



Nayid Triana Guzmán

**Sistema y método para la interpretación de la imaginación motora
de los movimientos de ponerse de pie y sentarse basado en interfaz
cerebro computadora**

Sistema y método para la interpretación de la imaginación motora de los movimientos de ponerse de pie y sentarse basado en interfaz cerebro computadora

Nayid Triana Guzmán

Documento presentado como requisito para optar por el título de Doctor en Ciencia Aplicada

Directores:

Codirector Temático: Álvaro David Orjuela Cañón y Andrés Leonardo Jutinico Alarcón

Codirector Metodológico: Edwin Alfredo Reyes Guzmán

Doctorado en Ciencia Aplicada
Universidad Antonio Nariño
Bogotá D.C.
2022

(Dedicatoria)

Doy gracias a Dios por haberme guiado en el camino y por haberme dado fuerza en los momentos difíciles. Dedico este trabajo a mis padres, cuyo amor, ejemplo y esfuerzo me han enseñado que las mejores cosas de la vida se consiguen con perseverancia, determinación y sacrificio. A mi prometida, que me ha acompañado en esta apasionante aventura, apoyándome y animándome a seguir mis sueños. A mis hermanos, por animarme a continuar con mis estudios de postgrado y sentirse orgullosos de mis logros, aunque yo estoy más orgulloso de que sean mi familia.

Esta tesis está dedicada a ellos.

Agradecimientos

Me gustaría expresar mi más profundo agradecimiento a mis codirectores temáticos el Dr. Álvaro David Orjuela Cañón y el Dr. Andrés Leonardo Jutinico Alarcón por todo su apoyo, por difundir mi curiosidad sobre el cerebro, la ciencia cognitiva y las interfaces cerebro-computadora que me permitió avanzar exitosamente en mi investigación. A mi codirector metodológico el Dr. Edwin Alfredo Reyes Guzmán por su mentoría, su diligencia y su acompañamiento en este proceso.

Estoy profundamente agradecido con mis amigos, compañeros y profesores del Doctorado en Ciencia Aplicada (DCA) y de la Facultad de Ingeniería Mecánica, Electrónica y Biomédica (FIMEB) de la Universidad Antonio Nariño, por apoyarme en mi formación. También quiero agradecer al Dr. Javier Mauricio Antelis Ortiz, al Dr. Omar Mendoza Montoya y a los colegas del laboratorio de Neurotecnología e Interfaces Cerebro-Computadora del Tecnológico de Monterrey campus Guadalajara, México, por su hospitalidad y amabilidad, siempre me hicieron sentir como en casa. A todo el equipo de la Vicerrectoría de Ciencia, Tecnología e Innovación - VCTI, de la Universidad Antonio Nariño, por aportar en mi crecimiento académico y de investigación.

Un agradecimiento especial a la Universidad Antonio Nariño y al Ministerio de Ciencia, Tecnología e Innovación de Colombia que a través de la “Convocatoria Doctorados Nacionales No. 785 de 2017” se financió mi beca de doctorado con proyecto 80740-594-2019, según lo establecido en el contrato No. 594 de 2019 con recursos provenientes de COLCIENCIAS, hoy MINCIENCIAS. Adicionalmente, quiero agradecer a la “Convocatoria nacional para fomentar la protección por patente y su uso comercial de adelantos tecnológicos en I+D+i que promuevan la potenciación económica del sector empresarial” iniciativa del Ministerio de Ciencia, Tecnología e Innovación, por la financiación para la radicación de la solicitud de patente de invención nacional NC2021/0012295 titulada “SISTEMA Y MÉTODO PARA LA INTERPRETACIÓN DE LA IMAGINACIÓN MOTORA DE LOS MOVIMIENTOS DE PONERSE DE PIE Y SENTARSE, BASADO EN INTERFAZ CEREBRO-COMPUTADORA” ante la Superintendencia de Industria y Comercio (SIC) de Colombia.

Resumen

Los sistemas de interfaz cerebro-computadora (ICC) basados en electroencefalografía (EEG) e imaginación motora (IM), han mostrado avances prometedores para la rehabilitación motriz de las extremidades inferiores. Sin embargo, en el estado del arte ha sido poco explorado sobre la IM del miembro inferior, especialmente se sabe poco acerca de la IM para la bipedestación y la sedestación. Por lo tanto, este trabajo presenta un sistema de ICC basado en EEG para la interpretación de la IM de estos tipos de movimientos. El propósito de este sistema es devolver cierta movilidad a personas con trastornos neuromusculares graves que no pueden imprimir la fuerza que se requiere para mover la interfaz física (ratón, teclado, joystick, micrófono, u otros periféricos) que usan dispositivos bipedestadores para realizar la transición de la posición sedente-bípeda.

En este proyecto se realizó un estudio con treinta y dos sujetos sanos que participaron utilizando el sistema de ICC propuesto con 17 electrodos de EEG activos. Para este estudio, fueron necesarias etapas de procesamiento digital de señales y de reconocimiento de patrones, donde se buscaba la eliminación de ruido y la decodificación de la señal de EEG para generar los comandos necesarios del sistema. Los mejores resultados se obtuvieron con una combinación del método del banco de filtros de patrones espaciales comunes (FBCSP) y la técnica del análisis discriminante lineal regularizado (RLDA) para decodificar los ritmos sensoriomotores (SMRs) de señal EEG en modo *offline* y *online*. En el análisis *offline* se encontró que la clasificación de las imágenes motoras versus el estado de reposo proporciona una exactitud global promedio del $88.51 \pm 1.43\%$ y del $85.29 \pm 1.83\%$ para las transiciones de sedente-bípedo y de bípedo-sedente, respectivamente. Las exactitudes globales promedio en los análisis *online* de sedente-bípedo y de bípedo-sedente fueron del $94.69 \pm 1.29\%$ y del $96.56 \pm 0.83\%$, respectivamente.

El resultado final es una ICC que analiza una tarea mental de IM realizada por el usuario para ponerse de pie o sentarse y la traduce en órdenes que podrían controlar dispositivos externos mediante señales cerebrales registradas con la técnica de EEG. Los resultados presentados en este documento demuestran que la interfaz propuesta es muy eficiente a la hora de comunicar las intenciones del usuario. Se demuestra que sujetos sin conocimientos previos de la tecnología de ICC pueden dominar la interfaz tras unos minutos de entrenamiento y alcanzar exactitudes del 100%. A partir de estos resultados, creemos que esta ICC puede ser útil para futuros sistemas de bipedestación controlados por el cerebro.

Palabras clave: interfaz cerebro-computadora (ICC), electroencefalografía (EEG), imaginación motora (IM), sentarse-pararse, procesamiento digital de señales, reconocimiento de patrones

Abstract

Brain-computer interface (BCI) systems based on electroencephalography (EEG) and motor imagery (MI) have shown promising advances for lower limb motor rehabilitation. However, little has been explored in the state of the art of lower limb MI, particularly little is known about MI for standing and sitting. Therefore, this work presents an EEG-based BCI system for MI interpretation of these types of movements. The purpose of this system is to restore some mobility to individuals with severe neuromuscular disorders who are unable to exert the force required to move the physical interface (mouse, keyboard, joystick, microphone, or other peripherals) used by standing devices to make the transition from seated to biped.

In this project, a study was conducted with thirty-two healthy subjects who participated using the proposed BCI system with 17 active EEG electrodes. For this study, digital signal processing and pattern recognition stages were necessary, where noise removal and decoding of the EEG signal were aimed to generate the necessary system commands. The best results were obtained with a combination of the filter bank common spatial pattern (FBCSP) method and the regularized linear discriminant analysis (RLDA) technique to decode the sensorimotor rhythms (SMRs) of the EEG in offline and online mode. In the offline analysis, the classification of motor imagery versus idle state provided a mean accuracy of $88.51 \pm 1.43\%$ and $85.29 \pm 1.83\%$ for the sit-to-stand and stand-to-sit transitions, respectively. The mean accuracies of the sit-to-stand and stand-to-sit online analyses were $94.69 \pm 1.29\%$ and $96.56 \pm 0.83\%$, respectively.

The final result is a BCI that analyzes a MI task performed by the user to stand or sit and translates it into commands to control external devices using brain signals recorded via EEG. The results presented in this thesis demonstrate that the proposed interface is very efficient in communicating the user's intentions. It is shown that subjects with no prior knowledge of BCI technology can master the interface after a few minutes of training and achieve accuracies of 100%. From these results, we believe that this BCI may be useful to future brain-controlled standing systems.

Keywords: brain-computer interface (BCI), electroencephalography (EEG), motor imagery (MI), sit-stand, digital signal processing, pattern recognition

Tabla de Contenido

Resumen.....	v
Abstract.....	vi
Lista de abreviaturas.....	viii
Lista de tablas.....	x
Lista de figuras.....	xi
Capítulo 1. Introducción.....	1
Capítulo 2. Marco teórico.....	4
Capítulo 3. Estado del arte y de la técnica.....	14
Capítulo 4. Problemática de I+D+i.....	33
Capítulo 5. Objetivos.....	37
Capítulo 6. Metodología.....	38
Capítulo 7. Resultados y Análisis.....	58
Capítulo 8. Producción.....	69
Capítulo 9. Conclusiones.....	72
Capítulo 10. Bibliografía.....	74
Capítulo 11. Anexos.....	88

Lista de abreviaturas

Abreviatura Término

<i>AAR</i>	adaptive autoregressive
<i>AIDA</i>	approximate information discriminant analysis
<i>ANC</i>	adaptive noise canceling
<i>ANN</i>	artificial neural network
<i>AO</i>	action observation
<i>AR</i>	autoregressive
<i>ASR</i>	artifact subspace reduction
<i>BCI</i>	brain-computer interface
<i>BMI</i>	brain-machine interface
<i>BP</i>	bereitschaftspotential
<i>CAR</i>	common average reference
<i>CCA</i>	canonical correlation analysis
<i>CPCA</i>	classwise principal component analysis
<i>CSP</i>	common spatial pattern
<i>CTeI</i>	ciencia, tecnología e innovación
<i>CWT</i>	continuous wavelet transform
<i>DWT</i>	discrete wavelet transform
<i>EEG</i>	electroencefalografía
<i>EOG</i>	electrooculogram
<i>ERD</i>	event-related desynchronization
<i>ERP</i>	event-related potential
<i>ERS</i>	event-related synchronization
<i>ERSP</i>	event-related spectral perturbation
<i>FBCSP</i>	filter bank common spatial pattern
<i>FFT</i>	fast Fourier transform
<i>FIR</i>	finite impulse response
<i>FN</i>	falso negativo
<i>FP</i>	falso positivo
<i>GND</i>	ground
<i>GUI</i>	graphical user interface
<i>I+D+i</i>	investigación, desarrollo e innovación
<i>ICA</i>	independent component analysis
<i>ICC</i>	interfaz cerebro-computadora
<i>ID</i>	identificación
<i>IIR</i>	infinite impulse response
<i>IM</i>	imaginación motora
<i>ITR</i>	information transfer rate
<i>KMI</i>	kinesthetic movement intention

Abreviatura Término

<i>LDA</i>	linear discriminant analysis
<i>LFDA</i>	local Fisher's discriminant analysis
<i>MCA</i>	morphological component analysis
<i>ME</i>	motor execution
<i>MI</i>	motor imagery
<i>MIBIF</i>	mutual information-based best individual feature
<i>MLP</i>	multilayer perceptron
<i>MMI</i>	mind machine interface
<i>MRCP</i>	movement-related cortical potential
<i>NCI</i>	neural control interface
<i>OA</i>	observación de la acción
<i>PSD</i>	power spectral density
<i>RBF</i>	radial basis function
<i>REF</i>	reference
<i>RLDA</i>	regularized linear discriminant analysis
<i>SIC</i>	superintendencia de industria y comercio
<i>SMR</i>	sensorimotor rhythm
<i>SSVEP</i>	steady-state visual evoked potential
<i>SVM</i>	support vector machine
<i>TF</i>	tiempo-frecuencia
<i>TFN</i>	tasa de falsos negativos
<i>TFP</i>	tasa de falsos positivos
<i>TVN</i>	tasa de verdaderos negativos
<i>TVP</i>	tasa de verdaderos positivos
<i>VEP</i>	visual evoked potential
<i>VN</i>	verdadero negativo
<i>VP</i>	verdadero positivo
<i>VPN</i>	valor predictivo negativo
<i>VPP</i>	valor predictivo positivo
<i>WoS</i>	web of science

Lista de tablas

Tabla 1. Búsqueda en patentes nacionales.....	20
Tabla 2. Búsqueda abierta.	21
Tabla 3. Búsqueda en patentes extranjeras.....	25
Tabla 4. Resultados de la búsqueda en patentes extranjeras.....	27
Tabla 5. Búsqueda en artículos científicos.....	28
Tabla 6. Resultados de la búsqueda en artículos científicos.....	29
Tabla 7. Comparación de las características de mayor rango de cada participante.	61
Tabla 8. Productos obtenidos durante el doctorado.	70
Tabla 9. Pasantía internacional.	70
Tabla 10. Participación en proyectos de investigación.	71

