

Determinación de movimientos a partir de señales electromiográficas utilizando máquinas de soporte vectorial.

Álvaro Ángel Orozco Gutiérrez.

M.Sc. Ingeniería Eléctrica; Ph.D (c) Bioelectrónica Universidad Politécnica de Valencia. Profesor Titular, Universidad Tecnológica de Pereira.

Gustavo Andrés Betancourt Orozco.

Ingeniero Electricista. Estudiante Maestría en Ingeniería Eléctrica, Universidad Tecnológica de Pereira

Eduardo Giraldo Suárez

Ingeniero Electricista. Estudiante Maestría en Ingeniería Eléctrica, Universidad Tecnológica de Pereira

Resumen

*Este documento discute una metodología para el reconocimiento de patrones de movimiento a partir de señales electromiográficas (EMG) del sistema fisiológico brazo – antebrazo, el cual parte del diseño y construcción de un sistema de instrumentación para la captación de señales electromiográficas teniendo en cuenta la normatividad **SENIAM (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles)** para electromiografía de superficie y las características de la señal EMG. Además, se aplicaron técnicas de procesamiento y caracterización basadas en: aproximación temporal, modelamiento paramétrico, **STFT (Short Time Fourier Transform)** y **Wavelets** en la construcción de un conjunto de características híbrido para ser utilizado en el reconocimiento de patrones de movimiento utilizando máquinas de soporte vectorial, que pueda ser utilizado para el control de una prótesis, una silla de ruedas en personas con discapacidad, o para la ejecución de tareas donde el contacto directo por parte del usuario no sea posible.*

Palabras clave: Electromiografía, instrumentación, caracterización de señales, clasificación de movimientos, máquinas de soporte vectorial.

Recibido para publicación: 03-11-2004

Aceptado para publicación: 22-06-2005

Introducción

En los últimos años han cobrado gran importancia los trabajos de investigación encaminados a la realización de interfaces hombre-máquina especialmente diseñados para la ayuda a personas con discapacidad o para la ejecución de tareas sin contacto directo por parte del operario (1). Una de las formas para conseguir ese objetivo es la captación de señales electromiográficas (EMG) provenientes de los músculos que están asociadas cualitativamente con el tipo de movimiento producido.

El estudio de estas señales ha permitido el desarrollo de importantes proyectos para el bienestar humano. Dichos trabajos comenzaron con los realizados por Graupe y Cline (2) en el reconocimiento de características en 1975 y seguidos por Doershuck en 1983 aplicando técnicas de correlación. En 1995 Kang (3) utilizó coeficientes cepstrales obteniendo índices de éxito del 85%. A partir de 1999 el departamento de Neuro-Ingeniería de la NASA (4) desarrolló técnicas de reconocimiento de patrones EMG por medio de redes neuronales y modelos ocultos de Markov. En el año 2002 Fergusson y Dunlop (5) desarrollaron técnicas de caracterización de señales EMG basadas en modelamiento paramétrico, STFT, Wavelets, y de reconocimiento con redes neuronales y métodos estadísticos (5).

En el 2003, se desarrollaron también trabajos para el entrenamiento de prótesis y predicción de fatiga en los músculos, así como optimización en el diseño de los algoritmos de reconocimiento de patrones en tiempo real. En estos algoritmos de extracción de características se pueden reconocer los implementados por Hudgins, Englehart y otros (6) realizando aproximación temporal y modelamiento paramétrico, así como los de Hannaford (7) y Farry (1) con aproximación espectral (FFT, STFT). Se han utilizado los

algoritmos de extracción de características basados en compresión con **wavelets** y **wavelet packets** y los de compresión EZW (8). Actualmente los trabajos de investigación en esta área están dirigidos a encontrar los algoritmos de procesamiento, caracterización y clasificación de patrones de dichas señales, que permitan el análisis y la determinación del tipo de movimiento (5, 9) con porcentajes de acierto entre 80% y el 97% dependiendo del número de electrodos y del número de movimientos detectados.

Basado en lo anterior este trabajo busca discutir:

- El diseño y desarrollo de un sistema de instrumentación y medida para la captación de señales electromiográficas utilizando la normatividad SENIAM.
- Los algoritmos implementados utilizando técnicas de adquisición continua en tiempo real, las técnicas de caracterización híbridas en tiempo y frecuencia utilizando la transformada Wavelet, la transformada rápida de Fourier (FFT), la STFT y el modelamiento paramétrico en el análisis de potenciales bioeléctricos,
- Y el reconocimiento de patrones utilizando un algoritmo basado en una máquina de soporte vectorial.

