

Análisis y clasificación de señales electroencefalográficas para el control de una órtesis robótica de mano con una interfaz cerebro computador basada en el paradigma de imaginación motora

Diego Sánchez González¹, Johann Barragán²,
Omar Mendoza-Montoya¹, Javier M. Antelis¹

¹ Tecnológico de Monterrey,
Escuela de Ingeniería y Ciencias,
México

² Universidad Autónoma de Bucaramanga,
Colombia

{A00573206, omendoza83, mauricio.antelis}@tec.mx,
jbarragan262@unab.edu.co

Resumen. El análisis de señales de electroencefalografía (EEG) en frecuencia se ha convertido en una herramienta poderosa para el estudio de la actividad cerebral durante diferentes tareas cognitivas y motoras. En este estudio, se utilizó esta técnica para analizar los datos de 10 participantes jóvenes que realizaron el paradigma de imaginación motora para el control de una órtesis robótica llamada Hand of Hope (HoH) para la rehabilitación de pacientes con enfermedades cardiovasculares e infartos cerebrales. La adquisición de la señal tuvo lugar en las etapas de entrenamiento y validación en línea. Los datos de entrenamiento fueron usados para calibrar un modelo de inteligencia artificial conocido como Filter Bank Common Spatial Pattern (FBCSP) para la extracción de características y un análisis discriminante lineal (LDA) como clasificador. Posteriormente, se realizó un análisis en frecuencia de la señal, con lo cual se estimó la desincronización de la potencia espectral entre las tareas de relajación e imaginación y la correlación entre estas señales en el dominio de la frecuencia. Los datos de validación en línea fueron usados para evaluar los rendimientos y capacidad de los participantes para mover la órtesis robótica, además del tiempo de detección de la señal. Los resultados indicaron una desincronización en la potencia espectral de los canales C3 y CP3 en las bandas alpha y theta durante la imaginación motora en comparación con el estado de relajación, lo que sugiere una activación de la corteza motora, sobre la que están posicionados los electrodos usados.

Palabras clave: Análisis frecuencial, inteligencia artificial, electroencefalografía, imaginación motora, interfaz cerebro computadora.

Analysis and Classification of Electroencephalographic Signals for the Control of a Robotic Hand Orthosis Using a Brain-Computer Interface Based on the Motor Imagery Paradigm

Abstract. The frequency analysis of electroencephalography (EEG) signals has emerged as a powerful tool for studying brain activity during different cognitive and motor tasks. In this study, we employed this technique to analyze data from 10 young participants who performed the motor imagery paradigm for the control of a robotic orthosis, known as "Hand of Hope" (HoH), used for the rehabilitation of patients with cardiovascular diseases and stroke. Signal acquisition took place during both the training and online validation stages. The training data was used to calibrate an artificial intelligence model, known as the Filter Bank Common Spatial Pattern (FBCSP), for feature extraction, and a linear discriminant analysis (LDA) as a classifier. This was followed by a frequency analysis of the signal, through which the desynchronization of spectral power between relaxation and imagination tasks was estimated, as well as the correlation between these signals in the frequency domain. The online validation data was used to evaluate the participants' performance and ability to move the robotic orthosis, as well as signal detection time. The results indicated a desynchronization in spectral power of the C3 and CP3 channels in the alpha and theta bands during motor imagery compared to the relaxed state, suggesting an activation of the motor cortex over which the used electrodes were positioned.

Keywords: Frequency analysis, artificial intelligence, electroencephalography, motor imagery, brain-computer interface.

1. Introducción

Los accidentes cerebrovasculares son una de las principales causas de discapacidad y muerte en todo el mundo. En México, el accidente cerebrovascular es la segunda causa principal de muerte después de las enfermedades del corazón. Según la Secretaría de Salud de México, cada año se producen alrededor de 130,000 casos de accidentes cerebrovasculares, y de estos, alrededor del 25 % resultan en la muerte del paciente [5].

Para abordar estos desafíos, la neuroingeniería ha surgido como una disciplina en rápido crecimiento que tiene como objetivo desarrollar tecnologías innovadoras para ayudar a los pacientes que han sufrido un accidente cerebrovascular a recuperarse y mejorar su calidad de vida.

Una de las áreas de enfoque en la neuroingeniería es la investigación y el desarrollo de interfaces cerebro-computadora o Brain Computer Interfaces (BCI), que permiten a los pacientes controlar dispositivos electrónicos y mecánicos mediante señales cerebrales. Las BCI también tienen el potencial de mejorar el proceso de rehabilitación al proporcionar una retroalimentación inmediata y precisa a los pacientes y los terapeutas.

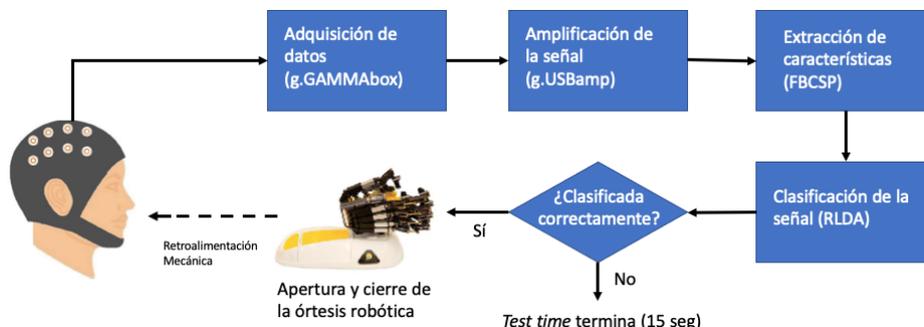


Fig. 1. Diagrama de bloques del sistema BCI+HoH.