Lista de figuras

Figura 1. El cerebro humano.	4
Figura 2. Etapas de un sistema de interfaz cerebro-computadora (ICC).	6
Figura 3. Números de fuentes en Google Scholar por año (desde 2000 al 2017) con las palabras claves “BCI + rehabilitation” (en rojo), filtrando “upper limb” (en verde) y “lower limb” (en morado).	22
Figura 4. Análisis de acoplamiento bibliográfico basado en los países.	23
Figura 5. Documentos por año.	24
Figura 6. Porcentaje de estudios que proponen enfoques inspirados y no inspirados en el cerebro.	24
Figura 7. Ilustración del montaje experimental del sistema de ICC basado en EEG e IM.	40
Figura 8. Descripción de la secuencia temporal de un ensayo realizado por el participante en el experimento de sentado a parado (ARRIBA) y en el experimento de parado a sentado (ABAJO).	41
Figura 9. Artefactos típicos que contaminan las tomas de EEG.	43
Figura 10. Retroalimentación visual continua durante el experimento <i>online</i> bípedo-sedente.	54
Figura 11. Diagrama de flujo de la clasificación <i>online</i>	55
Figura 12. Mapas de tiempo-frecuencia y topografías espectrales de EEG: (a) MotorImageryA, (b) IdleStateA, (c) MotorImageryB, y (d) IdleStateB.	59
Figura 13. Exactitud de clasificación (a) MotorImageryA vs. IdleStateA y (b) MotorImageryB vs. IdleStateB.	60
Figura 14. Comparación de los métodos de clasificación <i>offline</i> de sedente-bípedo y bípedo-sedente.	63
Figura 15. Exactitudes de las clasificaciones <i>offline</i> estimadas con los modelos FBCSP-RLDA.	64
Figura 16. Matrices de confusión obtenidas en los escenarios de clasificación <i>offline</i> de sedente-bípedo (a) y de bípedo-sedente (b) para todos los participantes.	65
Figura 17. Distribuciones (%) de la sensibilidad, precisión, especificidad y valor predictivo negativo de todos los participantes, obtenidas en los experimentos <i>online</i> de sedente-bípedo y bípedo-sedente.	67
Figura 18. Distribuciones de las exactitudes (a), los tiempos de detección (b) y los valores de ITR (c) de los experimentos de ICC <i>online</i> para todos los participantes.	68

Capítulo 1. Introducción

Hoy en día, cada vez más personas en todo el mundo que sufren de problemas de movilidad están confinadas a permanecer la mayor parte del tiempo recostados o sentados, lo cual conduce a una amplia gama de comorbilidades tales como trastornos metabólicos, enfermedades cardíacas, osteoporosis y úlceras por presión (Do *et al.*, 2013). En Colombia, una de las problemáticas presentes es el aumento de personas que sufren de parálisis o ausencia de miembros superiores e inferiores que requieren acceso a tecnologías de asistencia que les permitan ponerse de pie y sentarse (DANE - UNFPA Colombia, 2022). Para resolver este problema, esfuerzos tecnológicos, como las sillas de ruedas bipedestables y otros aparatos bipedestadores, han sido generados con el fin de devolver a la persona a la posición bípeda. Sin embargo, en algunos casos no es posible que personas con deficiencias neuromusculares severas puedan operar dichas tecnologías porque deben ser accionadas por movimientos físicos del usuario (Leaman & La, 2017). En este sentido, una de las posibles soluciones a estas limitantes son los sistemas de interfaz cerebro-computadora (ICC), los cuales han permitido que personas en circunstancia de discapacidad puedan ejercer funciones cerebrales para comunicarse e interactuar con los dispositivos que los rodean (Wolpaw *et al.*, 2020).

Un sistema de ICC monitoriza la actividad fisiológica del cerebro (señales eléctricas, oxigenación sanguínea, campos magnéticos, etc.) y la traduce en datos que puedan ser interpretados por una máquina para una aplicación de destino. La electroencefalografía (EEG), la cual es una técnica no invasiva que mide los potenciales eléctricos sobre el cuero cabelludo, es la modalidad de registro de la actividad eléctrica cerebral más utilizada en los sistemas de ICC debido a que ofrece una calidad de señal aceptable con una alta resolución temporal, es portátil, de bajo costo y los equipos son fáciles de usar (Sanei & Chambers, 2007). Los sistemas de ICC basados en EEG se han desarrollado durante más de 20 años y la elección del paradigma de ICC depende de la aplicación (Lotte, Nam, *et al.*, 2018). Entre las posibles estrategias reportadas en la literatura, los paradigmas de ICC no invasivos más exitosos se basan en tres enfoques principales: la respuesta evocada (como el P300), el potencial evocado visual y la imaginación motora (IM) (M. H. Lee *et al.*, 2019).

Sin embargo, a pesar de los esfuerzos de los últimos años por desarrollar sistemas de ICC confiables y robustos, las aplicaciones controladas por IM de los movimientos del miembro inferior aún se encuentran en una fase muy temprana y las investigaciones son relativamente escasas (Asanza *et al.*, 2022; Bobrova *et al.*, 2020). Muchos de los estudios de ICC basados en EEG e IM

para miembro inferior solo se han probado en configuraciones *offline* debido a la complejidad de los movimientos y a las configuraciones experimentales que producen señales de EEG poco realistas en comparación con las configuraciones experimentales *online* (Rodríguez-Ugarte *et al.*, 2017). Solo se ha realizado un pequeño número de estudios sobre los comportamientos de ponerse de pie y sentarse en modo *offline* (Bulea *et al.*, 2014; Chaisaen *et al.*, 2020; B. Singh & Natsume, 2022; Z. Zhou *et al.*, 2007). Por lo tanto, en este trabajo se propuso un nuevo paradigma de ICC basado en EEG para decodificar la información de IM *offline* y *online* para estos tipos de movimientos.

En las últimas décadas, se ha desarrollado una gran variedad de métodos para decodificar las tareas de IM a partir de las señales de EEG con el fin de mejorar el rendimiento de los sistemas de ICC (George *et al.*, 2022; A. Singh *et al.*, 2021). Estos métodos incluyen técnicas de extracción de características que utilizan representaciones temporales (Hamedi *et al.*, 2014; Kee *et al.*, 2017; Rodríguez-Bermúdez & García-Laencina, 2012; Samuel *et al.*, 2017), espectrales (Al-Fahoum & Al-Fraihat, 2014; Oikonomou *et al.*, 2017) y de tiempo-frecuencia (Aggarwal & Chugh, 2019; Z. Gao *et al.*, 2018; Kevric & Subasi, 2017; Ortiz *et al.*, 2020; Padfield *et al.*, 2019). No obstante, la utilidad de las técnicas de filtrado espacial en las aplicaciones de ICC ha sido explorada desde hace algunos años, como una forma de seleccionar las características más discriminativas en los registros de EEG para las tareas de IM, así como para reducir la enorme dimensionalidad que pueden representar los espacios de características (Ang *et al.*, 2012; Congedo *et al.*, 2017; Lotte, Bougrain, *et al.*, 2018; Rejer & Górski, 2018). En este sentido, se ha demostrado que el filtrado de patrón espacial común (CSP, por sus siglas en inglés, *common spatial pattern*) extrae la información discriminativa de forma más eficaz que otros filtros espaciales como el bipolar, el laplaciano o la referencia media común, así como las técnicas no supervisadas como el análisis de componentes independientes (H. He & Wu, 2018; Naeem *et al.*, 2009; Ortner *et al.*, 2015). Aunque existen estudios referentes al filtrado CSP y se aplicaron con éxito (Chaisaen *et al.*, 2020), en esta investigación se cubre un vacío en la literatura existente con relación a la decodificación *online* de los ritmos cerebrales de las señales de EEG durante las tareas de IM de ponerse de pie y sentarse.

Los estudios anteriores a este trabajo se han centrado en la decodificación de las señales de EEG de IM de la mano izquierda y de la mano derecha (que representaban sentarse y pararse) (Noda *et al.*, 2012; C. Wang *et al.*, 2018), IM de caminar para ponerse de pie y de las extremidades superiores para sentarse (Choi *et al.*, 2020), o potenciales evocados visuales (en las que las luces parpadeantes correspondían a la orden de ponerse de pie y sentarse) (Kwak *et al.*, 2017). Estos paradigmas de ICC han demostrado ser eficaces para transferir información del cerebro a una

máquina. Sin embargo, estas investigaciones no tratan la IM para ponerse de pie y sentarse de una forma más natural, sino que utilizan la IM del miembro superior, la marcha o potenciales evocados que son principios de ICC básicos en la decodificación de los ritmos cerebrales de las señales de EEG. Por lo tanto, para actuar como sistemas de ICC en las transiciones de sentado a parado y de parado a sentado requieren muchos más recursos cognitivos. Esto, además de ser un inconveniente para la práctica de la ICC, es relevante y uno de los retos actuales en el campo de ICC (M. Xu *et al.*, 2021). Por estas razones, teniendo en cuenta las aplicaciones de la IM de las extremidades inferiores y la necesidad de utilizar una ICC para estos movimientos que en el estado del arte han sido poco explorados, en este trabajo se establece un análisis de rendimiento *offline* y *online* de un sistema de ICC basado en EEG para la interpretación de la IM de dichos movimientos de manera más natural.


En el presente trabajo, se investigó si las personas podían controlar una ICC basada en EEG durante la IM para ponerse de pie y sentarse. Para ello, se exploraron dos escenarios diferentes de clasificación binaria en configuraciones *offline* y *online*. El objetivo del modo *offline* era obtener conjuntos de datos de entrenamiento individuales por cada participante en los experimentos *offline* para ajustar y evaluar los modelos de aprendizaje automático de la ICC (un modelo de sentado a parado y otro de parado a sentado para cada participante). Después de entrenar los modelos de la interfaz, el modo *online* tenía como objetivo medir la velocidad y la exactitud de la ICC para decodificar los ritmos cerebrales de las señales de EEG en tiempo real durante las tareas de IM para ponerse de pie y sentarse. Una de las mayores contribuciones del trabajo, es dicha ICC basada en EEG que permite reconocer tareas de IM *online* para ponerse de pie y sentarse, lo cual es crucial en la implementación de tecnologías de bipedestación controladas por el cerebro. Se utilizó el método de CSP con un banco de filtros espectrales para la extracción de características basadas en la modulación de la onda Theta (4-8 Hz) y el ritmo sensoriomotor que incluye dos bandas en el espectro: Alfa (8-12 Hz) y Beta (12-30 Hz), las cuales se asocian con las tareas relacionadas con el movimiento en la ejecución de la actividad física, la planificación motora, la intención de moverse y la imaginación de movimiento (Yuan & He, 2014). Para que la clasificación fuera lo más rápida y sencilla posible, se utilizó la versión regularizada del enfoque de análisis discriminante lineal.

Capítulo 2. Marco teórico

El cerebro es el órgano central del sistema nervioso humano (ver Figura 1). La superficie del cerebro se llama corteza cerebral y se divide en cuatro lóbulos: el lóbulo frontal, el lóbulo temporal, el lóbulo parietal y el lóbulo occipital. Estos lóbulos están asociados a diferentes tipos de actividades específicas, como la visión, el movimiento, la comprensión del lenguaje y la atención. Los lóbulos frontales son responsables del movimiento voluntario, la expresión y las funciones ejecutivas como la planificación, la coordinación, la organización, el monitoreo y el control. Es donde se asienta la personalidad de una persona. El lóbulo temporal se encarga de realizar las funciones auditivas, la comprensión del lenguaje y del habla. El lóbulo parietal es responsable de procesar información del sistema somatosensorial, a través de neuronas sensoriales primarias localizadas en la piel y otros tejidos del cuerpo. Éste presenta funciones motoras finas del cuerpo como la escritura y el equilibrio. Por último, el lóbulo occipital está relacionado con el procesamiento visual (Moreno Arévalo, 2021).

Figura 1.

El cerebro humano.



Nota: Tomado de (Moreno Arévalo, 2021).

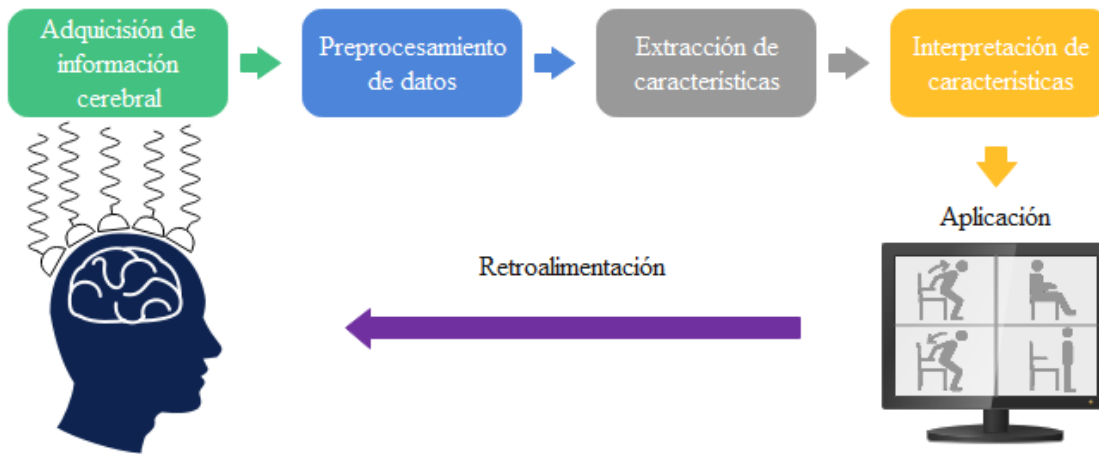
El comportamiento complejo, dinámico y voluntario de ponerse de pie y sentarse es una de las actividades más comunes de la vida diaria (B. Singh & Natsume, 2022). En el comportamiento intervienen los movimientos del segmento superior e inferior del cuerpo. Para realizar dichas acciones el cerebro humano debe producir una activación muscular en una secuencia precisa para generar los movimientos con éxito (Bhardwaj *et al.*, 2019; Schenkman *et al.*, 1990). Por lo tanto, los

procesos neuronales responsables de la generación y el control del movimiento se consideran como una de las funciones cerebrales cognitivas más relevantes ya que su correcto funcionamiento es crítico para la interacción entre el cerebro y los músculos (Leisman *et al.*, 2016; Schwartz, 2016). Si la comunicación entre el cerebro y el cuerpo se ve afectada por un deterioro del canal de comunicación neuromuscular debido a un trastorno neurológico funcional motor como el accidente cerebro vascular, la esclerosis lateral amiotrófica y la lesión medular, el individuo puede sufrir una pérdida parcial o total del control muscular normal. Dependiendo de la progresión y la complejidad del trastorno neurológico, estas pérdidas pueden expresarse en la falta de capacidad para ejecutar movimientos musculares voluntarios (Hanes & Schall, 1996; Schwartz, 2016; Svoboda & Li, 2018). Lo anterior, además de generar problemas emocionales y económicos de total dependencia a las personas afectadas por una discapacidad motora, también conlleva a que enfrenten una drástica reducción de la calidad de vida y de la interacción social (Krishnan *et al.*, 2001; Middleton *et al.*, 2007; Munce *et al.*, 2013).

