

INTERFAZ CEREBRO COMPUTADOR BASADO EN SEÑALES EEG PARA EL CONTROL DE MOVIMIENTO DE UNA PRÓTESIS DE MANO USANDO ANFIS

BRAIN COMPUTER INTERFACE BASED ON EEG SIGNALS FOR MOTION CONTROL OF HAND PROSTHESIS USING ANFIS

Alexandra Bedoya-Rojas, Est
Grupo de Investigación GI2B.
Instituto Tecnológico
Metropolitano.
Medellín, Colombia.
alex.patricia@hotmail.com

Jessica Giraldo-Leiva, Est
Grupo de Investigación GI2B
Instituto Tecnológico
Metropolitano.
Medellín, Colombia.
jessicagiraldo@hotmail.com

Ingrid-Durley Torres-Pardo, MSc
Grupo de Investigación GEA.
Institución Universitaria
Salazar y Herrera.
Medellín, Colombia.
i.torres@iush.edu.co

Miguel A. Becerra, MSc
Grupo de Investigación GEA.
Institución Universitaria
Salazar y Herrera.
Medellín, Colombia.
m.becerra@iush.edu.co

(Recibido el 10-04-2013. Aprobado el 10-06-2013)

Resumen. Existe un gran número de personas en el mundo que presentan amputación de miembros que son reemplazados usualmente por prótesis mecánicas. Por otro lado, las prótesis electromecánicas han venido tomando fuerza y son apoyadas por diferentes tipos de interfaces como las interfaces cerebro computador que permiten mejorar la funcionalidad de estas y, a pesar de mostrar resultados representativos para el control de las prótesis, aún es un campo abierto de investigación que busca mejorar su eficacia y eficiencia. En este artículo se presenta una metodología de clasificación de Señales Electroencefalográficas (EEG) para el control del movimiento de una prótesis de mano, basada en el sistema de inferencia neuro-difuso adaptativo (*Adaptive Neuro Fuzzy Inference System*, ANFIS) aplicado a características obtenidas de la Transformada Wavelet (TW) y los conjuntos difusos rough (FRS) a señales EEG obtenidas en el sistema 10-10. De esta forma el rendimiento del sistema propuesto fue medido utilizando validación cruzada 70-30 con 30 repeticiones, obteniendo un alto desempeño en términos de precisión, lo que significa que este modelo tiene potencial como clasificador en la detección de los cambios EEG para la generación de comandos que permitan el control del movimiento de la mano.

Palabras clave: Interfaz Cerebro Computador (BCI), Señales Electroencefalográficas (EEG), Sistema de Inferencia Neuro-difuso Adaptativo (ANFIS), Transformada Wavelet (WT).

Abstract. A large number of people in the world who have amputated limbs that are usually replaced by mechanical prostheses. Moreover, electromechanical prostheses have been gaining strength and are supported by different types of interfaces as brain interfaces computer that improve the functionality of these, despite show representative results for the control of prostheses, it is still an open field research that seeks to improve its effectiveness and efficiency. In this paper, we present a methodology for classification of electroencephalographic signals (EEG) to control movement of a prosthetic hand, based on the adaptive neurofuzzy inference system (ANFIS) applied to features derived from the wavelet transform is presented (TW) and the rough fuzzy sets (FRS) to EEG signals obtained in 10-10 system. Thus the performance of the proposed system was measured using cross-validation with 30 repetitions 70-30 obtaining high performance in terms of accuracy, which means that this model has potential as a classifier for the detection of EEG changes for the command generation for the control of hand movement.

Keywords: Brain Computer Interface (BCI), Electroencephalogram signals (EEG), Adaptive Neurofuzzy Inference System (ANFIS), Wavelet Transform (WT).

1. INTRODUCCIÓN

La Interfaz Cerebro Computador (BCI) es una alternativa eficiente para mejorar la calidad de vida en personas de diversos funcionales [1], que permite traducir pensamientos capturados por medio de ondas cerebrales Electroencefalográficas (EEG), en comandos para el control de dispositivos externos [2]. Aproximadamente el 15% de la población mundial vive con algún tipo de discapacidad [3] —como la carencia de extremidades—, para lo cual se han desarrollado diferentes tipos de prótesis, como las mecánicas y las electromecánicas que si bien han mejorado la precisión por medio de señales mioeléctricas, no parecen mejorar significativamente la facilidad del uso de la extremidad superior artificial o su aceptación por parte de los pacientes [4]. Para desarrollar un mejor sistema de control de prótesis se utiliza la BCI a partir de señales EEG superficiales, la cual presenta ventajas como: no ser invasiva, posibilidad de manejo por diferentes usuarios, mayor número de funciones, uso intuitivo y mayor semejanza con la forma natural de controlar las extremidades.