Esto puede ayudar a los pacientes a adaptarse a los cambios en su capacidad cognitiva y física y mejorar su capacidad para realizar actividades cotidianas. Para lograrlo, las BCI pueden hacer uso del paradigma de Imaginación Motora, Motor Imagery (MI), para producir los cambios en la actividad cerebral. En este paradigma, el usuario imagina el movimiento sin realizarlo. Esto induce un cambio en la potencia de las bandas de frecuencia de las señales de EEG obtenidas de la corteza motora.

Aunado a que las BCI basadas en EEG son una opción no invasiva para controlar dispositivos, este sistema resulta idóneo para su implementación en pacientes con las patologías previamente descritas [3]. Este artículo no solo se centra en analizar señales de EEG en frecuencia, las cuales fueron adquiridas a partir de un experimento diseñado con base al paradigma de imaginación motora, sino que además estudia distintas métricas evaluadas a partir de la implementación del algoritmo de clasificación.

2. Métodos y materiales

2.1. Descripción del experimento

La BCI implementada es una interfaz basada en EEG (por tanto, no invasiva y con buena resolución temporal) con etapas de entrenamiento y validación en línea, donde la primera adquiere los datos para entrenar al modelo y la segunda utiliza al efector HoH para otorgar una retroalimentación mecánica al participante al ejecutar el movimiento de apertura y cierre de la mano derecha de forma automática. En la (Fig. 1) se muestra el diagrama de bloques de la BCI con todos sus componentes.

El experimento consistió en que el participante estuviera sentado en una posición cómoda frente a un computador que le mostrara la secuencia de imágenes y sonidos para guiarle a través del experimento. Durante la etapa de entrenamiento se le permitió tener sus extremidades superiores en cualquier posición que juzgara más cómoda, mientras que durante la etapa de validación en línea se le sujetó la mano derecha a la órtesis robótica para permitir la retroalimentación motora del sistema.

Cada etapa consistió de 24 pruebas, con una duración de 6 minutos con 24 segundos para el entrenamiento y 9 minutos con 36 segundos para la validación en línea (como máximo, debido a que el tiempo de las pruebas durante la segunda etapa variaba con respecto al tiempo de clasificación de la señal).

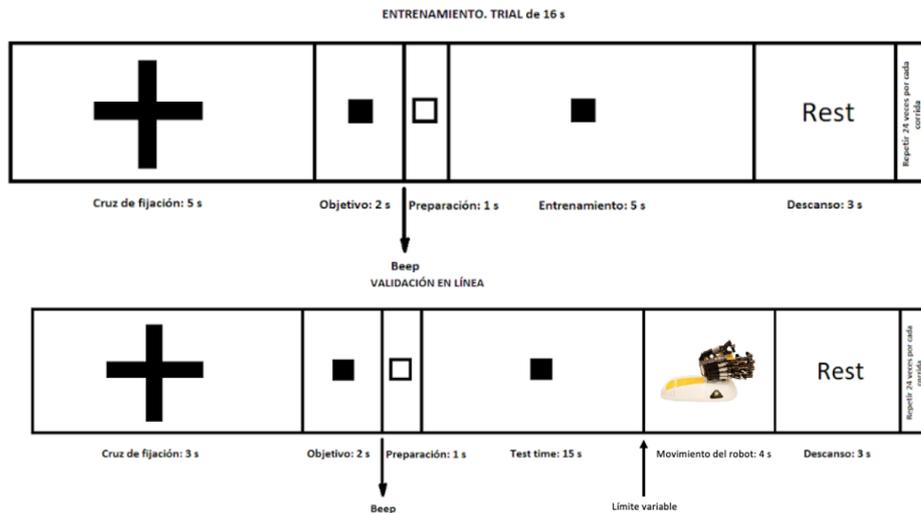


Fig. 2. (a) Línea temporal del entrenamiento. (b) Línea temporal de la validación en línea.

El experimento se realizó en un ambiente visual y acústicamente aislado para permitir la mayor concentración del participante y evitar distracciones que pudieran generar artefactos en la señal. En la figura (Fig. 2) se presenta la línea temporal del experimento para el entrenamiento y la validación en línea.

El experimento propuesto involucró a 10 participantes sanos de la Universidad Tecnológico de Monterrey (5 hombres, 5 mujeres; edad: 21 (± 2) años; todos diestros) sin ningún historial clínico de enfermedades cardiovasculares como accidentes cerebrovasculares o trastornos musculoesqueléticos. Todos aceptaron proporcionar un consentimiento informado por escrito antes de su participación.

El experimento fue facilitado por el Laboratorio de Neurotecnología (NTLab) del Tecnológico de Monterrey Campus Guadalajara. Ambas etapas hicieron uso del mismo equipo, a excepción del dispositivo de terapia Hand of Hope de Rehab Robotics (Universidad Politécnica de Hong Kong) que fue usado y conectado inalámbricamente con el sistema de clasificación para permitir la retroalimentación mecánica durante la segunda etapa del experimento.

Este dispositivo cuenta con un amplio rango de movimiento y una alta precisión en los movimientos, lo que permite una amplia gama de ejercicios de terapia para la mano y el brazo. También cuenta con sensores de presión en la superficie de contacto y con un sistema de control de fuerza que permite ajustar la cantidad de resistencia en los movimientos.

