

# Comparison of Feature Extraction Methods in EEG-based Brain Computer Interfaces

Aldana I. Roberts González, Francisco Guaita,  
Maximiliano Rossi, Carolina B. Tabernig and Rubén C. Acevedo

*Laboratorio de Ingeniería en Rehabilitación e Investigación Neuromusculares y Sensoriales (LIRINS), Facultad de Ingeniería, Universidad Nacional de Entre Ríos, Oro Verde, Argentina.*

---

**Abstract**— A brain computer interface is a system that records the activity of the CNS and converts it into an artificial output that replaces, restores, increases, supplements or improves the natural output of the CNS and therefore changes the interactions between the CNS and its external or internal environment. In this work it is of particular interest to detect the intention of the user to perform a movement using the sensorimotor beta (12-30 Hz) and mu (8-12 Hz) rhythms of the electroencephalogram as a control signal. It is proposed to improve the performance of a brain computer interface through feature extraction strategies based on the electroencephalogram power spectral density and feature selection methods. LIRINS own records were used and as a classifier a linear Fisher discriminant. The results obtained show that using only the channels located on the motor cortex and applying characteristic selection, the best performance was obtained, with a considerable reduction of features.

**Keywords**— brain computer interfaces, motor imagery, feature extraction.

---

**Resumen**— Una interfaz cerebro computadora es un sistema que registra la actividad del SNC y la convierte en una salida artificial que reemplaza, restaura, aumenta, suplementa o mejora la salida natural del SNC y por lo tanto cambia las interacciones presentes entre el SNC y su entorno externo o interno. En este trabajo es de particular interés detectar la intención del usuario para realizar un movimiento utilizando como señal de control los ritmos sensorimotora beta (12-30 Hz) y mu (8-12 Hz) del electroencefalograma. Se propone mejorar el desempeño de una interfaz cerebro computadora mediante estrategias de extracción de características basadas en la densidad espectral de potencia del electroencefalograma y métodos de selección de características. Se utilizaron registros propios del LIRINS y como clasificador un discriminante lineal de Fisher. Los resultados obtenidos 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.

**Palabras clave**— interfaz cerebro computadora, imaginaria motora, extracción de características.

---

## I. INTRODUCCIÓN

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, 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 voluntarios y queda completamente atrapado dentro de su cuerpo, incapacitado de cualquier comunicación o interacción con el medio que lo rodea [1]. En casos extremos las *interfaces cerebro computadoras* (ICC) proveen una alternativa para la comunicación del individuo, mientras que en casos menos severos son una novedosa herramienta para implementar terapias de neurorehabilitación en personas con discapacidad motora [2][3]. Una ICC “es un sistema que registra la actividad del sistema nervioso central (SNC) y la convierte en una salida artificial que reemplaza, restaura, aumenta,

suplementa o mejora la salida natural del SNC y por lo tanto cambia las interacciones presentes entre el SNC y su entorno externo o interno” [4]. Hay distintas formas de clasificar las ICC, 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, como es el caso del registro de electrocorticograma; y en las no invasivas se colocan electrodos de superficie sobre el cuero cabelludo o por registro de la actividad metabólica, por ejemplo. Dentro de estas últimas hay distintos paradigmas para implementar una ICC dependiendo de la señal que se utilice. En este trabajo se utiliza la señal de electroencefalografía (EEG) [1].

En personas despiertas, el EEG registrado en el área central ubicada sobre la corteza cerebral sensoriomotora presenta una actividad en el rango frecuencial entre los 8 y 12 Hz (ritmo mu) y entre los 12 y 30 Hz (ritmo beta) denominándose ritmos sensorimotora (RSM) [3]. La realización, preparación o intención del movimiento (IM), producen una disminución de la amplitud de los RSM, en el hemisferio contralateral al movimiento, la cual se denomina desincronización relacionada con eventos (ERD, del inglés *Event Related Synchronization*).

En la Fig. 1 se muestra el diagrama de bloques de una ICC, en el cual se puede observar sus dos fases de operación. En la fase de calibración se instruye a la persona a realizar determinadas tareas, se registran segmentos de EEG etiquetados, y de manera *off-line* se aplican estrategias de extracción de características del EEG y se entrena un clasificador. En la fase de uso se procesa la señal de EEG en forma continua tomando ventanas deslizantes, se extraen características y el clasificador genera una salida indicando la pertenencia a una clase; se ejecuta una acción mediante el actuador y finalmente la persona recibe la realimentación de la acción realizada, por ejemplo el control del cursor [5]. A continuación se detallará la fase de calibración, en la cual se contextualiza este trabajo.