El esquema del proyecto se observa en la figura 1. Este procedimiento se realizará para dos músculos (bíceps y tríceps), con el fin de caracterizar los patrones de movimiento del sistema fisiológico brazo-antebrazo como son: flexión, extensión, supinación, y pronación, para que sean reconocidos por un clasificador con porcentajes de acierto superiores al 90%, lo cual es superior a trabajos desarrollados sobre el mismo tema para el mismo número de canales (9).

Todo el software se desarrolló utilizando herramientas tales como LabVIEW™ Matlab™, y el V-Realm Builder™ para la visualización de resultados en un entorno virtual y con un manipulador didáctico de 5 grados de libertad.

Materiales y Métodos

La primera parte del proyecto fue la adquisición de la señal electromiográfica del sistema fisiológico brazo-antebrazo para permitir su procesamiento en un PC. Para esto se utilizó un modelo típico de instrumentación: captación de la señal (sensores), acondicionamiento (amplificadores y filtros), conversor análogo digital (tarjeta de adquisición de datos) y procesamiento (PC) (ver figura 2).

Sensores - Electrodo EMG

Las señales electromiográficas son producidas como respuesta a un movimiento muscular, donde el nivel de esfuerzo está determinado por el número de fibras musculares activadas durante la contracción por una neurona (10). El potencial eléctrico de una unidad motora puede ser medido utilizando electrodos de aguja o de superficie (11). Para este proyecto se utilizaron electrodos de superficie del tipo **Ag - ClAg** de acuerdo a la normatividad **SENIAM** para electromiografía de superficie. La señal medida de la piel es la

suma espacial y temporal de las unidades motoras individuales así como de los músculos en la vecindad del electrodo (12).

Para el posicionamiento de estos electrodos de superficie se tuvo en cuenta las recomendaciones dadas por la normatividad **SENIAM** (12) (ver figura 3).

De otra forma, se ha podido evidenciar que la señal EMG tiene una amplitud típica entre 0 y 6mV, y la frecuencia útil está en el rango de 0 a 500Hz con la mayor cantidad de energía concentrada entre los 50 y los 150Hz (13).

Acondicionamiento

El cuerpo humano es una excelente antena para el ruido ambiental especialmente a 60Hz que es precisamente el rango donde se concentra la mayor cantidad de energía de las señales EMG. Debido a esto se utilizaron amplificadores de instrumentación con un alto rechazo en modo común (**CMRR >120dB**) con lo cual se eliminó en gran parte este ruido.

También se utilizó un filtro pasa alto con frecuencia de corte en 15Hz para eliminar señales que no eran de interés para el proyecto como el potencial de repolarización de los músculos, así como un filtro pasa bajo con frecuencia de corte en 450Hz para eliminar frecuencias superiores que no contribuían con la información de interés y eliminar posibles distorsiones en la señal debido a una baja frecuencia de muestreo (**aliasing**) (13).

Adquisición

Para la adquisición de los datos se utilizó una tarjeta de DAQ 6024E de National Instruments conectada en modo diferencial con una frecuencia de muestreo de 1kHz, garantizando la adquisición en línea y la no pérdida de datos durante el procesamiento.

Preprocesamiento

En esta sección se implementaron las rutinas necesarias para la extracción de la parte de la señal que se quiere utilizar. De acuerdo a (14) los primeros 400ms de un movimiento muscular son suficientes para la identificación del movimiento por lo que se realizó la extracción de la señal con una ventana de esa amplitud, como se enseña en la figura 4.

Extracción de Características

La extracción de características fue hecha a partir de aproximación temporal, modelamiento paramétrico AR (**autoregresivo**), FFT, STFT, transformada Wavelet, generando un vector híbrido de características que permitirá la identificación de las señales electromiográficas.

A continuación se analizarán las características encontradas para un conjunto de datos electromiográficos obtenidos para dos músculos (bíceps y tríceps) en un sujeto de prueba sano (sin amputación).

Aproximación Temporal

Para este caso se utilizaron cuatro características, definidas por Ferguson y Du (5, 15):

- Valor Medio Absoluto: es el promedio del valor absoluto de la señal EMG.
- Cruces por cero: Es el número de veces que la señal EMG pasa por cero.
- Cambio de pendiente: Es el número de veces que cambia la dirección de crecimiento de la señal EMG.
- Longitud de la onda: esto es simplemente el acumulado de la distancia entre dos muestras consecutivas de la señal EMG.