La fase de adquisición de señales fue hecha con un dispositivo de adquisición (g.USBamp, g.tec, Austria), el cual cuenta con seguridad médica tipo II y puede adquirir señales de hasta 16 canales simultáneamente, permite una frecuencia de muestreo de hasta 1200 Hz, así como una ganancia de hasta 200.000 veces la amplitud original, además de estar diseñado para minimizar el ruido de las señales de EEG durante la adquisición, lo que garantiza una alta calidad de las señales adquiridas. También fueron usados 9 electrodos activos (g.SCARABEO) húmedos (g.GAMMA gel).

Los canales C3, C1, Cz, C2, C4, CP3, CPz y CP4 fueron colocados sobre la corteza motora y lóbulos parietales, y se usó AFz como tierra (GND) y el lóbulo derecho de la oreja como referencia (REF). Las señales de EEG fueron obtenidas a una frecuencia de muestreo de 256 Hz y digitalmente filtradas con un filtro pasa bandas con frecuencias de corte de 4 Hz a 60 Hz, usando un filtro Butterworth de octavo orden en cada electrodo.

Antes de comenzar la adquisición de datos se procuró que la señal fuera de buena calidad, para ello se revisó que la señal se mantuviera dentro del rango de $-100 \mu\text{V}$ a $100 \mu\text{V}$ y que no existiera ningún artefacto presente como el latido del corazón. Adicionalmente, un software desarrollado internamente en C++ fue usado para manejar y controlar las señales de EEG, guardar los datos, y procesarlos tanto offline como online (Copyright @ 2018 Instituto Tecnológico y de Estudios Superiores de Monterrey).

2.2. Estudios con datos de entrenamiento

El análisis offline de los datos de entrenamiento comenzó con la importación de los archivos en formato Electronic Batch Report (EBR) a MATLAB (MATLAB. (2022b). Natick, Massachusetts: The MathWorks Inc.).

Densidad de potencia espectral (PSD). En general, la Transformada de Fourier (FT) es la operación matemática usada para llevar una señal del dominio del tiempo al de la frecuencia. Existe además la noción de la Transformada Discreta de Fourier (DFT) (eq. 1) que usa señales discretas. Ambas son sin embargo ineficientes temporalmente, por lo que se usa un algoritmo llamado la Transformada Rápida de Fourier (FFT), cuya versión estocástica es la PSD [8]:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i}{N}nk}, \quad k = 0, 1, \dots, N-1. \quad (1)$$

La PSD es una medida utilizada para describir la distribución de energía de una señal en diferentes frecuencias. En el contexto del EEG, la PSD se refiere a la cantidad de energía de la señal que se encuentra en diferentes bandas de frecuencia del espectro de frecuencia de la señal.

Este parámetro es importante en el análisis de EEG porque proporciona información sobre la actividad eléctrica del cerebro en diferentes frecuencias. Diferentes patrones de actividad de EEG en diferentes frecuencias se han asociado con diferentes estados mentales y procesos cognitivos.

Por lo tanto, el análisis de la PSD puede proporcionar información valiosa sobre la función cerebral y puede ser útil en la investigación y el diagnóstico de trastornos neurológicos y psiquiátricos. Para calcular la PSD, se segmenta la señal discreta en ventanas solapadas cuyo valor de solapamiento es variable, entonces se extrae la FFT de cada ventana y se calcula su magnitud de acuerdo a (eq. 2):

$$\hat{S}_p(f_k) = \frac{1}{N} |X'(f_k)|^2, \quad k = 0, 1, \dots, N-1, \quad (2)$$

donde $X'(f_k)$ es la DFT de la señal $x'(n) = x(n)w(n)$, y $w(n)$ es una función ventana de tamaño N .

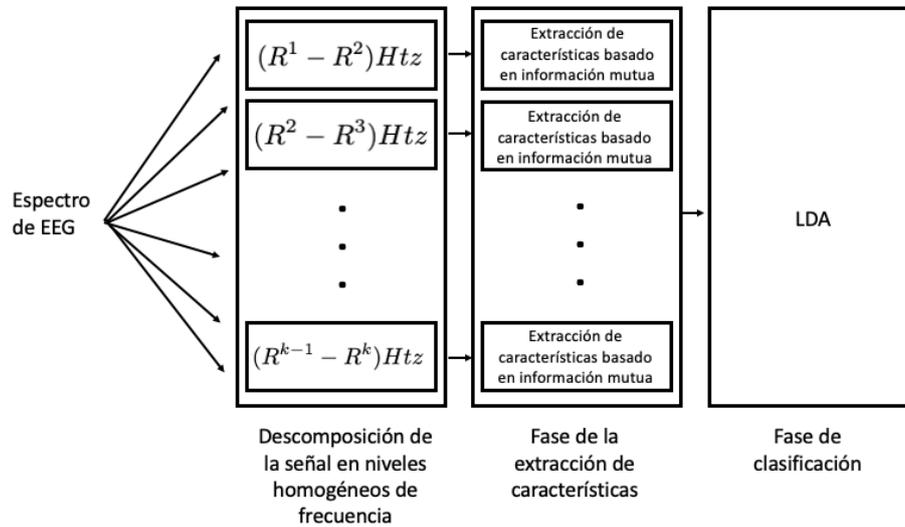


Fig. 3. Marco generalizado del FBCSP.

