

# EXTRACCIÓN DE CARACTERÍSTICAS EN INTERFACES CEREBRO COMPUTADORAS BASADAS EN TRANSFORMACIONES ORTOGONALES: RESULTADOS PRELIMINARES

Victoria Peterson<sup>1</sup>, Yanina Atum<sup>1</sup>, Florencia Jauregui<sup>1</sup> Iván Gareis<sup>1</sup>, Leonardo Rufiner<sup>1,2</sup> y Rubén Acevedo<sup>1</sup>

<sup>1</sup>Facultad de Ingeniería – Univesidad Nacional de Entre Ríos, Oro Verde, Argentina

<sup>2</sup> Facultad de Ingeniería y Cincias Hídricas – Univesidad Nacional del Litoral, Santa Fé, Argentina  
victoriapeterson09@gmail.com, yatum@bioingenieria.edu.ar, flor\_jp@hotmail.com,  
ivangareis@bioingenieria.edu.ar, lrufiner@bioingenieria.edu.ar, racevedo@bioingenieria.edu.ar

Palabras Claves: Interfaz cerebro computadora. Transformada wavelet. Transformada paquetes de wavelets.

## 1 INTRODUCCION

Una interfaz cerebro computadora (BCI, Brain Computer Interface) es un sistema que provee una nueva forma de comunicación directa entre el cerebro de una persona y el mundo exterior. Los sistemas de comunicación basados en señales de electroencefalograma (EEG) representan un grupo de paradigmas de BCI, dentro del cual se encuentra el basado en potenciales evocados relacionados a eventos (ERP, event related potentials) [1]. Los ERP son potenciales evocados de latencias mayores a 100 ms cuya manifestación depende de procesos psicológicos y conductuales, de los cuales el más estudiado es el P300. Cuando estímulos visuales, auditivos o somatosensoriales infrecuentes (o particularmente significativos) son mezclados con estímulos frecuentes (o de rutina), los primeros evocan un potencial en el EEG con un pico positivo cercano a los 300 ms.

Una BCI basada en ERP está compuesta por distintos bloques, como se muestra en la Figura 1, entre los cuales se encuentra el bloque de instrumentación, el de extracción de características y el de clasificación. Los últimos dos bloques conforman un sistema de reconocimiento de patrones donde el problema de clasificación a resolver tiene dos clases posibles: registros con respuesta (ERP) y registros sin respuesta.




Figura 1. Diagrama en bloques de una BCI típica.

Si bien existen diversas alternativas para la extracción de características, en este trabajo se proponen métodos de aproximación basados en diccionarios [2]. En este enfoque la señal de interés se considera como un elemento de un espacio de señales que puede representarse en función de una base o diccionario que favorezca la expresión de las características que mejoren el desempeño del clasificador. En este contexto se puede representar a la señal  $\mathbf{x} \in \mathbb{R}^N$  en función de una nueva base ortogonal mediante la ecuación  $\mathbf{a} = \varphi \cdot \mathbf{x}$  donde  $\mathbf{a} \in \mathbb{R}^N$  es el vector expresado en la nueva base y  $\varphi$  es una matriz  $\in \mathbb{R}^{N \times N}$  cuyas columnas son los elementos de la nueva base. En este trabajo al vector  $\mathbf{a}$  lo denominaremos patrón.

Si bien se puede generar una base ortogonal de muchas maneras, la transformada wavelet diádica discreta (DDWT, Diadic Discrete Wavelet Transform) es una alternativa ampliamente utilizada. La DDWT permite realizar un análisis multiresolución por nivel, donde en cada uno de ellos la señal se separa en una porción de altas frecuencias llamada *detalle* y en otra de bajas frecuencias llamada *aproximación*, cada una de las cuales tiene la mitad de las muestras de la señal original. La descomposición en el nivel posterior se realiza sobre la última aproximación, obteniendo así al final una aproximación y tantos detalles como veces se repita este proceso. El conjunto de coeficientes obtenido de esta manera contiene la información completa de la señal original y no tiene redundancia.

Otra alternativa, que permite un enfoque más general, es la transformada paquete de wavelets (WPT, Wavelet Packet Transform), en la cual a diferencia de la DDWT, no se emplea directamente una única base ortogonal, sino que esta se selecciona de una cantidad finita de posibles bases ortogonales. En este trabajo se utilizó el algoritmo denominado *mejor base ortogonal* (BOB, Best Orthogonal Basis) el cual selecciona la base para la cual la energía de los coeficientes presenta la menor entropía [3]. Debido a que este algoritmo selecciona una base diferente para cada señal analizada, se utilizó como estrategia aplicar BOB al promedio de las señales (épocas) con ERP, de este modo se obtuvo una base ortogonal que se utilizó como "plantilla" para obtener así los coeficientes wavelet packet para cada una de las épocas.

