

RECONOCIMIENTO DE PATRONES DE SEÑALES EMG, EMPLEANDO CLASIFICADOR BAYESIANO

José Alfredo Palacio¹, Daniel Agudelo², Mauricio Vásquez³

¹M.sc. Automatización y Control Industrial, Docente ITM, Calle 73 No 76A -354 Vía al Volador - Medellín - Colombia. E-mail: josepalacio@itm.edu.co.

²M.sc. Automatización y Control Industrial, docente UdeA, Calle 67 Número 53 - 108- Medellín - Colombia. E-mail: dagudelo@matematicas.udea.edu.co

³M.sc. Automatización y Control Industrial, Docente ITM, Calle 73 No 76A -354 Vía al Volador - Medellín - Colombia. E-mail: henryvasquez@itm.edu.co.

RESUMEN

Este artículo parte de la obtención de señales electromiográficas (EMG) captadas a diecinueve personas que realizan cinco tipos de movimientos. Estas señales son almacenadas en una base de datos y procesadas para obtener de estas características temporales y espectrales. Haciendo uso de selección automática de características, se obtienen las que presenten mejor desempeño y estas son empleadas finalmente en un clasificador bayesiano que determina la pertenencia o no a una clase de movimiento realizado. Se emplea la técnica de validación cruzada para validar los resultados del clasificador.

Palabras clave: Electromiografía, característica, clasificación, validación, selección, wavelet

Recibido: 28 de febrero de 2013.
Received: February 28th, 2013.

Aceptado: 17 de Junio de 2013.
Accepted: June 17th, 2013.

PATTERN RECOGNITION OF EMG SIGNAL USING BAYESIAN CLASSIFICATION

ABSTRACT

This article is based on the acquisition of electromyographic signals EMG captured from nineteen subjects performing five different types of movements. These signals are stored on a database and then processed to obtain temporal and spectral characteristics from them. Making use of an automatic selection of these characteristics, those that demonstrate the best performance are obtained and finally applied on a Bayesian classifier which determines whether or not it belongs to the class of movement that was performed. A Cross-validation technique is then employed to validate the outcome of the classifier.

Keywords: *Electromyography, feature, classification, validation, selection, wavelet*

1. INTRODUCCIÓN

Este trabajo forma parte de una propuesta de proyecto, en el que se requiere controlar un manipulador mecánico. Se basa en la clasificación de cinco tipos de movimiento partiendo de señales EMG captadas a diecinueve personas entre 16 y 55 años y tomadas de tres canales ubicados en el bíceps, tríceps y el flexor cubital del carpo, se realizó un tratamiento de la piel para lograr impedancias de orden de los 10 k Ω recortando los electrodos en el adhesivo para lograr aproximar esta impedancia. La ubicación de los electrodos, se basó en los estudios experimentales referenciados por [1] y [2].

Las señales EMG fueron adquiridas empleando un sistema propio de amplificación de instrumentación y una tarjeta de adquisición de datos P-TAD-S01 BASIC con 10 bit A/D, Comunicación USB, 8 Entradas Análogas, 2 Salidas Análogas, 8 Entradas Digitales, 7 Salidas Digitales. Soporte: LabVIEW (7.1 y versiones superiores). Las señales de cada canal, fueron pasadas por un proceso de caracterización temporal de valores RMS, el valor promedio, los coeficientes de correlación y la desviación típica y de caracterización espectral y Wavelet en cuanto a la frecuencia media y la energía.

De las características previamente extraídas se seleccionan las que mejor desempeño presentaron empleando el algoritmo (Sequential Floating Forward Selection) SFFS y finalmente se valida el clasificador bayesiano empleado mediante validación cruzada.

El proceso llevado a cabo se representa en la figura 1, donde ξ_i es la *i*-ésima característica empleada, CE. es el clasificador estadístico y mov el movimiento reconocido.




Figura 1. Esquema general de clasificación

2. MATERIALES Y MÉTODOS

A continuación se describen los elementos empleados y las técnicas de caracterización, selección, clasificación y validación en el proceso de reconocimiento de los patrones de las señales EMG.

2.1. Características Extraídas

Las características extraídas de la señal EMG, dan idea de diferentes comportamientos de la misma, en amplitud, fase, tiempo y frecuencia. A continuación se indican algunas de las características temporales y espectrales que pueden ser empleadas en la clasificación de movimientos musculares y se obtienen para cada canal (ver figura 2) y combinaciones de los mismos.