Cuando esta ventana es rectangular, el resultado es conocido como periodograma. A diferencia, cuando es no-rectangular, por ejemplo una ventana Hanning o Hamming, el resultado es un periodograma modificado. El efecto de una ventana no-rectangular es mitigar errores de estimación, como la "fuga", mejor conocido como leakage (cuando la potencia espectral de una banda de frecuencia se fuga a otras bandas, resultando en componentes incorrectos de frecuencia), los cuales son resultado de trabajar con señales finitas.

La mayor limitante de ambos métodos es que la PSD presenta alta variabilidad que no se reduce aún cuando su longitud aumenta. Para reducir el impacto de este inconveniente, se calcula el periodograma promediado, el cual resulta de promediar un número K de periodogramas de la señal estacionaria.

La idea del promediado se basa meramente en el hecho de que la varianza de la suma de un número K de señales independientes e idénticamente distribuidas a través de sus respectivas variables aleatorias, es $1/K$ veces la varianza de cada una de las variables aleatorias.

No obstante, en la práctica se tiene sólo un periodograma por señal adquirida, por lo que se utiliza el método de Welch-Barlett, el cual resulta de dividir el periodograma en segmentos independientes y luego promediarlos. Se sigue que el método para calcular el periodograma promediado está dado por (eq. 3):

$$\hat{S}(f_k) = \frac{1}{P} \sum_{p=0}^{P-1} \hat{S}_p(f_k), \quad k = 0, 1, \dots, M - 1, \quad (3)$$

donde M es la longitud de los segmentos P , y $\hat{S}_p(f_k)$ se calcula mediante (eq. 2). Este es justamente el tipo de método escogido para el análisis frecuencial presentado.

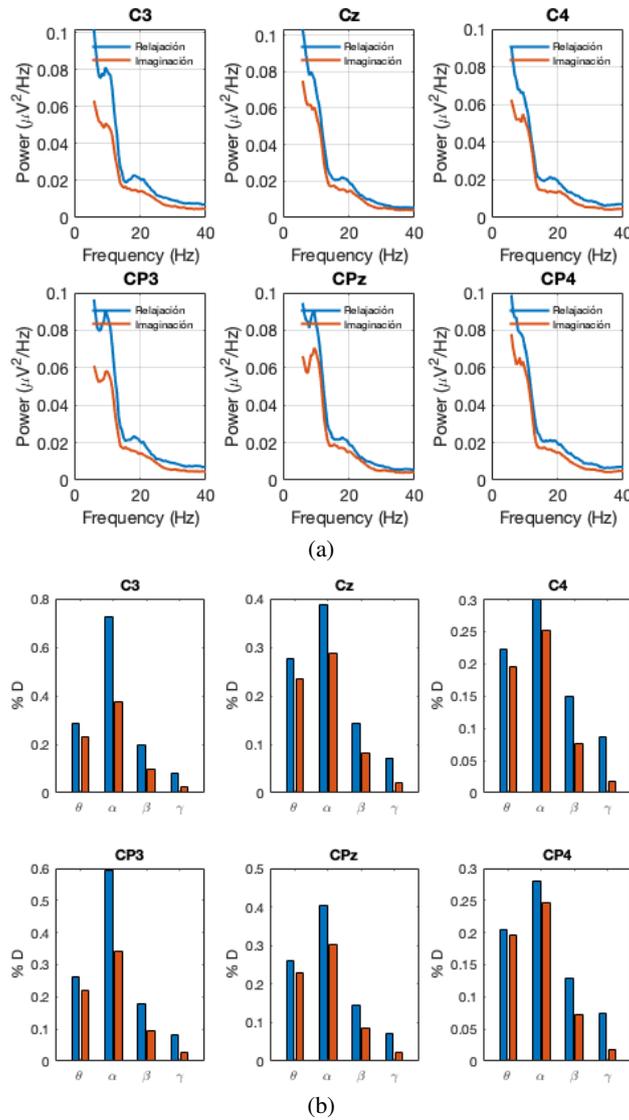


Fig. 4. (a) Desincronización espectral Promedio de participantes. (b) Desincronización espectral por bandas Promedio de Participantes.

Análisis de desincronización. Como se mencionó, el análisis de la Desincronización de la Potencia Espectral (D) es una técnica de EEG que permite estudiar la actividad cerebral asociada con la imaginación motora. Algunas de las ventajas de esta técnica incluyen su alta sensibilidad y especificidad para detectar cambios en la actividad cerebral relacionados con la imaginación motora, su capacidad para identificar patrones de actividad específicos para diferentes tipos de movimiento, y su utilidad en la rehabilitación de pacientes con discapacidades motoras [2].

Para obtener la desincronización se segmentaron las señales en ventanas de tiempo de 4 segundos en la etapa de entrenamiento, de forma que la ventana de relajación comprende los últimos 4 segundos del bloque de la cruz de fijación y la ventana de imaginación comprende 1 segundo después de haber comenzado el entrenamiento y hasta 4 segundos después.

Se obtuvo la PSD de estos tensores, cuyas medidas son $8 \times 1024 \times 24$ (canales, muestras, tareas), mediante FieldTrip (Donders Centre for Cognitive Neuroimaging) que segmenta las señales y las transforma al dominio frecuencial con la PSD, cuyo dominio va de 6 a 40 Hz, con una resolución frecuencial de 2 Hz/Hz.

A continuación, un promedio a lo largo de cada una de las 24 tareas fue realizado para reducir la estocasticidad de las señales y poder analizar mejor la disminución de la potencia espectral durante la ejecución de la imaginación en contraste con el periodo de relajación. De forma análoga, un promedio a lo largo de los 10 participantes fue hecho para concentrar la información.

