

## Estrategias de extracción de características para mejorar el desempeño de interfaces cerebro computadoras

Rubén C. Acevedo; Carolina B. Tabernig; Analía S. Cherniz; Alejandro Hadad

Autores: Facultad de Ingeniería, Universidad Nacional de Entre Ríos. Ruta provincial 11 km 10 Oro Verde, Entre Ríos, Argentina.

Contacto: [ruben.acevedo@uner.edu.ar](mailto:ruben.acevedo@uner.edu.ar)

ARK: <https://id.caicyt.gov.ar/ark:/s22504559/stwnexi3v>

### Resumen

Una interfaz cerebro computadora (BCI) es un sistema de comunicación que no depende de las salidas normales del cerebro, tales como vías nerviosas periféricas y músculos. Son una alternativa de comunicación para personas que han perdido casi por completo la posibilidad de interactuar con su entorno, así como también para implementar terapias de rehabilitación. Hay distintas formas de clasificarlas: una de ellas es según la modalidad de la señal utilizada, clasificándose en invasivas y no invasivas. Dentro de estas últimas están las basadas en electroencefalograma y las basadas en potenciales evocados relacionados con eventos. En el primer caso, es necesario detectar la sincronización/desincronización relacionada con eventos de los ritmos mu y beta, y en el otro, la onda P300. El problema de detección de los eventos mencionados puede verse como un problema de clasificación de 2 clases. Una BCI puede representarse mediante tres bloques principales: instrumentación, extracción de características y clasificador. Estos últimos son de particular interés, ya que mejorando el desempeño de estos mejorará el desempeño de la BCI, el cual puede evaluarse mediante la tasa de aciertos. La extracción de características se puede dividir en una etapa de generación de características y otra de selección de características. En este proyecto se propuso evaluar distintas alternativas de extracción de características combinadas con distintos clasificadores.

**Palabras clave:** Interfaz cerebro computadoras, aprendizaje maquina, extracción de características.

## Objetivo

Mejorar el desempeño de interfaces cerebro computadoras a través de la utilización de estrategias de extracción de características, propiciando su implementación en tiempo real.

## Marco teórico y metodológico

Los caminos naturales a través de los cuales el cerebro humano se comunica con el exterior pueden resultar dañados de manera irreversible como secuela de accidentes, traumas o enfermedades tales como la esclerosis lateral amiotrófica, la esclerosis múltiple, distrofia muscular, accidentes cerebro vasculares (ACV), entre otras. En la mayoría de los casos, la capacidad de la persona para generar la orden motora se encuentra intacta, pero no así las vías nerviosas periféricas, las placas neuromusculares o los músculos en sí mismos. En los casos más severos, como esclerosis lateral amiotrófica, el individuo pierde la capacidad de realizar casi por completo movimientos a voluntad y queda completamente atrapado dentro de su cuerpo, incapacitado de cualquier comunicación o interacción con el medio que lo rodea [1]. Éste es el llamado síndrome de enclaustramiento o *locked in*, en el cual el individuo afectado pierde toda capacidad de comunicación a pesar de tener sus capacidades cognitivas inalteradas. En estos casos extremos, las interfaces cerebro computadoras (BCI, del inglés *Brain Computer Interface*) proveen una alternativa para la comunicación. Por otro lado, en casos menos severos, como el de personas que sufrieron un ACV –donde las vías periféricas se encuentran en buenas condiciones–, son una novedosa herramienta para implementar terapias de neuro-rehabilitación en personas con discapacidad motora [2]-[6]

Las primeras investigaciones en BCI datan de los años 70; sin embargo, recién en los últimos años se ha producido un extraordinario crecimiento del área. En la 1ra Reunión Internacional en Tecnología de BCI se acordó la siguiente definición: “Una Interfaz Cerebro Computadora es un sistema de comunicación que no depende de las salidas normales del cerebro, tales como vías nerviosas periféricas y músculos” [7]. A esta primer conferencia le siguieron otras en 2003 y 2005, cuyas conclusiones pueden ser consultadas en [8]-[11]. Sin embargo, en el año 2012 la definición evolucionó de la siguiente manera:

“Una BCI es un sistema que registra la actividad del sistema nervioso central (SNC) y lo traduce en una salida artificial que reemplaza, restaura, mejora o complementa las salidas del SNC natural; por lo tanto, modifica las interacciones del SNC con el resto del cuerpo o con el mundo externo” [12].