2.1.1. Características Temporales

En la mayoría de los casos, las características temporales que han sido usadas en señales EMG son: la señal RMS, cruces por cero, la media de la señal rectificada [3].

Algunas de las características temporales que pueden dar idea del movimiento realizado se expresan en la tabla 1.

2.1.2. Características Espectrales y wavelet.

Las características espectrales y de wavelet entregan información oculta en las características temporales. Las wavelets van más allá entregando tanto detalles temporales como espectrales [4], la transformada wavelet en tiempo discreto (TWTD), es una característica que entrega un análisis multiresolución, dando idea del tiempo y la frecuencia (escala) en ventanas de señal variable.

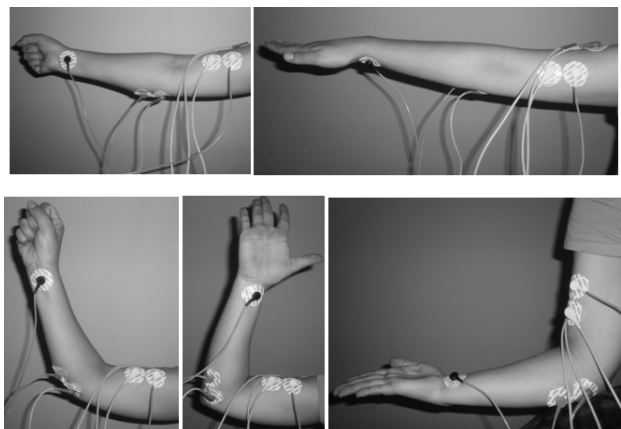


Figura 2. Ubicación de los electrodos en uno de los voluntarios tomando los cinco movimientos

Tabla 1. Características temporales

Nombre	Descripción	Cálculo
Valor RMS	Permite caracterizar la señal de acuerdo a su contenido de energía.	$RMS = \sqrt{\frac{\sum_{i=1}^n (x_i)^2}{n}}$
Valor medio	Describe la tendencia central de la señal EMG.	$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$
Correlación	Se usa para determinar la similitud entre la información contenida en los diferentes canales de la señal tomada.	$r = \frac{s_{xy}}{s_{xx}s_{yy}}$ donde: $s_{xy} = \sum_{i=1}^n xy - \frac{\sum_{i=1}^n x \sum_{i=1}^n y}{n}$
Desviación típica	Mide la dispersión de los datos respecto al valor medio.	$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$

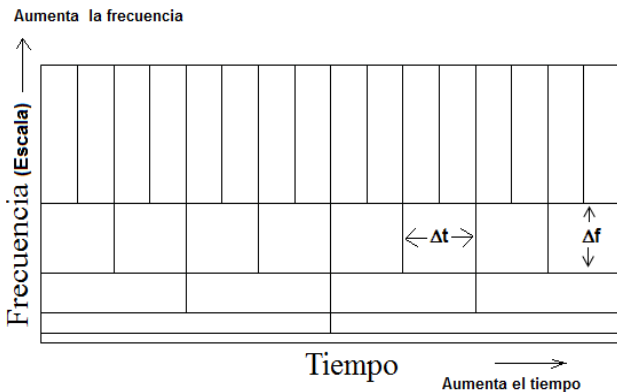


Figura 3. Banco de filtros

De la transformada wavelet discreta se derivan otras características como son la energía y la energía Shannon [5]. En la tabla 2 se indican las características espectrales analizadas para cada canal y combinación de los mismos:

La wavelet, se realizó empleando un banco de filtros pasa bajo y pasa alto en cuyo proceso se repite n niveles tomando como señal a filtrar la generada por el filtro pasa baja del nivel previo, en la figura 3 se puede apreciar el diagrama multiresolución generado al combinar los diferentes niveles de descomposición en escalas contra la

Tabla 2. Características Espectrales y Wavelets

Nombre	Descripción	Cálculo
Frecuencia media	Es el coeficiente entre los momentos espectrales uno y cero.	$\bar{f} = \frac{\sum_0^1 f \cdot s(f)}{\sum_0^1 s(f)}$
Energía Wavelet	Energía total de los coeficientes en cada nivel de descomposición para detalle y aproximación.	$E_n = \sum_k C_k ^2$
Energía Shannon	Determina la intensidad media de la señal en amplitudes altas o bajas al emplear un operador logarítmico de la misma energía.	$E_s = \frac{-1}{M} \sum_k c(k)^2 \log(c(k)^2)$