Finalmente, se obtuvieron los porcentajes de desincronización en cada electrodo con (eq. 4) y por cada banda. Para obtener las bandas de frecuencia de donde esta disminución en la potencia espectral es más notable, se realiza una segmentación de la señal en ventanas de frecuencia:

$$D \% = \frac{\text{PSD}_{\text{event}} - \text{PSD}_{\text{baseline}}}{\text{PSD}_{\text{baseline}}} \times 100. \quad (4)$$

Correlación entre relajación e imaginación. La correlación en el espectro de frecuencia de señales de EEG es un aspecto fundamental para el diseño de BCI especialmente en el caso de paradigmas de imaginación motora utilizados para el control de dispositivos robóticos [1].

Al utilizar la imaginación motora, se activan las mismas redes neuronales que se utilizan para la planificación y ejecución de movimientos físicos, lo que se traduce en cambios en la actividad cerebral detectados por la EEG. El estudio de la correlación en el espectro de frecuencia de estas señales puede proporcionar información valiosa sobre los patrones de actividad neuronal asociados con la imaginación de movimientos específicos.

Para su estudio, se utilizaron las librerías de análisis de correlación en el dominio frecuencial de FieldTrip. Esta librería calcula el coeficiente de correlación usado para examinar diferencias significativas en las características basadas en la potencia espectral de distintos eventos, y con ello seleccionar la potencia espectral de los canales con la tasa más alta de discriminación de clases. El coeficiente de correlación fue calculado independientemente para cada electrodo y frecuencia (eq. 5):

$$r_j = \frac{\sum_{i=1}^N (x_{j,i} - \bar{x}_j)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_{j,i} - \bar{x}_j)^2 \sum_{i=1}^N (y_i - \bar{y})^2}}, \quad (5)$$

donde $x_{j,i}$ es la i -ésima muestra de la j -ésima característica, y_i es la clase de la etiqueta asociada a la muestra i -ésima y la notación de barra representa el promedio a lo largo de todos los participantes.

Tabla 1. Desincronización Porcentual por Canal por Banda.

Banda	C3	C1	Cz	C2	C4	CP3	CPz	CP4
Theta (θ)	51.65	42.67	36.65	39.88	39.29	52.53	43.72	31.08
Alpha (α)	58.68	46.22	25.10	22.49	20.79	52.08	25.09	20.30
Beta (β)	43.83	36.65	32.90	34.49	41.68	44.43	31.10	36.75
Gamma (γ)	57.18	32.33	31.68	33.93	55.02	59.50	41.33	47.28
Promedio	52.83	39.47	31.59	32.70	39.19	52.14	35.31	33.85

Las características seleccionadas fueron los valores de potencia espectral en α : [8, 12] Hz y θ : [4 8] Hz, las cuales son las bandas de imaginación motora que presentan mayor r-cuadrada. En el estudio, esta selección de características fue realizada individualmente para cada electrodo. Entonces el vector de características es $x \in \mathbb{R}^{n \times 1}$ con una etiqueta de clase $y \in [\text{Relajación, Imaginación}]$ para imaginación motora, donde n varía de acuerdo al número de electrodos usados.

2.3. Estudios con datos de validación

Extracción de características El algoritmo Filter Bank Common Spatial Pattern (FBCSP) es una técnica de extracción de características que se utiliza comúnmente en el análisis de señales de electroencefalograma (EEG) para el paradigma de imaginación motora. Este algoritmo es importante en la imaginación motora debido a que los componentes frecuenciales de las señales pueden variar entre los sujetos.

Por ejemplo, alguna frecuencia particular de los ritmos sensorimotores no es la misma para todos los usuarios. El FBCSP utiliza una técnica de filtrado de banco de filtros para separar la señal EEG en varias bandas de frecuencia. Luego, se aplica la técnica Common Spatial Pattern (CSP) a cada una de las bandas de frecuencia para extraer características discriminativas de la señal [1].

Una de las principales razones para elegir FBCSP es maximizar la varianza relativa entre el par de valores en los Estados de Información Mutua. Otro criterio para la selección de FBCSP es su capacidad para discriminar el espectro de la señal EEG específico del sujeto. En varias demostraciones FBCSP ha demostrado una notable mejora de rendimiento en comparación con los modelos más avanzados del estado del arte.

Estructuralmente, el algoritmo FBCSP (Fig. 3) consta de 4 pasos para seleccionar características espaciotemporales del espectro del EEG. En la fase 1, el canal de EEG se descompone en trozos de señal equidistantes mediante el filtro Chebyshev Tipo II. En la segunda fase los trozos de señal descompuestos se transforman linealmente en el vector de características (ecuación 6):

$$X = [cf_1, cf_2, \dots, cf_k], \quad (6)$$

donde $cf_i \in \mathbb{R}^{2m}$ representa m pares de características CSP para mediciones de EEG filtradas por un pasa bandas. En la tercera fase, las características son seleccionadas basándose en Mutual Information of Best Individual Feature (MIBF).

Este algoritmo ordena las primeras k características en orden decreciente considerando información mútua de las características. Finalmente, se han clasificado las observaciones fusionando características débiles basadas en aprendizaje, en una única característica fuerte de forma iterativa [6].

Clasificador. Después de la extracción de características con FBCSP y CSP, se utiliza un clasificador para determinar la clase a la que pertenece la señal EEG. Uno de los clasificadores más utilizados para este propósito es el análisis discriminante lineal (LDA), que es un clasificador supervisado que busca una combinación lineal de características que maximice la separación entre las clases.

