una metodología efectiva para la caracterización de señales electromiográficas de superficie para la identificación de 6 movimientos de la mano. Se usan diferentes esquemas de la Transformada Wavelet para caracterizar las señales y se emplea el índice de separabilidad entre clases de Davies-Bouldin para la construcción de una Transformada Wavelet óptima. La metodología propuesta logra un acierto promedio superior al 92% sobre la base de datos construida.

PALABRAS CLAVES: Señales electromiográficas de superficie, Transformada Wavelet Discreta, bancos de filtros adaptativos, Transformada Wavelet Packet Óptima.

ABSTRACT

This document presents an effective methodology for the characterization of surface electromyography signals for the identification of 6 hand movements. Different schemes are used to characterize EMG signals based on the Wavelet Transform; the Davies-Bouldin index of separation between classes is used too for the construction of an Optimal Wavelet Transform. The proposed methodology achieves classification accuracy above 92% over the database built.

KEYWORDS: Surface Electromyography signals, Discrete Wavelet Transform, Adaptive Filter Banks, Optimal Wavelet Packet.

RUBÉN D. PINZÓN MORALES.

Ingeniero Electrónico.
Investigador Grupo Laboratorio de Automática, Microelectrónica e Inteligencia Computacional - LAMIC Universidad Distrital FJC, Bogotá.
rdpinzonm@correo.udistrital.edu.co

DIEGO ÁNDRES MORALES B.

Ingeniero Electrónico.
Investigador Grupo Laboratorio de Automática, Microelectrónica e Inteligencia Computacional - LAMIC Universidad Distrital FJC, Bogotá.
diego.morales@iee.org

VÍCTOR HUGO GRISALES P.

Ingeniero Electrónico, Ph.D.
Profesor Prog. Ingeniería Electrónica, Investigador Grupo Laboratorio de Automática, Microelectrónica e Inteligencia Computacional - LAMIC Universidad Distrital FJC, Bogotá.
vhgrisales@udistrital.edu.co

1. INTRODUCCIÓN

Las señales electromiográficas de superficie (SEMG) se han convertido en una herramienta muy importante en el reconocimiento de patrones, control de dispositivos, rehabilitación, entre otros campos debido a la facilidad con la que se pueden adquirir de forma no invasiva y sin peligro para el individuo. Esta señal provee información en tiempo y en frecuencia acerca de la actividad neuromuscular presente en el músculo activo correspondiente a la suma de la actividad de un número mayor de *unidades motoras* más pequeñas. Para la extracción de las características más relevantes de esta señal se ha usado la transformada Wavelet en sus diferentes formas debido a su flexibilidad para concentrar la energía de la señal en el espacio tiempo-frecuencia, demostrando ser bastante adecuada para esta tarea. Una de las configuraciones más flexibles y rápidas para implementar esta transformada es mediante los esquemas de actualización (*lifting scheme*) desarrollados por Sweldens [1], los cuales permiten incluir etapas adaptativas que cambien las características de la Wavelet según sea el comportamiento local de la señal a analizar.

El estudio de las señales EMG ha permitido el desarrollo de importantes proyectos para el bienestar humano. Dentro de los trabajos pioneros se encuentran Hudgins y Englehart y otros [2], quienes desarrollaron una metodología para el entrenamiento de prótesis y predicción de fatiga en los músculos así como la optimización de los algoritmos de reconocimiento de patrones para aplicaciones en tiempo real. Se destacan los algoritmos de aproximación temporal y modelamiento paramétrico, así como los de Hannaford [3] y Farry [4] con análisis espectral con las transformadas FFT y STFT.

Diferentes técnicas de caracterización de las señales EMG se han reportado con el fin de clasificar correctamente patrones en las mismas que ayuden al reconocimiento de movimientos. En el 2005, L. Deqiang y otros [5] introducen una combinación entre el análisis wavelet y la lógica difusa para la clasificación de señales EMG logrando un acierto promedio del 87.5%. En el 2006, E. Giraldo y otros [6], reportan el uso combinado de características temporales, espectrales y tiempo-frecuencia logrando porcentajes de acierto promedio del 93%. En el año 2006, G. Wang y otros [7], desarrollan

una metodología para la clasificación de señales EMG usando Wavelets óptimas y el criterio de Davies-Bouldin, reportando porcentajes de acierto máximos de 93.7%. Todas estas metodologías presentadas tienen la particularidad que son para solo 4 movimientos a diferencia de la presente propuesta orientada al reconocimiento de 6 movimientos buscando porcentajes promedio de acierto con mejoras significativas.