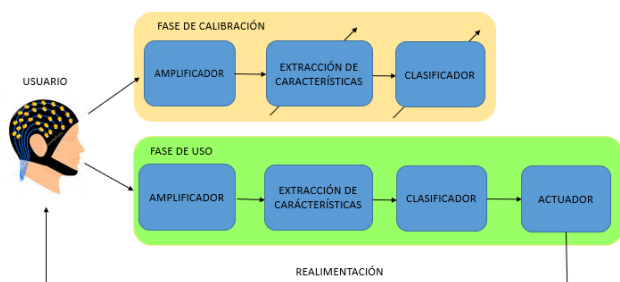


Fig. 1: Diagrama de bloques de una interfaz cerebro-computadora en sus dos fases de operación.

La extracción de características tiene como objetivo generar una representación alternativa de la señal de EEG para optimizar el desempeño del clasificador, y en consecuencia de la ICC. Si bien en algunos casos es suficiente, en otros es conveniente realizar una selección de dichas características, que es un proceso por el cual se selecciona un subconjunto relevante de éstas para modelar un determinado comportamiento o resolver un problema.

Considerando lo descripto anteriormente, la detección de la ERD constituye un problema de clasificación de 2 clases, donde una de las clases corresponde a la existencia de ERD y la otra al descanso. En general se asume que las clases son linealmente separables, por lo que principalmente se utilizan clasificadores lineales, como por ejemplo el discriminante lineal de Fisher o máquina de soporte vectorial [6].

En este trabajo se propone evaluar el desempeño del clasificador utilizando distintas estrategias de extracción de características, en la fase de calibración, que combinan densidad espectral de potencia del EEG y métodos de selección de características.

## II. MATERIALES Y MÉTODOS

### A. Base de señales

Se trabajó con una base de señales de EEG generada en el Laboratorio de Ingeniería en Rehabilitación e Investigación Neuromusculares y Sensoriales (LIRINS) en la Facultad de Ingeniería de la Universidad Nacional de Entre Ríos. La misma está conformada por señales de EEG registradas en doce voluntarios sin secuelas neurológicas ni cognitivas (edad promedio  $32 \pm 9$  años, min 23, máx. 50, 6 de sexo femenino). El protocolo de registro fue aprobado por el Comité de Ética de la Provincia de Entre Ríos (RENIS IS001667) y todos los participantes firmaron el consentimiento informado [7].

Para conformar la base de señales se registraron 8 canales de EEG en configuración monopolar por medio de un

sistema formado por un amplificador g.MOBilab+® y el software BCI2000. La señal fue muestreada a una frecuencia de 256 Hz y posteriormente sub-muestreada a 128 Hz. Se utilizaron electrodos pasivos de copa de oro según la versión extendida del sistema internacional 10-20 ubicados en C3, C4, T7, T8, Pz, F3, F4 y Cz. Los electrodos de tierra y referencia se colocaron en el mastoides derecho e izquierdo, respectivamente.

Los registros realizados en cada voluntario se dividieron en 3 series (S1, S2 y S3) con pausas de descanso entre cada una. Cada serie incluyó la realización de tres tareas en respuesta a una consigna visual: IM del pie derecho (realización de una muy leve contracción muscular sin movimiento articular visible, de manera de simular el intento motor de una persona con secuela de accidente cerebrovascular), del pie izquierdo y descanso. Las tareas de IM tuvieron una duración de 2.5 segundos y se repitieron 10 veces cada una de forma aleatoria durante cada serie. La duración de la tarea de descanso fue de 3 y 4 segundos, durante la misma se presentó una pantalla blanca y se le indicó al voluntario que no realice ninguna actividad de IM y se relaje.

Para segmentar las señales de EEG de las distintas series, y conformar posteriormente los patrones temporales, se utilizó un registro de marcas temporales para identificar el tiempo de aparición de la consigna visual. Esto permitió detectar el inicio de la IM y así poder definir los intervalos correspondientes a IM y a descanso, como se muestra en la Fig. 2.




Fig. 2: Ejemplo de obtención de los patrones temporales de una IM y de un descanso.

Se descartaron los 500 msec posteriores al tiempo de aparición de la consigna visual y se tomaron los siguientes 2 seg como intervalo donde el sujeto realizó la IM. Además, se descartaron 500 ms anteriores y se tomaron los 2 segundos anteriores al inicio de la tarea de IM como intervalo de descanso.