En la figura 5 se observan los vectores de características utilizando aproximación temporal para los cuatro movimientos, tomando 30 muestras por movimiento y de acuerdo a las convenciones de la tabla 1.

Modelamiento Paramétrico AR

Se conoce que una señal EMG adquirida a través de electrodos de superficie (14) puede ser considerada como la salida de un filtro pasa bajo que representa al músculo y las fibras musculares, con la salida del filtro aproximadamente Gausiana. Debido a que el filtro óptimo para un proceso Gausiano es un filtro lineal, se pueden escoger modelos AR que además de presentar un bajo costo computacional, representan la mejor aproximación de la señal EMG (5, 14). Las características extraídas fueron los 3 coeficientes de menor orden del modelo (14), para un modelo de orden 5. En la figura 6 se observan los vectores de características utilizando modelamiento paramétrico AR para los cuatro movimientos, tomando 30 muestras por movimiento y de acuerdo a las convenciones de la tabla 2.

Aproximación Espectral

Para la obtención de características utilizando aproximación espectral se utilizaron dos métodos (15, 16):

Periodograma: Una forma de estimar la densidad del espectro de potencia (PSD) de una señal es simplemente encontrar la transformada discreta de Fourier (usualmente hecha con FFT) y tomar la magnitud al cuadrado del resultado. Este estimado es llamado *periodograma*.

A partir de este cálculo se extraen dos características:

- Potencia promedio de la señal EMG.
- Potencia máxima de la señal EMG.

Espectrograma: Calcula la transformada de Fourier dependiente del tiempo para una señal, usando una ventana deslizante. Esta forma de transformada de Fourier, también se conoce como STFT. El *espectrograma* es la magnitud de esta función.

A partir de este cálculo se extraen dos características:

- Energía media de la señal EMG.
- Energía máxima de la señal EMG.

En la figura 7 se observan los vectores de características utilizando aproximación espectral para los cuatro movimientos, tomando 30 muestras por movimiento y de acuerdo a las convenciones de la tabla 3.

Descomposición con Wavelets

Teniendo en cuenta los resultados obtenidos por (14), se utilizaron los coeficientes de los niveles de descomposición que mejor representaran la señal, con base en la energía y la entropía, utilizando **Wavelet Packets**; se realizaron 5 niveles de descomposición, con una **wavelet** del tipo **Daubechies** de orden 6, y con entropía tipo **Shannon** (17, 18, 19). En la figura 8 se observan los vectores de características utilizando descomposición por **Wavelet Packets** para los cuatro movimientos, tomando 30 muestras por movimiento y de acuerdo a las convenciones de la tabla 4.

Pruebas para Reconocimiento de Patrones de Movimiento

Las características obtenidas para las dos señales musculares fueron agrupadas en un vector para ser utilizadas como entradas en una máquina de soporte vectorial multiclase (MCSVM), las cuales representan las técnicas más novedosas de aprendizaje que han sido introducidas en el área de minimización de riesgo estructural (SRM), y en la teoría de límites VC (Vapnik Chervonenkis). En las tareas más fáciles de reconocimiento de patrones, las máquinas de soporte vectorial (SVM) utilizan un plano que divide las clases a reconocer para crear un clasificador con un margen máximo entre clases (20, 21). En los casos en los que las clases dadas no puedan ser linealmente separables en el espacio de entrada original, la SVM primero transforma los datos a un espacio de características de una dimensión mayor (ie: 2D \rightarrow 3D) en donde sean linealmente separables, por medio de una función conocida denominada Kernel. Luego de este paso de transformación, la tarea de la SVM es encontrar una frontera lineal óptima que separe las clases de datos que se desea. Se tomaron 30 vectores de 40 características para cada uno de los cuatro patrones de movimiento seleccionados (flexión, extensión, supinación, pronación), que permitieron el entrenamiento de la máquina de soporte vectorial (22, 23) (ver figura 9).

Las pruebas se realizaron sobre 4 sujetos de prueba (2 con amputación por debajo del codo *P.C.A.*, y 2 sin amputación *P.S.A.*). Como resultado, durante el reconocimiento de patrones, se consiguieron los porcentajes de acierto mostrados en la tabla 5.