En la segunda sección de este documento se presentarán las diferentes técnicas y métodos para la caracterización tiempo-frecuencia de las señales SEMG, lo cual permitirá la construcción de la transformada wavelet packet adaptativa y óptima en el sentido de máxima separabilidad entre clases, propuesta de este trabajo. En la sección 3 se mostrarán los resultados obtenidos de caracterización de las señales SEMG y finalmente se presentarán las conclusiones pertinentes.

2. MÉTODOS

2.1 Captación de las señales EMG

De acuerdo a los movimientos de interés que se seleccionan como básicos de la mano: apertura (Ape), cierre (Cie), flexión (Fle), extensión (Ext), supinación (Sup) y pronación (Pro) se ubicaron 4 electrodos diferenciales de plata (99.1%) sobre los siguientes músculos: músculo Pronador Redondo para resaltar el movimiento de pronación de la mano, músculo Supinador Largo correspondiente al movimiento de supinación de la mano, músculo Flexor Común Superficial de los Dedos para resaltar los movimientos de apertura y cierre de la mano y finalmente se ubicó el cuarto electrodo sobre el músculo Palmar Menor para resaltar los movimientos flexión y extensión de la mano. La ubicación perpendicular y longitudinal de cada electrodo se realizó siguiendo las recomendaciones de la SENIAM **¡Error! No se encuentra el origen de la referencia.**, y usando el equipo de electromiografía Delsys® BAGNNOLI-4 del grupo de investigación en Control e Instrumentación de la Universidad Tecnológica de Pereira¹, con amplificación diferencial x1000, filtros pasa banda de 20 Hz a 450 Hz, frecuencia de muestreo de 1 kHz con resolución de 15 bits/canal. Los registros fueron normalizados con ventanas de 400ms.

2.2 Caracterización usando la Transformada Wavelet

La transformada Wavelet Discreta (DWT) ha venido siendo usada para la caracterización de señales en diferentes campos, desde la caracterización de señales bioeléctricas [6], la caracterización de señales no

estacionarias 1-D y 2-D [9], el análisis de armónicos para

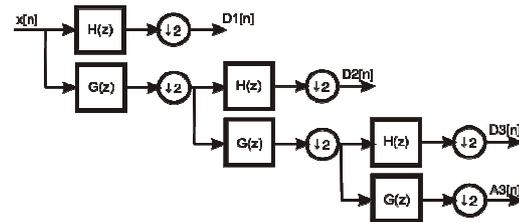


Figura 1. Esquema de descomposición de la transformada wavelet Discreta de nivel 3. Donde $H(z)$ es el filtro de aproximación, $G(z)$ es el filtro de detalle, $D_n[n]$ son los coeficientes de nivel n y $A_3[n]$ son los coeficientes de nivel 3.

la detección de fallas en máquinas [10], entre muchas otras aplicaciones. Usualmente se usa el algoritmo de Mallat [11] con bancos de filtros en cuadratura para la implementación de esta transformada usando funciones ortogonales para la proyección la señal a analizar. Sin embargo, esta descomposición diádica no redundante de la Figura 1, tiene sus limitaciones como la distorsión de fase implícita por el uso de wavelets madre no simétricas, o las fugas de energía debido a las zonas solapadas de los filtros de detalle y de aproximación [12], o la rigidez de la resolución en frecuencia donde se tiene un ancho de banda pequeño para las componentes de frecuencia baja y un ancho de banda amplio para las componentes de alta frecuencia (división logarítmica de la frecuencia).

La transformada wavelet packet (WPT) propuesta por Ronal Coifman, es una solución al problema de la rigidez de la resolución en frecuencia de la DWT, ya que permite la selección de diferentes anchos de banda para las diferentes componentes en frecuencia mediante la descomposición de las componentes de detalle y de aproximación del esquema básico de Mallat, cualidad que permite la adaptación de esta transformada a los comportamientos frecuenciales de la señal. Esta descomposición *completa* resulta en un árbol binario (ver Figura 2). Para comparación se puede observar en la Figura 3 la división del espacio tiempo-frecuencia que

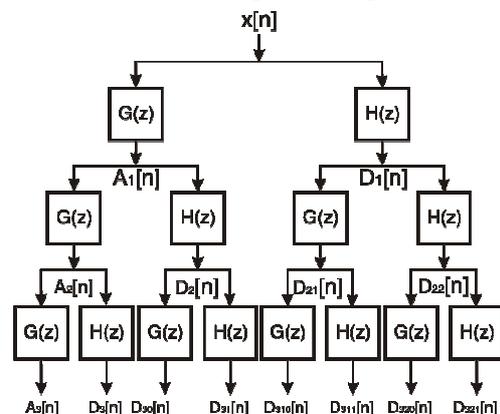


Figura 2. Descomposición binaria usando la WPT. La descomposición se realiza tanto por el canal de detalle como por el canal de aproximación.