Tanto la IM de pie izquierdo como la de pie derecho se consideraron como pertenecientes a una misma clase, por lo que cada serie estuvo constituida por 20 intentos de IM por cada canal. Así, se formaron 8 matrices de patrones temporales de IM de  $256 \times 20$  y otras 8 matrices del mismo tamaño correspondiente a patrones de descanso, tal como se muestra en la Fig. 3.



Fig. 3: Patrones temporales para un canal de registro.

### B. Estrategias de extracción de características

En el contexto de detección de ERD, una de las alternativas más reportada en la bibliografía es la *densidad espectral de potencia* (PSD, del inglés *power spectral density*) [8]. La

PSD de una señal representa la distribución de potencia media de ésta en el dominio de la frecuencia y se calcula mediante la Ec. 1:

$$P_{XX}(f) = T \sum_{k=-\infty}^{\infty} r_{xx}(k) e^{-j2\pi f k T} \quad -\frac{1}{2T} \leq f \leq \frac{1}{2T} \quad (1)$$

donde T es el período de muestreo y  $r_{xx}(k)$  es la función de autocorrelación de la señal de interés [9].

Uno de los métodos más populares de selección de características es la *eliminación recursiva de características* (ERC) [10], en el cual el proceso de selección se realiza durante el entrenamiento del clasificador. La implementación del método ERC puede resumirse en los siguientes pasos:

1. Entrenamiento del clasificador.
2. Cálculo y almacenamiento de la tasa de aciertos.
3. Determinación del peso de conexión con menor valor absoluto.
4. Eliminación de la característica asociada al peso.

$$\mathbf{w}^T \cdot \mathbf{x} + \mathbf{w}_0 = 0$$

En este trabajo se evaluaron estrategias de extracción de características basadas en la PSD de la señal de EEG y el algoritmo de ERC, las cuales se describen a continuación.

### B.1 PSD

Se calculó la PSD de los patrones temporales mediante el método de Welch [9] en consecuencia se generaron nuevos patrones de 128 características por canal correspondientes a los valores de amplitud de la PSD. Posteriormente se seleccionó la banda de frecuencia correspondiente a los RSM, por lo que los patrones se conformaron mediante concatenación de las 23 características de cada uno de los 8 canales registrados, dando un total de 184 características. En consecuencia, por cada serie se conformó una matriz de 184x20 con patrones de IM y otra del mismo tamaño con los patrones de descanso.

### B.2 PSD y ERC

Tomando los patrones generados en la sección anterior, en esta estrategia luego se aplicó el algoritmo de ERC. Debido a esto, tanto los patrones con IM y como los de descanso tuvieron longitud variable.

### B.3 PSD promedio en RSM

En esta estrategia, se calculó la potencia promedio de las bandas mu y beta de los patrones PSD mediante la Ec. 2

$$P = \frac{\sum_{i=1}^N X_i}{N} \quad (2)$$

donde P representa la potencia promedio de la banda, N la cantidad de características y  $X_i$  los valores de PSD en dicha banda. Así, los patrones quedaron conformados por dos características por cada canal de registro. Por cada serie se generó una matriz de 16x20 con patrones de IM y otra del mismo tamaño con los patrones de descanso.

### B.4 PSD en C3, C4 y Cz

Considerando que la ERD relacionada a la IM de los pies se manifiesta principalmente en el área sensoriomotora, en esta estrategia se conformaron patrones solo con los canales C3, C4 y Cz, en los cuales previamente se calculó la PSD. Así, para cada serie se generaron patrones formados por 69

características (23 por cada canal), dando lugar a una matriz de 69x20 de patrones con IM y otra del mismo tamaño para los patrones de descanso.

### B.5 PSD en C3, C4 y Cz y ERC

A partir de estos patrones generados en la sección anterior, en esta estrategia posteriormente se aplicó el algoritmo de ERC, generando un nuevo conjunto de patrones que también fue evaluado.

### B.6 Filtrado espacial Laplaciano y PSD

El filtrado espacial Laplaciano tiene como objetivo mejorar la relación señal a ruido de un registro. Es una operación sobre un electrodo teniendo en cuenta la información de los electrodos en el entorno sin realizar ninguna modificación previa de sus valores, además es una de las estrategias más utilizada para detectar la ERD en un canal en particular. En la Fig. 4 se muestran los electrodos utilizados en el registro de EEG, para aplicar el filtro Laplaciano, definido por la Ec. 3, se utilizó la información de los canales C3, C4, Pz y F4, donde  $Cz_{SLF}$  se refiere al canal Cz después de aplicar dicho filtro [11].