Los resultados se observan en diferentes entornos virtuales realizados con el **toolbox** de realidad virtual de Matlab™, y la herramienta V-Realm Builder™ (24), y con un manipulador didáctico de 5 grados de libertad, como se observa en la figura 10. Los resultados obtenidos y más información adicional de este artículo se puede obtener en: <http://ohm.utp.edu.co/~egiraldos/>

Conclusiones

Las técnicas de instrumentación utilizadas permiten que la señal adquirida pueda ser analizada exitosamente si se tienen en cuenta tanto la normatividad para la adquisición de señales EMG de superficie, como lo referente a las técnicas para eliminación de perturbaciones (potenciales de repolarización de los músculos, ruido ambiental, artefactos) así como las técnicas de adquisición y procesamiento (25).

La adquisición de la señal utilizando técnicas modernas de almacenamiento de datos en memoria (**circular buffer**) garantiza que el análisis sea hecho sobre toda la señal y que no se pierdan datos durante esta operación por lo que se puede dar confiabilidad al sistema.

Se utilizaron técnicas de caracterización híbridas permitiendo un mejor desempeño por parte del clasificador, lo cual se evidenció en el tiempo de entrenamiento de la máquina de soporte vectorial, y en los porcentajes de acierto. Comparando con otros trabajos realizados sobre el mismo tema y que utilizan el mismo número de electrodos, se tiene que los porcentajes de acierto en la clasificación cuando se utilizan vectores de características híbridas son entre un 5% y un 10% superiores (18). Además, el tiempo utilizado en el procesamiento y reconocimiento de las señales EMG se encuentra alrededor de los 200ms para ventanas de datos de 400ms, con lo que se garantiza una respuesta del sistema en tiempos cercanos a los 600ms, que es comparable a los resultados obtenidos por otros investigadores (1, 9).

La utilización de entornos virtuales tridimensionales muestra el alcance de este trabajo para ser aplicado en ambientes físicos reales, tanto en el control de procesos industriales como para la ayuda de personas con discapacidad donde el movimiento de un par de músculos es suficiente para controlar un dispositivo que les pueda prestar un servicio.

Referencias bibliográficas

- (1) FARRY, Kristin; WALKER, Ian; BARANIUK, Richard. Myoelectric Teleoperation of a Complex Robotic Hand. IEEE Transaction On Robotic and Automation, October 1996; 12 (5).
- (2) GRAUPE, D. EMG pattern analysis for patient responsive control of FES in paraplegics for walker-supported walking. Fellow, IEEE trans on Biomedical Engineering. July 1989; 36 (7).
- (3) KANG, W.; SHIU, J.; LAI, J. S.; TSAO, C. C.; KUO, T. The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition. IEEE Transactions on Biological Engineering, 1995.
- (4) JORGENSEN, C.; WHEELER, K.; STEPNIIEWSKI, S. Bioelectric control of a 757 class high fidelity aircraft simulation. Proceedings of the World Automation Congress, June 11-16, Wailea, Maui, Hawaii, 2002.
- (5) FERGUSON, Simon; DUNLOP, Reg. Grasp Recognition from Myoelectric Signals. Proc. 2002 Australasian Conference on Robotics and Automation, Auckland, 27-29 November 2002.
- (6) ENGLEHART, K.; HUDGINS, B.; CHAN, A.D.C. Continuous Multifunction Myoelectric Control using Pattern Recognition. Technology and Disability. 2003; 15 (2): 95-103.
- (7) HANNAFORD, B.; LEHMAN, S. Short Time Fourier analysis of the Electromyogram: Fast Movements and Constant Contraction. IEEE Transactions on Biomedical Engineering 1986; (BME-33), 1173-1181.
- (8) NORRIS, J.; ENGLEHART, K.; LOVELY, D.F. Myoelectric signal compression using the EZW algorithm. 23rd Conference of the IEEE Engineering in Medicine and Biology Society, Istanbul, October 2001.
- (9) DAISUKE, N. Studies on electromyogram to motion classifier. PhD Thesis, Hokkaido University, 2001.
- (10) BASMAJIAN, J. V.; DE LUCA C. J. Muscles alive. Their function revealed by electromyography. Williams & Wilkens, Baltimore, 1985.
- (11) VILLE, Claude. Biología Avanzada. Interamericana Editores, 1990; p813-820.
- (12) FRERIKS, B.; HERMENS, H. European Recommendations for Surface Electromyography, Results of the SENIAM project. Disponible en: www.seniam.org, 2002.
- (13) GERDLE, B.; KARLSSON, S.; DAY, S.; DJUPSJÖBACKA M. Acquisition, Processing and Analysis of the Surface Electromyogram. Modern Techniques in Neuroscience. Capítulo 26: p705-755. Ed. Windhorst U. & Johanson H. Springer Verlag, Berlin, 1999.
- (14) BIRKENDAL, L.; COLLEN, T.; DAGILIS, S.; DELAVERNHE, G.; EMBORG, J. Pattern Recognition of upper-body electromyography for control of lower limb prostheses. Institute of Electronic Systems, Aalborg University, June 2002.
- (15) DU, S.; VUSKOVIC, M.; Temporal vs. Spectral Approach to Feature Extraction from Prehensile EMG Signals. Department of Computer Science, San Diego State University, 2003.
- (16) Signal Processing Toolbox. Matlab 6.1. Disponible en: www.mathworks.com, 2004.
- (17) MALLAT, S. A wavelet tour of signal processing. Academic Press, 1999.
- (18) ADDISON, P. S. The illustrated Wavelet Transform Handbook. J. Reville, Ed. Institute of Physics Publishing, 2002.