El LDA utiliza la información obtenida de la matriz de covarianza de cada clase y la matriz de covarianza combinada de todas las clases para calcular la combinación lineal óptima. Luego, se utiliza esta combinación lineal para clasificar la señal EEG en una de las dos clases [9]. Si x representa un vector real de un número n de características para una época de EEG, el modelo de clasificación evalúa la función (eq.7):

$$f(x) = g\left(\sum_{i=1}^n b_i x_i + d\right), \quad (7)$$

donde b y d son los coeficientes del modelo lineal y $g(a)$ es una función escalar. Entonces el modelo de clasificación devuelve la etiqueta $l \in [1, -1]$ para la evaluación observada basada en la evaluación de $f(x)$. Un enfoque típico es usar algún umbral dado que los valores encima de ellos tienen la etiqueta $l = 1$ y valores por debajo $l = -1$.

LDA encuentra la clase de la etiqueta l que maximiza la condición probabilística $p(L = l|X = x)$. Asume que las funciones de densidad probabilísticas $p(X = x|L = -1)$ y $p(X = x|L = 1)$ tienen una distribución normal m_{-1} , m_1 y matrices de covarianza C_{-1} , C_1 . Bajo estas suposiciones, la regla de decisión $p(L = 1|X = x) > p(L = -1|X = x)$ es expresada como un producto punto $b'x + d > 0$, donde:

$$b = 2C^{-1}(m_1 - m_{-1}), \quad (8)$$

$$d = \ln\left(\frac{P(L = -1)}{P(L = 1)}\right) + m'_{-1}C^{-1}_{-1}m_{-1} - m'_1C^{-1}_1m_1, \quad (9)$$

y $P(L = l)$ es la probabilidad de la clase etiquetada como l . El objetivo de estos dos modelos de clasificación es la discriminación de las clases para obtener una etiqueta ($l = 1$) cuando se detecta la imaginación y ($l = -1$) cuando no se detecta.

Métricas de rendimiento. Para evaluar el rendimiento del clasificador en la tarea de detección de imaginación motora se usaron las siguientes métricas:

- Precisión de la clase de detección de imaginación motora (C1): rendimiento en la clasificación de la imaginación de apertura y cierre de la mano derecha.
- Precisión de la clase de no detección de imaginación motora (C2): rendimiento en la clasificación de la falta de imaginación de apertura y cierre de la mano derecha.

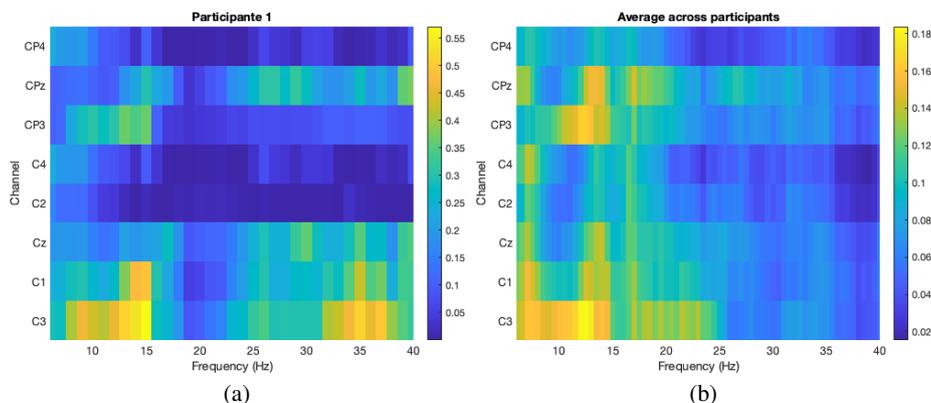


Fig. 5. (a) Correlación en el dominio de la frecuencia entre ambos eventos Participante 1. (b) Correlación en el dominio de la frecuencia entre ambos eventos Promedio de participantes.

- Promedio de ambas clases (C_{total}): promedio de la clase de detección de imaginación motora (C1) y la clase de falta de imaginación motora (C2).
- Puntaje de clasificación correcta (Score): cantidad de veces que se detectó correctamente la imaginación de apertura y cierre de la mano derecha. Este puntaje varía de 0 (ninguna detección) a 24 (detección en todas las tareas).
- Tiempo de detección (TD): Tiempo transcurrido entre el inicio del test time y la detección de la imaginación motora. No hay un tiempo de detección determinado para participantes en cuyas tareas se haya terminado el tiempo disponible para realizar la imaginación y que no se haya clasificado.

Cabe mencionar que el tiempo de detección puede ser útil para evaluar la capacidad del participante para generar señales de EEG claras y distinguibles que se puedan utilizar para controlar una BCI. Además, el tiempo de clasificación de señales de EEG también puede estar relacionado con el rendimiento y el puntaje total del participante. Por ejemplo, si el tiempo de clasificación es largo, puede indicar que el participante tiene dificultades para generar señales de EEG claras y distinguibles, lo que puede afectar negativamente su rendimiento en la tarea [9].

3. Resultados

3.1. Datos de entrenamiento

En la figura (Fig. 4) se presentan los resultados de la densidad de potencia espectral y del análisis de desincronización a lo largo de un promedio de los 10 participantes, con el fin de eliminar variabilidades producto de la estocasticidad de la señal. Estos resultados corresponden al promedio de la potencia espectral de las 24 pruebas en 6 de los 8 canales de EEG. Los canales C1 y C2 no se muestran para permitir mejor visualización de las gráficas. Finalmente, la banda delta no se muestra porque se le aplicó un filtro a la señal a partir de 4 Hz.