¹ Cortesía del Ingeniero Álvaro Ángel Orozco y de los investigadores del grupo de investigación en Control e Instrumentación bajo el proyecto de Colciencias 110-14-17905.

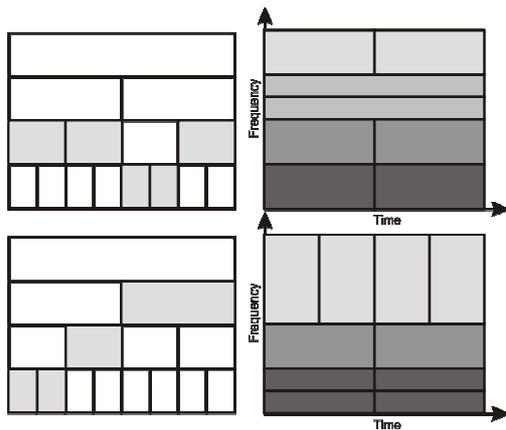


Figura 3. División del espacio tiempo-frecuencia usando dos bases ortogonales diferentes de la transformada Wavelet Packet.

se logra con dos bases diferentes de la transformada WPT.

Normalmente en el análisis con la DWT los coeficientes que se obtienen de las salidas de cada uno de los sub-espacios de análisis resultan en sistemas no redundantes. Sin embargo, si se realiza el mismo ejercicio con la WPT y se toman las salidas de cada uno de las señales en cada uno de los sub-espacios simultáneamente, claramente se tienen más salidas que entradas lo cual sería un sistema redundante. No obstante, existen como se muestra en [13], $2^{2(j-1)}$ caminos independientes y ortogonales llamados “bases”, que se pueden seleccionar, y que analizan completamente la señal sin pérdida de información y sin incluir redundancia.

Diferentes algoritmos han sido desarrollados para la selección automática de la mejor base. Clásicamente el algoritmo de entropía de Shannon desarrollado por Coifman [15] ha sido usado para seleccionar la mejor base entre toda la librería wavelet. Recientemente, otros métodos basados en índices de separabilidad entre clases [7] han sido usados por sus cualidades en la selección de los sub-espacios no solapantes que mejor representan la señal permitiendo mayor flexibilidad en los anchos de banda para cada frecuencia. En este trabajo se seleccionó el índice de Davies-Bouldin (DB) como algoritmo de penalización de la separabilidad entre clases.

El índice DB mide la relación entre la dispersión de los datos y el centro de la clase o centro de clúster, de las diferentes clases. Este índice requiere del cálculo de la similitud entre clústeres como en (1), donde D_{jj} y D_{ii} son las dispersiones del i -ésimo y del j -ésimo clúster dadas por (3), respectivamente, y D_{ij} es la distancia entre los centros estadísticos de los clústeres dado por (2).

$$R_{i,j} = \frac{D_{i,i} + D_{j,j}}{D_{i,j}} \quad (1)$$

$$D_{i,j} = \|m_i - m_j\| \quad (2)$$

$$D_{i,i} = \frac{1}{N_i} \left[\sum_k \|x(k) - m\|^2 \right]^{1/2} \quad (3)$$

Donde m es la media del respectivo clúster y N es el número de datos. El índice de DB es determinado viendo el peor caso de separación como en (4), donde C corresponde al número de movimientos.

$$DB = \frac{1}{C} \left[\sum_k \max_{i \neq j} (R_{i,j}) \right] \quad (4)$$

Este criterio se calcula sobre las energías relativas de cada uno de los sub-espacios generados por la descomposición con la WPT y luego son comparados los respectivos índices DB, siendo la *mejor base* la combinación de sub-espacios no solapantes que tienen índices más pequeños. Esto garantiza la mejor separabilidad entre clases sin redundancia de información.