(19) Wavelet Toolbox. Matlab 6.1. Disponible en: www.mathworks.com, 2004.

(20) Joachims, T. Making large-scale svm learning practical. Advances in kernel methods - support vector learning. B. Schlkopf and C. Burges and A. Smola (ed.) MIT-Press, 1999.

(21) KECCMAN, V. Learning and soft computing, support vector machines, neural networks, and fuzzy logic models. A Bradford Book, 2001.

(22) Franc, Vojtech; Hlavac, Vaclav. Statistical pattern recognition toolbox for matlab users guide. Center for Machine Perception, Department of Cybernetics, Faculty of Electrical Engineering, Czech Technical University Technicka 2, 166 27 Prague 6, Czech Republic, <http://cmp.felk.cvut.cz>, 2004.

(23) G. C. Cawley. MATLAB support vector machine toolbox. Disponible en: <http://theoval.sys.uea.ac.uk/~gcc/svm/toolbox>. University of East Anglia, School of Information Systems, Norwich, Norfolk, U.K. NR4 7TJ, 2000.

(24) Virtual Reality Toolbox. Matlab 6.1. Disponible en: www.mathworks.com, 2004.

(25) ENGLEHART, K. Signal Representation for Classification of the Transient Myoelectric Signal. PhD Thesis, University of New Brunswick, Fredericton, New Brunswick, 1998.

