

Control asíncrono de sistemas BCI basados en ERP mediante la detección de potenciales evocados visuales de estado estable provocados por los estímulos periféricos del paradigma *oddball*

Santamaría-Vázquez, Eduardo; Martínez-Cagigal, Víctor; Gomez-Pilar, Javier y Hornero, Roberto

Departamento de Teoría de la Señal y Comunicaciones e Ingeniería Telemática, Universidad de Valladolid, España. Emails: eduardo.santamaria@gib.tel.uva.es, victor.martinez@gib.tel.uva.es, javier.gomez@gib.tel.uva.es, robhor@tel.uva.es.

Abstract

Synchronicity is an inherent feature of brain-computer interface (BCI) spellers based on event related potentials (ERPs). These systems always make a selection, even when users are engaged in another task. This represents a great limitation in real-life applications, such as wheelchair control or web browsers, in which an asynchronous control should be a key feature. The aim of this study is to design, develop and test a novel algorithm to discriminate whether the user wants to select a command or is not attending the stimuli. In order to achieve such asynchronous control, our method detects the steady-state visual evoked potentials provoked by non-target stimuli of ERP-based spellers. The proposed method was validated with offline data from 5 healthy subjects, achieving an average accuracy of 99.7%. Our approach is independent of the ERP classification stage, which reduces inter-session variability. Furthermore, to the best of our knowledge, it is the first algorithm for asynchronous control that does not need to extend the duration of the calibration sessions.

Keywords: Brain-computer interfaces, event-related potentials, asynchrony, control-state detection, steady-state visual evoked potentials, P300.

Resumen

Los sistemas Brain-computer interface (BCI) basados en potenciales relacionados con eventos (ERPs) son sistemas intrínsecamente síncronos que realizan selecciones de manera constante, incluso cuando el usuario no está prestando atención a los estímulos. Esto representa una gran limitación en aplicaciones reales, donde se requiere un control asíncrono. El objetivo de este estudio es diseñar, desarrollar y evaluar un novedoso método de asincronía que discrimine si el usuario quiere seleccionar un comando o está realizando otra tarea. Para alcanzar este objetivo, nuestro método detecta

los potenciales evocados visuales de estado estable provocados por los estímulos no objetivo del paradigma oddball. Este método ha sido probado en 5 sujetos sanos, alcanzando una precisión del 99.7% en la detección del estado de control. Este algoritmo es independiente del método de clasificación de los ERPs, reduciendo la variabilidad inter-sesión. Además, hasta donde tenemos conocimiento, es el primer método de asincronía que no necesita extender las sesiones de calibración del sistema.

Palabras clave: Interfaces cerebro-ordenador, potenciales relacionados con eventos, detección del estado de control, asincronía, potenciales evocados visuales de estado estable, P300.

1. Introducción

Los sistemas Brain-computer interface (BCI) permiten la comunicación directa entre el cerebro y un dispositivo externo, identificando las intenciones del usuario a partir de su actividad neuronal. En la actualidad, la principal aplicación de los sistemas BCI es la mejora de la independencia y la calidad de vida de personas con grave discapacidad, proporcionando una alternativa accesible a los canales de comunicación habituales, que requieren el control de músculos y nervios periféricos (Wolpaw et al., 2002). En la práctica, estos sistemas emplean la electroencefalografía (EEG) para registrar la señal eléctrica del cerebro ya que es una técnica portable, no invasiva y de bajo coste en comparación con otras disponibles, como la magnetoencefalografía (MEG), la electrocorticografía (ECoG), o la espectroscopia de infrarrojo cercano funcional (fNIRS) (Wolpaw & Wolpaw, 2012).