Desde hace varios años, se viene explorando la utilidad de la tecnología de interfaz cerebro-computadora (ICC) como alternativa para abordar las limitaciones de estas deficiencias motoras. La ICC es un sistema artificial que integra hardware y software, el cual evita las vías eferentes normales del cuerpo proporcionando un canal de comunicación directo y no muscular entre el cerebro y dispositivos externos (Nicolas-Alonso & Gomez-Gil, 2012; Wolpaw *et al.*, 2020). Por lo tanto, la ICC puede ayudar a mejorar la calidad de vida de los pacientes con discapacidades motoras al proporcionarles tecnologías médicas de asistencia más independientes y autónomas, y ofrece un nuevo enfoque de investigación para el estudio de la funcionalidad del cerebro. Esta tecnología emergente ha despertado el interés por el desarrollo no sólo de aplicaciones de rehabilitación y recuperación motora, sino también de aplicaciones no biomédicas como el entretenimiento, la comunicación y el control remoto de dispositivos del entorno.

La idea principal de un sistema de ICC es medir e interpretar la actividad cerebral relacionada con la intención del usuario, que se transmite como señales de comandos hacia el control de actuadores para la operación de dispositivos externos. En la Figura 2 se muestra el diseño de una ICC que se ha desarrollado para aplicaciones de comunicación y control, en donde es posible identificar etapas secuenciales como se describen a continuación:

Figura 2.

Etapas de un sistema de interfaz cerebro-computadora (ICC).

Nota: Fuente propia.

- Adquisición de información cerebral. En la primera etapa, los sistemas de ICC adquieren datos de la actividad cerebral como señales eléctricas, ondas magnéticas o flujos sanguíneos, principalmente. Por lo tanto, se puede utilizar una gran variedad de técnicas para medir esta actividad. Las técnicas de adquisición de dicha información más comunes que se emplean son la resonancia magnética funcional, que mide los cambios en los niveles de oxigenación en el cerebro dependiendo de los estados diamagnéticos y paramagnéticos de la hemoglobina cuando hay mayor actividad neuronal (Sitaram *et al.*, 2007), la espectroscopia funcional de infrarrojos cercanos, que monitoriza los cambios en el flujo sanguíneo del cerebro asociados a la actividad neuronal (Naseer & Hong, 2015), la magnetoencefalografía, que registra los campos magnéticos producidos por el cerebro (Mellinger *et al.*, 2007), la electrocorticografía que registra los cambios eléctricos en la corteza cerebral con sensores invasivos (Miller *et al.*, 2020) y la técnica de electroencefalografía que registra la actividad eléctrica sobre el cuero cabelludo con electrodos no invasivos (McFarland & Wolpaw, 2017).
- Preprocesamientos de datos. En el sistema de ICC propuesto, esta etapa se encarga de mejorar la relación señal-ruido de las señales de EEG para su posterior procesamiento. El objetivo de esta etapa es reducir la información no relevante incluida en las señales cerebrales. Estos datos irrelevantes se producen porque las señales cerebrales son susceptibles a diferentes fuentes de ruido (por ejemplo, señales electromiográficas y electrocardiográficas, fluctuaciones de la línea eléctrica, etc.) (Bansal & Mahajan, 2019).

- Extracción de características. La etapa de extracción de características obtiene información discriminadora de las señales preprocesadas. Dicha información puede ser una característica en particular como la amplitud y frecuencia en las señales de EEG. La extracción de características es el proceso de identificar las características relevantes y transformarlas en una información significativa que pueda ser interpretada por el sistema de ICC (Torres-García *et al.*, 2022).
- Interpretación de las características extraídas. En esta etapa, un modelo de clasificación o aprendizaje automático evalúa las características y devuelve etiquetas que representan la intención del usuario, o valores numéricos que indican la fuerza de los fenómenos medidos. En la interpretación de las características, las características generadas en la etapa anterior se discriminan, se clasifican según la intención del usuario y se transforman en comandos para una aplicación (Vega *et al.*, 2016). Los resultados de la interpretación de características se utilizan como mensajes o señales de control que se envían a una aplicación.
- Aplicación. En la etapa final, la interfaz transforma las etiquetas e índices obtenidos en una señal que se envía a una pantalla para proporcionar información directa al usuario en función de los resultados obtenidos. Aquí, dispositivos externos se pueden controlar con los resultados obtenidos del modelo de clasificación, por lo que se puede establecer la comunicación entre la interfaz y dispositivos periféricos. Existen diversas aplicaciones tales como sillas de ruedas, prótesis, exoesqueletos, interfaces de comunicación, etc., en las cuales se podría utilizar la ICC (Abdulkader *et al.*, 2015).

Finalmente, la acción ejecutada por la aplicación sirve como retroalimentación al usuario para saber si la intención ha sido correctamente interpretada por el sistema de ICC o no ha sido detectada verdaderamente.

Mediante la técnica de EEG, la actividad cerebral puede observarse a diferentes frecuencias. Se sabe que estas frecuencias específicas están correlacionadas con determinados estados mentales y lóbulos del cerebro. Las ondas cerebrales más conocidas son las siguientes (Moffett *et al.*, 2017):

- Delta, δ (< 4 Hz); Se asocia sobre todo a las señales con forma de onda lenta y alta amplitud (alrededor de $100 \mu\text{V}$), la cual es mayormente dominante durante el sueño profundo. Debido a su baja frecuencia esta puede ser confundida con frecuencias causadas por el movimiento de los músculos, el cuello o la quijada (Moreno Arévalo, 2021).

- Theta, θ (4-8 Hz); Se relaciona con la memoria cuando se realizan tareas que demandan mucha memoria de trabajo. También son predominantes en un estado de meditación profundo y su amplitud oscila entre 50 y 100 μV (Klimesch, 2018).
- Alfa, α (8-12 Hz); Suele presentarse en el lóbulo occipital y parietal del cerebro, y su amplitud se encuentra entre 30 y 60 μV . Su desincronización está asociada a la supresión de objetos no relevantes durante una tarea de atención, un estado de relajación o un elevado estado de alerta. Su sincronización se observa sobre todo al cerrar los ojos (Niedermeyer & Silva, 2005).
- Beta, β (12-30 Hz); Se detecta en un estado de concentración, conciencia y vigilia con una amplitud entre los 10 y 30 μV . Las ondas Beta Altas en frecuencia se generan principalmente en la región frontal y central del cerebro, donde están más afectadas por los movimientos de las extremidades y actividades musculares (Tzagarakis *et al.*, 2010).
- Gamma, γ (> 30 Hz); Está vinculada a la actividad cognitiva y motora y se ha relacionado con diferentes actividades cerebrales intensas como el cálculo cortical y el aprendizaje asociativo. Su amplitud es muy pequeña, alrededor de los 10 μV (Moungiakmas & Papakostas, 2022).

Un factor fundamental para el funcionamiento de un sistema de ICC es el tipo de intención del usuario que la ICC interpreta como información significativa (Abiri *et al.*, 2019). Las tareas mentales que el usuario realiza de forma voluntaria deben modular los cambios en la actividad cerebral. Estas tareas se dividen en dos grandes categorías: en la primera categoría se encuentran las tareas mentales evocadas, que requieren que el usuario centre su atención en un conjunto de estímulos sensoriales externos presentados de manera visual, auditiva, táctil, etc., lo que desencadena una respuesta específica y automática en la actividad cerebral, como los potenciales evocados P300 y los potenciales evocados visuales de estado estacionario; y, en la segunda categoría están las tareas mentales inducidas (o autogeneradas), en las que el usuario realiza una tarea mental que no depende de un estímulo externo.

Los cambios en la actividad cerebral modulados por estos tipos de tareas mentales, el sistema ICC los asocia con una orden o acción a ejecutar. Un ejemplo de una tarea mental inducida por el usuario es el paradigma de imaginación motora (IM) (Luis G. Hernandez-Rojas *et al.*, 2022). En este paradigma, el usuario simula o emula mentalmente un movimiento (imaginando el movimiento), tratando de reproducir la experiencia cinestésica que eventualmente pueda inducir la modulación deseada sin la necesidad de moverse. Esto induce cambios de potencia en las bandas de

frecuencia de las señales de EEG obtenidas principalmente de la corteza cerebral sensoriomotora (Luis Guillermo Hernandez-Rojas *et al.*, 2020). Después de que el usuario realiza la estrategia de IM, el sistema de ICC utiliza estos cambios de potencia como características discriminatorias sobre la imaginación de movimiento. Luego, la ICC aplica un modelo de clasificación para reconocer el movimiento imaginado frente a otros estados mentales (por ejemplo, imaginación de movimiento frente a no movimiento). Por último, los resultados del clasificador se utilizan como órdenes para activar un dispositivo.

Otro factor importante para el desarrollo de los sistemas de ICC es identificar cuándo el usuario realiza la tarea mental. Para esto existen dos tipos de protocolos de ICC: el síncrono, en el que el usuario interactúa con el sistema durante ventanas de tiempo específicas, y el asíncrono, en el que el usuario puede interactuar con el sistema en cualquier momento sin necesidad de esperar una ventana de tiempo específica (Nooh *et al.*, 2011). En el protocolo síncrono, el sistema guía al usuario en la tarea mental que debe realizar a través de instrucciones (indicaciones auditivas, visuales o táctiles). La ventaja del protocolo síncrono en los sistemas de ICC es que especifican el momento para la realización de la tarea mental en periodos de tiempo conocidos lo que facilita la detección de la intención del usuario. Sin embargo, esto reduce la interacción continua entre el usuario y el sistema. En el protocolo asíncrono, los sistemas de ICC independientemente procesan y decodifican de forma continua las tareas mentales, una tras otra, que el usuario puede estar realizando sin esperar hasta que se complete (el usuario no está necesariamente guiado por una indicación previa). La ventaja de esta estrategia es que proporciona una interacción más natural entre el usuario y el sistema (el usuario decide la tarea mental sin esperar una instrucción previa a realizarla y el sistema de ICC debe poder identificarla). Sin embargo, esta estrategia tiene la desventaja de que el procesamiento y la decodificación de la intención del usuario se vuelven más complejos en comparación con el protocolo síncrono. Todas estas configuraciones, estrategias y características deben tenerse en cuenta para el desarrollo de un sistema de ICC óptimo que, según su finalidad, pueda mejorar la interacción entre el usuario y la interfaz.

Los sistemas de ICC basados en IM se han desarrollado principalmente para la restauración de la función motora, la rehabilitación neuromotora y las aplicaciones no médicas. En la restauración de la función motora, los sistemas de ICC permiten establecer una comunicación directa entre el cerebro y sillas de ruedas eléctricas, brazos robóticos protésicos o dispositivos ortopédicos, con el fin de ofrecer una tecnología de asistencia para la ejecución de movimientos perdidos total o parcialmente (J. Zhang & Wang, 2021). Por ejemplo, una prótesis robótica de mano

puede ser controlada a través de una ICC para ejecutar los movimientos de agarre de la mano paralizada (Ajiboye *et al.*, 2017; Hochberg *et al.*, 2012). Otra aplicación típica de los sistemas de ICC en la restauración de funciones motoras son los exoesqueletos robóticos para los movimientos del miembro inferior (Choi *et al.*, 2020; C. Wang *et al.*, 2018).

En el campo de la rehabilitación motora, desde hace varios años se ha explorado la utilidad de la ICC como una tecnología emergente para la neurorrehabilitación que podría facilitar al usuario la recuperación de las funciones perdidas, al promover la utilización de áreas cerebrales relacionadas con las áreas afectadas por la discapacidad motora y al servir como herramienta de entrenamiento para inducir la plasticidad cerebral (Daly & Wolpaw, 2008; Edwardson *et al.*, 2013; Ramos-Murguialday *et al.*, 2012). La ICC tiene especial importancia en el ámbito de la neurorrehabilitación, teniendo en cuenta que evidencia científica demuestra que la recuperación funcional mejora con la participación activa por parte de la persona en el proceso terapéutico (Joa *et al.*, 2012). Normalmente, las principales aplicaciones están relacionadas con programas de rehabilitación guiados por una ICC con un sistema robótico o con realidad aumentada (Cho *et al.*, 2018; Mane *et al.*, 2020; Si-Mohammed *et al.*, 2020). Además de facilitar la ganancia de plasticidad cerebral, otros resultados notables de estos sistemas de ICC son aumentar el compromiso del usuario en la terapia de rehabilitación, por lo que los usuarios experimentan un mayor control (cognitivo y físico) de los ejercicios terapéuticos (Sebastián-Romagosa *et al.*, 2020, 2021). Las aplicaciones de los sistemas de ICC para la rehabilitación motora incluyen el control de dispositivos ortopédicos para la terapia de la isquemia (Cervera *et al.*, 2018), la inmersión en sistemas de realidad aumentada (Vourvopoulos *et al.*, 2019), y la realización de terapias asistidas con robots (Norman *et al.*, 2016).