Figuras y tablas

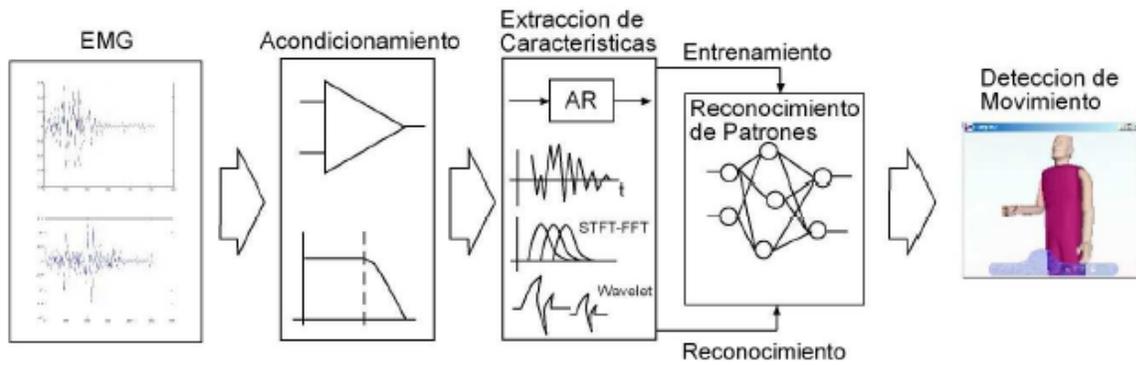


Figura 1: Esquema general del proyecto

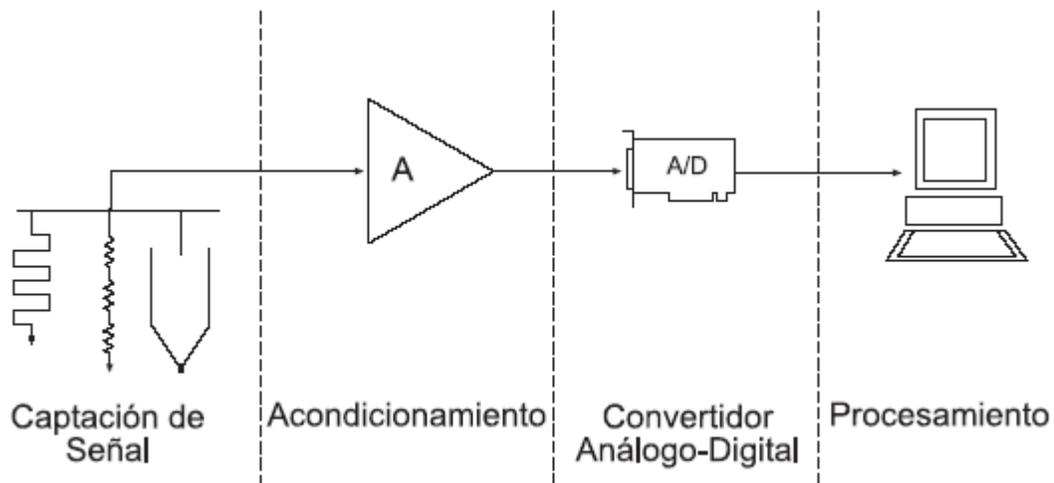


Figura 2: Sistema de instrumentación típico

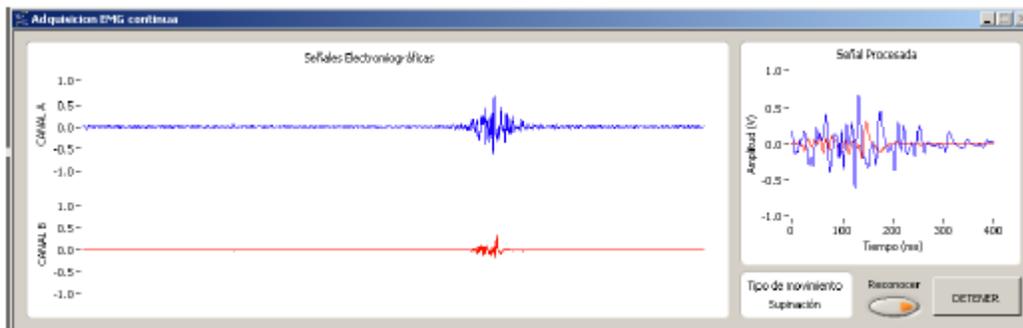


Figura 4: Extracción de 400 ms de la señal EMG

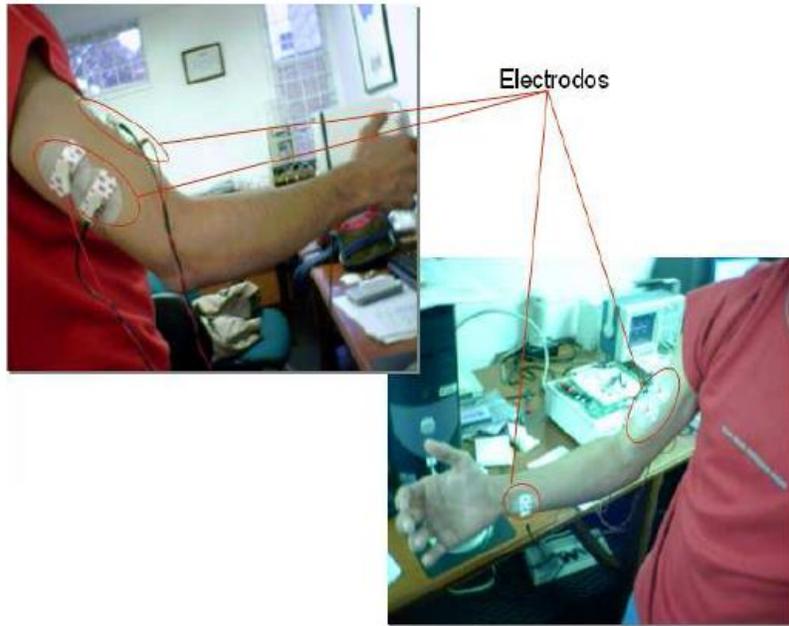


Figura 3: Posicionamiento de los electrodos de superficie

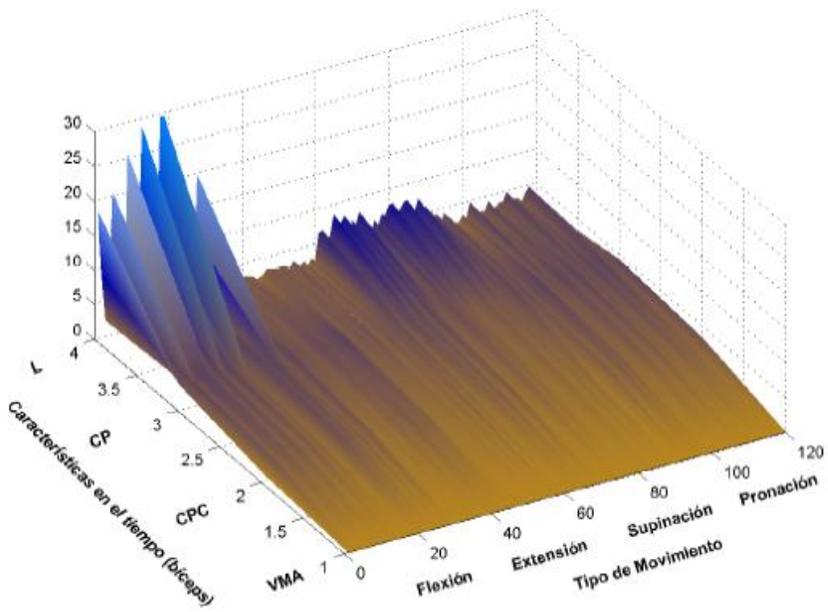