Tabla 2. Resultados del algoritmo de clasificación.

Participante	C1	C2	Ctotal	Score	Score (%)
1	0.97	0.96	0.97	21	87.50 %
2	0.97	0.95	0.96	14	58.33 %
3	0.86	0.89	0.87	21	87.50 %
4	0.87	0.86	0.87	11	45.83 %
5	0.91	0.94	0.93	10	41.67 %
6	0.90	0.86	0.88	24	100.00 %
7	0.87	0.94	0.91	11	45.83 %
8	0.87	0.93	0.90	6	25.00 %
9	0.86	0.93	0.89	21	87.50 %
10	0.90	0.99	0.94	23	95.83 %

Los cambios más relevantes aparecen en la figura 4(b), donde la desincronización porcentual es la métrica cuantitativa que permite concluir que son los canales C3 y CP3 los que exhiben mayor diferencia en este respecto. Es decir que la tarea de imaginación motora de la apertura y cierre de la mano derecha se encuentra con mayor prominencia en los canales C3 y CP3 sobre la corteza motora y en las banda alpha de frecuencia.

Haciendo uso de (eq.4), se obtiene en la tabla (1) la desincronización porcentual para todos los canales en cada una de las bandas estudiadas. Los valores se presentan en valor absoluto, debido a que estos son negativos por exhibir mayor potencia en la relajación (baseline) que en la imaginación. Nótese que este procedimiento reafirma que la desincronización de la PSD es más prominente en C3 y CP3 en la banda alpha.

Otro análisis que además tuvo lugar en los datos de entrenamiento fue la correlación entre la relajación e imaginación en el espectro de potencia aplicado a cada canal de forma independiente. Se muestran los resultados del participante 1 en la figura (Fig. 5)(a) y el promedio de todos ellos en la figura (Fig. 5)(b). Se discute además los resultados análogos entre ambos estudios, de desincronización espectral y correlación entre eventos, y cómo ambos llevan a conclusiones similares acerca de qué canales y qué bandas de frecuencia exhiben mayor importancia en la detección de imaginación.

La gráfica 5(a) muestra que existe una correlación significativa en el canal C3 de la banda alpha. Aunque esto es cierto, también muestra lo mismo en la banda gamma, lo cual no corresponde con la literatura de las BCI usadas con imaginación motora. En realidad no es sino hasta promediar los resultados a lo largo de todos los participantes que se disminuye la estocasticidad de los datos permitiendo reforzar las conclusiones hasta ahora mostradas y eliminando este fenómeno atípico de la banda gamma. Se muestra además en la figura 5(b) que otro canal representativo en la banda alpha es CP3, lo cual, corresponde con los resultados esperados.

3.2. Datos de validación

Se muestra en la tabla (2) los resultados de las métricas utilizadas para evaluar al rendimiento de los participantes al utilizar la BCI. Donde una precisión mayor al 75 % en las métricas de las clases indica que el clasificador es capaz de identificar correctamente la imaginación de apertura y cierre de la mano derecha por lo

Tabla 3. Resultados del tiempo de detección (tiempo en segundos).

Prueba	1	2	3	4	5	6	7	8	9	10
Promedio	6.6	7.9	5.8	4.4	6.0	5.9	6.4	6.4	4.0	4.3
Desviación estándar	3.6	3.4	2.6	1.8	3.1	3.2	3.0	3.9	1.5	1.5
Máximo	13.3	14.2	12.0	8.5	11.7	13.2	11.6	13.8	9.4	8.3
Mínimo	3.2	3.4	3.4	3.2	3.4	3.2	3.2	3.4	3.2	3.2

menos tres cuartas partes de las veces, mucho mayor al 50 % que en teoría sería mínimamente necesario para discernir entre un modelo de toma de decisiones y la aleatoriedad cuando existen solo 2 opciones de clasificación. Sin embargo, 4 de los 10 participantes movieron la órtesis robótica un número de veces tal que el score porcentual se muestra por debajo del umbral de la aleatoriedad del 50 % (participantes: 4, 5, 7, 8).

Estos mismos participantes no exhiben precisiones en las métricas de las clases necesariamente bajas (de hecho los participantes 5, 7 y 8 obtuvieron precisiones de clases promediadas mayores al 90 %). Por lo cual no se puede decir que existe una relación directa entre el rendimiento del clasificador y el score que finalmente el participante logra.

El segundo estudio realizado con los datos de validación en línea fue el tiempo de detección, el cual otorga información valiosa sobre qué tan difícil fue para el participante completar la tarea. La tabla (3) muestra un resumen de estos resultados, excluyendo aquellas pruebas donde no se clasificó la señal.

El promedio permite tener una comprensión más clara acerca de qué participante logró clasificar las señales de forma más rápida, siendo este el participante 9, quien con un puntaje del 87.5 % de aciertos, duró solo 4 segundos. Mientras que el participante que más tardó fue el 2, con un puntaje del 58.33 % de aciertos. De forma análoga, los extremos del número de aciertos muestran que el participante que obtuvo el 100 % duró 5.9 segundos, lo cual es justo la media del promedio de los tiempos.

Por su parte, el participante que obtuvo solo el 25 % de aciertos está tan solo un poco por encima de la media. Sin embargo, los resultados más concluyentes son aquellos que contrastan los extremos del tiempo de clasificación, puesto que se observa que, generalmente, los participantes que más tardan en clasificar la señal son también quienes menos aciertos tienden a hacer.