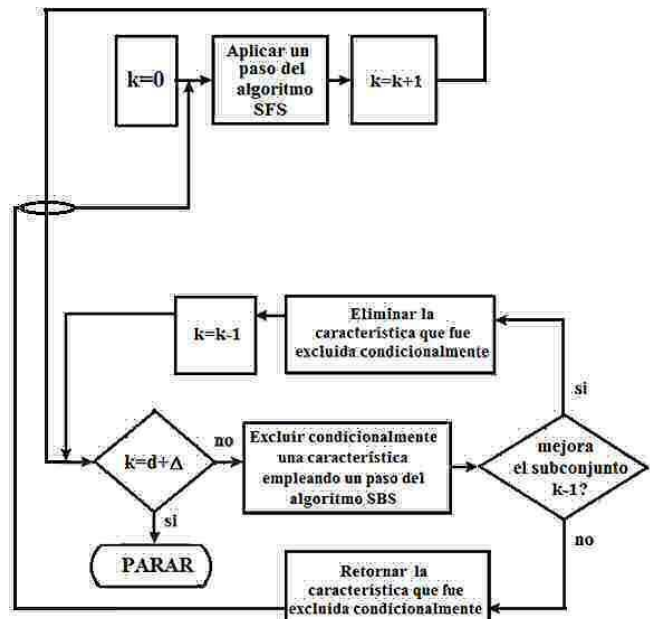


Figura 4. Selección de características (SFFS)

señal temporal resultante, logrando aproximaciones en bajas frecuencia (escalas) y detalle en alta frecuencia (escalas).

2.2. Selección de Características

La figura 4 representa el proceso que se lleva a cabo en la selección de características. Tanto los valores temporales (figura 5a) como espectrales (figura 5b), suministran información sobre cada señal que puede ser empleada para diferenciarla de las demás.




Figura 5. Señal temporal y su densidad espectral




Figura 6. Longitud de señal tomada del canal dos vs canal uno más tres

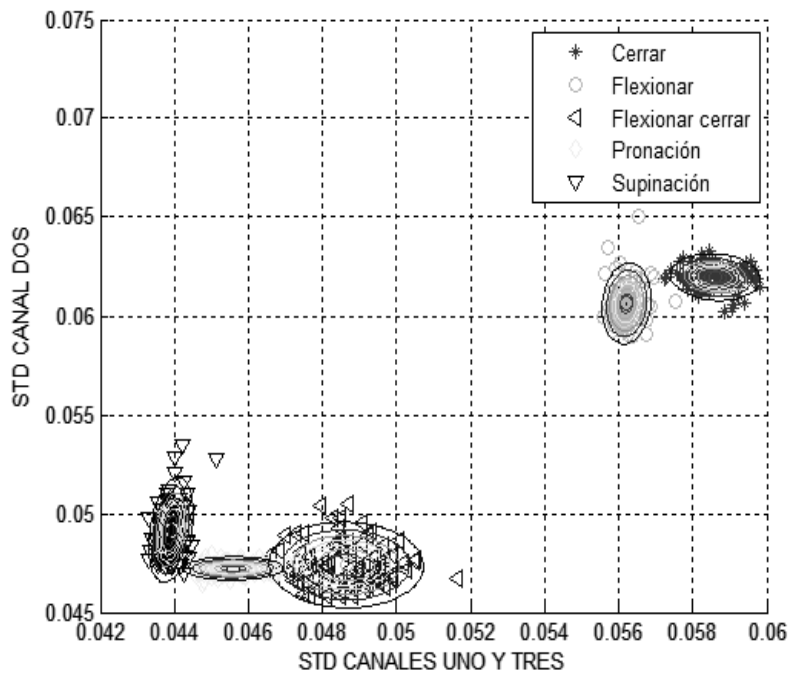


Figura 7. Desviación típica

En la figura 6, se describe la matriz que contiene el espacio de representación de las señales procesadas en tiempo, Wavelets y frecuencia. Donde $\xi_{i,K,m}$ es el valor extraído a la muestra i con K como el número total de características que es de 67, extraídas para cada una de las 171 muestras por movimiento (m)

En la figura 7 se representa un par de características (desviación típica o STD) seleccionadas aleatoriamente y asociadas a los tres canales EMG. En la que se aprecia similitud entre algunas de las clases.