Una de las estructuras más flexibles y eficientes computacionalmente para implementar la transformada wavelet y que permite incluir etapas adaptativas es el propuesto por Sweldens [1] a través de los esquemas de actualización o *lifting schemes* que consisten en la iteración de los siguientes 3 pasos:

- 1) Separación: dividir la señal original en dos conjuntos diferentes, e.g. se divide la señal original $x[n]$ en las muestras pares $xe[n] = x[2n]$ y en las muestras impares $xo[n] = x[2n-1]$.
- 2) Predicción: se generan los coeficientes de detalle (frecuencias altas) $d[n]$ como el error en la predicción de $x[n]$ usando la información de $xe[n]$, usando el operador de predicción P .

$$d[n] = xo[n] - P(xe[n]) \quad (5)$$

- 3) Actualización: combinando $xe[n]$ y $d[n]$ se obtienen los coeficientes de aproximación (frecuencias bajas) $c[n]$ que representan una aproximación a la señal original. Eso es logrado aplicando un operador de actualización U a los coeficientes de la wavelet y sumándolos con $xe[n]$.

$$A[n] = xe[n] - U(d[n]) \quad (6)$$

En la Figura 4 se puede apreciar el esquema de actualización con los dos operadores P y U .

Los esquemas de actualización permiten incluir etapas adaptativas al seleccionar los filtros de actualización primaria $P(z)$ y los filtros de actualización dual $U(z)$ con algún criterio de decisión D el cual dependa de las características locales de la señal de entrada $x(n)$. En la Figura 5 se puede apreciar el esquema de actualización dual y primario adaptativo.

La selección adecuada de los filtros P y U permite la construcción de la transformada wavelet. De hecho cualquier transformada wavelet ortogonal o biortogonal

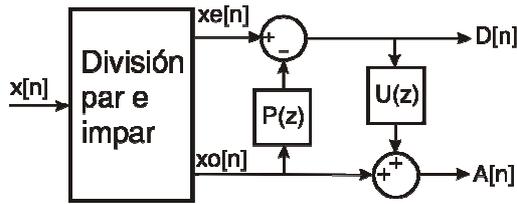


Figura 4. Esquema de actualización primaria (operador de predicción P) y dual (operador de actualización U).

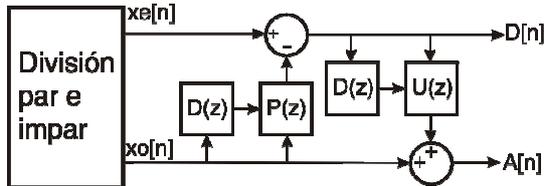


Figura 5. Esquema de actualización adaptativo primaria y dual con los criterios de decisión D .

puede ser construida a través de esquemas de actualización, donde el orden del filtro está relacionado con el número de momentos de desvanecimiento de las wavelets.

2.3 Selección de características y reducción de dimensionalidad

Como características relevantes del análisis con la transformada wavelet se crea un conjunto de características que comprenden medidas estadísticas y de energía de los máximos locales de los sub-espacios de la mejor base. Estas características son *invariantes a la traslación* a diferencia de los propios coeficientes de la transformada que tienen este, inclusive pequeños desplazamientos de la señal pueden hacer que los coeficientes cambien totalmente [14]. Sin embargo, el espacio de características es de alta dimensionalidad (40 características). Para la reducción de esta dimensión se emplea el Análisis de Componentes Principales (PCA) que permite representar un conjunto de datos en un espacio de dimensión menor al original sin pérdida de información significativa, proyectando los datos sobre los vectores propios del espacio inicial. El criterio que se maximiza es la varianza.

2.4 Clasificación

Con el propósito de validar las diferentes técnicas presentadas se entrena un clasificador Bayesiano lineal usando validación cruzada *k-fold* con un 30% de la base de datos para validación y el restante 70% para validación, y para 10 experimentos o folds.