Finalmente, cabe destacar que los participantes 9 y 10 tienen una desviación estándar muy por debajo de la de los demás, al mismo tiempo que son justamente estos participantes quienes mayor número de aciertos obtuvieron.

4. Conclusiones

Los resultados obtenidos en este estudio indicaron una desincronización significativa en la potencia espectral de los canales C3 y CP3 en las bandas alpha y theta durante la tarea de imaginación motora de apertura y cierre de la mano derecha en comparación con la relajación. Esta desincronización en la potencia espectral sugiere una activación de la corteza motora, específicamente en la región sobre la que están posicionados los electrodos utilizados en este estudio.

Estos hallazgos son consistentes con investigaciones previas que han demostrado que la activación de la corteza motora durante la imaginación se puede detectar mediante el análisis de las señales de EEG en frecuencia.

Por otro lado, este estudio utilizó diferentes técnicas de evaluación de la señal de EEG de imaginación motora para los datos de entrenamiento, donde se calibró un modelo de inteligencia artificial para extraer las características de la señal y se realizó un análisis frecuencial para detectar los canales y bandas de potencia más representativos, y para los datos de validación en línea, donde se planteó hacer una correlación entre las métricas del clasificador. Sin embargo, en lo que respecta a dicha correlación, se concluye que no existe una significancia estadística lo suficientemente alta como para correlacionar directamente estas métricas entre sí.

En conjunto, estos hallazgos demuestran que el análisis de señales de EEG en el dominio de la frecuencia puede ser una herramienta útil para el estudio de la actividad cerebral durante la imaginación motora, y puede ser utilizado para la calibración de modelos de inteligencia artificial para el control de dispositivos robóticos.

Referencias

1. Antelis, J. M., Gudiño-Mendoza, B., Falcón, L. E., Sanchez-Ante, G., Sossa, H.: Dendrite morphological neural networks for motor task recognition from electroencephalographic signal. *Biomedical Signal Processing and Control*, vol. 44, pp. 12–24 (2018) doi: 10.1016/j.bspc.2018.03.010
2. Antelis, J. M., Montesano, L., Ramos-Murguialday, A., Birbaumer, N., Minguez, J.: On the usage of linear regression models to reconstruct limb kinematics from low frequency EEG signals. *Public Library of Science ONE*, vol. 8, no. 4, p. e61976 (2013) doi: 10.1371/journal.pone.0061976
3. Gilete-Tejero, I. J., Ippolito-Bastidas, H. Z., Bernal-García, L. M., Mata-Gómez, J., García-Moreno, R., Ortega-Martínez, M., Cabezudo-Artero, J. M.: Efecto de la edad en el pronóstico de pacientes con traumatismo craneoencefálico sometidos a craneotomía: análisis de una serie quirúrgica. *Revista de Neurología*, vol. 66, no. 4, pp. 113–120 (2018) doi: 10.33588/rn.6604.2017411
4. Hernandez-Rojas, L. G., Cantillo-Negrete, J., Mendoza-Montoya, O., Carino-Escobar, R. I., Leyva-Martinez, I., Aguirre-Guemez, A. V., Barrera-Ortiz, A., Carrillo-Mora, P., Antelis, J. M.: Brain-computer interface controlled functional electrical stimulation: Evaluation with healthy subjects and spinal cord injury patients. *IEEE Access*, vol. 10, pp. 46834–46852 (2022) doi: 10.1109/access.2022.3170906
5. Johnson, C. O., Nguyen, M., Roth, G. A., Nichols, E., Alam, T., Abate, D., Abd-Allah, F., Abdelalim, A., Abraha, H. N., Abu-Rmeileh, N. M., Adebayo, O. M., Adeoye, A. M., Agarwal, G., Agrawal, S., Aichour, A. N., Aichour, I., Aichour, M. T. E., Alahdab, F., Ali, R., Alvis-Guzman, N., et al: Global, regional, and national burden of stroke, 1990–2016: A systematic analysis for the Global Burden of Disease Study 2016. *The Lancet Neurology*, vol. 18, no. 5, pp. 439–458 (2019) doi: 10.1016/s1474-4422(19)30034-1
6. Kai-Keng, A., Zhang-Yang, C., Haihong, Z., Cuntai, G.: Filter bank common spatial pattern (FBCSP) in brain-computer interface. In: *IEEE International Joint Conference on Neural Networks* (2008) doi: 10.1109/ijcnn.2008.4634130
7. Klein, T. J., Lewis, M. A.: A physical model of sensorimotor interactions during locomotion. *Journal of Neural Engineering*, vol. 9, no. 4, pp. 046011 (2012) doi: 10.1088/1741-2560/9/4/046011

8. Ojeda, L. D., Pabon, J. J., Antelis, J. M.: Classification of hand movements in motor execution and motor imagery tasks from EEG signals recorded with a low-cost recording system. In: *Memorias del Congreso Nacional de Ingeniería Biomédica*, vol. 1, no. 1, pp. 187–190 (2014)
9. Triana-Guzman, N., Orjuela-Cañon, A. D., Jutinico, A. L., Mendoza-Montoya, O., Antelis, J. M.: Decoding EEG rhythms offline and online during motor imagery for standing and sitting based on a brain-computer interface. *Frontiers in Neuroinformatics*, vol. 16 (2022) doi: 10.3389/fninf.2022.961089