El objetivo de este trabajo es resolver en forma eficiente el problema de clasificación. Para esto se propone evaluar el desempeño de una BCI utilizando la DDWT y la WPT (mediante BOB) como métodos de extracción de características para la detección de la señal de ERP.

## 2 MATERIALES Y MÉTODOS

### 2.a Registros

Se utilizó una base de datos generada en el Laboratorio de Neuro Imagenología del Departamento de Ingeniería Eléctrica de la Universidad Autónoma Metropolitana (México) empleando el software BCI2000 a partir de su aplicación P300\_Speller basada en el deletreador propuesto por Donchin y Farwell [4]. La misma consta de registros de diez canales de EEG realizados a sujetos sanos, con la configuración de electrodos que se observa en la Figura 2. Para el presente trabajo sólo se utilizaron los registros de diez sujetos [5].




Figura 2. Configuración de electrodos.

## 2.b Generación de patrones

Se construyeron conjuntos de patrones para cada uno de los sujetos, cada patrón está conformado por las muestras correspondientes a un segundo de registro comenzando en el instante del estímulo. Se concatenaron las épocas correspondientes a cada uno de los diez canales, resultando un patrón de 2560 muestras o características (la frecuencia de muestreo de los registros fue de 256 Hz). Dentro de estos conjuntos hay patrones correspondientes a las dos clases analizadas en el trabajo: señales de EEG con ERP y señales de EEG sin ERP.

Los conjuntos de patrones utilizados en el trabajo son:

- Patrones temporales

Corresponden a épocas individuales (single trials) de EEG con ERP y sin ERP, las cuales están disponibles en la base de datos. Estas fueron muestreadas a 256 Hz, en este trabajo se las decimó a una frecuencia de 64 Hz.

- Patrones wavelets

La transformada wavelet ha sido extensamente utilizada en el análisis de ERP por su habilidad de explorar efectivamente tanto las características de ERP en el dominio del tiempo como en el de la frecuencia [6]. En este trabajo se emplea la DDWT y la WPT utilizando la wavelet *Daubechies 4*, la cual ha sido ampliamente utilizada en el análisis de EEG [6] y que además se asemeja morfológicamente a la onda P300 de los ERP [7]

Los patrones wavelets utilizados fueron el resultado de aplicar:

- a) DDWT: se aplicó la DDWT a los registros temporales descomponiendo hasta el nivel 6, los patrones se formaron con los coeficientes de los *detalles* del nivel 1 al 6 y con los de la *aproximación* del nivel 6.
- b) DDWT con filtrado: considerando que la energía de los ERP está por debajo de los 10 Hz, al conjunto de patrones DDWT se pusieron a cero los coeficientes de los *detalles* del nivel 1 y 2.
- c) WPT: se aplicó la WPT a los registros temporales descomponiendo hasta el nivel 6. Para obtener los coeficientes wavelets packets se utilizó el procedimiento descrito en la sección introducción.
- d) DDWT con denoising por umbral: a los coeficientes obtenidos por DDWT se aplicó un método de denoising basado en umbral. La definición del umbral se hizo utilizando la función de riesgo SURE (Stein's Unbiased Risk Estimator) realizando un denoising hard de manera global en todos los niveles [8].
- e) WPT con denoising por umbral: a los coeficientes obtenidos por WPT se le aplicó el mismo método de denoising descrito en el punto anterior.

## 2.c Clasificador

Suponiendo que las clases del problema son linealmente separables, se implementó como clasificador al discriminante lineal de Fisher (FLD, Fisher's Linear Discriminant) [9]. Este clasificador utiliza una función lineal de las características del patrón siendo una de sus principales ventajas la sencillez computacional que posee [10]. Por otro lado es uno de los clasificadores más utilizados en BCI, constituyendo uno de los estándares en el área.

Por cada una de las cinco estrategias de extracción de características, se generó un conjunto de patrones por sujeto. Se obtuvieron así diez conjuntos por estrategia. Se estimó la bondad de cada uno de dichos conjuntos aplicando validación cruzada de 5 particiones. La desviación estándar presente en la Tabla 1 es respecto a los promedios sobre los sujetos.

Los índices que se utilizaron para evaluar el desempeño del sistema completo fueron el porcentaje de aciertos, sensibilidad y especificidad.

### 3 RESULTADOS Y DISCUSION

Para los diferentes tipos de patrones se calcularon los índices de desempeño mencionados anteriormente, los cuales se muestran en la tabla 1.