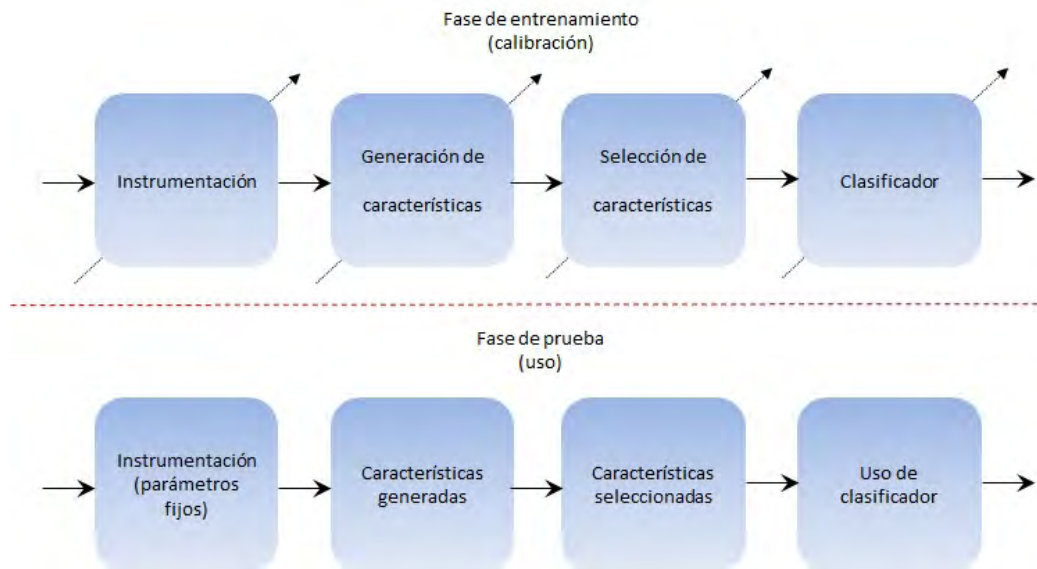
Hay distintas formas de clasificar las BCI; una de ellas es según la modalidad de la señal utilizada, clasificándose en invasivas y no invasivas. En el caso de las invasivas, se aplican electrodos directamente sobre la corteza cerebral (por ejemplo, para el registro de electrocorticograma), y en las no invasivas se colocan electrodos de superficie sobre el cuero cabelludo [1]. Considerando estas últimas, se pueden clasificar las BCI en función de la señal de control a utilizar: están aquellas que utilizan señales espontáneas y las que utilizan señales evocadas. Las señales espontáneas son generadas por una persona voluntariamente sin ningún estímulo externo; tal es el caso de los ritmos sensorimotrices del electroencefalograma (EEG). Las señales evocadas son generadas

inconscientemente por una persona cuando recibe estímulos externos; una de las más conocidas son potenciales evocados relacionados con eventos (ERP, del inglés *Event Related Potentials*) [13].

En personas despiertas, el EEG registrado en el área central ubicada sobre la corteza cerebral motora presenta una actividad en el rango frecuencial entre los 8 y 12 Hz (ritmo *mu*) y entre los 12 y 30 Hz (ritmo *beta*) [14]. El movimiento, o la preparación para el movimiento, suelen ir acompañados de una disminución de estos ritmos sensorimotors, especialmente en el hemisferio contralateral al movimiento, la cual se denomina desincronización relacionada con eventos (ERD, del inglés *Event Related Synchronization*). De otra manera, el aumento de estos ritmos se produce en la relajación después del movimiento, produciendo lo que se denomina sincronización relacionada con eventos (ERS, del inglés *Event Related Synchronization*) [15]. Sin embargo, lo más relevante para el caso de una BCI es que en la mayoría de las personas la ERD y la ERS no requieren de un movimiento real, sino que también se manifiestan con la imaginación o intención de realizar un movimiento y este hecho es utilizado para ejecutar una acción mediada por una BCI [16]. Los ERP son potenciales evocados con latencias mayores a 100 ms cuya manifestación depende de procesos psicológicos y conductuales. La BCI más conocida que utilizó este paradigma fue el denominado “deletreador de Donchin” [18], el cual consiste en la iluminación aleatoria de las filas o columnas de una matriz en la que se representan las letras del abecedario. En el caso de una matriz de 6x6 caracteres alfanuméricos, se dispone de 36 caracteres que representan las letras del abecedario y comandos especiales de una sola palabra arreglados en filas y columnas. En este caso, la persona debe prestar atención cuando se ilumina la fila/columna en la cual se encuentra el carácter alfanumérico que le interesa seleccionar. Esta situación se denomina estímulo infrecuente y, como consecuencia, se generará una onda a los 300 ms posterior al estímulo llamada onda P300. La detección de esta onda permite determinar la intención de una persona para realizar una acción, lo cual no es simple, ya que la señal de ERP posee una relación señal a ruido muy baja [19].