De otro lado, existen estudios que han destacado la importancia de la ICC basada en EEG para aplicaciones no médicas. El objetivo principal de estos sistemas de ICC es mejorar la interacción humano-máquina. Esto permite optimizar el desempeño humano para conseguir otros tipos de habilidades potencialmente novedosas (Blankertz *et al.*, 2010). Las principales aplicaciones de estos sistemas son los videojuegos (Ahn *et al.*, 2014; de Castro-Cros *et al.*, 2020; Kerous *et al.*, 2018), la comunicación y el control a distancia entre el humano y dispositivos del entorno (Guger *et al.*, 2019; Kosmyna *et al.*, 2016; LaFleur *et al.*, 2013; Lu & Bi, 2021), la medición de la atención (Škola *et al.*, 2019), la carga de trabajo (Kohlmorgen *et al.*, 2007; Tremmel *et al.*, 2019) y los estados mentales como la fatiga (Müller *et al.*, 2008; Zammouri *et al.*, 2018) y las emociones (Iacoviello *et al.*, 2015; Torres *et al.*, 2020) en las actividades diarias.

Independientemente de que la finalidad de la ICC sea para la restauración de la función motora, la rehabilitación (o recuperación) motora, o el uso en dispositivos no médicos, las configuraciones de los sistemas de ICC convencionales basados en EEG e IM tienen principalmente los siguientes componentes:

- La electroencefalografía (EEG) que es la técnica de medición de las tareas mentales más frecuentemente utilizada en los sistemas de ICC (Aggarwal & Chugh, 2022; Vaid *et al.*, 2015).
- Una fase de preprocesamiento que se requiere para mejorar la calidad de la señal de EEG, especialmente durante los experimentos *online* o *closed-loop* (Minguillon *et al.*, 2017).
- La información neuronal que está relacionada con el movimiento se adquiere generalmente en las señales cerebrales capturadas en las bandas de frecuencia de 8 a 12 Hz (ritmo cerebral Alfa) y de 13 a 30 Hz (ritmo cerebral Beta) (Feng *et al.*, 2019; Ramos-Murguialday & Birbaumer, 2015).
- Las técnicas de extracción de características que más se utilizan en el dominio del tiempo, frecuencia, tiempo-frecuencia y espacio, buscan caracterizar y poder tener una representación de movimiento o su intencionalidad generalmente de personas sanas (Lotte, Bougrain, *et al.*, 2018; Rashid *et al.*, 2020; A. Singh *et al.*, 2021).
- Para entrenar los modelos de clasificación, los métodos clásicos de aprendizaje automático supervisado que son los más utilizados para clasificaciones binarias (Aggarwal & Chugh, 2022; Arpaia *et al.*, 2022; George *et al.*, 2022).
- El principio de imaginación motora (IM) de los sistemas de ICC para diferentes movimientos corporales que se basa en la modulación de los ritmos sensoriomotores, la cual no es una tarea fácil de realizar. Sin embargo, es la estrategia que se realiza de forma más natural para identificar diferentes tareas mentales (George *et al.*, 2021; Neuper *et al.*, 2005).
- El protocolo síncrono en una ICC basada en EEG e IM, el cual es el que más se aplica en este tipo de sistemas tanto sin retroalimentación en modo *offline* como con retroalimentación en modo *online* (Tsui & Gan, 2007; Yadav *et al.*, 2020).
- La retroalimentación que tiene un gran impacto en el mejoramiento del funcionamiento del sistema (Fleury *et al.*, 2020).

Desafortunadamente, una ICC basada en EEG sólo puede interpretar con éxito unas pocas tareas de imaginación motora (IM). La imaginación de movimientos de brazos, piernas y lengua son las tareas de IM más comunes en este tipo de sistemas (Morash *et al.*, 2008). Para decodificar más de dos clases de tareas de IM se necesitan equipos de EEG con una alta densidad de electrodos, lo que aumenta la complejidad de la ICC y las etapas de procesamiento (Yi *et al.*, 2013).

Uno de los aspectos más importantes en el funcionamiento de los sistemas de ICC se encuentra en los métodos de procesamiento de señales de EEG y en cada etapa que lo componen, es decir, preprocesamiento, extracción de características, selección efectiva de características y clasificación (Wierzgała *et al.*, 2018). De este modo, una gran variedad de métodos en procesamiento digital de señales, han sido aplicados para decodificar la información presente en la corteza cerebral durante actividades cognitivas y musculares, entre las cuales se destacan el uso de análisis de componentes independientes (B. Zhou *et al.*, 2019), patrones espaciales comunes (R. Xu *et al.*, 2017) y transformada wavelet (Sadiq *et al.*, 2019). Así mismo, la investigación en la caracterización de EEG ha incluido determinar cuáles son las sub-bandas de EEG que proveen la mayor cantidad de información útil para aplicaciones de ICC (P. Xu *et al.*, 2014), en donde el propósito principal es la inclusión de tecnologías basadas en aprendizaje de máquina para la decodificación o predicción de algún tipo de actividad cognitiva o motora (movimiento muscular, emociones, sentimientos, etc.) codificada en las ondas cerebrales en ambientes de ICC en tiempo real.

A pesar del éxito de los sistemas de ICC para el control del movimiento, en los últimos años las principales características utilizadas para estos sistemas ofrecen una solución limitada que restringe su usabilidad en situaciones reales y en actividades de la vida diaria. Por ejemplo, la forma convencional de clasificar estas señales de EEG es emplear clasificadores supervisados clásicos como el análisis discriminante lineal (LDA, por sus siglas en inglés, *linear discriminant analysis*), las máquinas de soporte vectorial (SVMs, por sus siglas en inglés, *support vector machines*) y sus derivaciones (Vega *et al.*, 2016). Esto ha proporcionado resultados satisfactorios en entornos de laboratorio. Sin embargo, los sistemas de ICC basados en EEG requieren dar un paso adelante hacia aplicaciones en actividades reales de la vida diaria. Por lo tanto, se requieren algoritmos más complejos para maximizar la exactitud de la decodificación. En consecuencia, es necesario explorar nuevos modelos de clasificación como los basados en el aprendizaje profundo. Potencialmente, esto podría mejorar la robustez y el desempeño de estos sistemas.

Una de las contribuciones que más se destacan en los últimos años en el uso de los sistemas de ICC basados en imaginación motora (IM) es en el tema de retroalimentación neuronal (conocido como *neurofeedback* en inglés), que tiene por objeto el enseñar a modificar selectivamente determinados parámetros de la actividad cerebral (Omejc *et al.*, 2018). El método, todavía en fase de experimentación, se propone llegar a influir positivamente en la conducta y en funciones cognitivas como la atención (Sitaram *et al.*, 2017). El entrenamiento del usuario suele consistir en un protocolo de *neurofeedback* en el que se pide al sujeto que realice una determinada tarea de IM (por ejemplo, movimientos imaginarios de una extremidad) (Neuper & Pfurtscheller, 2009). El sistema de ICC proporciona información en tiempo real sobre el desempeño del usuario al comparar los ritmos sensoriomotores con respecto a una actividad de referencia que representa la ausencia de movimientos imaginarios (estado de reposo). La retroalimentación puede ser auditiva o visual, y a veces complejas visualizaciones de la actividad cerebral para incentivar al usuario a producir las modulaciones deseadas (Hwang *et al.*, 2009). Por tanto, lo que se busca con estos sistemas no solo es restaurar o fortalecer la funcionalidad motora de algunos músculos esqueléticos, sino también buscar la plasticidad cerebral, así que un sistema de ICC basado en EEG e IM se convierte en una tecnología física o virtual controlada por el usuario, donde este último controla el proceso de mejora.

Capítulo 3. Estado del arte y de la técnica

Teniendo en cuenta el diseño y funcionamiento de un sistema de interfaz cerebro-computadora (ver Figura 2), a continuación, se presentan los diferentes resultados divulgados e identificados en el estado del arte y de la técnica a través de documentos de artículos académicos, científicos, patentes nacionales, extranjeras y búsqueda tecnológica y comercial abierta.

3.1. Análisis electroencefalográfico durante imaginación motora

En los últimos años, la investigación ha progresado considerablemente en el análisis electroencefalográfico de las actividades cerebrales con el fin de estudiar la capacidad fundamental de las neuronas de trabajar en sincronía para generar actividad oscilatoria durante la imaginación motora (IM). Dicha actividad rítmica registrada en el córtex sensoriomotor se denomina ritmo sensoriomotor (SMR). El ritmo SMR incluye la onda Alfa, normalmente con una frecuencia de 10 Hz (rango de 8-12 Hz), a menudo mezclado con un ritmo Beta (alrededor de 20 Hz), y un componente Gamma (alrededor de 40 Hz) que se registra en lados opuestos de la corteza sensoriomotora, más preferentemente sobre C3 y C4 (Kübler & Mattia, 2016).

Por medio del ritmo sensoriomotor (SMR), (Z. Zhou *et al.*, 2007) demostraron que es posible decodificar el intento de levantarse a partir de los cambios de las señales de EEG en la onda Mu (alrededor de 10 Hz) y en la onda Beta (alrededor de 20 Hz). El estudio informa sobre los fenómenos conocidos como desincronización / sincronización relacionada con eventos (ERD / ERS) en las bandas de frecuencias de las ondas Mu y Beta, es decir, una disminución y un aumento de las amplitudes espectrales de los ritmos Mu y Beta (Gert Pfurtscheller & Neuper, 1997). Los resultados mostraron una ERD significativa en el ritmo Mu central con patrones de ERS en el ritmo Beta durante la bipedestación imaginaria en participantes sanos.

Mientras que (Z. Zhou *et al.*, 2007) demostraron que la ERD tiene la capacidad de categorizar tareas gruesas de las extremidades inferiores, incluida la identificación de la bipedestación imaginaria, (Bulea *et al.*, 2014) investigaron la capacidad de decodificar la intención de movimiento a partir del ritmo Delta (0.1-4 Hz) de la EEG registrada inmediatamente antes de la ejecución del movimiento en voluntarios sanos. (Bulea *et al.*, 2014) descubrieron que las bajas

frecuencias de la señal de EEG, en particular el potencial cortical relacionado con el movimiento (MRCP), contienen información relativa al movimiento de las extremidades inferiores y al control del equilibrio. Utilizando las frecuencias de la onda Delta (0.1-4 Hz) de la señal de EEG adquirida mientras los sujetos pasaban de estar sentados a una postura de pie, pudieron clasificar la intención de movimiento (es decir, si el sujeto iba a ponerse de pie, sentarse o permanecer en reposo). En general, este estudio sugiere que la EEG en la banda de frecuencia de la onda Delta registrada inmediatamente antes del movimiento contiene información discriminatoria sobre el tipo de movimiento.

De acuerdo con (Bulea *et al.*, 2014; Z. Zhou *et al.*, 2007), la ERD/ERS y la MRCP desempeñan un papel importante en una interfaz cerebro-computadora (ICC) para la rehabilitación de las extremidades inferiores, especialmente en la bipedestación y la sedestación. Sin embargo, se sabe poco sobre las diferencias en la activación cortical entre la bipedestación y la sedestación. Por lo tanto, (Chaisaen *et al.*, 2020; Choi *et al.*, 2020; B. Singh & Natsume, 2022; Triana-Guzman *et al.*, 2022) han demostrado la utilidad de las señales de EEG como enfoque integral para comprender cómo el cerebro actúa en el comportamiento de pasar de estar sentado a estar de pie y viceversa. Todos estos estudios confirman que la tarea de imaginación motora (IM) genera ritmos cerebrales en la EEG para la bipedestación y la sedestación. Esto implica que estos fenómenos de la EEG pueden utilizarse en una ICC operada por IM para estos tipos de movimientos.

3.2. Preprocesamiento de datos de EEG

Una vez que el sistema de ICC adquiere las señales de EEG, los ritmos cerebrales deben ser analizados y preprocesados para identificar patrones de actividad cerebral que contiene el registro de EEG. La etapa de preprocesamiento lleva a cabo las siguientes operaciones: reducción del ruido (filtrado de la señal), submuestreo, referenciación, supresión de artefactos oculares y musculares, e interpolación de los datos faltantes. El objetivo de esta etapa es mejorar la relación señal-ruido de las señales de EEG para su posterior procesamiento (Bigdely-Shamlo *et al.*, 2015).

En la literatura, el filtrado de frecuencia es el método más utilizado en la etapa de preprocesamiento de los sistemas de ICC (Elsayed *et al.*, 2017). Para distinguir información motora, las señales de EEG se filtran en los rangos de frecuencia que contienen los ritmos Alfa y Beta. Hay diferentes enfoques para elegir las bandas de frecuencia de los ritmos Alfa y Beta. De acuerdo con

(Dagdevir & Tokmakci, 2021), algunos investigadores prefieren utilizar un filtro pasa-banda de 8-30 Hz para proporcionar una respuesta de frecuencia estable relacionada con la desincronización / sincronización relacionada con eventos (ERD / ERS). Además, informan que otros investigadores, que consideran que las oscilaciones de la ERD y la ERS se encuentran también en la banda de frecuencias alrededor de los 40 Hz, prefieren un filtro pasa-banda de 8-40 Hz. Por último, indican que en algunos estudios la banda de frecuencia de 4-8 Hz del ritmo Theta también debería considerarse para mejorar el rendimiento de estos sistemas.