3. RESULTADOS

Para la caracterización de las señales SEMG usando la DWT un parámetro importante para seleccionar es precisamente la wavelet madre. En este trabajo se usan

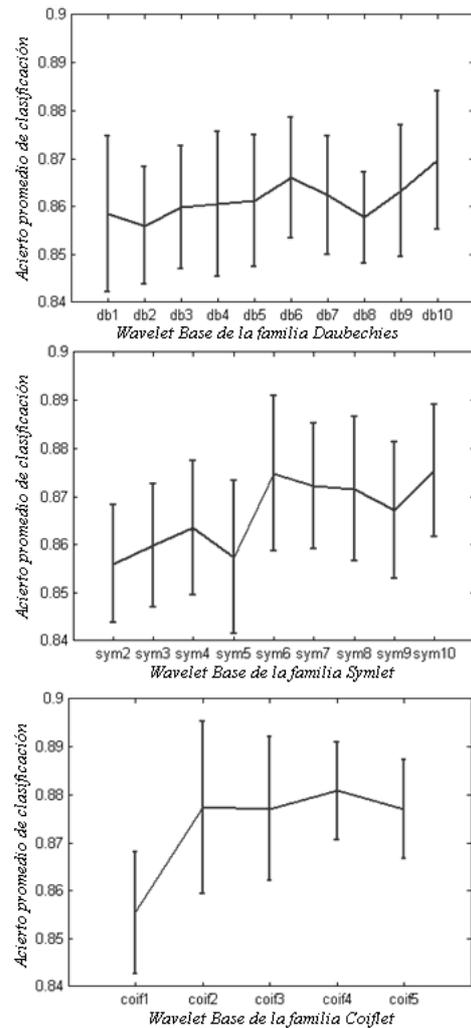


Figura 6. Resultados de clasificación promedio para tres diferentes familias de Wavelet Madre y diferentes órdenes. 1) Daublet 2) Symlet y 3) Coiflet

las wavelet madre de las familias Coiflet, Daubechies, symlet [14], las cuales presentan una aceptable relación entre soporte, número de momentos de desvanecimiento y la regularidad. En la Figura 6 se aprecian los resultados de clasificación promedio para cada una de estas funciones y variando el número de momentos de desvanecimiento.

Los mejores aciertos de clasificación se obtuvieron usando los órdenes más grandes de las funciones wavelet, donde al ir aumentado la regularidad y el número de momentos desvanecimiento las funciones se ajustan mejor a las singularidades de la señal SEMG, mientras que los ordenes bajos no resultan apropiados para la caracterización. A pesar de que no se puede identificar una función wavelet madre como “superior” al resto, se puede seleccionar la mejor función wavelet del experimento que al igual que en [4] para señales SEMG es la Coiflet de orden 4.

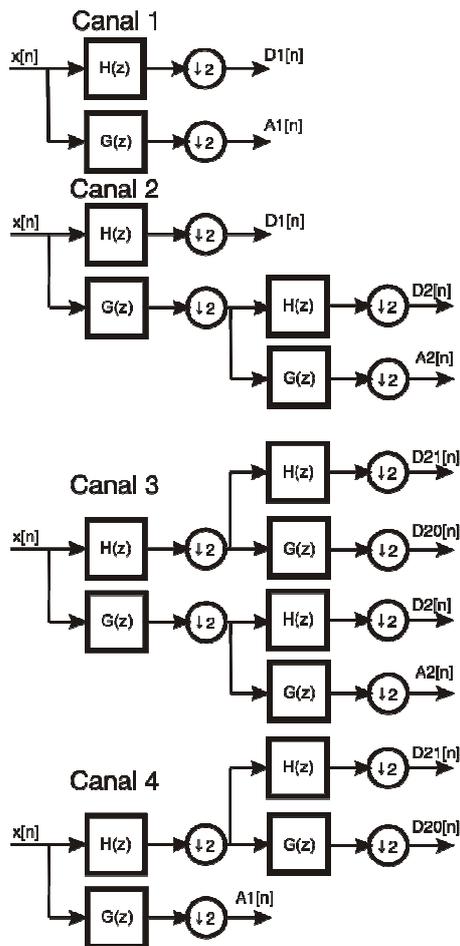


Figura 7. Mejores bases para la transformada Wavelet Packet para cada canal de adquisición por separado usando el algoritmo de Davies-Bouldin como metodología de selección de los espacios que maximizan la separabilidad entre clases.