De lo expuesto anteriormente, el problema de detección de los eventos de interés (ERD/ERS u onda P300 según sea el caso) puede abordarse como un problema de clasificación de 2 clases posibles, en el que una de las clases  $C_1$  corresponde a señales donde *existe el evento* y la otra clase  $C_2$  corresponde a señales donde *no existe el evento*. En la Figura 1 se muestra el diagrama de bloques de una BCI, en el cual además se describen las fases requeridas para su utilización: 1) una fase de entrenamiento *offline* durante la cual se calibra el sistema y 2) la fase de uso *online*, en la que el sistema puede reconocer patrones de actividad cerebral y traducirlos en comandos para un actuador o dispositivo a controlar.

La fase de entrenamiento suele ser necesaria para identificar los filtros (espaciales y/o espectrales) adecuados y las mejores estrategias de extracción de características para entrenar al clasificador; los resultados obtenidos se usan *online* para operar la BCI. La fase de uso es un circuito a lazo cerrado, que comienza cuando el usuario produce un patrón de EEG o ERP específico y se registran estas señales. Luego se procesan utilizando los filtros y se extraen características definidas en la etapa *offline*. Finalmente, estas características se clasifican antes de ser traducidas a un comando para una aplicación y, posteriormente, se proporciona una realimentación al usuario para informarle si se reconoció un comando mental específico o no [20].

**Figura 1****Figura 1. Esquema de uso de una ICC: etapa offline (calibración) y etapa online (uso)**

Fuente: Adaptado de [20].

La extracción de características se divide en dos etapas: una es la generación de características y la otra es la de selección de características. La generación de características tiene como objetivo producir una representación alternativa de la señal de entrada original para mejorar el desempeño del clasificador y, en consecuencia, de la BCI. Si bien en algunos casos con esto es suficiente, en general es conveniente utilizar además algoritmos de selección de características para disminuir la cantidad de características (o coeficientes) y además facilitar la implementación en hardware de la BCI, ya que esto permite que el tiempo computacional requerido sea menor. Entre los métodos de extracción de características que se han utilizado, se puede mencionar métodos de estimación espectral [21], transformada wavelet [22][23], estrategias de filtrado espacial tales como *common spatial pattern* (CSP) [24] y CSP combinado con descomposición modal empírica [25], entre otros. En lo que respecta a selección de características, entre otros métodos se han utilizado algoritmos genéticos [26][27][30] y el método de eliminación recursiva de características con diversos grados de éxito [31][32].

El clasificador más utilizado por la comunidad de investigadores es el discriminante lineal de Fisher (*Fisher Linear Discriminant*, FLD), dado que se supone que las clases involucradas en el problema son linealmente separables. Aunque tiene una implementación simple y un bajo costo computacional, ofrece un rendimiento similar en comparación con los métodos más complejos para el problema de clasificación descripto [33][34].

Hay dos aspectos que afectan la precisión de la detección del evento: una es la separabilidad de las clases y la otra es la relación señal a ruido (RSR), la cual es muy baja en ambos casos, pero sobre todo en el caso de los ERP [20]. Para mejorar la RSR, se utilizaron representaciones de las señales de EEG y ERP que permitan su descomposición en bases y/o distribuciones tiempo-frecuencia que resalten aspectos discriminativos de estas. Combinando esto con algoritmos de selección de características y

clasificadores adecuados, se espera mejorar la separabilidad entre clases.