La señal de EEG es la superposición de componentes cíclicas, denominadas ritmos, y transitorias que reflejan la actividad subyacente del cerebro. Particularmente, los potenciales relacionados con eventos (event-related potentials, ERPs) son la respuesta natural del cerebro ante diferentes tipos de eventos. Los ERPs provocados por un estímulo visual (e.g. una iluminación repentina) se conocen como ERPs visuales (Luck, 2014). Farwell y Donchin (Farwell & Donchin, 1988) propusieron por primera vez un sistema BCI que utilizaba los ERPs visuales para detectar las intenciones de los usuarios mediante el paradigma *oddball*. Este paradigma presenta una matriz de comandos al usuario, cuyas filas y columnas se iluminan de manera aleatoria. La iluminación de todas las filas y columnas de la matriz se denomina secuencia. Durante este proceso, el usuario debe mirar fijamente el comando que desea seleccionar, emitiendo un ERP cuando este se ilumina. El sistema analiza las épocas de señal inmediatamente posteriores a cada estimulación, determinando la fila y columna que tienen mayor probabilidad de contener un ERP. Una vez detectada la fila y la columna, se selecciona el comando correspondiente y se vuelve a empezar el

proceso. Para mejorar la precisión del sistema, es habitual que se realicen varias secuencias de estimulación, aumentando la confianza en la selección.

Numerosos estudios han mejorado la precisión y la velocidad de selección de comandos en los sistemas BCI basados en ERPs (Aydin et al., 2018; Rezeika et al., 2018; Schettini et al., 2014). Sin embargo, aún existen grandes limitaciones que impiden su uso fuera de un entorno controlado de laboratorio. En concreto, los sistemas BCI basados en ERPs son sistemas síncronos, lo que implica que siempre se selecciona un comando en cada iteración del algoritmo, incluso aunque el usuario no esté prestando atención a los estímulos. Esto supone una gran limitación para la mayoría de aplicaciones reales de estos sistemas BCI, como el control de una silla de ruedas o la navegación web, donde detectar si el usuario está controlando la aplicación es un requisito fundamental para su funcionamiento (Aloise et al., 2011; Zhang et al., 2008).

Recientemente, varios estudios han intentado abordar este problema. En general, los algoritmos propuestos hasta el momento definen un umbral sobre diferentes medidas derivadas de la salida de la etapa de clasificación de los ERPs (Aydin et al., 2018; Martínez-Cagigal et al., 2017; Zhang et al., 2008). Sin embargo, este enfoque presenta varios inconvenientes. En primer lugar, estos algoritmos presentan una alta variabilidad inter-sesión (Schettini et al., 2014). La amplitud y latencia de los ERPs de una misma persona es variable en el tiempo, provocando que la precisión asociada al umbral establecido en la etapa de calibración se vea reducida en sesiones posteriores. Además, estos algoritmos necesitan extender las sesiones de calibración del clasificador para adquirir datos del usuario mientras no está controlando la aplicación, lo que reduce su usabilidad en un entorno real. El desarrollo de nuevos algoritmos independientes de la etapa de clasificación de los ERPs podría ayudar a superar estas limitaciones. Pinegger et al. (Pinegger et al., 2015) desarrollaron una primera aproximación basada en la hipótesis de que la frecuencia de estimulación a la que se iluminan las filas y columnas de la matriz de comandos estaría presente en el EEG del usuario, alcanzando un 79.5% de precisión. A pesar de la novedad de este enfoque, el rendimiento alcanzado no permite un control asíncrono satisfactorio de la aplicación.

El objetivo de este estudio es diseñar, desarrollar y evaluar un novedoso método para la detección del estado de control del usuario en sistemas BCI basados en ERPs que permita superar las limitaciones anteriores. Nuestra hipótesis de partida es que las estimulaciones periféricas de la matriz de comandos provocan un potencial evocado de estado estable (steady-state visual evoked potential, SSVEP) en el usuario cuando está controlando el sistema. Los SSVEPs son formas de onda similares a sinusoides que aparecen en el EEG cuando se recibe un estímulo visual repetitivo a una frecuencia constante (Luck, 2014). El método diseñado es independiente de la etapa de clasificación de los ERPs. Además, hasta

donde tenemos conocimiento, es el primer método de asincronía que no necesita aumentar la duración de las sesiones de calibración.

2. Métodos

1.1. Adquisición de la señal y sujetos

La señal de EEG fue registrada con 8 electrodos situados en las posiciones Fz, Cz, Pz, P3, P4, PO7, PO8 y Oz de acuerdo con el sistema internacional 10-20 extendido. Esta configuración es habitual en los sistemas BCI basados en ERPs (Aloise et al., 2011). Se ha usado un equipo g.USBamp para la amplificación y conversión de la señal de EEG al dominio digital, utilizando una frecuencia de muestreo de 256 Hz. La plataforma MEDUSA[®] ha sido utilizada para registrar y guardar los datos, procesar la señal de EEG y presentar las matrices de estimulación a los participantes (Santamaría-Vázquez et al., 2018).