Figura 5: Características de la señal utilizando aproximación temporal

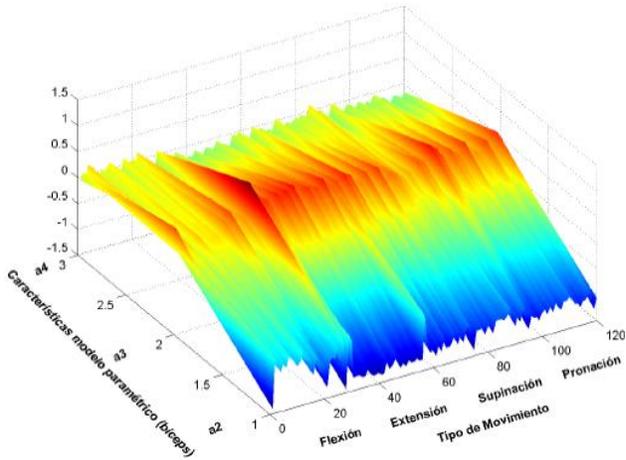


Figura 6: Características de la señal utilizando modelamiento paramétrico

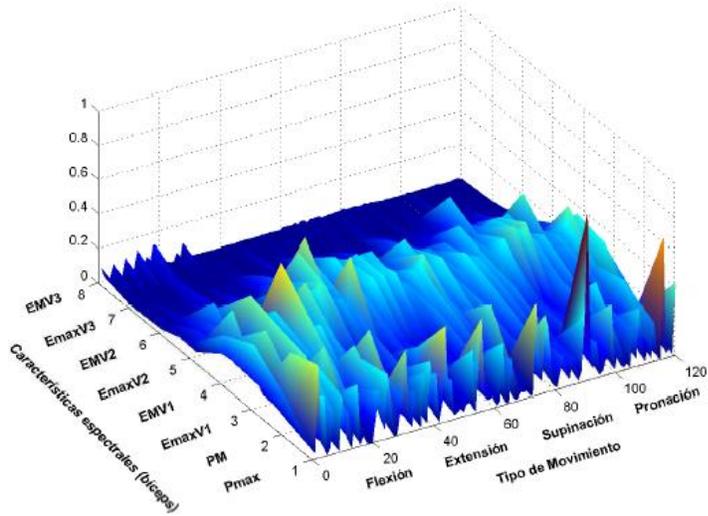


Figura 7: Características de la señal utilizando aproximación espectral

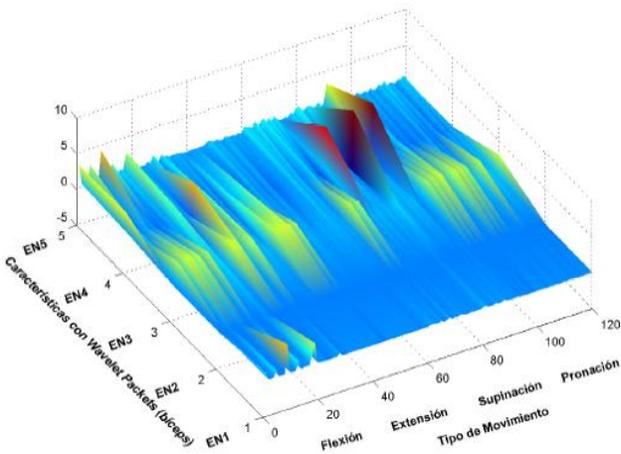


Figura 8: Características de la señal utilizando descomposición por Wavelet Packets