Para esto, la metodología que se llevó adelante se resume como sigue: a) implementación de estrategias de extracción de características combinadas con distintos clasificadores y b) comparación de desempeños.

### **a) Implementación de estrategias de extracción de características combinadas con distintos clasificadores**

Se combinaron estrategias de extracción de características con distintos clasificadores con el objetivo de resaltar los rasgos discriminativos de las señales de interés y favorecer la detección de la ERD/ERS y de la onda P300, según corresponda. Para esto se utilizaron registros propios así como también bases de datos de registros correspondientes a procesos de calibración de una BCI basada en ritmos sensorimotrices [4] y de una BCI basada en P300 [37].

- Métodos de estimación espectral: en el paradigma de ERD/ERS es indispensable obtener información de los ritmos del EEG involucrados en el proceso. Bajo esta hipótesis se implementaron distintos métodos que en forma general se pueden agrupar en métodos paramétricos y no paramétricos.
- Distribuciones tiempo-frecuencia lineales: transformaciones lineales como la transformada de Fourier de tiempo corto o transformada wavelets se han utilizado en el paradigma de ERP [38] y muy poco en el de ERD/ERS, por lo que se profundizó su utilización en este último bajo la hipótesis de que la descomposición de la señal de EEG mediante bases de soporte compacto como las wavelets permitirá un mejoramiento de la relación señal a ruido y de esta manera favorecerá la detección del fenómeno de ERD/ERS.
- Clasificadores: si bien el discriminante lineal es el clasificador más utilizado en la comunidad de investigadores. En este proyecto se valoraron otros clasificadores, como las máquinas de soporte vectorial, redes neuronales, k-vecinos más cercanos, entre otros.

### **b) Comparación de desempeños**

Para cada estrategia de extracción de características, combinada con un clasificador, se calcularon índices de desempeño tales como precisión, sensibilidad, especificidad, área bajo la curva ROC, entre otros [36]. Posteriormente se determinó la/s mejor/es, previa realización del análisis estadístico correspondiente.

## **Resultados y conclusiones**

Se evaluaron estrategias de extracción de características basadas en la Densidad Espectral de Potencia (PSD, del inglés *Power Spectral Density*) del EEG y métodos de selección de características, en particular el método de Eliminación Recursiva de Características. Se utilizaron registros propios del Centro de Ingeniería en Rehabilitación e Investigaciones Neuromusculares y Sensoriales (CIRINS) y como clasificador un LDA. Los resultados muestran que utilizando solo los canales ubicados sobre la corteza motora y aplicando selección de características se obtuvo el mejor desempeño, con una reducción considerable de características. Para más detalle ver: "Comparison of feature extraction methods in EEG-based Brain Computer interfaces". A. Roberts, F. Guaita, M. Rossi, C. Tabernig, R. Acevedo; Revista Argentina de Bioingeniería. Vol. 24 No 3. Pág. 29-33 (2020).

Se evaluaron los métodos de Welch y Yule-Walker, para obtener la PSD, combinados con una máquina de soporte vectorial lineal como clasificador. Los resultados obtenidos muestran el mejor desempeño del método no paramétrico (Welch). Para más detalle ver: “ERD detection in EEG-based BCI using power spectral density and support vector machines”, Melina Pilz, Rubén Acevedo. En Memorias del 23° Congreso Argentino de Bioingeniería, Argentina: Sociedad Argentina de Bioingeniería. 2022.

También se comparó el desempeño de un perceptrón multicapa (MLP, del inglés *MultiLayer Perceptron*), una máquina de soporte vectorial (SVM, del inglés *Support Vector Machine*) lineal y una SVM no lineal. Para el entrenamiento y evaluación de los clasificadores, se utilizaron registros propios de señales de EEG de 8 voluntarios. Como método de extracción de características se utilizó la densidad espectral de potencia mediante el método de Welch. Para comparar el desempeño de los clasificadores se calcularon la tasa de aciertos y la tasa de verdaderos positivos. Los resultados mostraron que la SVM lineal obtuvo mejor desempeño que la SVM no lineal y el MLP. Para más detalle ver: “Performance evaluation of SVM and MLP in EEG-based brain-computer interfaces for neurorehabilitation”, Diana Vértiz del Valle, Alejandro Quiroga, Melina Pilz, Rubén Acevedo. En Memorias del 23° Congreso Argentino de Bioingeniería, Argentina: Sociedad Argentina de Bioingeniería. 2022.