Otro parámetro considerado en la etapa de preprocesamiento son las épocas o episodios registrados de la EEG en un ensayo o prueba experimental (del inglés, *trial*), las cuales representan segmentos de datos de muestras contiguas con longitudes variables según en el paradigma de control de la tarea de imaginación motora (IM). Algunos investigadores utilizan la señal que cubre todo el intervalo de tiempo de imaginación durante el experimento (Luo *et al.*, 2019; Malan & Sharma, 2019), mientras que otros prefieren dividir la señal en diferentes ventanas de tiempo hasta cubrir todo el periodo de IM. Las ventanas de tiempo se seleccionan en función de eventos o marcadores específicos de tiempo y se eligen en base a los estados de las tareas de los usuarios (Dai *et al.*, 2020; Sayed *et al.*, 2017).

Para validar una época, los sistemas de ICC calculan diferentes variables con el fin de verificar si la época del registro de EEG no está contaminada por distintos artefactos fisiológicos (movimientos oculares, contracciones musculares, ritmos cardíacos, impedancias de la piel, frecuencias respiratorias), no fisiológicos (condiciones ambientales, movimientos involuntarios de la instrumentación del sujeto, fallas en los electrodos/canales de EEG, errores en el equipo de adquisición, fluctuaciones de la red eléctrica, malas conexiones o cableados, potenciales transitorios) u otras fuentes de ruido (Moreno Arévalo, 2021). Por ejemplo, los valores pico a pico superiores a 100 o 200 microvoltios pueden indicar que el sujeto está parpadeando, o que algunos electrodos están colocados incorrectamente. Asimismo, los valores de desviación estándar elevados revelan que el amplificador está saturado, que los electrodos no están haciendo buen contacto con el cuero cabelludo o que hay artefactos musculares. Adicionalmente, los valores de potencia normalizados con las señales filtradas en bandas de frecuencias de 20 a 30 Hz se utilizan para detectar artefactos musculares. Por lo tanto, las técnicas de preprocesamiento mencionadas anteriormente han demostrado mejorar la relación señal-ruido de la señal de EEG para facilitar la tarea de extraer información relevante en la etapa de extracción de características (Luis G. Hernandez-Rojas *et al.*, 2022; Mendoza-Montoya, 2017; Triana-Guzman *et al.*, 2022).

3.3. Extracción de características

Luego del preprocesamiento, las señales pasan por uno o varios tipos de algoritmos de extracción de características. La extracción de características es el paso del procesamiento de las señales en el que se extrae información discriminatoria y no redundante de los datos de EEG para obtener un conjunto de características sobre las que se puede realizar la clasificación. Las técnicas de extracción de características que se aplican a las señales de EEG de imaginación motora (IM) incluyen el análisis en el dominio del tiempo, de la frecuencia, de tiempo-frecuencia y el filtrado espacial. El filtrado espacial es el método predominante para mejorar la relación señal-ruido de los datos (George *et al.*, 2021). A continuación, se resumen las aproximaciones de extracción de características más utilizadas para trabajar con las señales de EEG en una ICC basada en IM (Al-Saegh *et al.*, 2021).

Los enfoques de extracción de características, como el modelado autorregresivo (AR, por sus siglas en inglés, *autoregressive model*), analizan las señales en el dominio del tiempo. Con el modelado AR, por ejemplo, se ajusta un modelo AR a segmentos de los datos, y los coeficientes AR y el espectro resultante se utilizan como características para el entrenamiento de un modelo de clasificación (Kevric & Subasi, 2017; Kołodziej *et al.*, 2010; Krusienski *et al.*, 2006). También se puede utilizar un modelo autorregresivo adaptativo (AAR, por sus siglas en inglés, *adaptive autoregressive model*), que consiste en ajustar un modelo a las distribuciones cambiantes de la señal, a través de los segmentos temporales de los datos (G. Pfurtscheller *et al.*, 2000; Rodríguez-Bermúdez & García-Laencina, 2012; Schlögl *et al.*, 1997). En la literatura, los parámetros del modelo AAR han sido estimados usando mínimos cuadrados recursivos, mínimos cuadrados medios y filtrado Kalman (Schlögl, 2000).

Los enfoques de extracción de características basados en el dominio de la frecuencia también han sido útiles para extraer características de IM en los datos de EEG (Oikonomou *et al.*, 2017; Rodríguez-Bermúdez & García-Laencina, 2012). Mientras que en algunos estudios se utiliza la transformada rápida de Fourier (conocida por sus siglas en inglés FFT, *fast Fourier transform*) para obtener el espectro de potencia (Rodríguez-Bermúdez & García-Laencina, 2012), en otros se utiliza el método de Welch para calcular el espectro de potencia (Oikonomou *et al.*, 2017). Una ventaja del método de Welch es que reduce la cantidad de ruido en el espectro a diferencia de la

FFT. El método de Welch se encarga de disminuir la varianza en el espectro de potencia, pero tiene la desventaja de la resolución en frecuencia que es más baja en comparación con la densidad espectral de potencia convencional o el periodograma modificado (George *et al.*, 2021).

En general, una de las limitaciones de los métodos de extracción de características enfocados en el dominio del tiempo o en el dominio de la frecuencia es que se excluyen características importantes con gran poder de discriminación, ya que la información se calcula sólo en un dominio. Por ejemplo, las características en el dominio temporal no proporcionan información oscilatoria, mientras que en el dominio espectral no se proporciona información sobre cómo cambia el espectro de la señal a lo largo del tiempo. Estas limitaciones se resuelven mediante representaciones de tiempo-frecuencia con técnicas de análisis como la transformada corta de Fourier (Z. Wang *et al.*, 2018), la transformada wavelet (Alyasseri *et al.*, 2019), las wavelets de tipo Morlet (Zhiwen Zhang *et al.*, 2019), la transformada wavelet continua (H. K. Lee & Choi, 2019), la transformada wavelet discreta (Virgilio G. *et al.*, 2020) y la transformada de Hilbert (J. Zhou *et al.*, 2018).

El filtrado espacial es una forma de extracción de características que se enfoca en los sensores o en los datos (George *et al.*, 2021). Los enfoques basados en los sensores incluyen el filtrado laplaciano y la referencia media común (Lotte, Bougrain, *et al.*, 2018). Por otro lado, los enfoques basados en los datos se categorizan en supervisados o no supervisados. Los algoritmos supervisados más comunes para tareas oscilatorias como la IM se basan en el método de patrón espacial común (CSP) y sus variantes (Blanco-Diaz *et al.*, 2022; Togha *et al.*, 2021; Triana-Guzman *et al.*, 2022). Las técnicas no supervisadas incluyen el análisis de componentes principales y el análisis de componentes independientes. El enfoque basado en datos no supervisado más utilizado es el análisis de componentes principales (Kevric & Subasi, 2017).

Una vez extraídas las características, también es conveniente realizar un proceso de selección de características para eliminar la información redundante. Los criterios de correlación y la información mutua son ampliamente utilizados (A. Singh *et al.*, 2021). Vale la pena mencionar que los algoritmos presentados anteriormente revelan datos de las señales de EEG preprocesadas en los sistemas de ICC basados en IM, los cuales son necesarios para obtener información discriminativa en la siguiente etapa de interpretación de características.

3.4. Interpretación de características

Todas las características descritas antes representan en esencia la fuerza de las modulaciones que suscita la actividad cerebral, las cuales pueden utilizarse para construir modelos de clasificación. (Arpaia *et al.*, 2022) han clasificado los algoritmos para el procesamiento de señales utilizados en la literatura como enfoques de aprendizaje automático no inspirados en el cerebro y los inspirados en el cerebro. En general, los algoritmos de aprendizaje automático que aprenden de los datos sin explicitar sus regularidades se encuentran en el enfoque inspirado en el cerebro. De otro lado, el enfoque no inspirado en el cerebro consiste en aprender de los datos generalmente extrayendo características diseñadas a-priori.

Las estrategias de clasificación más comunes dentro del enfoque no inspirado en el cerebro son los árboles de decisión (Baig *et al.*, 2017), las máquinas de soporte vectorial (Quitadamo *et al.*, 2017) y el análisis discriminante lineal (Molla *et al.*, 2021; Triana-Guzman *et al.*, 2022), mientras que los enfoques más recientes inspirados en el cerebro son las redes neuronales artificiales (Triana Guzmán *et al.*, 2019), las redes neuronales profundas (Chaudhary *et al.*, 2019) y las redes neuronales de impulsos (del inglés, *spiking neural networks*) (H. Wang *et al.*, 2020). Cabe destacar que la mayoría de los enfoques inspirados en el cerebro pueden llevar a cabo la extracción, selección y clasificación de características en un solo proceso. Sin embargo, especialmente con los enfoques de aprendizaje profundo, es fácil incurrir en un sobreajuste debido a la escasez de datos disponibles (Al-Saegh *et al.*, 2021). Para superar este problema, se pueden utilizar estrategias de aumento de datos (Roy *et al.*, 2019) o de aprendizaje por transferencia (Al-Saegh *et al.*, 2021).

Cada sistema de ICC basado en EEG e IM requiere métodos específicos para el preprocesamiento de los datos, la extracción y selección de características, y la clasificación de patrones según la naturaleza de las señales moduladas y las condiciones de operación del sistema (Lotte, Bougrain, *et al.*, 2018). Actualmente, éste es un problema crucial para la investigación de ICC. Por esta razón, científicos e ingenieros de varias disciplinas han colaborado en este campo para proporcionar modelos de clasificación de propósito general que evalúen un conjunto de características y devuelven datos categóricos o numéricos que representen los fenómenos medidos en diferentes aplicaciones (Kawala-Sterniuk *et al.*, 2021).

3.5. Aplicación

3.5.1 Patentes nacionales

Se realizó una búsqueda en patentes nacionales con el fin de identificar el estado de la técnica más cercano a la aplicación propuesta. Las palabras claves de búsqueda empleadas se presentan a continuación:

Tabla 1.

Búsqueda en patentes nacionales.

Fecha	Fuente Consultada	Ecuación de búsqueda	Nro. Resultados obtenidos	Nro. Resultados relevantes
23/05/2021	SIC	“imaginación motora”	0	0
23/05/2021	SIC	interfaz OR software AND interactuar OR operar AND tecnología AND sedestación OR bipedestación AND “funciones cerebrales” OR mente	65	0
23/05/2021	SIC	interfaz AND “cerebro computadora” AND interpretar AND movimientos AND “ponerse de pie” AND sentarse	0	0
23/05/2021	SIC	interfaz AND “cerebro computadora”	0	0
23/05/2021	SIC	interfaz AND control AND neuronal	0	0
23/05/2021	SIC	interfaz AND mente AND maquina	0	0
23/05/2021	SIC	interfaz AND cerebro AND maquina	0	0
23/05/2021	SIC	software AND “cerebro computadora”	0	0
23/05/2021	SIC	dispositivo AND adquisición AND señales AND cerebrales	0	0
23/05/2021	SIC	“señales eléctricas” AND cerebrales	0	0
23/05/2021	SIC	“ponerse de pie” AND sentarse	0	0
23/05/2021	SIC	aparatos AND verticalizan	0	0
23/05/2021	SIC	“cerebro computadora”	0	0
23/05/2021	SIC	G06F 3/01	0	0

Nota: SIC, Superintendencia de Industria y Comercio de Colombia (<https://www.sic.gov.co>).

Al realizar las indagaciones a los documentos de patentes nacionales se evidencia que ninguno tiene relación directa con el objeto de estudio de la presente aplicación. Las patentes nacionales encontradas anteriormente no impactan de manera directa la novedad, el concepto técnico ni el inventivo, debido a que no divulgan similares características o atributos idénticos a los de la propuesta de invención.

3.5.2 Búsqueda abierta

Se realizó una búsqueda abierta en motor de búsqueda de Internet para conocer documentos asociados a la aplicación propuesta, las siguientes ecuaciones de búsqueda fueron utilizadas:

Tabla 2.

Búsqueda abierta.

Fecha	Fuente Consultada	Ecuación de búsqueda	Nro. Resultados relevantes
15/11/2021	Google Scholar	(brain AND computer AND interface) OR (bci) AND (sit OR stand)	31
15/11/2021	Google Scholar	(brain AND computer AND interface) OR (bci) AND (feature AND extraction) AND (motor AND imagery)	45
18/05/2021	Google Scholar	(brain AND computer AND interface) OR (bci) AND (method OR methodology OR procedure OR strategy OR process OR technique OR practice OR approach OR formula) AND (interpret OR read OR decipher OR decode) AND (“motor imagination” OR “motor thinking” OR “motor mental representation” OR “brain functions”) AND (motion OR move OR action) AND (“stand up” OR “be standing” OR “be standing up” OR “be on your feet” OR “be upright” OR standing) AND (“sit down” OR “be seated” OR perch) AND (disabled OR handicapped OR paraplegic OR paralytic)	3
18/05/2021	Google Scholar	(brain AND computer AND interface) OR (bci) AND (device OR apparatus OR instrument) AND (control OR operate OR dominate) AND (“motor imagination” OR “motor thought” OR “mental motor representation” OR “brain functions”) AND (wheelchair) AND (disabled OR paraplegic OR paralytic)	2
18/05/2021	Google Scholar	(“standing machines” OR “standing apparatus” OR “chair to stand up”) AND (assisted OR control) AND (interface) AND (“brain-computer” OR BCI OR “brain computer” OR “brain-machine” OR “brain machine”) AND	0

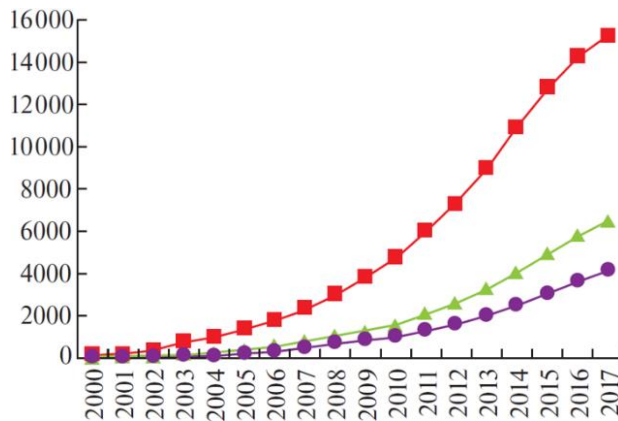
		(disabled OR invalid)	
18/05/2021	Google Scholar	(“neural control interface” OR NCI OR “mind machine interface” OR MMI OR “direct neural interface” OR DNI OR “brain-machine interface” OR BMI) AND (control OR direct OR operate) AND (“wheelchair standing” OR “embedded systems”)	0
18/05/2021	Google Scholar	(system) AND (interface) AND (“brain computer”) AND (“non-invasive”) AND (electroencephalography OR EEG) AND (control) AND (“standing electric wheelchair” OR “standing device”) AND (“brain signals”)	1
18/05/2021	Google Scholar	(interface) AND (“brain-computer”) AND (control OR operate OR dominate) AND (wheelchair) AND (disabled OR paraplegic OR paralytic)	0
18/05/2021	Google Scholar	(“brain-computer interface”) AND (interpret) AND (movements) AND (stand OR sit)	1

Nota: Google Scholar (<https://scholar.google.com>).