Cinco sujetos sanos (media 25.8 ± 1.09 años) han participado en los experimentos. El protocolo de experimentación ha sido aprobado por el comité ético correspondiente y todos los participantes han dado su consentimiento de participación informado.

1.2. Método propuesto

El método propuesto, denominado *Oddball Steady Response Detection* (OSRD), es un nuevo algoritmo para detectar el estado de control del usuario en sistemas BCI basados en ERPs. El algoritmo debe diferenciar entre dos estados de control: (i) el usuario está atendiendo a los estímulos y quiere seleccionar un comando, y (ii) el usuario no está atendiendo a los estímulos y no quiere seleccionar ningún comando. OSRD recibe como entrada la señal EEG cruda correspondiente a la selección de un comando. Una vez procesada la señal, el algoritmo proporciona una salida binaria $y \in \{0,1\}$ en función del estado de control detectado. A continuación, se detallan las diferentes etapas del método OSRD.

1.2.1. Pre-procesado de la señal

El objetivo de esta etapa es incrementar la relación señal a ruido (SNR). Se aplica un filtro paso banda entre $[f_{st} - bw_1/2, f_{st} + bw_1/2]$, donde f_{st} es la frecuencia de estimulación del paradigma (inversa del tiempo entre dos iluminaciones consecutivas) y bw_1 es heurísticamente seleccionado como 1 Hz. Posteriormente, se aplica un filtro espacial

referencia media común (*common average reference*, CAR) para eliminar las componentes de ruido comunes a todos los canales del EEG (Martínez-Cagigal et al., 2019).

1.2.2. Extracción de características

OSRD extrae dos características para diferenciar entre los dos estados de control del usuario. La primera está basada en el método de análisis de correlación canónica (*canonical correlation analysis*, CCA) (Krzanowski, 2000). Este análisis estadístico multivariante permite encontrar correlaciones subyacentes entre dos conjuntos de datos multidimensionales, siendo utilizado habitualmente para la detección de SSVEPs (Zhang et al., 2013). CCA encuentra la combinación lineal óptima de cada conjunto de datos (i.e. \mathbf{X}, \mathbf{Y}) para maximizar la correlación entre ambos. En este caso, \mathbf{X} es la señal de EEG correspondiente a un trial, con dimensiones $N \times C$, donde N es el número de muestras y C el número de canales utilizados. Por otra parte, \mathbf{Y} es la señal de referencia, que es un seno de frecuencia f_{st} y dimensiones $N \times 1$. Consecuentemente, la primera característica es el coeficiente de correlación máximo entre \mathbf{X} e \mathbf{Y} :

$$c_1 = CCA(\mathbf{X}, \mathbf{Y}) \quad (1)$$

La segunda característica (c_2), se deriva directamente de la estimación del espectro del EEG. Con el objetivo de aumentar la resolución espectral, se concatenan todos los canales del EEG en un único vector de dimensiones $N \cdot C \times 1$. Posteriormente, se calcula la densidad espectral de potencia (*power spectral density*, PSD) de este vector mediante el método de Welch. La segunda característica es la diferencia entre el valor medio de la PSD en un rango estrecho alrededor de f_{st} , y el valor medio en un rango más amplio:

$$c_2 = \frac{1}{bw_2} \int_{f_{st}+bw_2/2}^{f_{st}+bw_2/2} S(f)df - \frac{1}{bw_1} \int_{f_{st}+bw_1/2}^{f_{st}+bw_1/2} S(f)df, \quad (2)$$

donde $S(f)$ representa la PSD, y bw_1 y bw_2 fueron fijados a 2 y 0.1 Hz respectivamente. Estos valores han sido escogidos heurísticamente para considerar suficientes muestras dentro de cada una de las bandas de manera que aumente la robustez del método frente al ruido.