Tabla 1: Indicadores de desempeño

Patrones	Aciertos	Sensibilidad	Especificidad
Temporales	$73 \pm 0,0559$	$0,74 \pm 0,0508$	$0,73 \pm 0,0608$
WPT	$71 \pm 0,0581$	$0,73 \pm 0,0611$	$0,73 \pm 0,0564$
DDWT	$71 \pm 0,0488$	$0,73 \pm 0,0520$	$0,73 \pm 0,0456$
DDWT con filtrado	$80 \pm 0,0745$	$0,83 \pm 0,0606$	$0,83 \pm 0,0540$
DDWT con denoising por umbral	$71 \pm 0,0616$	$0,73 \pm 0,0597$	$0,73 \pm 0,0536$
WP con denoising por umbral	$72 \pm 0,0537$	$0,73 \pm 0,0600$	$0,73 \pm 0,0422$

### 4 CONCLUSIONES

Del análisis de la tabla 1 se puede concluir que los mejores resultados se obtuvieron cuando se utilizaron los patrones DDWT aplicando un método de filtrado utilizando información del espectro de frecuencias de la señal para eliminar los coeficientes de los detalles del nivel 1 y 2 de la descomposición obtenida. Desde el punto de vista de espacios de señales, evidentemente el no utilizar esas proyecciones hace que la distribución de los patrones correspondientes a las dos clases del problema a resolver (registros con ERP y registros sin ERP) queden mejor separados.

El resto de las alternativas propuestas no presentaron un desempeño superior al obtenido por los patrones temporales. Tanto para los patrones DDWT como para los WPT, posiblemente la elección de la wavelet Daubechies 4 no fue la más apropiada. Por otro lado, los resultados sugieren, que la estrategia propuesta de selección de bases mediante BOB no brinda una mejor representación en términos de la discriminación entre ambas clases. Esto puede deberse tanto a que el BOB está pensando en el contexto de aplicaciones de compresión, como a la utilización de una única señal promedio. En trabajos futuros se explorará otros algoritmos para seleccionar una base ortogonal, como por ejemplo el denominado local discriminant basis.

Los patrones generados aplicando un denoising por umbral a los patrones DDWT y WPT tampoco presentaron un buen desempeño, en este caso hay muchas alternativas para evaluar; como por ejemplo otros métodos de selección de umbral.

Si bien es un trabajo preliminar, los resultados obtenidos nos permiten definir una serie de trabajos a futuro para mejorar el desempeño en la detección de ERP.

### REFERENCIAS

- [1] Gentiletti, G., Tabernig, C. and Acevedo, R. (2007). Interfaces Cerebro Computadora: Definición, Tipos y Estado Actual. In proceedings of CLAIB 2007. Porlamar, Nueva Esparta. Springer. Vol. 18, pp. 1117–1121.
- [2] Rufiner, H.L. (2009). "Análisis y modelado digital de la voz: técnicas recientes y aplicaciones", aprobado por consejo Editorial UNL. Ediciones UNL, Colección Ciencia y Técnica. ISBN 978-987-657-090-9.
- [3] Coifman, R.R and Wickerhauser, M.V. (1992). Entropy-Based Algorithms for Best Basis Selection. IEEE Transactions on Information Theory. Vol. 38, no. 2, pp. 713-719.
- [4] Farwell, F.A and Donchin, E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. Electroencephalography and Clinical Neurophysiology. Vol. 70, pp.510-523.
- [5] Ledesma-Ramirez, C., Bojorges-Valdez, E., Yáñez-Suarez, O., Saavedra, C., Bougrain, L. and Gentiletti, G. (2010). An Open-Access P300 Speller Database. Paper presented at Fourth international BCI meeting. Monterrey, California.

- [6] Perseh, B. and Sharafat, A. (2012). An Efficient P300-Based BCI Using Wavelet Features and IBPSO-Based Channel Selection. Journal of Medical Signals and Sensors. Vol. 2.
- [7] Samar, V.J., Bopardikar, A., Rao, R. and Swartz, K. (1999). Wavelet Analysis of Neuroelectric Waveforms: A Conceptual Tutorial. Brain and Language. Vol. 66, pp.7-60.
- [8] Donoho D L, Johnstone I M (1994) Threshold selection for wavelet shrinkage of noisy data. Proc. 16th Annual Conf. of the IEEE Eng. Med Biol. Society, 24a - 25a, IEEE Press.
- [9] Duda, R., Hart, P. and Stork, D (2000). Pattern Classification (2nd Edition). Wiley-Interscience. ISBN-10: 0471056693.
- [10] Elizondo, D. (2006). The Linear Separability Problem: Some Testing Methods. IEEE Transactions on Neural Networks. Vol. 17, no. 2.