En el análisis comparativo de las fuentes en Google Scholar, comparando los estudios de ICC que abordan las extremidades inferiores con respecto a las superiores, se demostró que había alrededor de 1.5 veces menos resultados para miembro inferior (Bobrova *et al.*, 2020). Sin embargo, el interés ha ido aumentando significativamente en los últimos 20 años (ver Figura 3).

Figura 3.

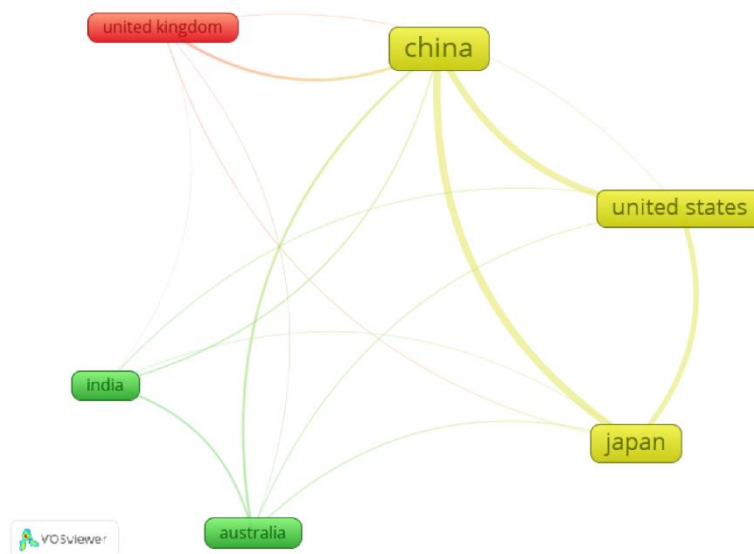
Números de fuentes en Google Scholar por año (desde 2000 al 2017) con las palabras claves “BCI + rehabilitation” (en rojo), filtrando “upper limb” (en verde) y “lower limb” (en morado).



Nota: Tomado de (Bobrova *et al.*, 2020).

Con el uso de la herramienta de software VosViewer (<https://www.vosviewer.com>), para el análisis bibliométrico se construyó una red de acoplamiento bibliográfico entre los países con mayor número de resultados encontrados con las palabras clave TITLE-ABS-KEY ((feature AND extraction) AND (robust) AND (motor AND imagery)) AND PUBYEAR > 2016 (Moumgiakmas & Papakostas, 2022). Como se muestra en la Figura 4, China, Japón y los Estados Unidos de América tienen un acoplamiento bibliográfico más fuerte en función del número total de citas. Además, China es el país con mayor número de referencias y citas. Le siguen Japón, Estados Unidos de América, Australia, Reino Unido e India.

Figura 4.
Análisis de acoplamiento bibliográfico basado en los países.



Nota: Tomado de (Moumgiakmas & Papakostas, 2022).


Como se indica en la Figura 5, hubo un aumento de publicaciones en 2019. Casi el 69% de los artículos que se publicaron en el 2019, describen una versión modificada del método de CSP o sus variantes. CSP es uno de los métodos de extracción de características más comunes y populares en el paradigma de imaginación motora (IM), en comparación con los otros dominios de características como el tiempo, frecuencia y tiempo-frecuencia (Moumgiakmas & Papakostas, 2022).

En (Arpaia *et al.*, 2022) se hizo un análisis metrológico del estado del arte sobre cómo clasificar exitosamente las señales de EEG en una ICC basada en IM. En la búsqueda se podrían

separar en un 53% los enfoques no inspirados en el cerebro (del inglés, *non-brain-inspired*) y un 47% los enfoques inspirados en el cerebro (del inglés, *brain-inspired*). Sin embargo, al considerar su evolución cronológica (ver Figura 6), en los últimos 5 años los enfoques no inspirados en el cerebro han estado siendo menos explotados gradualmente en comparación con los enfoques inspirados en el cerebro.

Figura 5.


Documentos por año.



Nota: Tomado de (Moumgiakmas & Papakostas, 2022).

Figura 6.

Porcentaje de estudios que proponen enfoques inspirados y no inspirados en el cerebro.



Nota: Tomado de (Arpaia *et al.*, 2022).

Las tecnologías encontradas anteriormente no impactan de manera directa la novedad y el concepto inventivo de la aplicación propuesta, debido a que no se evidencia un documento que comprenda las mismas características de la presente propuesta.

3.5.3 Patentes extranjeras

Se realizó una búsqueda en patentes extranjeras para identificar de manera detallada los diferentes componentes de la propuesta de patente y cubrir todas las patentes que tengan iguales características. Las ecuaciones de búsqueda empleadas se presentan a continuación:

Tabla 3.

Búsqueda en patentes extranjeras.

Fecha	Fuente Consultada	Ecuación de búsqueda	Nro. Resultados obtenidos	Nro. Resultados relevantes
20/05/2021	Patent inspiration	TAC = (method OR methodology OR procedure OR strategy OR process OR technique OR practice OR approach OR formula) AND (interpret OR read OR decipher OR decode) AND (“motor imagination” OR “motor thinking” OR “motor mental representation” OR “brain functions”) AND (motion OR move OR action) AND (“stand up “OR “be standing” OR “be standing up” OR “be on your feet” OR “be upright” OR standing) AND (“sit down” OR “be seated” OR perch) AND (disabled OR handicapped OR paraplegic OR paralytic)	0	0
20/05/2021	Patent inspiration	TAC = (interface OR “mind-machine interface” OR “electroencephalographic signal”) AND (control OR operate OR interpret OR read OR Decipher OR decode) AND (device OR apparatus OR mechanism) AND (movements OR “stand up” OR “be standing” OR “sit down”)	20	0
20/05/2021	Patent	TAC = (device OR apparatus OR	1	0

	inspiration	instrument) AND (interpret OR read OR decipher OR decode) AND (“motor imagination” OR “motor thinking” OR “motor mental representation” OR “brain functions”) AND (disabled OR handicapped OR paraplegic OR paralytic)		
20/05/2021	Patent inspiration	TAC = (device) AND (EEG OR “electroencephalographic signal”) AND (read OR transmit OR interpret) AND (“brain functions” OR “motor imagination”) AND (disabled OR handicapped OR paraplegic OR paralytic)	0	0
20/05/2021	Patent inspiration	TAC = (device OR hardware) AND (interpret OR read) AND (“brain functions” OR “motor imagination” OR “motor thinking”) AND (“stand up” OR “be standing” OR “sit down”)	0	0
20/05/2021	Patent inspiration	TAC = (software OR program) AND (read OR transmit OR interpret) AND (“brain functions”) AND (chair OR “wheelchair” OR “standing chair”)	2	0
20/05/2021	Patent inspiration	TAC = (“brain-computer interface” OR software) AND (interpret OR read OR decipher OR decode) AND (movements) AND (“standing chair”)	0	0
20/05/2021	Patent inspiration	TAC = (interface) AND (“brain-computer”) AND (control OR operate OR dominate) AND (wheelchair) AND (disabled OR disabled OR paraplegic OR paralytic)	4	1
20/05/2021	Patent inspiration	TAC = (interface) AND (“brain-computer”) AND (control OR operate OR dominate) AND (wheelchair OR “standing chair”)	19	7
20/05/2021	Patent inspiration	TAC = (“automatic stand chair lifting system”) AND (“brain-computer interface” OR software)	0	0

Nota: Patent inspiration (<https://www.patentinspiration.com>).

En la Tabla 4, se presenta un cuadro comparativo con algunas patentes extranjeras que hacen referencia a la materia de análisis de la presente propuesta. Sin embargo, las patentes encontradas anteriormente no impactan de manera directa la novedad y el concepto inventivo debido a que las características técnicas combinadas de la propuesta de invención producen un

efecto técnico que es un nuevo paradigma de IM para los movimientos de ponerse de pie y sentarse. Es decir, el efecto técnico que produce la combinación es mayor que la suma de los efectos técnicos de las características individuales. Es irrelevante si cada característica individual es total o parcialmente conocida (Capítulo 2.13.7.2. Guía para examen de solicitudes de patente de invención y modelo de utilidad - Superintendencia de Industria y Comercio de Colombia) (Robledo Del Castillo *et al.*, 2012).

Como resumen a las actividades de búsqueda en patentes nacionales, patentes extranjeras y búsqueda abierta, se encontraron limitaciones o desventajas de las tecnologías anteriores con relación a la presente propuesta cuyos componentes, ventajas técnicas o funcionales se muestran en la Tabla 4.

Tabla 4.

Resultados de la búsqueda en patentes extranjeras.

Comparativo del estado de la técnica más cercano								
Componentes, ventajas técnicas o funcionales	Documentos cercanos que afectan							
	P1	P2	P3	P4	P5	P6	P7	P8
Interfaz cerebro-computadora basada en EEG que ejecuta comandos de control	x	x	x	x		x	x	x
Dispositivos no invasivos	x	x	x		x	x	x	x
Utiliza la imaginación motora	x			x	x	x		
Posee un gorro con electrodos	x	x	x		x	x	x	x
Es un sistema portátil e inalámbrico		x	x					
Adquiere señales de EEG y extrae características asociadas a la imaginación del movimiento de pararse y/o sentarse					x			
Interpreta las señales de EEG relacionadas con la imaginación de los movimientos de ponerse de pie y/o sentarse								
Permite el control de dispositivos bipedestadores mediante la interfaz cerebro-computadora						x	x	

Nota: P1 (Liu *et al.*, 2018), P2 (徐圣普 *et al.*, 2018), P3 (Guo *et al.*, 2021), P4 (Leuthardt *et al.*, 2006), P5 (Wan *et al.*, 2009), P6 (Morimoto *et al.*, 2012), P7 (Contreras-Vidal *et al.*, 2018), P8 (鲁守银 *et al.*, 2018).

3.5.4 Artículos científicos

Se realizó una búsqueda en bases de datos científicas para conocer el estado del arte relacionado al tema de investigación. Las ecuaciones de búsqueda empleadas se presentan en la Tabla 5. La Tabla 6 presenta un resumen de algunos de los trabajos más relevantes.

Tabla 5.

Búsqueda en artículos científicos.

Fecha	Fuente Consultada	Ecuación de búsqueda	Nro. Resultados obtenidos	Nro. Resultados relevantes
15/11/2021	Scopus	TITLE-ABS-KEY ((brain AND computer AND interface) OR (bci) AND (sit OR stand))	142	53
15/11/2021	WoS	(brain AND computer AND interface) AND (sit OR stand) (Topic)	91	24
15/11/2021	Scopus	TITLE-ABS-KEY ((brain AND computer AND interface) OR (bci) AND (motor AND imagery)) AND PUBYEAR > 2015 AND PUBYEAR < 2021 AND (LIMIT-TO (DOCTYPE, "ar")) AND (LIMIT-TO (LANGUAGE, "English"))	887	89
15/11/2021	Scopus	TITLE-ABS-KEY ((brain AND computer AND interface) OR (bci) AND (feature AND extraction) AND (motor AND imagery)) AND PUBYEAR > 2015 AND PUBYEAR < 2021 AND PUBYEAR > 2015 AND PUBYEAR < 2021	522	49
24/05/2021	Scopus, WoS	TITLE-ABS-KEY ((system) AND (interpretation OR reading) AND ("motor imagination"))	0	0
24/05/2021	Scopus, WoS	TITLE-ABS-KEY ((system OR method) AND (interpret OR read) AND ("motor imagination"))	0	0
24/05/2021	Scopus	TITLE-ABS-KEY ((interface OR software) AND (interact OR operate) AND (technology) AND (sit OR stand) AND ("brain functions" OR mind))	1	0

Nota: Scopus (<https://www.scopus.com>), Web of Science (WoS) (<https://www.webofscience.com>).

Tabla 6.

Resultados de la búsqueda en artículos científicos.