La literatura reporta una gran cantidad de algoritmos de clasificación que han sido probados para el desarrollo de sistemas BCI, presentando inconvenientes en la toma y la clasificación de las señales [5], por lo que se ha discutido sobre las ventajas de los diferentes clasificadores, presentando a ANFIS con resultados significativos en la modelación de sistemas no lineales, además de ser un sistema que se aproxima a la forma en que los humanos procesan la información [6], demostrando una alta eficiencia [7], [8]. De igual forma se han desarrollado diferentes estudios de ANFIS junto con la Transformada Wavelet, para la clasificación de señales EEG, entre ellas la estimación de niveles de sueño [10] y la detección de alteraciones en la actividad EEG durante los episodios de hipoapnea del sueño [11]. Por lo anterior, ANFIS se puede considerar como una alternativa adecuada para la etapa de clasificación en el desarrollo de sistemas BCI [9], cuya capacidad discriminante puede ser potencializada utilizando la Transformada Wavelet para la representación de la señal.

Así, en este trabajo, se presenta una metodología para la generación de comandos a partir de señales EEG que contienen información del movimiento de la mano. El sistema parte de la obtención de características aplicando la Transformada Wavelet a las señales EEG; luego, con la finalidad de obtener un espacio de representación con alta capacidad dis-

criminante, se realiza la selección de características aplicando conjuntos difusos Rough con entropía y finalmente la etapa de clasificación es realizada mediante un sistema de inferencia difuso, obtenido a partir de ANFIS.

Un enfoque basado en la Transformada Wavelet y ANFIS, junto con un análisis de relevancia para la reducción de características mediante conjuntos difusos Rough, es presentado con el fin de proporcionar un sistema de clasificación de señales EEG de alto desempeño para la generación de comandos de control, aplicado a los movimientos de una prótesis de mano.

2. MATERIALES Y MÉTODOS

En esta sección se presenta el marco teórico y la metodología del sistema BCI propuesto.

2.1 Base de datos

La base de datos utilizada pertenece a PhysioNet y fue construida por los desarrolladores de BCI2000. Consta de 1526 registros de 64 señales EEG (sistema 10-10), cada uno con duración entre uno y dos minutos, obtenidos de 109 voluntarios. Cada individuo cuenta con 14 registros, correspondiente a diferentes tareas motoras e imaginarias así: línea base de ojos abiertos, línea base de ojos cerrados, apertura y cierre del puño izquierdo o derecho, apertura y cierre de ambos puños o pies [12], las cuales fueron adquiridas a una frecuencia de 160Hz, usando el sistema BCI2000. Finalmente, fueron seleccionadas 400 señales libres de artefactos para el desarrollo de este estudio [13].

2.2 Transformada Wavelet

La Transformada Wavelet es una transformada tiempo-frecuencia que funciona en una base multi-escala que permite la descomposición de una señal en n escalas (ver Fig. 1), donde cada una representa un grosor particular de la señal bajo estudio [6] y se obtiene a partir de una wavelet prototipo llamada wavelet madre [14].




Figura 1 Descomposición transformada wavelet discreta [1]

La TW puede expresarse en términos de un filtro pasa bajas que cumpla la condición (1) y su filtro complementario (2) [14].

$$(z)(z^{-1}) + (-z)(z^{-1}) = 1 \quad (1) \quad G(z) = z H(-z^{-1})$$

Una secuencia de filtros con aumento de longitud se puede obtener de:

$$H_{i+1}(z) = (z 2i)(z) \quad (3)$$

$$G_{i+1}(z) = (z 2i)(z), i=0, \dots, 1 \quad (4)$$

Con la condición inicial $H_0(z) = 1$ Se expresa como una escala 2 en el dominio del tiempo.