Fig. 4: Filtrado espacial Laplaciano.

$$Cz_{SLF} = Cz - \frac{C4+C3+Pz+F4}{4} \quad (3)$$

En esta estrategia se calculó la PSD sobre el canal  $Cz_{SLF}$ , la longitud de los patrones en este caso fue de 23 características. Generando por cada serie una matriz de 20x23 de patrones de IM y otra del mismo tamaño para patrones de descanso.

### B.7 Filtrado espacial Laplaciano y PSD promedio en RSM

En esta última estrategia implementada se calcularon los valores de la potencia promedio de los RSM del canal  $Cz_{SLF}$  resultado patrones de 2 características. Finalmente, para cada una de las series se conformó una la matriz de 20x2 con patrones de IM y otra del mismo tamaño con patrones de descanso.

Las estrategias evaluadas en este trabajo se resumen en la tabla I, en la cual se indican las siglas utilizadas para presentar los resultados, así como también la longitud original de los patrones.

TABLA I  
ESTRATEGIAS DE EXTRACCIÓN DE CARACTERÍSTICAS

Estrategias	Sigla	Características por patrón
Densidad espectral de potencia	PSD	23 x 8 canales
Densidad espectral de potencia + ERC	PSD+ERC	-
Laplaciano en Cz +PSD	LAP <sub>Cz</sub> +PSD	23
PSD en C3, C4 y Cz	PSD <sub>C3,4,Z</sub>	23 x 3 canales
PSD en C3, C4 y Cz + ERC	PSD <sub>C3,4,Z</sub> +ERC	-
Potencia promedio de RSM	PRSM	2 x 8 canales
Laplaciano en Cz + PSD + potencia promedio RSM	LAP <sub>Cz</sub> +PRSM	2

C. Clasificación

En este trabajo se utilizó como clasificador un discriminante lineal de Fischer (FLD, Fisher's Linear Discriminant), el cual es uno de los más utilizados en la bibliografía [6].

Entonces, para evaluar el desempeño en la fase de calibración se considera el desempeño del clasificador para detectar cuando hay ERD y cuando no la hay.

Para evaluar el desempeño del clasificador obtenido en cada una de las estrategias implementadas se calcularon los siguientes índices de desempeño:

$$Tasa\ de\ aciertos\ (TA) = \frac{Patrones\ bien\ clasificados}{Total\ de\ patrones}$$

$$Sensibilidad\ (S) = \frac{VP}{VP + FN}$$

$$Especificidad\ (E) = \frac{VN}{VN + FP}$$

donde VP son verdaderos positivos, VN son verdaderos negativos, FP son falsos positivos y FN son falsos negativos. Los índices de desempeño fueron obtenidos primero entrenando el clasificador con los patrones generados a partir de las series S1 y S2 y testeando con los patrones generados a partir de S3. Luego, se entrenó el clasificador con los patrones generados a partir de las series S1 y S3 y se testeó con los patrones generados a partir de S2, y finalmente, entrenando con los patrones generados a partir de S2 y S3 y testeando con los patrones generados a partir de S1. Finalmente se calculó un promedio de los índices de desempeño obtenidos en las tres vías como resultado final.

III. RESULTADOS

En la Fig. 4 se muestran los índices de desempeño promedio calculados sobre todos los sujetos para cada estrategia propuesta.




Fig. 4: Índices de desempeño generados por el clasificador para las distintas estrategias. A: PSD, B: PSD + ERC, C: LAP<sub>Cz</sub> + PSD, D: PSD<sub>C3,4,Z</sub>, E: PSD<sub>C3,4,Z</sub> + ERC, F: PRSM, G: LAP<sub>Cz</sub> + PRSM.

En la Tabla II se muestran los valores de los índices de desempeño y la cantidad de características de cada patrón resultantes de la aplicación de cada estrategia.

