

# Técnicas de reconocimiento de patrones para la clasificación de señales EEG en sistemas BCI

Germán Rodríguez Bermúdez, Pedro J. García Laencina, José L. Roca González,  
Joaquín Roca González, Joaquín Roca Dorda

Centro Universitario de la Defensa (CUD) de San Javier, MDE-UPCT  
Base Aérea de San Javier, C/ Coronel López Peña, s/n 30720 Santiago de la Ribera (Murcia) España  
E-mail: german.rodriiguez@tud.upct.es, pedroj.garcia@tud.upct.es

**Resumen.** Los sistemas de interfaz cerebro ordenador (*Brain Computer Interface, BCI*) permiten su uso como un nuevo canal de comunicación. La extracción de características y la clasificación son elementos clave en el rendimiento de los sistemas BCI. Este trabajo presenta los resultados preliminares del estudio de la clasificación bajo una extracción de característica “clásica” mediante densidad espectral de potencia y la combinación de otras extracciones de características como *Transformadas Wavelet*, *parámetros de Hjörth* y *modelado autoregresivo*, para de esta forma conseguir un incremento en la clasificación de señales EEG.

## 1 Introducción

Los sistemas de interfaz cerebro ordenador (o BCI, del inglés *Brain Computer Interface*) permiten la implementación de canales de entrada en ayudas técnicas a partir del análisis de la actividad cerebral. En la actualidad, al haber incorporado nuevas modalidades para la estimación de la actividad cerebral, se puede recurrir a la definición propuesta volitiva. El concepto de sistemas BCI ha evolucionado desde su introducción por Vidal en 1973, para el que “... los sistemas BCI procesan el EEG espontáneo así como las respuestas evocadas ante estímulos acotados en el tiempo bajo distintas condiciones con el fin de controlar dispositivos externos” [1], y por Wolpaw *et al.*, según la cual “los sistemas BCI dotan al cerebro de un nuevo canal de comunicación y control no muscular” [2]. Más recientemente, Kleber y Birbaumer adaptaron esta definición con el fin de resaltar su utilidad en dispositivos de comunicación alternativa, al “... permitir a los usuarios el envío de mensajes e instrucciones al mundo exterior sin necesidad de usar sus músculos” [3].

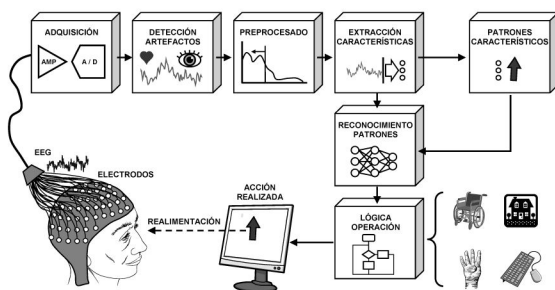


Figura 1. Esquema general de BCI basado en señal EEG.

Con el fin de implementar estos sistemas, se suele recurrir a esquemas similares al recogido en la Figura 1. Así, se parte del registro de la actividad cerebral mediante la adquisición de distintas bioseñales (en función de la modalidad considerada). Una vez preprocesada y acondicionada, dicha actividad es analizada mediante distintas técnicas de

procesamiento de señal y reconocimiento de patrones con el fin de obtener un conjunto de características representativas de la misma. Seguidamente, y haciendo uso de técnicas de clasificación de patrones, se procede a la identificación de la intencionalidad asociada al estado cerebral actual, en base a unos criterios predefinidos. A continuación, el sistema genera la salida correspondiente al estado cerebral detectado, que dependerá de la lógica de operación utilizada. Finalmente, se cierra un bucle realimentado al recibir el usuario la información sobre la acción realizada por el sistema. Tradicionalmente, la mayoría de los sistemas BCI en tiempo real están basados en la extracción de características de la potencia espectral y un clasificador tipo LDA (*Linear Discriminant Analysis*). En este artículo se pretende mejorar las prestaciones finales obtenidas por el clasificador LDA haciendo uso de técnicas de extracción de características complementarias a las características de potencia espectral. Los resultados en experimentos off-line muestran las ventajas de esta metodología sobre la tradicional.

## 2 Materiales y métodos

### 2.1. Datos

Los datos sobre los que se ha trabajado están extraídos del “*BCI-Competition II*”, que es una competición a nivel mundial donde diferentes grupos de investigación trataban de decodificar señales EEG accesibles vía web<sup>1</sup>. Además, se dispone de una descripción detallada de cómo habían sido obtenidas las bioseñales. En concreto trabajaremos sobre el conjunto de datos III. Estos datos fueron obtenidos de una mujer normal de 25 años de edad, en una sesión con realimentación. El sujeto estaba sentado y relajado en un sillón y el objetivo era controlar una barra de realimentación que aparecía en pantalla imaginando el movimiento de la mano derecha e izquierda en función de la flecha que se indique en la

<sup>1</sup> <http://www.bbci.de/competition/ii/>

pantalla. El orden en el que se le indicaba en que mano debía pensar era aleatorio.