Primer autor (Año)	Canales de EEG	Principio	Sujetos		Tarea experimental	Interfaz cerebro computadora/máquina		
			Enfermos	Sanos		Preprocesamiento	Características	Decodificador
(Z. Zhou <i>et al.</i> , 2007)	41	MI	ninguno	10	intención de pararse	filtro pasa-banda 0.5-60 Hz, filtro rechaza-banda 50 Hz	ritmo Mu 9-13 Hz, 11-13 Hz, ERD / ERS, ritmo Beta 21-24 Hz, SMR	infomax extendido basado en ICA combinado con CWT
(Noda <i>et al.</i> , 2012)	64	MI	ninguno	1	imaginación de movimiento del brazo izquierdo / derecho para pararse / sentarse	filtro Laplaciano, sustracción de la referencia media común	7-30 Hz filtro Butterworth pasa-banda 4 orden, SMR, ERD	L1-regresión logística regularizada
(Do <i>et al.</i> , 2013)	64	MI	1 lesionado en la médula espinal	1	intención de caminar y estar de pie	CAR, los canales de EEG con ruido fueron removidos en modo <i>online</i>	1-40 Hz, SMR, ERD	CPCA y AIDA - clasificador Bayesiano
(Kilicarslan <i>et al.</i> , 2013)	64	MI y KMI	1 lesionado en la médula espinal	11	intención de caminar y estar de pie	esquema robusto ANC (filtrado H) para remover artefactos oculares y derivas de la señal,	0.1-2 Hz filtro pasa-banda Butterworth 2 orden, ritmo Delta, MRCP	<i>offline</i> y <i>online</i> , modelo de mezcla Gaussiana y LFDA

ASR								
(Bulea et al., 2014)	64	ME	ninguno	10	pararse / sentarse / quietud	filtro pasa-alto 0.05 Hz fase-cero Butterworth 8 orden, los canales de EEG con ruido fueron removidos en modo <i>offline</i> , ASR	0.1-4 Hz filtro pasa-banda fase-cero Butterworth 3 orden, ritmo Delta, MRCP	modelo de mezcla Gaussiana y LFDA
(García-Cossio et al., 2015)	62	ME	3 por accidente cerebro vascular	10	caminata pasiva, caminata activa, y estar de pie	CAR, CCA	8-12 Hz ritmo Mu, 20-30 Hz ritmo Beta Alto, 30-40 Hz ritmo Gamma Bajo, SMR, ERD/ERS	L2-regresión logística regularizada
(Donati et al., 2016)	11	KMI	8 lesionados en la médula espinal	ninguno	algunos comandos de alto nivel relacionados con la marcha	CAR	3 Hz ritmo Delta, MRCP, 7-12 Hz ritmo Mu, 16-20 Hz ritmo Beta, SMR, ERD/ERS	<i>online</i> , CSP con análisis discriminante lineal
(Kwak et al., 2017)	8	VEPs	ninguno	11	caminar, girar a la izquierda / derecha, pararse / sentarse	filtro rechaza-banda 60 Hz, CCA	SSVEP 9 Hz (caminar), 11 Hz (izquierda), 15 Hz (derecha), 13 Hz (pararse), 17 Hz (sentarse)	<i>online</i> , K-vecinos cercanos

(C. Wang et al., 2018)	6, 32	VEPs, MI	ninguno	4	caminar, pararse / sentarse, imaginación de movimiento de mano izquierda / derecha y pies	5-35 Hz filtros pasa-banda IIR Butterworth 8 orden y Chebyshev tipo II, eliminación del nivel DC, remoción de artefactos por parpadeo (4 Hz) e interferencia de la fuente de poder (50 Hz)	SSVEP 6 Hz (caminar), 10 Hz (sentarse), 12 Hz (pararse), Imaginación motora (mano izquierda / derecha y pies), SMR	CCA, CSP - clasificador SVM
(Chaisaen et al., 2020)	11	AO, MI, ME	ninguno	8	pararse / sentarse	filtro pasa-banda 1-40 Hz, filtro rechaza-banda 50 Hz, submuestreo (250 Hz), reducción de artefactos de EOG con ICA	4-40 Hz, 9 banco de filtros desde ritmo Theta a ritmo Gamma Bajo, ERD / ERS, SMR, MRCP	<i>offline</i> , CSP - clasificador SVM
(Choi et al., 2020)	31	MI	ninguno	10	pararse / marchar / sentarse	7-34 Hz filtro pasa-banda IIR fase-cero Butterworth desde ritmo Theta Alto a ritmo Gamma Bajo	7-34 Hz, 6 banco de filtros desde ritmo Mu Bajo a ritmo Beta Alto, ERD / ERS, SMR	<i>offline y online</i> , CSP - MIBIF - clasificador SVM
(B. Singh & Natsume, 2022)	6	ME	ninguno	10	pararse / sentarse	filtro pasa-banda 0.05-30 Hz, artefactos de EOG fueron	4 Hz ritmo Delta, BP, MRCP	MCA

identificados por
inspección visual y
excluidos
manualmente

Nota: AO, *action observation*; KMI, *kinesthetic movement intention*; MI, *motor imagery*; ME, *motor execution*; ERP, *event-related potential*; VEPs, *visual evoked potentials*; SMR, *sensorimotor rhythm*; CWT, *continuous wavelet transform*; ICA, *independent component analysis*; CAR, *common average reference*; CCA, *canonical correlation analysis*; ASR, *artifact subspace reduction*; CPCA, *classwise principal component analysis*; AIDA, *approximate information discriminant analysis*; ANC, *adaptive noise canceling*; LFDA, *local Fisher's discriminant analysis*; ERD, *event-related desynchronization*; ERS, *event-related synchronization*; MRCP, *movement-related cortical potential*; BP, *Bereitschaftspotential*; EOG, *electrooculogram*; CSP, *common spatial pattern*; IIR, *infinite impulse response*; SSVEP, *steady-state visual evoked potential*; SVM, *support vector machine*; MIBIF, *mutual information-based best individual feature*; MCA, *morphological component analysis*.

Estos estudios lograron detectar información motora mientras se imaginaba o ejecutaba un movimiento siguiendo un protocolo síncrono. Estos trabajos se basan en características temporales y frecuenciales como el potencial cortical relacionado con el movimiento (MRCP), el ritmo sensoriomotor (SMR), y transformaciones en tiempo-frecuencia y espaciales como la transformada wavelet continua (CWT) y el método de patrón espacial común (CSP). Asimismo, los algoritmos de clasificación más utilizados fueron la máquina de soporte vectorial (SVM), el análisis discriminante lineal (LDA) y sus derivaciones. La mayoría de estos trabajos han explorado el reconocimiento de movimientos en escenarios de clasificación biclase (por ejemplo, movimiento imaginado frente a no movimiento) y multiclase (por ejemplo, varios movimientos imaginados y ningún movimiento) en configuraciones *offline* (es decir, utilizando grabaciones de EEG en intervalos de tiempo específicos y fijos). Es importante destacar que estos estudios han demostrado que es posible utilizar las señales de EEG para reconocer diferentes movimientos del miembro inferior. Varios estudios han explorado la realización de movimientos a partir de la información decodificada del potencial evocado visual de estado estacionario (SSVEP) de forma continua en el tiempo. Sin embargo, los artículos encontrados anteriormente no divulgan un sistema y método para la interpretación de la imaginación motora de los movimientos de ponerse de pie y sentarse de manera más natural y basados en una interfaz cerebro-computadora *offline* y *online*. De acuerdo con lo anterior, ningún documento enseña todas las características de la presente propuesta.

Capítulo 4. Problemática de I+D+i

Para personas con algunas limitaciones en la movilidad de sus extremidades tanto superiores como inferiores, las sillas de ruedas bipedestadoras, exosqueletos robóticos, prótesis u ortesis y otros aparatos bipedestadores son una opción terapéutica para la mejora de funciones físicas y orgánicas. Estos dispositivos usan una interfaz de control generalmente accionada por una fuerza del usuario para realizar la transición de la posición sedente-bípeda. Pero, para personas con enfermedades y/o condiciones físicas específicas como pérdidas o parálisis de extremidades, representan un problema ya que no es posible imprimir la fuerza que se requiere para mover la interfaz de control o no se les considera adecuado que puedan operarla de manera segura. Lo anterior, además de generarles problemas emocionales y económicos de total dependencia también les impide llevar una vida dentro de los estándares normales (Leaman & La, 2017).

Para algunas de estas personas, desde hace varios años se ha explorado la utilidad de las señales de electroencefalografía (EEG) como fuente de información que permite detectar la intencionalidad del usuario a través de una interfaz cerebro-computadora (ICC) para el control de un sistema externo. Los paradigmas de ICC actuales que han considerado los movimientos de ponerse de pie y sentarse, suelen basarse en el miembro superior (Noda *et al.*, 2012; C. Wang *et al.*, 2018), en la marcha (Choi *et al.*, 2020), o en los potenciales evocados visuales (Kwak *et al.*, 2017). Aunque estos sistemas han demostrado ser eficaces en transferir información del cerebro a un computador, no es la forma natural como la imaginación motora (IM) para ponerse de pie y sentarse y requieren muchos más recursos cognitivos para que el cerebro interactúe con ellos. De acuerdo con la aplicación y la necesidad de usar técnicas *online*, y debido a que ha sido poco explorado un sistema de ICC basado en EEG para la interpretación de la IM de los movimientos de ponerse de pie y sentarse, surgió esta oportunidad de innovación. Por desgracia, a pesar de los avances más recientes en neurociencia (ciencia cognitiva) y neurotecnología (interfaces cerebro-computadora), el diseño de sistemas prácticos controlados por el cerebro se enfrenta a varios retos que deben resolverse antes de emplear la tecnología de ICC en tareas del mundo real (X. Gao *et al.*, 2021).

Los sistemas de registro de EEG estándar suelen requerir la aplicación de gel conductor u otra sustancia en los electrodos para proporcionar mediciones precisas. Esta tarea puede ser tediosa y consumidora de tiempo, e incluso los técnicos capacitados pueden necesitar entre 30 y 60 minutos para preparar los 32 o 64 electrodos adherentes sobre el cuero cabelludo del sujeto de prueba para

registrar su actividad cerebral en una sola sesión. En el caso de los pacientes, este problema se dificulta drásticamente en la autonomía del sistema, ya que se requiere la asistencia de una persona entrenada para colocar el dispositivo correctamente. Por otra parte, para las personas sanas, la realización correcta de una sesión de ICC puede ser un procedimiento arduo y complicado. Por esta razón, los sistemas de ICC prácticos reducen el número de electrodos y a veces sustituyen los electrodos estándar por electrodos secos que no utilizan gel conductor. Estos nuevos sistemas disminuyen significativamente el tiempo de preparación, sin embargo, los electrodos secos no son cómodos de llevar puestos durante varias horas. Éste sigue siendo uno de los problemas de desarrollo de sistemas de ICC basados en EEG, además de ofrecer una calidad de señal aceptable en un equipo de bajo costo y fácil de usar para el público en general. Incluso, este problema ha persistido desde los primeros desarrollos de la tecnología de ICC y probablemente continuará durante los próximos años (Rashid *et al.*, 2020).

En la actualidad, las aplicaciones médicas de la ICC se limitan al laboratorio, y la mayoría de los trabajos publicados sólo han demostrado cómo podrían incorporarse eventualmente a las tecnologías de asistencia. Adicionalmente, existen todavía importantes limitaciones en el uso de la señal de EEG en sistemas de ICC antes de ver las aplicaciones de dispositivos bipedestadores controlados por el cerebro en la vida cotidiana. Entre estas se puede mencionar la baja tasa de transferencia de información para una interacción más natural entre el usuario y el dispositivo controlado, la alta variabilidad de las señales de EEG entre sujetos, la cantidad de tareas de imaginación motora que se pueden clasificar, la interferencia de otras señales (artefactos) que contaminan la señal de EEG, el porcentaje de efectividad en la generación de comandos y el tiempo empleado en la preparación, el entrenamiento y rutinas de calibración, son algunos de los problemas de investigación abiertos en la comunidad de ICC (McFarland & Wolpaw, 2017).

No obstante, para abordar algunas de las limitantes anteriores muchos investigadores utilizan algoritmos emergentes en el procesamiento y clasificación de señales cerebrales que permiten tener sistemas de ICC más naturales. De otro lado, uno de los principales problemas en estos estudios es la alta variabilidad de estos registros entre individuos de un mismo experimento, razón por la cual la construcción de bases de datos de ICC correctamente documentadas es fundamental para llevar a cabo este tipo de investigaciones. Desde el punto de vista del diseño de una ICC basada en EEG e imaginación motora (IM), a continuación, se describen algunos retos críticos (Allison & Neuper, 2010; Edlinger *et al.*, 2015; M. H. Lee *et al.*, 2019; Nicolas-Alonso & Gomez-Gil, 2012; Sebastián-Romagosa *et al.*, 2021; M. Xu *et al.*, 2021):

- Los sistemas de ICC basados en IM ofrecen tasas de transferencia de información demasiado bajas, lo que se traduce en una interacción lenta entre el usuario y la interfaz. Para compensar estas limitaciones, se debe encontrar un balance entre la velocidad y la exactitud de detección del sistema para no producir comandos erróneos y riesgos para el usuario por un mal diseño.
- La actividad cerebral tiende a mostrar una gran variabilidad entre los sujetos, razón por la cual se construyen conjuntos de datos específicos por individuo en las etapas de entrenamiento en lugar de usar bases de datos generales. Más allá de la validación del sistema y la calibración de algunos parámetros, aún no está claro cómo utilizar las grandes bases de datos registradas en múltiples estudios para generar modelos de clasificación universales con el fin de reducir o eliminar las sesiones de entrenamiento.
- Varios factores ambientales (el ruido, la iluminación, la hora del día, etc.) y relacionados con el usuario (la motivación, la fatiga, etc.) alteran la actividad cerebral, lo que aumenta la variabilidad en las señales medidas entre los sujetos. Para solucionar este problema, el modelo implementado en la ICC debe ser capaz de adaptarse y ajustarse para evitar el decrecimiento del desempeño de los sujetos.
- La IM es por sí misma una tarea mental exigente que resulta agotadora tras unas pocas horas de operación de la ICC. Por lo tanto, se deben buscar alternativas para mantener descansado y motivado al usuario con la retroalimentación de su desempeño y pausas entre las tareas mentales.
- No todos los usuarios pueden producir señales cerebrales que la ICC pueda reconocer y clasificar satisfactoriamente. Esta ineficiencia o analfabetismo (del inglés, *illiteracy*) obliga a explorar diferentes paradigmas de control en la misma aplicación y a desarrollar nuevos algoritmos para que más usuarios puedan utilizar la ICC.
- Una ICC práctica debe identificar la clase de reposo o inactividad (del inglés, *idle class*), que representa cuando el usuario no quiere imaginar un movimiento. En muchos trabajos publicados, los paradigmas de control suponen que el usuario genera señales de imaginación motora continuamente. Sin embargo, en escenarios más realistas, el usuario no quiere interactuar con el sistema todo el tiempo.