Siguiendo la línea anterior, se comparó el desempeño de 4 tipos de clasificadores: perezoso (K-vecinos más cercanos), conexionista (perceptrón multicapa), basado en kernel (máquina de vectores de soporte) y estadístico (discriminante lineal). Aunque se informaron la Tasa de Aciertos (Acc) y la Tasa de Verdaderos Positivos (TPR) para el desempeño de los clasificadores, esta última se tomó como una métrica más apropiada debido a la aplicación de la BCI en rehabilitación. Los resultados obtenidos muestran que la TPR más alta pertenece a clasificadores menos complejos, como máquina de vectores de soporte lineal y discriminante lineal. Para más detalle ver: “Performance comparison of different classifiers to detect motor intention in EEG-based BCI”, Alejandro Quiroga, Diana Vértiz del Valle, Melina Pilz, Rubén Acevedo., IFMBE Proceedings book series (CLAIB2022), Ed. Springer, 2022 (in press).

Además de la PSD se evaluaron otras estrategias de extracción de características con el objetivo de detectar la ERD, tales como la transformada wavelet y descomposición modal empírica (EMD, del inglés *Empirical Modal Decomposition*). Se utilizaron registros propios y como clasificador un discriminante lineal de Fisher. Los resultados obtenidos muestran que los mejores desempeños fueron obtenidos por las estrategias basadas en la transformada wavelet, en particular cuando se considera solo la información correspondiente al ritmo mu. Para más detalle ver: “Detection of ERD in EEG based Brain Computer interfaces using wavelet transform and empirical modal decomposition”. R. Toffoli, A. Roberts, R. Sanchez, C. Tabernig, R. Acevedo; Proceedings del XXII Congreso de Bioingeniería (2020).

Además de los resultados obtenidos en el contexto de BCI basadas en EEG, se evaluaron estrategias de extracción y selección de características para una BCI basada en el paradigma de ERP. Se comparó el desempeño de diferentes descomposiciones ortogonales basadas en la transformada wavelet para la extracción de características, así como diferentes filtros, envolturas y alternativas integradas para la selección de características. Se obtuvieron tasas de acierto superiores al 75 % para la mayoría de las estrategias analizadas con un costo computacional relativamente bajo. Para más detalle ver: Acevedo R., Atum, Y., Gareis, I., Biurrun Manresa J., Medina Bañuelos V. Rufiner

L. "A comparison of feature extraction strategies using wavelet dictionaries and feature selection methods for single trial P300-based BCI", *Medical, Biological Engineering & Computing* (2018). <https://doi.org/10.1007/s11517-018-1898-9>.

También se evaluaron dos estrategias para la selección de canales para una BCI basada en el paradigma de ERP. La primera estrategia se diseñó específicamente para cada tema, mientras que la segunda estrategia tenía como objetivo encontrar un conjunto de canales independientes del sujeto. En ambas estrategias se utilizaron algoritmos genéticos (GA, del inglés *Genetic Algorithms*) y el algoritmo ERC. La etapa de clasificación se realizó mediante un discriminante lineal. Se utilizó un conjunto de datos de registros de EEG de 18 sujetos sanos para probar las configuraciones propuestas. Los resultados mostraron que un subconjunto fijo de cuatro canales de EEG independientes del sujeto seleccionado mediante GA proporcionó el mejor compromiso entre la configuración de BCI y el rendimiento del sistema de prueba única. Para más detalle ver: "A comparison of subject dependent and subject-independent channel selection strategies for single-trial P300 brain computer interfaces". Y. Atum, M. Pacheco, R. Acevedo, C. Tabernig, J. Biurrun Manresa; *Medical and Biological Engineering and Computing*, 57 num. 12 (2019): 2705 - 2715.