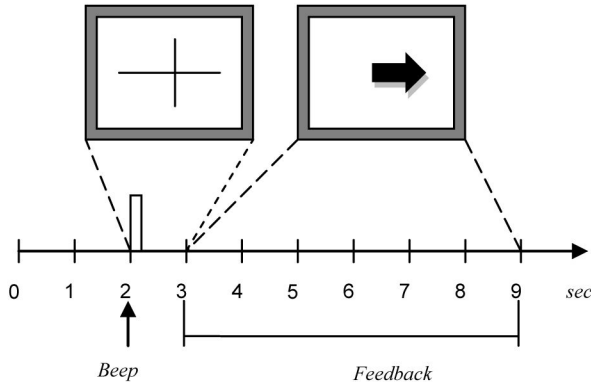


Figura 2. Esquema temporal del paradigma




Figura 3. Posición de los electrodos

El experimento consistió en 7 iteraciones con 40 tareas cada una. Todas las iteraciones se realizaron en el mismo día dejando unos minutos de descanso entre ellas. Se obtuvieron 280 casos de estudio con 9 segundos de duración cada uno. Los primeros 2s la pantalla estaba vacía, en  $t=2s$  una señal acústica marcaba el inicio de la prueba, seguidamente aparecía una cruz en la pantalla durante un segundo; y en  $t=3s$ , una flecha (izquierda o derecha) marcaba la mano que había que mover imaginariamente mientras aparecía una barra en pantalla que debíamos mover en el sentido de la flecha incrementado la imaginación de nuestro movimiento (Figura 2). La realimentación se basa en la obtención de los parámetros adaptativos y autoregresivos del canal #1 (C3) y #3 (C4), combinados con un clasificador de discriminante lineal LDA para conseguir una única salida.

La grabación se realizó con un amplificador Gtec y electrodos de Ag/AgCl. Tres canales bipolares EEG (anterior '+', posterior '-') fueron medidos (C3, Cz y C4). La frecuencia de muestreo utilizada fue 128Hz y se filtró entre 0.5 y 30Hz (Figura 3). En particular, este estudio se ha centrado en los canales C3 y C4.

## 2.2. Extracción de características

La señal descrita anteriormente fue procesada "off-line" utilizando diferentes métodos de extracción de características [4]. Para ello se ha utilizado el *Toolbox* de procesamiento avanzado de señal de *Labview* (v.8.6) operando sobre la ventana de realimentación predefinida, tal y como se muestra en las siguientes secciones del artículo.

## Potencia espectral en las bandas Alpha y Beta

Es ampliamente conocido que la PSD (*Power Spectral Density*) en las bandas  $\alpha$  y  $\beta$  puede calcularse a través de:

$$P_{\alpha} = \frac{FFT^*(EEG_{\alpha}) \cdot FFT(EEG_{\alpha})}{n^2} \quad (1)$$

$$P_{\beta} = \frac{FFT^*(EEG_{\beta}) \cdot FFT(EEG_{\beta})}{n^2} \quad (2)$$

donde  $n$  es el número de muestras de la ventana temporal, la FFT es la transformada rápida de Fourier y  $*$  es la conjugada compleja.

## Parámetros de Hjörth

Los momentos espectrales de orden 0, 2 y 4 de la señal  $x=[x_1, x_2, \dots, x_n]$  se pueden expresar como sigue:

$$m_0 = \frac{1}{n} \sum_{i=1}^n x_i \quad (3)$$

$$m_2 = \frac{1}{n} \sum_{i=1}^n d_i = \frac{1}{n} \sum_{i=1}^n (x_i - x_{i-1}) \quad (4)$$

$$m_4 = \frac{1}{n} \sum_{i=1}^n (d_i - d_{i-1})^2 = \frac{1}{n} \sum_{i=1}^n (x_i - 2x_{i-1} + x_{i-2})^2 \quad (5)$$

Los parámetros de Hjørth ( $h_0$ : actividad,  $h_1$ : movilidad y  $h_2$ : complejidad) se obtienen de la siguiente forma:

$$h_0 = m_0 \quad (6)$$

$$h_1 = \sqrt{\frac{m_2}{m_0}} \quad (7)$$

$$h_2 = \sqrt{\frac{m_4}{m_2} - \frac{m_2}{m_0}} \quad (8)$$

## Modelado AR

Asumiendo que la señal EEG es estacionaria, los parámetros Auto-Regresivos (AR) se pueden obtener satisfaciendo:

$$x_{n+1} \approx x_n + a_1 x_{n-1} + \dots + a_m x_{n-m} \quad (9)$$

donde  $m$  es el orden del modelo AR,  $[1, a_1, a_2, \dots, a_m]$  es el vector de coeficientes del modelo. Después de consultar la bibliografía [4], y basándonos en nuestra experiencia experimental previa, se ha establecido el orden del modelo AR a 6.