Empleando el selector representado por la figura 4, se procedió ahora a la implementación del

clasificador bayesiano entrenándolo con las características entregadas por el selector SFFS [6].

2.3. Clasificación y Validación

Uno de los métodos de reconocimiento de patrones, es el de inferencia estadística, en el que se estima la probabilidad a posteriori de la pertenencia de una muestra a una determinada clase, mediante la evaluación de la probabilidad a priori realizada en el proceso de segmentación de clases. Y evaluada según el teorema de Bayes (ecuación 1) [7], el cual determina que:

$$P(\omega_i | \mathbf{x}) = \frac{P(\mathbf{x} | \omega_i)P(\omega_i)}{p(\mathbf{x})} \tag{1}$$

Donde $p(\mathbf{x})$ es la densidad espectral (PDF) de \mathbf{x} (vector de características), $p(\mathbf{x}|\omega_i)$ es la probabilidad a priori para los datos empleados en el entrenamiento y $p(\omega_i)$ es la probabilidad de cada clase que en este caso se toma como el inverso del número de clases.

$$p(\mathbf{x}) = \sum_{i=1}^2 P(\mathbf{x}|\omega_i)P(\omega_i) \tag{2}$$

El clasificador Bayesiano puede fijarse para dos clases como:

Si $p(\omega_1 | \mathbf{x}) > p(\omega_2 | \mathbf{x})$, \mathbf{x} es clasificado por ω_1

Si $p(\omega_1 | \mathbf{x}) < p(\omega_2 | \mathbf{x})$, \mathbf{x} es clasificado por ω_2

La figura 8, muestra las distribuciones gaussianas generadas para cada función de distribución de probabilidad (ecuación 3), tomando datos de entrenamiento con dos características para construir las bases de las gaussianas y posteriormente se hizo pasar cada dato al proceso de validación y se entregó el grado de pertenencia a la clase que mejor probabilidad entregó.

$$p(\mathbf{x}) = \frac{1}{(2\pi)^2 |\Sigma|^2} e^{-\frac{1}{2}(\mathbf{x}-\mu)^T \Sigma^{-1}(\mathbf{x}-\mu)} \tag{3}$$

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{bmatrix}$$

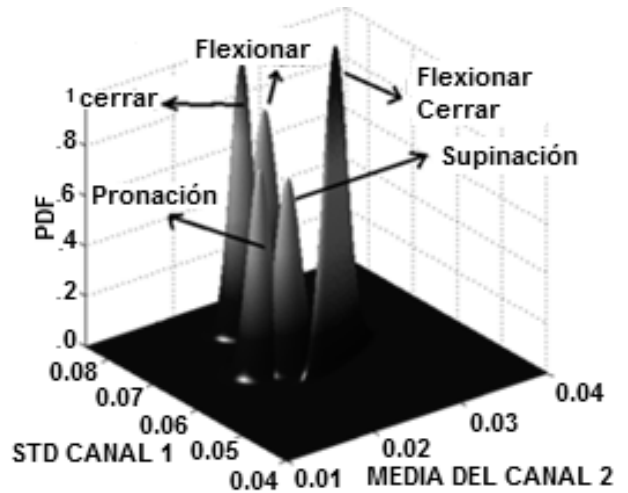


Figura 8. Distribución Gaussiana de las clases de movimiento

$p(\mathbf{x})$ genera una distribución gaussiana con base elíptica dependiente de los valores de la varianza σ_1 y σ_2 y la covarianza σ_{12} valores determinados por los datos empleados en la etapa de entrenamiento del clasificador. La función se puede construir en un espacio superior que albergue más de dos combinaciones de características.

Se consiguieron los mejores resultados, empleando tres combinaciones de características apoyados en el método de validación cruzada En [8] en las que se rotan muestras de entrenamiento y muestras clasificadas, la distribución en el espacio de características se indica en la figura 9 y su matriz de confusión se muestra a continuación:

Tabla 3. Matriz de confusión para los datos representados en la figura 8 dados por el selector de características SFFS

	cerrar	Flexionar	flexionar cerrar	Pronación	supinación
Cerrar	100%	0	0	0	0
flexionar	0	100%	0	0	0
cerrar	0	0	100%	0	0
flexionar			0	0	0
pronación	0	0	0	100%	0
supinación	0	0	0	0	100%