### Indicadores de producción

Acevedo R., Atum, Y., Gareis, I., Biurrun Manresa J., Medina Bañuelos V. Rufiner L. "A comparison of feature extraction strategies using wavelet dictionaries and feature selection methods for single trial P300-based BCI", *Medical, Biological Engineering & Computing* (2018). <https://doi.org/10.1007/s11517-018-1898-9>

Atum, Yanina; Pacheco, Marianela; Acevedo, Rubén; Tabernig, Carolina; Biurrun Manresa, José. "A comparison of subject-dependent and subject-independent channel selection strategies for single-trial P300 brain computer interfaces". *Medical and Biological Engineering and Computing*, 57 num.12 (2019): 2705 - 2715.

Aldana Roberts González; Francisco Guaita; Maximiliano Rossi ; Carolina Tabernig; Rubén Acevedo. "Comparison of feature extraction methods in EEG based brain computer interface". *Revista Argentina de Bioingeniería*, 24 num.3 (2020): 29 - 34

Carolina Tabernig; Carolina Carrere; Yanina Atum; Rubén Acevedo. "Brain Computer Interfaces for Communication, Mobility and Motor Recovery", en *Advances in Technology Assisted Neurorehabilitation*, ISBN: 9780128198773, Elsevier, 2020. (Capítulo de libro en proceso de edición).

Ma. del Rosario Toffoli González; Aldana Roberts González; Roberto Sánchez Amador; Carolina Tabernig; Ruben Acevedo. "Detection of ERD in EEG based brain computer interfaces using wavelet transform and empirical modal decomposition". En *Memorias del 22° Congreso Argentino de Bioingeniería*, Argentina: Sociedad Argentina de Bioingeniería, 2020.

Diana Vértiz del Valle, Alejandro Quiroga, Melina Pilz, Rubén Acevedo. "Performance evaluation of SVM and MLP in EEG-based brain-computer interfaces for neurorehabilitation". En *Memorias del 23° Congreso Argentino de Bioingeniería*, Argentina: Sociedad Argentina de Bioingeniería, 2022.

Julián Furios, L. Carolina Carrere, Rubén Acevedo, José Biurrun Manresa, Carolina. B. Tabernig. "A comparison of methods for the determination of event-related desynchronization onset latency". En *Memorias del 23° Congreso Argentino de Bioingeniería*, Argentina: Sociedad Argentina de Bioingeniería, 2022.

Melina Pilz, Rubén Acevedo. "ERD detection in EEG-based BCI using power spectral density and support vector machines" En Memorias del 23° Congreso Argentino de Bioingeniería, Argentina: Sociedad Argentina de Bioingeniería, 2022.

Alejandro Quiroga, Diana Vértiz del Valle, Melina Pilz, Rubén Acevedo. "Performance comparison of different classifiers to detect motor intention in EEG-based BCI", IFMBE Proceedings book series (CLAIB2022), Ed. Springer, 2022 (in press).