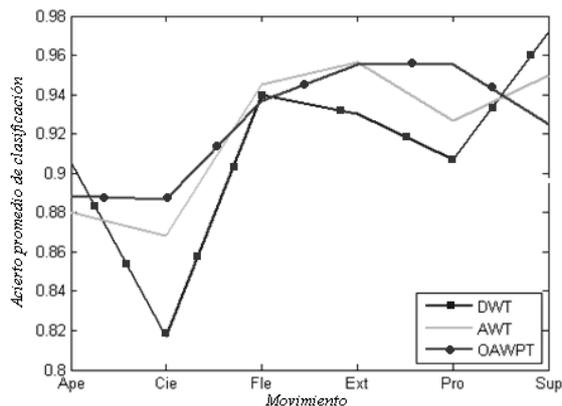


Figura 8. Comparación de las transformada wavelet Discreta, adaptativa y packet. En el eje y está el porcentaje promedio de acierto en la clasificación y en el eje x se tienen los diferentes movimientos.

Aparte de la selección de la Wavelet madre el único parámetro ajustable de la DWT es el nivel de descomposición j . Para una señal de longitud N el mayor

número de descomposición es $f_{max} = \log_2 N$, en este caso $N=400$; por tanto el nivel máximo de descomposición con la DWT que se puede llevar a cabo es de $j_{max}=8$. Sin embargo, puede encontrarse que uno de los niveles inferiores posea mayor información que el nivel inmediatamente superior, por lo cual es necesario el uso de algún criterio para seleccionar el mejor nivel de descomposición [15]. En este trabajo se usó la entropía de Shannon como medida de la información presente en cada nivel de descomposición. Como resultado se encontró que el mejor nivel de descomposición para estas señales es $j=2$.

En el caso de la transformada wavelet adaptativa el mejor esquema de actualización se selecciona comparando los porcentajes de acierto en la clasificación de dos esquemas diferentes de actualización: primario adaptativo y dual fijo (Up), y primario-dual adaptativo (UdP). Los filtros H y G que se usaron fueron propuestos por Deslauriers-Dubuc [9]; **Error! No se encuentra el origen de la referencia.**, los cuales tienen una aceptable relación entre el tamaño del soporte de la función y el orden de aproximación (orden del filtro). En la Tabla 1 se reportan los resultados de clasificación promedio para cada uno de los movimientos usando los dos esquemas de actualización mencionados.

AWT	%Ape	%Cie	%Fle	%Ext	%Pro	%Sup	%Total
Up	90.9	77.75	95.58	94.42	98.9	90.4	91.33±0.6
UdP	90.3	77.67	96.50	95.42	98.8	88.7	91.25±0.5

Tabla 1. Resultados en la clasificación promedio por movimiento para los dos esquemas de actualización de la transformada Wavelet Adaptativa.

Para la transformada wavelet packet, como se mencionó anteriormente, es necesaria la selección de la mejor base. En este trabajo se utilizó el algoritmo de Davies-Bouldin y como resultado la base que maximiza la separación entre las clases (movimientos) para la base de datos es la mostrada en la Figura 7 para cada uno de los canales de adquisición por separado.

En la Figura 8 se muestra la comparación de las diferentes transformadas wavelet mencionadas. Se puede apreciar el porcentaje promedio de acierto para cada movimiento usando la transformada wavelet Discreta (DWT), la transformada wavelet adaptativa (AWT) y la transformada wavelet packet (OAWPT).

Los resultados muestran con una diferencia del 2% en el porcentaje promedio de clasificación total, que el esquema de la WPT presenta mejores resultados que las otras transformadas debido a que esta última contiene información tanto del canal de aproximación como del canal de detalle, además seleccionando la mejor base para evitar redundancia de información, la WPT ha demostrado ser eficaz para el análisis de señales electromiográficas como en [7] y [2].

Finalmente se realiza la reducción del espacio característico usando análisis de componentes principales (PCA). En la Tabla 2 se muestran los aciertos promedio de clasificación para cada movimiento variando el número de componentes principales.

	%Ape	%Cie	%Fle	%Ext	%Pro	%Sup	%Total
PCA5	83.0	75.1	91.1	96.1	96.3	86.5	88.06±8.4
PCA10	89.0	85.8	94.3	96.1	94.5	91.3	91.86±4.3
PCA15	88.8	88.3	95.1	96.1	93.8	91.1	92.33±3.3
PCA20	89.1	89.6	94.1	94.6	96.1	92.1	92.69±3.5

Tabla 2. Resultados en la clasificación promedio por movimiento para diferentes cantidades de características usando reducción con PCA.

De acuerdo con las diferentes pruebas realizadas, se aprecia que solo se necesita un número reducido de componentes principales (20) para representar el espacio característico original entregado por la AOWPT, donde el espacio inicial era de 40 características.