TABLA II  
ÍNDICES DE DESEMPEÑO

Estrategias	S	E	TA	# caract
PSD	57,4±10,8	56,7±11,2	57,0±6,1	184
PSD+ERC	53,5±5,9	65,4±12,3	59,4±7,3	26±15
LAP <sub>Cz</sub> +PSD	50,7±7,2	61,3±10,0	56,0±5,8	23
PSD <sub>C3,4,Z</sub>	55,7±8,0	55,6±5,7	55,6±4,0	69
PSD <sub>C3,4,Z</sub> +ERC	57,6±10,8	64,1±10,9	60,8±6,8	14±9
PRSM	57,4±10,8	56,7±11,2	60,6±6,7	16
LAP <sub>Cz</sub> +PRSM	49,1±8,0	71,3±8,8	56,0±5,8	2

IV. DISCUSIÓN

Los índices de desempeño obtenidos con PSD aplicada sobre todos los 8 canales, así como en el caso de los obtenidos con PSD sobre los canales C3, C4 y Cz; mejoran cuando se utiliza la eliminación recursiva de características. Además se produce una reducción significativa en el número de características, en el caso de PSD sobre los 8 canales de aproximadamente 85 % mientras que en la PSD sobre los canales C3, C4 y Cz de aproximadamente 80 %.

La estrategia de potencia media de RSM arrojó altos valores en los índices de desempeño, con la ventaja adicional de tener una alta eficiencia computacional, ya que utiliza solo 16 características por patrón.

La utilización de los registros de C3, C4 y Cz presenta la más alta tasa de aciertos y una reducción significativa en la cantidad de electrodos, lo cual es una ventaja a la hora de utilizar la ICC.

La mayoría de las estrategias propuestas muestran un mejor desempeño que una de las estrategias más utilizadas en la bibliografía como es la aplicación del filtro Laplaciano sobre el canal Cz.

V. CONCLUSIONES

Los resultados obtenidos son alentadores y permiten concluir que es suficiente utilizar solo los canales ubicados sobre la corteza motora para evaluar nuevas estrategias de extracción de características, tales como representación de señales basadas en diccionarios wavelets o descomposición modal empírica, así también como también otros algoritmos

de selección como por ejemplo tipo *wrappers* basados en algoritmos genéticos.

#### AGRADECIMIENTOS

Este trabajo fue financiado por la Universidad Nacional de Entre Ríos mediante el Proyecto de Investigación y Desarrollo #6198.

#### REFERENCIAS

- [1] G. G. Gentiletti, C. B. Tabernig, and R. C. Acevedo, "Interfaces cerebro computadora: Definición, tipos y estado actual," *IFMBE Proc.*, vol. 18, pp. 1117–1121, 2008.
- [2] J. J. Daly and J. R. Wolpaw, "Brain-computer interfaces in neurological rehabilitation," *Lancet Neurol.*, vol. 7, no. 11, pp. 1032–1043, 2008.
- [3] U. Chaudhary, N. Birbaumer, and A. Ramos-Murguialday, "Brain-computer interfaces for communication and rehabilitation," *Nat. Rev. Neurol.*, vol. 12, no. 9, pp. 513–525, 2016.
- [4] J. R. Wolpaw, *Brain-Computer Interfaces: Principles and practice*, vol. 53, no. 9. 2013.
- [5] R. Singla, A. Devgan, P. Gogna, and A. Batra, "Fixation of delayed union or non-union posterior cruciate ligament avulsion fractures," *J. Orthop. Surg.*, vol. 22, no. 1, pp. 70–74, 2014.
- [6] F. Lotte *et al.*, "A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update," *J. Neural Eng.*, vol. 15, no. 3, 2018.
- [7] C. B. Tabernig, "Tecnología para la rehabilitación motora basada en la planeación y ejecución de movimientos.," *Br. J. Psychiatry*, 2018.
- [8] N. Gursel Ozmen, L. Gumusel, and Y. Yang, "A Biologically Inspired Approach to Frequency Domain Feature Extraction for EEG Classification," *Comput. Math. Methods Med.*, vol. 2018, pp. 19–24, 2018.
- [9] G. Pfurtscheller, C. Neuper, D. Flotzinger, and M. Pregenzer, "EEG-based discrimination between imagination of right and left hand movement," *Electroencephalogr. Clin. Neurophysiol.*, vol. 103, no. 6, pp. 642–651, 1997.
- [10] R. Acevedo, Y. Atum, I. Gareis, J. Biurrun Manresa, V. Medina Bañuelos, and L. Rufiner, "A comparison of feature extraction strategies using wavelet dictionaries and feature selection methods for single trial P300-based BCI," *Med. Biol. Eng. Comput.*, vol. 57, no. 3, pp. 589–600, 2019.
- [11] D. Felipe D', C. Barón, J. Manuel, and R. Cortés, "Reconocimiento de Imaginación Motora de Señales EEG en el Dominio Temporal aplicando Modelos Paramétricos Escrita por," 2011.