1.2.3. Observaciones sintéticas

Los sistemas BCI basados en ERPs deben ser recalibrados debido a la alta variabilidad inter-sesión de estas formas de onda (Schettini et al., 2014). De hecho, para asegurar un rendimiento adecuado, es recomendable que el usuario seleccione varios comandos de entrenamiento antes de utilizar el sistema. Este procedimiento requiere una gran cantidad tiempo, haciendo que el sistema sea poco práctico en la vida real. Además, todos los métodos de asincronía definidos hasta el momento requieren aumentar la duración de estas

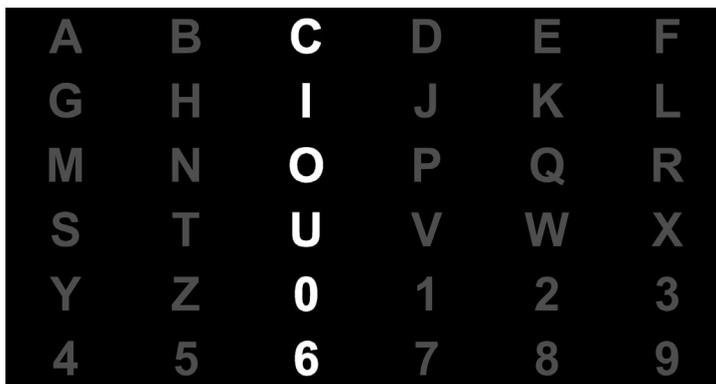
sesiones de calibración para adquirir señales de los usuarios mientras no están controlando la aplicación. OSRD supera esta limitación mediante la creación de observaciones sintéticas que simulan a aquellas que se obtendrían mientras el usuario no está atendiendo a los estímulos. Asumiendo que la PSD del EEG mantiene sus características alrededor de la frecuencia f_{st} , se puede simular una observación mediante el desplazamiento de la frecuencia $f'_{st} = f_{st} + f_0$, donde f_0 es fijada a 0.5 Hz de manera heurística. Posteriormente, este valor se usa en las ecuaciones 1 y 2 para realizar los cálculos. Este procedimiento se basa en la hipótesis de que las características de la señal de EEG cuando el usuario está atendiendo a los estímulos en la frecuencia f'_{st} son similares a las obtenidas en la frecuencia f_{st} cuando el usuario no está controlando el sistema.

1.2.4. Clasificación de características

La última etapa del algoritmo determina el estado de control del usuario a partir de las características c_1 y c_2 . OSRD asigna $y = 1$ si se detecta que el usuario estaba atendiendo a los estímulos de la matriz de comandos, o $y = 0$ en caso contrario. El método utilizado para la clasificación de características es el análisis discriminante lineal (linear discriminant analysis, LDA), debido a su amplio uso en sistemas BCI (Martínez-Cagigal et al., 2019; Pinegger et al., 2015; Wolpaw & Wolpaw, 2012).

1.3. Análisis experimental

Se realizaron dos análisis independientes con el objetivo de comprobar la eficacia del método de asincronía propuesto. Los sujetos realizaron dos sesiones idénticas, en cada una de las cuales se registraron 30 selecciones mientras los usuarios estaban atendiendo a los estímulos, y 30 selecciones mientras los usuarios estaban visualizando un video. Por tanto, el conjunto de datos total estaba formado por 120 selecciones, 60 de cada tipo. Cada una de las selecciones estaba formada por 15 secuencias de estimulación. Durante estos registros, se utilizó la matriz de comandos representada en la figura 1. La frecuencia de estimulación durante las pruebas se fijó en $f_{st} = 5.71$ Hz (Pinegger et al., 2015).



A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	0	1	2	3
4	5	6	7	8	9

Fig. 1. Matriz de comandos utilizada durante los experimentos con la tercera columna iluminada.

En el primer análisis, se aplicó a cada participante por separado el procedimiento *leave-one-out* (LOO) en el conjunto de 120 selecciones. En cada iteración del algoritmo, la fase de entrenamiento del clasificador usó la señal completa de cada selección (15 secuencias). Sin embargo, en la fase de evaluación se consideró la señal correspondiente a 1, 5, 10 o 15 secuencias, con el objetivo de analizar la precisión del sistema en función de este parámetro.