## Referencias bibliográficas

- [1] Gentiletti, G., Tabernig, C. y Acevedo, R. (2007). Interfaces Cerebro Computadora: Definición, Tipos y Estado Actual. En *Proceedings of IV Latin American Congress of Biomedical Engineering (CLAIB2007)* (pp. 1117-1121).
- [2] Daly, J. y Wolpaw, J.R. (2008). Brain-Computer Interfaces in Neurological Rehabilitation. *Laneur*, 7, 1032-1043.
- [3] Gentiletti, G.G, Gebhart, J.G., Acevedo, R.C., Yáñez-Suárez, O. y Medina-Bañuelos, V. (2009). Command of a simulated wheelchair on a virtual environment using a brain-computer interface. *Ingénierie et Recherche Biomédicale*, 30(5), 218-225.
- [4] Carrere, C. y Tabernig, C. (2015). Detection of foot motor imagery using the coefficient of determination for neurorehabilitation based on BCI technology. *IFMBE Proceedings - CLAIB*, 49, 944-947.
- [5] Tabernig, C.B., Carrere, L.C., Lopez, C.A. y Ballario, C. (2015). EEG Event-Related Desynchronization of patients with stroke during motor imagery of hand movement. *Journal of Physics: Conference Series*.
- [6] Chaudhary, U., Birbaumer, N. y Ramos-Murguialday, A. (2016). Brain-computer interfaces for communication and rehabilitation. *Nature Reviews Neurology*, 12, 513-525.
- [7] Wolpaw, J.R. et al. (2000). Brain-computer interface technology: A review of the first international meeting. *IEEE Transactions on Rehabilitation Engineering*, 8(2), 164-173.
- [8] Cincotti, F., Bianchi, L., Birch, G., Guger, C., Mellinger, J., Scherer, R., Schmidt, R. N., Suárez, O. Y. y Schalk, G. (2006). BCI Meeting 2005—Workshop on Technology: Hardware and Software. *IEEE Transactions on Rehabilitation Engineering*, 14(2), 128-131.
- [9] Kübler, A., Mushahwar, V. K., Hochberg, L. R. y Donoghue J. P. (2006). BCI Meeting 2005—Workshop on Clinical Issues and Applications. *IEEE Transactions on Rehabilitation Engineering*, 14(2), 131-134.
- [10] McFarland, D.J., Anderson, C.W., Müller, K.R., Schlögl, A. y Krusienski, D.J. (2006). BCI Meeting 2005-Workshop on BCI Signal Processing: Feature Extraction and Translation. *IEEE Transactions on Rehabilitation Engineering*, 14(2), 135-138.
- [11] Wolpaw, J.R., Loeb, G. E., Allison, B. Z., Donchin, E., Nascimento, O. F., Heetderks, W.J., Nijboer, F., Shain, W. G. y Turner, J. N. (2006). BCI Meeting 2005—Workshop on Signals and Recording Methods. *IEEE Transactions on Rehabilitation Engineering*, 14(2), 138-141.
- [12] Wolpaw, J. y Wolpaw, E. (2012). *Brain Computer Interfaces: Principles and Practice*. Oxford University Press.
- [13] Ramadan, R. y Vasilakos, A. (2017). Brain computer interface: control signals review. *Neurocomputing*, 223, 26-44.
- [14] Niedermeyer, E. y Lopes da Silva, E. (2005). *Electroencephalography: Basic principles, clinical applications, and related fields* (5ª ed.). Lippincott Williams & Wilkins.



- [15] Wolpaw, J., Birbaumer, N., McFarland, D., Pfurtscheller, G. y Vaughan T. (2002). Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767-791.
- [16] Pfurtscheller, G., Neuper, C., Flotzinger, D. y Pregenzer, M. (1997). EEG-based discrimination between imagination of right and left hand movement. *Electroencephalography and Clinical Neurophysiology*, 103, 642-651.
- [17] Rufiner, H. L. (2010). *Análisis y representación de la voz mediante técnicas no convencionales*. E. UNL.
- [18] Farwell, L. y Donchin, E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and clinical neurophysiology*, 70(6), 510-523.
- [19] Mak, J. y Wolpaw, J. (2009). Clinical applications of brain-computer interfaces: Current state and future prospects. *IEEE reviews in biomedical engineering*, 2, 187-199.
- [20] Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A. y Yger, F. (2018). A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces: A 10-year Update. *Journal of Neural Engineering*, 15(3).
- [21] Brodu, N., Lotte, F. y Lécuyer, A. (2011). Comparative study of band-power extraction techniques for Motor Imagery classification. En *2011 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB)* (pp. 1-6).
- [22] Bostanov, V. (2004). BCI competition 2003-data sets ib and iib: feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram. *IEEE Transactions on Biomedical engineering*, 51(6), 1057-1061.
- [23] Mowla, M., Huggins, J. y Thompson, D. (2017). Enhancing P300-BCI performance using latency estimation. *Brain-Computer Interfaces*, 4(3), 137-145.
- [24] Lotte, F. (2014). A Tutorial on EEG Signal Processing Techniques for Mental State Recognition in Brain-Computer Interfaces. En E. Reck Miranda y J. Castet, *Guide to Brain-Computer Music Interfacing*. Springer.
- [25] Wei, H., Pengfei, W. y Liping, W. (2012). A Novel EMD-Based Common Spatial Pattern for Motor Imagery Brain-Computer Interface. En *Proceedings of the IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI 2012)* (pp. 216-219).
- [26] Dal Seno, B., Matteucci, M. y Mainardi, L. (2008). A genetic algorithm for automatic feature extraction in p300 detection. En *Neural Networks, 2008. IJCNN 2008 (IEEE World Congress on Computational Intelligence)* (pp. 3145-3152).
- [27] Kee, C.-Y., Ponnambalam, S. y Loo, C.-K. (2015). Multi-objective genetic algorithm as channel selection method for P300 and motor imagery data set. *Neurocomputing*, 161, 120-131.
- [28] Pacheco, M., Atum, Y., Acevedo, R. y Rufiner, L. (2016). Evaluation of different parents selection methods in a genetic algorithm wrapper for P300 BCI. En *XXV Congresso Brasileiro de Engenharia Biomédica*. Sociedade Brasileira do Engenharia Biomédica.
- [29] Atum, Y., Biurrun Manresa, J., Rufiner, L. y Acevedo, R. (2014). Genetic Feature Selection for a P300 Brain Computer Interface. En *VI Latin American Congress on Biomedical Engineering CLAIB 2014*.