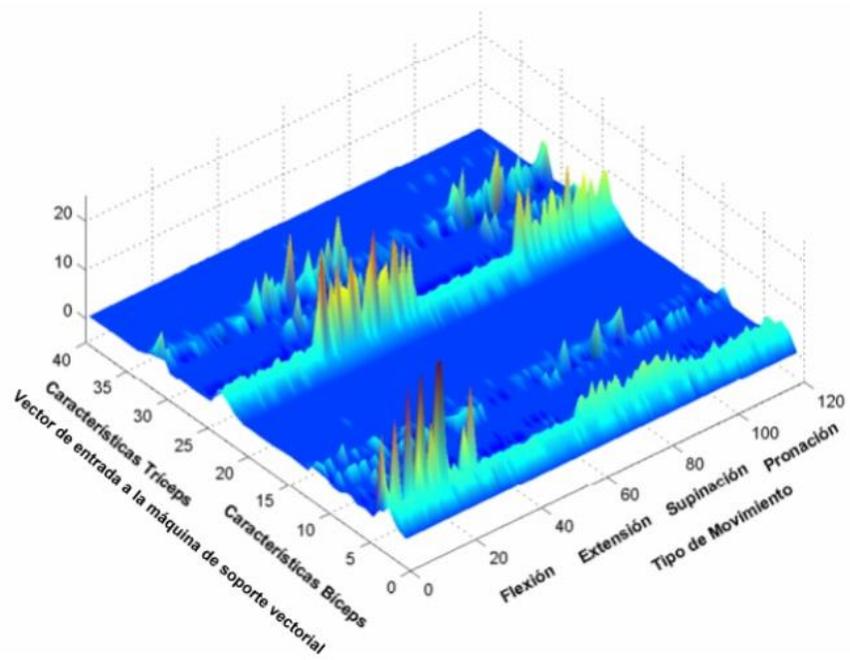


Figura 9: Patrones de entrenamiento para la máquina de soporte vectorial



Figura 10: Entornos virtuales para la visualización de resultados y manipulador didáctico de 5 grados de libertad.

Tabla 1: Convenciones para la aproximación temporal

Tabla 1: Convenciones para la aproximación temporal	
Tipo de Característica	Convención
Valor medio absoluto	VMA
Cruces por cero	CPC
Cambio de pendiente	CP
Longitud de la onda	L

Tabla 2: Convenciones para el modelamiento paramétrico

Tabla 2: Convenciones para el modelamiento paramétrico	
Tipo de Característica	Convención
Coefficiente a_2	a2
Coefficiente a_3	a3
Coefficiente a_4	a4

Tabla 3: Convenciones para la aproximación espectral

Tabla 3: Convenciones para la aproximación espectral	
Tipo de Característica	Convención
Potencia máxima (periodograma)	Pmax
Potencia promedio (periodograma)	PM
Energía máxima primera ventana (espectrograma)	EmaxV1
Energía media primera ventana (espectrograma)	EMV1
Energía máxima segunda ventana (espectrograma)	EmaxV2
Energía media segunda ventana (espectrograma)	EMV2
Energía máxima tercera ventana (espectrograma)	EmaxV3
Energía media tercera ventana (espectrograma)	EMV3

Tabla 4: Convenciones para la descomposición por Wavelets Packets

Tabla 4: Convenciones para la descomposición por Wavelets Packets	
Tipo de Característica	Convención
Entropía mínima nivel de descomposición 1	EN1
Entropía mínima nivel de descomposición 2	EN2
Entropía mínima nivel de descomposición 3	EN3
Entropía mínima nivel de descomposición 4	EN4
Entropía mínima nivel de descomposición 5	EN5

Tabla 5: Porcentajes de acierto de las máquinas de soporte vectorial

Tipo de Movimiento	Repeticiones	Aciertos P.S.A	Porcentaje P.S.A.	Aciertos P.C.A.	Porcentaje P.C.A.
Flexión	100	96	95%	94	94%
Extensión	100	96	96%	93	93%
Supinación	100	91	91%	94	94%
Pronación	100	90	90%	87	87%