$$h_{i+1}(k) = [h]_{12^i} \times h_i(k) \quad (5)$$

$$g_{i+1}(k) = [g]_{12^i} \times h_i(k) \quad (6)$$

Donde el subíndice $[\cdot]_{12^m}$ indica el muestreo ascendente por un factor de m, y k indica el tiempo discreto. La wavelet normalizada y las funciones de base de escala $\varphi_{i,l}(k)$, $\psi_{i,l}(k)$, pueden ser definidas como:

$$\varphi_{i,l}(k) = 2^{-i} h_i(k - 2^i l) \quad (7)$$

$$\psi_{i,l}(k) = 2^{-i} g_i(k - 2^i l) \quad (8)$$

Donde el factor $2^{i/2}$ es un producto de normalización interna e i y l son los parámetros de escala y traducción, respectivamente. La descomposición por medio de la transformada wavelet discreta se describe por medio de:

$$(i)(l) = (k) \times \varphi_{i,l}(k) \quad (9)$$

$$(i)(l) = (k) \times \psi_{i,l}(k) \quad (10)$$




Figura 2 Red ANFIS

Donde $d_{(i)}(l)$ y $d_{(i)}(l)$ son los coeficientes de aproximación y los coeficientes de detalle de resolución i respectivamente.

2.3 Modelo ANFIS

ANFIS es un modelo difuso tipo sugeno que facilita el aprendizaje y la adaptación de los sistemas. Este modelo combina las capacidades de la red neuronal adaptativa y el enfoque cualitativo de la lógica difusa [8].

Para el desarrollo de la arquitectura de la red ANFIS es necesario tener en cuenta las dos reglas difusas *if-then*, basadas en el modelo de primer orden difuso sugeno así:

Regla 1:

$$\text{if } (x \text{ is } A1) \text{ and } (y \text{ is } B1) \text{ then } (f1=p1x+q1y+r1) \quad (10)$$

Regla 2:

$$\text{if } (x \text{ is } A2) \text{ and } (y \text{ is } B2) \text{ then } (f2=p2x+q2y+r2) \quad (11)$$

Donde x y y son las entradas, A_i y B_i son los conjuntos difusos, f_i representa las salidas de la región difusa —especificadas por la regla difusa— y p_i , q_i y r_i son los parámetros de diseño que se determinan durante el proceso de formación. Para poner en práctica estas dos reglas, en la Fig. 2 se muestra la arquitectura ANFIS, en la que un círculo indica un nodo fijo, mientras que un cuadrado indica un nodo adaptativo [6]. ANFIS está conformada por cinco capas que operan de la misma forma descrita por [15].

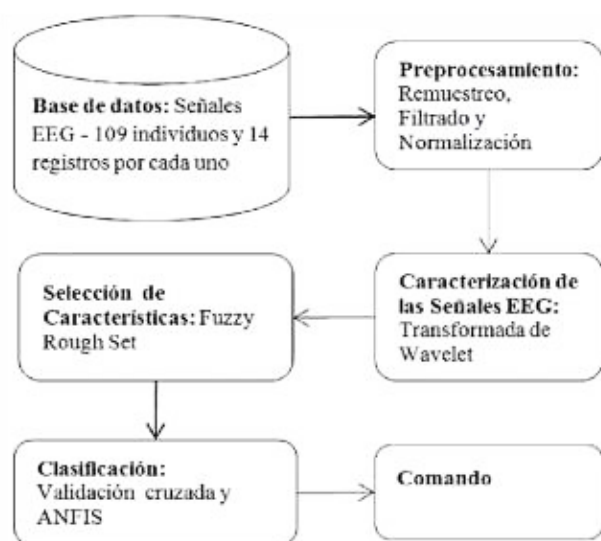


Figura 3 procedimiento general propuesto

3. PROCEDIMIENTO PROPUESTO

De acuerdo a la Fig. 3, para disminuir las perturbaciones de las señales EEG, se realizó un remuestreo a 150Hz, aplicando un filtro FIR antialiasing y se normalizaron las señales en el rango [-1 1]. Posteriormente, se realizó una caracterización para el reconocimiento de patrones por medio de la Transformada Wavelet Symlet con 6 niveles de descomposición y, con el objetivo de obtener un mínimo conjunto de características, se realizó la selección de estas, aplicando FRS (conjuntos difusos Rough) [17]. Finalmente, un modelo ANFIS con parámetros de entrenamiento, descritos en la Tabla 1, fue implementado para la clasificación de señales EEG en tareas motoras e imaginadas, concernientes a movimientos de la mano y pies, donde el conjunto de características seleccionado fue normalizado y usado como vector de entrada y se determinó el desempeño del modelo aplicando validación cruzada 70-30 con 30 fold, donde se analizó la capacidad de representación del espacio de características.