- [30] Atum, Y., Biurrum Manresa, J., Rufiner, L. y Acevedo, R. (2015). Genetic Feature Selection for a P300 Brain Computer Interface. *IFMBE PROCEEDINGS*, 49, 603 - 606.
- [31] Qi, H., Xu, M., Li, W., Yuan, D., Zhu, W., An, X., Ming, D., Wan, B. y Wang, W. (2010). Feature selection study of p300 speller using support vector machine. En *Robotics and Biomimetics (ROBIO), 2010 IEEE International Conference* (pp. 1331-1334). IEEE.
- [32] Rakotomamonjy, A. y Guigue, V. (2008). BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller. *IEEE Transactions on Biomedical Engineering*, 55(3), 1147-1154.
- [33] Bashashati, A., Fatourehchi, M., Ward, R.K. y Birch, G.E. (2007). A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, 4(2).
- [34] Gerven, M., Farquhar, J., Schaefer, R., Vlek, R., Geuze, J., Nijholt, A., Nick, R., Haselager, P., Vuurpijl, L., Gielen, S. y Desain, P. (2009). The brain-computer interface cycle. *Journal of Neural Engineering*, 6(4).
- [35] Thomas, E., Dyson, M. y Clerc, M. (2013). An analysis of performance evaluation for motor-imagery based BCI. *Journal of Neural Engineering*, 10.
- [36] Mowla, M. R., Huggins, J. E. y Thompson, D. E. (2018). Evaluation and Performance Assessment of Brain-Computer Interface System. En *Brain-Computer Interfaces Handbook: Technological and Theoretical Advances* (1ª ed.) (pp. 635-649). CRC Press.
- [37] Ledesma-Ramirez, C., Bojorges-Valdez, E., Yañez-Suarez, O., Saavedra, C, Boygrain, L. y Gentiletti, G. (2010). *An Open-Access P300 Speller Database*. Fourth international BCI meeting, Monterrey, California, USA.
- [38] Acevedo, R., Atum, Y., Gareis, I., Biurrum Manresa, J., Medina Bañuelos, V. Rufiner, L. (2018). A comparison of feature extraction strategies using wavelet dictionaries and feature selection methods for single trial P300-based BCI. *Medical, Biological Engineering & Computing*, 57, 589-600. <https://doi.org/10.1007/s11517-018-1898-9>

**PID 6198 Denominación del Proyecto**

Estrategias de extracción de características para mejorar el desempeño de interfaces cerebro computadoras

**Director**

Rubén Carlos Acevedo

**Codirectora**

Carolina Beatriz Tabernig

**Unidad de Ejecución**

Universidad Nacional de Entre Ríos

**Dependencia**

Facultad de Ingeniería

**Contacto**

[ruben.acevedo@uner.edu.ar](mailto:ruben.acevedo@uner.edu.ar)

**Cátedra/s, área o disciplina científica**

Ingenierías y tecnologías aplicadas a la salud humana

**Integrantes del proyecto**

Docentes: Analía S. Cherniz, Alejandro Hadad. Becarios: Aldana Roberts González (becaria PID) y Katherine Tschoop (becaria CIN)

**Fechas de iniciación y de finalización efectivas**

01/02/2019 y 24/12/2022

Aprobación del Informe Final por Resolución C.S. N° 013/24 (01-03-2024)