En el segundo análisis el procedimiento de evaluación se modificó de la siguiente manera: en la fase de entrenamiento solamente se consideraron las 60 selecciones realizadas por cada usuario mientras atendía a los estímulos, creando otras 60 observaciones sintéticas en estado de no-control a partir de ellas. Sin embargo, en la fase de evaluación del procedimiento LOO, se utilizaron selecciones en estado de no-control reales. El objetivo de este análisis era determinar si las observaciones sintéticas permiten un correcto funcionamiento del algoritmo.

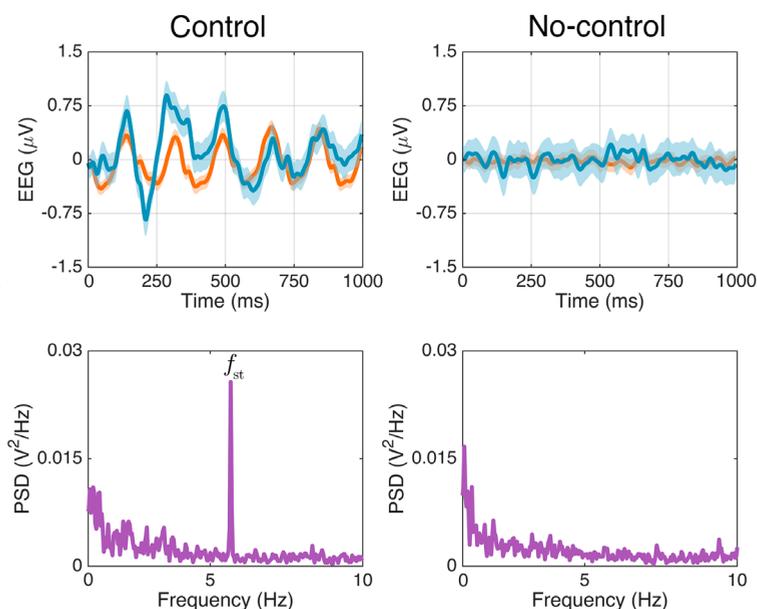


Fig. 2. Representación temporal y espectral del EEG en los dos estados de control para el usuario U05 en el canal Cz. En la parte de superior se muestran las épocas de señal promediadas para estímulos objetivo (azul) y periféricos (naranja). La parte sombreada representa el intervalo de confianza al 95%. En la parte inferior se muestra la PSD de la señal correspondiente. Como se puede observar, en la PSD correspondiente al estado de control se refleja un pico a la frecuencia de estimulación del paradigma.

3. Resultados

La figura 2 muestra la representación temporal y frecuencial de las señales en estado de control y en estado de no-control del sujeto U05, en el canal Cz. En las dos subfiguras superiores, la línea azul representa la media de las épocas de señal correspondientes a los estímulos objetivo, mientras que la línea naranja representa la media de las épocas correspondientes a estímulos no-objetivo. El área sombreada representa el intervalo de confianza al 95%. En la parte de debajo de la figura se representa la PSD de la señal correspondiente a todas las épocas de señal.

Los resultados de clasificación de los dos análisis realizados se muestran en la tabla 1. En ella se observan las precisiones alcanzadas por OSRD en la fase de test de LOO utilizando observaciones de no-control reales (columna R) y sintéticas (columna S). Las precisiones están desglosadas por número de secuencias.

4. Discusión

En este estudio se ha evaluado un nuevo método de asincronía para sistemas BCI basados en ERPs. Este método se basa en la detección de los SSVEPs provocados por las estimulaciones periféricas del paradigma *oddball*. En la figura 2 podemos observar como la representación temporal del EEG cuando el usuario está controlando el sistema muestra el SSVEP tanto en las épocas de señal correspondientes a los estímulos objetivo (iluminaciones del comando que el usuario quiere seleccionar) como en las correspondientes a los estímulos no objetivo (iluminaciones del resto de comandos). Por el contrario, sólo las épocas de señal correspondientes a las iluminaciones del comando deseado muestran el ERP del usuario, incluyendo el potencial evocado P300. Asimismo, la