Tabla 1. Parámetros de entrenamiento - ANFIS

| | |
|----------------------------------|---|
| Número de capas | 5 |
| Tipo de FIS | Takagi- Sugeno |
| Número de entradas | 30 |
| Tipo de particionamiento | Subtractivo |
| Radio de Influencia subclúster | 0.5 |
| Tipo de algoritmo de aprendizaje | Mínimos cuadrados y gradiente descendiente. |
| Número de reglas difusas | 70 |
| Error de entrenamiento | 0.01 |

4. RESULTADOS Y DISCUSIÓN

La Tabla 2 presenta medidas estadísticas del rendimiento del modelo desarrollado en este trabajo en términos de exactitud, especificidad y sensibilidad, en la clasificación de las señales EEG para la detección de 2 tareas motoras y dos imaginarias, correspondientes a la apertura/cierre de una mano (T1) y apertura/cierre de ambas manos o pies (T2), las cuales son probadas independientemente del sujeto. Así, el sistema demostró el mejor desempeño con las tareas motoras T1 y T2 con un acierto de 93.1% y 92.4% respectivamente.

La Tabla 3 muestra una comparación del rendimiento del sistema propuesto con otros sistemas BCI. El enfoque BCI propuesto Wavelets/ANFIS, alcanzó una exactitud del 91.55% presentando una diferencia mínima de 0.1% respecto a los resultados obtenidos en [18], donde usaron solo señales imaginarias y obtuvieron una exactitud del 91.65% y respecto al estudio realizado en [19], se presenta una diferencia de 3.45% por debajo, que puede atribuirse a que el estudio fue realizado con señales obtenidas en condiciones controladas y porque en este modelo tomaron 2 parámetros para el clasificador, que fueron: λ (influencia del umbral del parámetro de asignación) y Sc (zona de influencia de la neurona), los cuales corresponden a parámetros propios de cada individuo, por lo que requiere una fase de configuración que permita inicializar correctamente los parámetros, lo cual proporciona, a su vez, un incremento en el rendimiento del sistema, mientras que en este estudio, para los 109 individuos, no se tuvieron en cuenta parámetros de inicialización.

Tabla 2. Tasa de clasificación Wavelet - ANFIS

| | Especificidad (%) | Sensibilidad (%) | Acierto (%) |
|-----------|-------------------|------------------|-------------|
| Motora T1 | 95.1±1.3 | 91.5±0.7 | 93.2±1.2 |
| Motora T2 | 91.5±0.7 | 91.7±1.1 | 92.4±0.9 |
| Imag T1 | 94.0±0.8 | 87.8±1.0 | 90.1±0.8 |
| Imag T2 | 91.4±1.3 | 89.9±1.1 | 90.5±1.0 |

Tabla 3. Comparación con otros enfoques

| Enfoque | Exactitud (%) |
|-------------------------------|---------------|
| HHT /SVM [18] | 91.65 |
| RBF/HMM [19] | 95 |
| Wavelets/ANFIS (Este Trabajo) | 91.55 |

5. TRABAJOS FUTUROS

Como trabajo futuro se propone un sistema automático que facilite la eliminación de artefactos de las señales y la sintonización de los parámetros ANFIS.

6. CONCLUSIONES

En este estudio se desarrolló un sistema BCI basado en un enfoque ANFIS para la generación de comandos, con el que se obtuvo un alto desempeño en promedio, pero alcanzando una mayor exactitud con señales generadas de tareas motoras respecto a las obtenidas a través de tareas imaginarias. Mediante la utilización de coeficientes Wavelet Symlet de 6 niveles de descomposición y la selección de características, basada en conjuntos difusos Rough, se demostró una adecuada representación de las señales EEG. De igual forma, con la aplicación de ANFIS se logró obtener un sistema adecuado, con una alta exactitud, sensibilidad y especificidad, para el control de una prótesis de mano.