**Transformada Wavelet Continua.**

La CWT (*Continuous Wavelet Transform*) viene definida por

$$WT_{(u,a)} = (s, \Psi_{u,a}) = \int_{-\infty}^{\infty} S(t) \Psi_{u,a}^*(t) dt \quad (10)$$

siendo  $WT_{(u,a)}$  los coeficientes resultado de la transformada. Además,

$$\Psi_{u,a} = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-u}{a}\right) \quad (11)$$

es la transformada wavelet continua con  $u$  el factor de desplazamiento y  $a$  el factor de escala. En particular, este trabajo ha empleado la wavelet Daubechies D2.

**Ventana temporal de interés**

Por último, hay que destacar que se ha establecido para el cálculo de la extracción de características una ventana temporal de un segundo en el centro del periodo de clasificación con realimentación, es decir entre 5.5s y 6.5s.

**2.2. Clasificación usando LDA**

Debido a sus conocidas prestaciones para sistemas BCI [4], se ha optado por trabajar con un clasificador LDA bajo la implementación clásica de Fisher. Dado un patrón de entrada determinado, el discriminante lineal asigna una clase (entre dos posibles clases –problema de clasificación binario–) en función de la salida del LDA que se obtiene a través de la combinación lineal de las características de entrada de dicho patrón y el vector de pesos  $w$  que define al discriminante. Básicamente, el clasificador LDA divide el espacio muestral en subespacios mediante hiperplanos. Los supuestos para la utilización del LDA de Fisher son normalidad multivariada e igualdad de matrices de covarianzas entre los grupos de patrones de las dos clases, y bajo ambas hipótesis, se obtiene una solución única para  $w$ . Para más detalles, se recomienda al lector consultar [5].

**3 Resultados**

Tras el proceso de extracción de características se dispone de un conjunto de 140 patrones, donde cada patrón está definido por un vector de 34 características de entrada: 4 de potencia espectral, 6 de los parámetros de Hjörth, 12 de modelado AR y 12 correspondientes a los coeficientes de la transformada Wavelet). Dado que se dispone de un número reducido de patrones, y con objeto de disminuir los efectos derivados de la selección aleatoria de los conjuntos de entrenamiento y test, la evaluación experimental se ha realizado con una validación cruzada del tipo *Leave-One-Out* (LOO) [5]. Los resultados obtenidos utilizando distintos métodos de extracción de características se muestran en la Tabla 1.

**Tabla 1.** Probabilidad de acierto (%) obtenida con LDA bajo diferentes métodos de extracción de características.

PSD	Hjörth	AR	CWT	Combinación (PSD+Hjörth +AR+CWT)
73.57	62.86	72.86	71.46	80.71

En concreto, los resultados utilizando individualmente cada método de extracción son prácticamente similares, siendo PSD el más apropiado (como es ampliamente conocido en la práctica) mientras que el uso de los parámetros de Hjörth es menos apropiado ya que, atendiendo a los resultados obtenidos para este problema, proporcionan información menos relevante para la resolución de la tarea de clasificación. Por otro lado, es muy beneficioso aprovechar la información generada a partir de distintos métodos de extracción de características con objeto de mejorar las prestaciones finales del sistema BCI. En concreto, conseguimos incrementar la probabilidad de acierto hasta 80.71%, lo que supone una ventaja considerable con respecto al método que mejor resultado ha proporcionado de manera individual (PSD, 73.57%).

**4 Conclusiones**

Los sistemas BCI constituyen un área de investigación que despierta gran interés para la comunidad científica gracias a las grandes ventajas y multitud de aplicaciones futuras que puede ofrecer a la sociedad. Para ello, es necesario desarrollar técnicas y algoritmos que mejoren sensiblemente las capacidades actuales de los sistemas BCI existentes en el mercado. Los autores de este artículo muestran que la combinación de características de distinta naturaleza puede mejorar los resultados finales proporcionados por el clasificador.

**Referencias**

- [1] Vidal, J. J., Toward direct brain-computer communication, *Annu. Rev. Biophys. Bioeng.*, vol. 2 pp. 157-180, 1973.
- [2] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M., Brain-computer interfaces for communication and control, *Clin Neurophysiol.*, vol. 113, no. 6, pp. 767-791, June 2002.
- [3] Kleber, B. and Birbaumer, N., Direct brain communication: neuroelectric and metabolic approaches at Tübingen. *Cognitive Processing*, vol. 6, no. 1, pp. 65-74, Mar.2005.
- [4] Bashashati, A., Fatourech, M., Ward, R. K. and Birch G. E., A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals, *Journal of Neural Engineering*, vol. 4, no. 2, pp. R32–R57, 2007.
- [5] Bishop C. M., *Pattern Recognition and Machine Learning*. Springer, New York, USA, 2006.