Tabla 1. Resultados de los análisis

	No. Secuencias							
	1		5		10		15	
	R	S	R	S	R	S	R	S
U01	63.3	64.2	94.2	95.0	97.5	97.5	100	100
U02	65.8	64.2	95.8	95.0	96.7	96.7	98.3	98.3
U03	63.3	62.5	97.5	97.5	100	100	100	100
U04	60.0	56.7	94.2	95.0	99.2	98.3	100	100
U05	73.3	72.5	96.7	96.7	99.2	99.2	100	100
Media	65.1	64.0	95.7	95.8	98.5	98.3	99.7	99.7
STD	4.5	5.1	1.3	1.1	1.2	1.7	0.7	0.7

Precisiones del método OSRD en porcentaje (%). R: evaluación mediante LOO con selecciones no-control reales. S: evaluación mediante LOO con selecciones no-control sintéticas.

representación frecuencial de la señal muestra claramente un pico a la frecuencia de estimulación de la matriz, correspondiente con el SSVEP generado. Por el contrario, ninguno de estos fenómenos se aprecia cuando el usuario está realizando otra tarea.

En la tabla 1 se muestran los resultados de clasificación. No se han encontrado diferencias significativas, independientemente del número de secuencias considerado, entre las precisiones alcanzadas cuando se entrena el algoritmo con selecciones no-control reales o sintéticas (test de rangos con signo de Wilcoxon, $p\text{-valor} > 0.05$). Estos resultados sugieren que la duración de las sesiones de calibración podría reducirse a la mitad, registrando únicamente selecciones mientras el usuario está atendiendo a los estímulos, sin que el rendimiento en la detección del estado de control del usuario se vea comprometido. Asimismo, se aprecia cómo la precisión crece a medida que se consideran más secuencias de estimulación, alcanzando un máximo del 99.7% para 15 secuencias.

Aunque existen varios estudios que han tratado previamente el problema de la asincronía en sistemas BCI basados en ERPs, únicamente el estudio de Pinegger et al. (Pinegger et al., 2015) permite una comparación directa con este trabajo por ser el único que proporciona la precisión en la detección del estado de control del usuario de manera aislada. En este artículo se presentan dos métodos de asincronía diferentes, evaluados en 21 sujetos de control y utilizando 15 secuencias de estimulación. El primer método utiliza la salida de la etapa de clasificación de los ERPs, detectando que el usuario estaba atendiendo a los estímulos cuando la probabilidad de clasificación superaba un determinado umbral, alcanzando una precisión del 94.2%. El segundo método, al igual que el presente estudio, detecta los SSVEPs provocados por el paradigma *oddball* independientemente de la etapa de clasificación de los ERPs, alcanzando una precisión del 79.5%. Por último, la hibridación de los dos métodos alcanza un 95.5% de precisión. En comparación, OSRD alcanza una precisión del 99.7% con el mismo número de secuencias de estimulación, superando a los tres métodos anteriores. Además, es el único que no necesita aumentar la duración de las sesiones de calibración gracias al cálculo de observaciones no-control sintéticas.

A pesar de los resultados positivos alcanzados en este estudio, se pueden señalar varias limitaciones. En primer lugar, el método ha sido evaluado con 5 sujetos de control. Un mayor número de sujetos permitiría asegurar la generalización de los resultados. Asimismo, el sistema no se ha probado con sujetos con grave discapacidad, la población que presumiblemente se beneficiaría del método. La inclusión de nuevas medidas complementarias basadas en análisis estadístico podría mejorar los resultados de clasificación, y deberían ser estudiadas en el futuro (Martínez-Cagigal et al., 2019). En este estudio únicamente se han analizado los resultados de clasificación a la hora de detectar el estado de control del usuario. Sin embargo, en el futuro sería de gran utilidad analizar

también la precisión en la selección de comandos de un sistema que utilice OSRD para la monitorización de la atención del usuario, así como probar el método en sesiones *online*.

5. Conclusiones

Este estudio presenta un novedoso método para determinar el estado de control del usuario en sistemas BCI basados en ERPs mediante la detección de los SSVEPs provocados por el paradigma *oddball*. El método propuesto ha sido evaluado en 5 sujetos sanos, alcanzando una precisión media con 15 secuencias de estimulación del 99.7%, superando a otros métodos actuales. Además, éste presenta dos ventajas respecto a otros enfoques anteriores: (i) es independiente de la etapa de clasificación de los ERPs para la selección de comandos, lo que reduce la variabilidad inter-sesión que afecta a estas formas de onda; y (ii) es, hasta donde tenemos conocimiento, el primer método que no necesita registrar la señal de EEG mientras el usuario no está controlando el sistema BCI, reduciendo drásticamente el tiempo de calibración necesario.