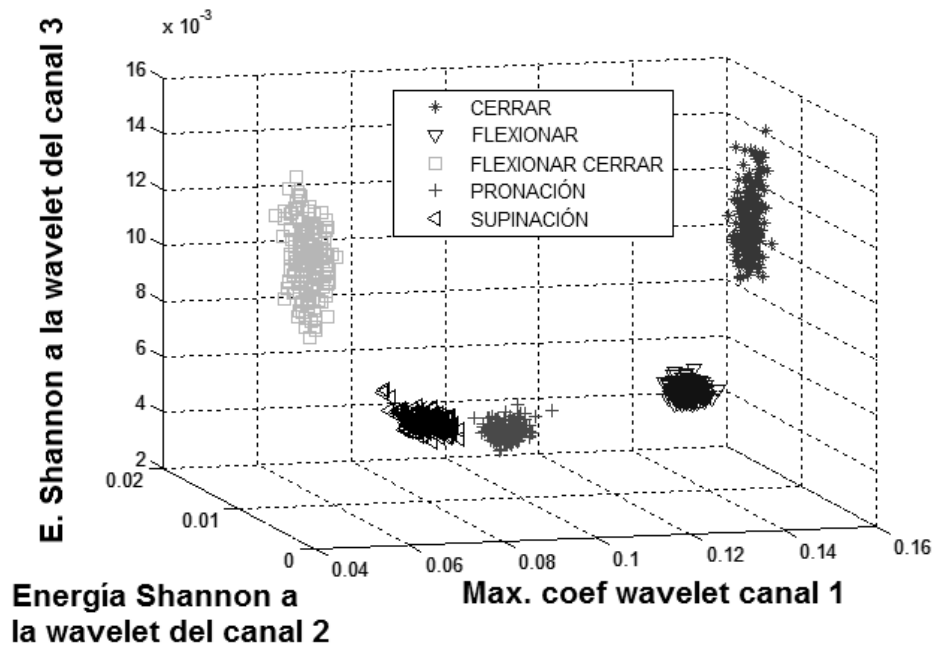


Figura 9. Distribución espacial de las tres características seleccionadas

3. RESULTADOS

Los resultados obtenidos, mejoran la clasificación de algunos movimientos con respecto a otros autores, pero no se logra unificar el mismo tipo de movimiento en las diferentes fuentes consultadas.

El clasificador bayesiano se puede acoplar fácilmente a más de tres características. Los tres canales son necesarios para poder obtener una clasificación del 100% de acuerdo a los datos obtenidos del selector SFFS

Las características de coeficiente wavelet y la energía wavelets son las más relevantes en la clasificación de las señales EMG procesadas. Es importante también comprar a futuro los datos obtenidos con adquisiciones empleando equipos profesionales.

4. CONCLUSIONES

El clasificador bayesiano se puede acoplar fácilmente a más de tres características. Las características de coeficiente wavelet y la energía wavelets son las más relevantes en la clasificación de las señales EMG procesadas. Los tres canales son necesarios para poder obtener una clasificación del 100% de acuerdo a los datos obtenidos del selector SFFS

5. REFERENCIAS

- [1] SENIAM. Welcome to SENIAM. [En línea] <http://www.seniam.org/>.
- [2] Criswell, E. (2011). *Surface Electromyography*. Sudbury: Jones and Bartlett Publishers.
- [3] Singh, Vijay Pal. 2010. *Empirical Modelling and Classification of Surface Electromyogram*. Melbourne: College of Science, Engineering and Health RMIT University
- [4] Arikidis, Nikolaos S., Eric W. , Abel y Forst, Alan. 2002, *Interscale Wavelet Maximum-A Fine to Coarse Algorithm for Wavelet Analysis of the EMG Interference Pattern*. IEEE Trans on Biomed Eng, págs.337–344.
- [5] Rask, Peter, y otros. 2006, *Feature Extraction for Systolic Heart Murmur Classification*. Annals of Biomedical Engineering, págs. 1666–1677.
- [6] Pudil , P. , Novovicova, J. y Kittler, J. . 1993, *Floating search methods in feature selection*. Elsevier Science B.V., págs. 1119-1125.
- [7] Romo , Harold A., Realpe, Judy C. y Jojoa, E. Pablo. 2007, *Análisis de Señales EMG Superficiales y su Aplicación en Control de Prótesis de Mano*. Revista Avances en Sistemas e Informática, págs. 127-136.
- [8] Khezri, M. y Jahed, M. 2007, *A Novel Approach to Recognize Hand Movements Via sEMG Patterns*. Proceedings of the 29th Annual International, págs. 4907-4910.