4. CONCLUSIONES Y RECOMENDACIONES

Se presentó una metodología eficaz para caracterización de señales EMG de superficie usando diferentes transformadas wavelet con un porcentaje de acierto promedio en la clasificación superior al 92%, usando un clasificador bayesiano lineal para la identificación de los seis movimientos básicos de la mano.

Se encontró que un número menor a 20 componentes principales (de un espacio inicial de 40 características invariantes a la traslación) es suficiente para modelar el comportamiento de las señales SEMG. Los porcentajes de clasificación obtenidos con la transformada wavelet packet y óptima en el sentido de Davies-Bouldin, son superiores a los obtenidos con las otras transformadas wavelet implementadas, esto debido a la combinación de la flexibilidad en la resolución del espacio tiempo-frecuencia que permite la descomposición binaria de la WPT y la excelente aproximación usando los esquemas de actualización adaptativos.

Si bien los porcentajes de acierto obtenidos en la discriminación para los seis movimientos básicos de la mano se consideran interesantes, a manera de recomendación y/o trabajo futuro convendría aumentar el número de pacientes en el estudio y explorar otros esquemas de caracterización y clasificación diferentes al empleado (clasificador Bayesiano lineal) en aras de continuar el desarrollo a la fecha.

5. BIBLIOGRAFÍA

[1] W. Sweldens, "The lifting scheme: A custom-design construction of biorthogonal wavelets," *J. Appl. Comp. Harm. Anal.* vol. 3, no. 2, pp. 186-200, 1996.

- [2] K. Englehart, Hudgins, B.; Chan, A.D.C. "Continuous Multifunction Myoelectric Control using Pattern Recognition". *Technology and Disability*, vol 15, pp. 95-103, 2003.
- [3] B. Hannaford, S. Lehman, "Short Time Fourier Analysis of the Electromyogram: Fast Movements and Constant Contraction". *IEEE Transactions on Biomedical Engineering*, vol. BME-33, pp.1173-1181, Dic. 1986.
- [4] K. Farry, I. Walker, R. Baraniul, "Myoelectric teleoperation of a complex robotic hand". *IEEE Transactions on Robotics and Automation*, vol. 12, pp. 775-788, Oct. 1996.
- [5] L. Deqiang, W. Pedrycz, N. Pizzi, "Fuzzy wavelet packet based feature extraction method and its application to biomedical signal classification" *IEEE Transactions on Biomedical Engineering*, vol. 52, no 6, pp. 1132-1139, Jun. 2005.
- [6] G. Betancourt, E. Giraldo, J. Franco. "Reconocimiento de patrones de movimiento a partir de señales electromiográficas," *Scientia et Técnica* año X, no 26, Dic. 2004.
- [7] G. Wang, Z. Wang, W. Chen, J. Zhuang. "Classification of surface EMG signals using optimal wavelet packet method based on Davies-Bouldin criterion," *Springer Medical and Biological Engineering*, vol. 44, no. 10, pp. 865-872, Oct. 2006.
- [8] SENIAM.org, the European concerted action in the Biomedical Health and Research Program (BIOMED II) of the European Union. Consultado en Ago 2008.
- [9] E. Giraldo. "Caracterización de señales no estacionarias 1D y 2D usando wavelets adaptativas". Msc. Disertación. Dept. Ingeniería Eléctrica. Universidad Tecnológica de Pereira, 2006.
- [10] Yan R, Gao RX. An efficient approach to machine health diagnosis based on harmonic wavelet packet transform. *Robot Com Int Manuf.* vol 21, pp 291–301, 2005
- [11] S. Mallat, "A Wavelet Tour of Signal Processing", Academic Press, 1999.
- [12] Z.K. Peng, M.R. Jackson, J.A. Rongong, F.L. Chu, R.M. Parkin "On the energy leakage of discrete wavelet transform". *Mechanical Systems and Signal Processing*, 2008.
- [13] M. Wikerhauser. "Two fast approximate wavelet algorithms for image processing, classification, and recognition" *Optical Engineering*, vol. 33, no 7, pp 2225-2235, 1994.
- [14] Mallat, S. S, Zhonh, "Characterization of signals from multiscale edges" *IEEE Trans. Pattern Recognition and Machine Intelligence*, vol. 14, no. 7, 1992.
- [15] R. Coifman, M. Whickerhauser. "Entropy-based algorithms for best basis selection", *IEEE Transaction on Information Theory*, vol. 38, no 2, pp. 713-718. Mar 1992.