Agradecimientos

Este estudio ha sido financiado por el proyecto DPI2017-84280-R del Ministerio de Ciencia, Innovación y Universidades y FEDER y el proyecto “Análisis y correlación entre el genoma completo y la actividad cerebral para la ayuda en el diagnóstico de la enfermedad de Alzheimer” (Programa Operativo de Cooperación Transfronteriza España-Portugal, POCTEP, 2014-2020) de la Comisión Europea y FEDER. Eduardo Santamaría-Vázquez es beneficiario de una ayuda de Personal Investigador en Formación (PIF) financiada por la Consejería de Educación de la Junta de Castilla y León y el Fondo Social Europeo. Víctor Martínez-Cagigal es beneficiario de una ayuda PIF-UVA de la Universidad de Valladolid.

Referencias

- Aloise, F., Schettini, F., Aricò, P., Leotta, F., Salinari, S., Mattia, D., Babiloni, F., Cincotti, F., 2011. P300-based brain-computer interface for environmental control: An asynchronous approach. *J. Neural Eng.* 8.
- Aydin, E.A., Bay, O.F., Guler, I., 2018. P300-Based Asynchronous Brain Computer Interface for Environmental Control System. *IEEE J. Biomed. Heal. Informatics* 22, 653–663.
- Farwell, L.A., Donchin, E., 1988. Talking off the top of your head: toward a mental

- prosthesis utilizing event-related brain potentials. *Electroencephalogr. Clin. Neurophysiol.* 70, 510–523.
- Krzanowski, W., 2000. *Principles of multivariate analysis.* OUP Oxford.
- Luck, S.J., 2014. *An introduction to the event-related potential technique.* MIT press.
- Martínez-Cagigal, V., Gomez-Pilar, J., Álvarez, D., Hornero, R., 2017. An Asynchronous P300-Based Brain-Computer Interface Web Browser for Severely Disabled People. *IEEE Trans. Neural Syst. Rehabil. Eng.* 25, 1332–1342.
- Martínez-Cagigal, V., Santamaría-Vázquez, E., Gomez-Pilar, J., Hornero, R., 2019. Towards an accessible use of smartphone-based social networks through brain-computer interfaces. *Expert Syst. Appl.* 120, 155–166.
- Pinegger, A., Faller, J., Halder, S., Wriessnegger, S.C., Müller-Putz, G.R., 2015. Control or non-control state: that is the question! An asynchronous visual P300-based BCI approach. *J. Neural Eng.* 12, 014001.
- Rezeika, A., Benda, M., Stawicki, P., Gemblar, F., Saboor, A., Volosyak, I., 2018. Brain-computer interface spellers: A review. *Brain Sci.* 8.
- Santamaría-Vázquez, E., Martínez-Cagigal, V., Hornero, R., 2018. MEDUSA: Una Nueva Herramienta Para El Desarrollo De Sistemas Brain-Computer Interface Basada en Python. *Cognitive Area Networks* 5, 87-92
- Schettini, F., Aloise, F., Aricò, P., Salinari, S., Mattia, D., Cincotti, F., 2014. Self-calibration algorithm in an asynchronous P300-based brain-computer interface. *J. Neural Eng.* 11.
- Wolpaw, J., Wolpaw, E.W., 2012. *Brain-computer interfaces: principles and practice.* OUP USA.
- Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G., Vaughan, T.M., 2002. Brain Computer Interfaces for communication and control. *Clin. Neurophysiol.* 4, 767–791.
- Zhang, H., Guan, C., Wang, C., 2008. Asynchronous P300-based brain-computer interfaces: a computational approach with statistical models. *IEEE Trans. Biomed. Eng.* 55, 1754–63.
- Zhang, Y., Zhou, G., Jin, J., Wang, X., Cichocki, A., 2013. Frequency Recognition in SSVEP-based BCI using Multiset Canonical Correlation Analysis. *Int. J. Neural Syst.* 24.