AGRADECIMIENTOS

Agradecemos al programa de Ingeniería Biomédica del Instituto Tecnológico Metropolitano ITM, como también al centro de investigación de la Institución Universitaria Salazar Herrera de Medellín, Colombia.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Dobkin B. H. "Brain-computer interface technology as a tool to augment plasticity and outcomes for neurological rehabilitation", *The Journal of Physiology*, no. 579, pp. 637-642, 2007.
- [2] Blankertz B., Müller K. R., Krusienski D., Schalk G., Wolpaw J. R., Schlögl A., Pfurtscheller G., Millán J. del R., Schröder M., Birbaumer N., "The BCI Competition III: validating alternative approaches to actual BCI problems, *IEEE Transactions of Neural Systems and Rehabilitation Engineering*", pp. 153-159, June 2006.
- [3] Organización Mundial de la Salud, Resumen Informe sobre la Discapacidad, Organización Mundial de la Salud y Banco Mundial, Resumen Informe Mundial sobre la Discapacidad, 2011, 17 de Agosto de 2013. , http://www.who.int/disabilities/world_report/2011/summary_es.pdf
- [4] Jiang N., Dosen S., Müller K. R., Farina D., "Myoelectric Control of Artificial Limbs- ¿Is There a Need to Change Focus?" *IEEE signal processing*, pp. 152-150, September 2012.
- [5] Kousarrizi M. R. N., Ghanbari A. A., Teshnehlab M., Aliyari M., Gharaviri A., "Feature Extraction and Classification of EEG Signals using Wavelet Transform, SVM and Artificial Neural Networks for Brain Computer Interfaces". *IEEE*, pp. 352-355, August 2009.
- [6] Übeyli E. and Güler I. "Adaptative Neuro-Fuzzy Inference System for Classification of EEG Signals Using Wavelet Coefficients", *Journal of Neuroscience Methods*, pp. 113-121, April 2005.

- [7] Hsu W., "Embedded prediction in feature extraction: application to single-trial EEG discrimination." *Clinical EEG Neuroscience Official Journal of EEG and Clinical Neuroscience Society*, vol. 44, no. 1, pp. 31-38, January 2012.
- [8] Übeyli E. D., "Automatic detection of electroencephalographic changes using adaptive neuro-fuzzy inference system employing Lyapunov exponents." *Expert Systems With Applications*, vol.36, Issue 5, pp. 9031-9038, July 2009.
- [9] Odeh S., Hodali J., Sleibi M., and Ilyaa S., "Cursor Movement Control Development by Using ANFIS Algorithm". *The International Arab Journal of Information Technology*, pp. 448-453, June 2009.
- [10] Yidiz A., Poyraz M., Kirbaz G., and Akin M., "Application of adaptative neuro-fuzzy inference system for vigilance level estimation by using wavelet-entropy feature extraction". *Expert systems whit applications*, vol. 36, Issue 4, pp. 7390-7399, May 2009.
- [11] Übeyli E., Cvetkovic D., Holland G., and Cosic I., "Adaptive neuro-fuzzy inference system employing wavelet coefficients for detection of alterations in sleep EEG activity during hypopnoea episodes." *Digital Signal Processing*, vol. 20, Issue 3, pp. 678–691, May 2010.
- [12] Goldberger A., Amaral L., Glass L., Hausdorff J., Ivanov P., Mark R., Mietus J., Moody G., and Peng C.-K., "Components of a New Research Resource for Complex Physiologic Signals". *Circulation Electronic Pages*, pp. 215-220, 2000.
- [13] Schalk G., McFarland D., Hinterberger T., Wolpaw J., and Birbaumer N., "BCI2000: A GeneralPurpose Brain-Computer Interface (BCI) System." *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1034-1043, June 2004.
- [14] Güler I., and Ubeyli E., "Application of adaptive neuro-fuzzy inference system for detection of electrocardiographic changes in patients with partial epilepsy using feature extraction". *Expert Systems with Applications*, pp. 323–330, 2004.
- [15] J.-S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Trans. Syst. Man Cybern.*, vol. 23, no. 3, pp. 665–685, May 1993.
- [16] M. Becerra, "Metodología dinámica sobre espacios de representación abstracta basada en técnicas estocásticas orientada a la detección de soplos cardiacos a partir de los cuatro focos de auscultación," Tesis de Maestría, Maestría en Automatización y Control Industrial, Institución Universitaria Instituto Tecnológico Metropolitano, 2013.
- [17] Orrego D. A., Becerra M. A., and Delgado Trejos E. "Dimensionality reduction based on fuzzy rough sets oriented to ischemia detection," in *34th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, San Diego, California, USA pp. 2012, pp. 5282 –5285.
- [18] Lu P, Yuan D, Lou Y, Liu C, and Huang S. "SingleTrial Identification of Motor Imagery EEG based on HHT and SVM." *Lecture Notes in Electrical Engineering*, vol. 256, pp. 681-689, 2013.
- [19] Pérez J. L. M., and Cruz A. B., "Adaptive RBF-HMM BiStage Classifier Applied to Brain Computer Interface." *Communications in Computer and Information Science*, vol. 127, pp. 152–65, 2011.