Por tal motivo, la presente propuesta aborda los retos técnicos descritos anteriormente y se plantea la siguiente pregunta de investigación:

¿Cómo implementar un sistema de ICC portátil e inalámbrico para la interpretación de la tarea mental de imaginar los movimientos de ponerse de pie y sentarse, basado en señales de EEG y usando métodos de inteligencia computacional?

Capítulo 5. Objetivos

5.1. Objetivo general

Desarrollar un sistema y método de interfaz cerebro-computadora para la interpretación de la imaginación motora (IM) de los movimientos de ponerse de pie y sentarse, basado en señales de electroencefalografía (EEG) y usando técnicas de inteligencia computacional.

5.2. Objetivos específicos

- Construir un conjunto de datos de señales de electroencefalografía (EEG) en un ambiente de laboratorio de interfaz cerebro-computadora relacionada con la imaginación motora de los movimientos de ponerse de pie y sentarse en sujetos sanos.
- Identificar la configuración apropiada del sistema de adquisición de señales eléctricas cerebrales (EEG) para el registro de información en tareas que involucran la imaginación motora.
- Definir la serie de pasos del método y las técnicas de inteligencia computacional para procesar, caracterizar y decodificar la información asociada a la imaginación motora registrada en las señales de EEG adquiridas de los sujetos sanos.
- Evaluar la funcionalidad del sistema y el método completo para la difusión de resultados en artículos científicos y la protección por patente de invención.

Capítulo 6. Metodología

Los sistemas de interfaz cerebro-computadora (ICC) que detectan la imaginación motora (IM) mediante el registro de señales de electroencefalografía (EEG), están diseñados para medir la modulación de ritmos o componentes oscilatorios estrechamente relacionados con determinados procesos neurofisiológicos provocados de forma activa por el usuario. En estos sistemas, la ICC analiza las propiedades locales, endógenas y oscilatorias de las señales de EEG sin tener en cuenta la actividad relacionada con eventos exógenos (es decir, información de estímulos externos presentados de forma pasiva que provocan potenciales relacionados a eventos) (Beppi *et al.*, 2021). En consecuencia, el análisis y la discriminación de la actividad relacionada con la IM se basa en la medición de la actividad oscilatoria en las señales de EEG a través de la modulación de los ritmos sensoriomotores explotados por el usuario.

Este capítulo presenta la implementación de la ICC basada en EEG e IM. También se describen las diferentes estrategias de procesamiento de señales, extracción y selección de características, clasificación de patrones y las rutinas de entrenamiento y calibración *offline* utilizadas para construir el modelo de aprendizaje automático de la ICC. Finalmente, en la última sección se muestra el análisis estadístico y varias pruebas para validar el modelo de clasificación y el funcionamiento *online* de la ICC.

6.1. Participantes

En el estudio participaron 32 sujetos sanos de entre 19 y 29 años (16 mujeres y 16 hombres). La edad media (\pm desviación estándar) de los participantes era de 22.4 (\pm 2.3) años. Ninguno de los participantes tenía antecedentes de trastornos neurológicos, musculoesqueléticos o de otro tipo, y todos tenían una visión normal o corregida a normal. Todos los participantes eran estudiantes universitarios, sin relación académica con los experimentadores, y ninguno tenía experiencia previa con experimentos de EEG o ICC. Antes de comenzar su sesión experimental, los participantes fueron debidamente informados de la naturaleza del estudio y se les instruyó sobre la correcta ejecución de los experimentos. Además, los participantes firmaron voluntariamente un consentimiento informado de acuerdo con el protocolo experimental aprobado por el comité de ética de la Universidad Antonio Nariño. Este protocolo experimental siguió las normas de la

Declaración de Helsinki (World Medical Association, 2013). Cada sujeto recibió una compensación económica por su participación al final de su sesión.

6.2. Registro de datos electroencefalográficos


Los datos de EEG se obtuvieron de la corteza cerebral a partir de 17 electrodos húmedos activos (g.LADYbird) montados en un sistema de amplificación de biopotenciales g.Nutilus PRO (g.tec medical engineering GmbH, Austria) con tecnología de transmisión de datos inalámbrica (véase la Figura 7). Los electrodos se humedecieron con gel conductor y se colocaron según el sistema internacional 10-20 en las siguientes posiciones alrededor de la corteza motora primaria (R. Xu *et al.*, 2017): F3, Fz, F4, FC5, FC1, FC2, FC6, C3, Cz, C4, CP5, CP1, CP2, CP6, P3, Pz y P4, con el electrodo de tierra (GND) colocado en AFz y el electrodo de referencia (REF) colocado en el lóbulo de la oreja derecha. Las señales de EEG se adquirieron a una frecuencia de muestreo de 250 Hz y se filtraron digitalmente en pasa-banda con frecuencias de corte de 0.01 a 60 Hz, utilizando un filtro Butterworth de 6° orden en cada electrodo (Podder *et al.*, 2014). Antes de iniciar el registro de EEG, se verificó que la impedancia de los electrodos fuera inferior a 30 k Ω utilizando la herramienta de medición de la impedancia proporcionada por el fabricante del g.Nutilus PRO. Además, se utilizó una plataforma de software desarrollada en C++ para gestionar y controlar la ejecución del experimento, recolectar las señales de EEG, almacenar los datos y procesarlos tanto *offline* como *online* (Copyright © 2018 Instituto Tecnológico y de Estudios Superiores de Monterrey).

6.3. Diseño experimental

Los experimentos se realizaron en una sala aislada acústicamente en la que sólo estaban presentes el participante y el experimentador. El participante estaba sentado en una silla en una postura que le resultara cómoda pero que no afectara a la adquisición de los datos. Frente al participante, se colocó una pantalla de televisión de 40 pulgadas a unos 3 m, como se muestra en la Figura 7. En esta pantalla, una interfaz gráfica de usuario, conocida también como GUI (del inglés *graphical user interface*), mostraba imágenes que guiaban al participante durante el experimento. Cada sesión experimental se dividió en dos fases: una fase *offline* y una fase *online*.

Figura 7.

Ilustración del montaje experimental del sistema de ICC basado en EEG e IM.



Nota: Tomado de (Triana-Guzman *et al.*, 2022).

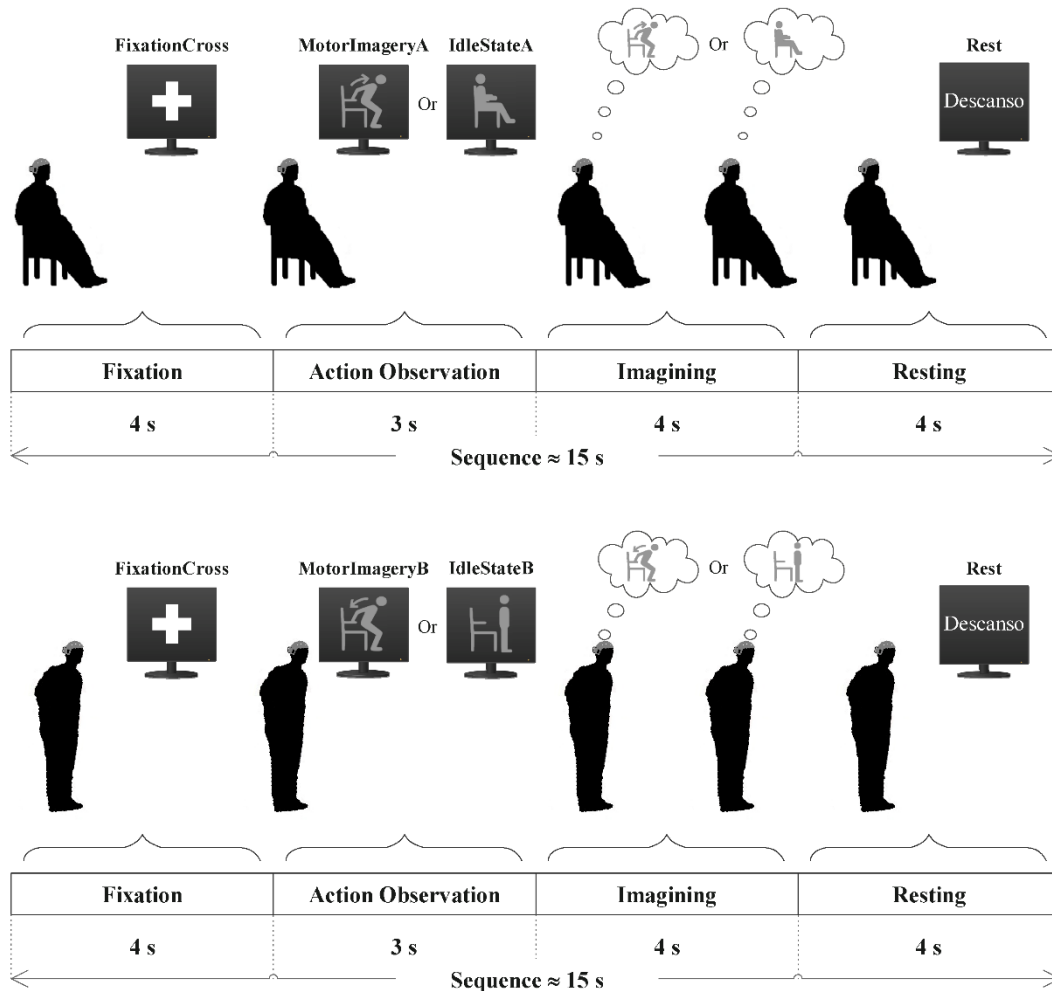
6.3.1 Fase *offline*

Los experimentos en modo *offline* consistieron en registrar las señales de EEG de los participantes durante los ensayos (del inglés, *trials*) de imaginación motora (IM) para ponerse de pie y sentarse que fueron guiados por la GUI presentada en la pantalla del televisor (véase la Figura 8). Justo antes de comenzar el registro de las señales de EEG, los participantes practicaron las secuencias de tareas mentales que indicaba la GUI en la pantalla del televisor. Una vez iniciado el registro de las señales de EEG, se realizaron seis corridas (del inglés, *runs*) *offline* en las que los participantes estaban de pie en tres corridas y sentados en las otras tres. El participante podía elegir el orden de las corridas, y entre cada corrida había un descanso de unos minutos para que el participante evitara la fatiga y el aburrimiento, se recuperara y se preparara para continuar con la grabación de EEG de la siguiente corrida. En cada corrida, el participante tenía que repetir un bloque de 30 ensayos de tareas mentales indicadas por señales visuales presentadas continuamente

en la pantalla en una secuencia pseudoaleatoria. La secuencia temporal de las tareas mentales realizadas por cada participante se muestra en la Figura 8. Cada secuencia de un ensayo constaba de cuatro pasos:

Figura 8.

Descripción de la secuencia temporal de un ensayo realizado por el participante en el experimento de sentado a parado (ARRIBA) y en el experimento de parado a sentado (ABAJO).



Nota: Tomado de (Triana-Guzman *et al.*, 2022).

1. Fijación: Como primer paso, aparecía un símbolo de una cruz en la pantalla del televisor durante 4 s, durante los cuales se pedía al participante que evitara cualquier movimiento o esfuerzo del cuerpo y que permaneciera concentrado mientras miraba el símbolo.

2. Observación de la acción: En el segundo paso, aparecía una figura en la pantalla del televisor durante 3 s, la cual el participante debía observar y realizar una tarea experimental posteriormente en el tercer paso.
3. Imaginación: En el tercer paso, el participante tenía que visualizar la acción indicada por la figura mostrada en el segundo paso y realizar una tarea experimental durante 4 s en respuesta a la figura. Por ejemplo, la tarea podía consistir en estar sentado sin moverse mientras imaginaba activamente el movimiento de ponerse de pie (etiquetado como MotorImageryA), estar sentado sin moverse y sin imaginar el movimiento de ponerse de pie (etiquetado como IdleStateA), estar de pie sin moverse mientras imaginaba activamente el movimiento de sentarse (etiquetado como MotorImageryB), o estar de pie sin moverse y sin imaginar el movimiento de sentarse (etiquetado como IdleStateB).
4. Descanso: Finalmente, en el cuarto paso de la secuencia, el texto “Descanso” aparecía en la pantalla del televisor durante 4 s, indicando al participante que descansara de la tarea experimental, parpadeara o moviera la cabeza y el cuerpo si era necesario.

Se pidió a los participantes que evitaran o minimizaran el esfuerzo muscular y el parpadeo desde el primer paso hasta el tercero de cada secuencia. Para cada participante, se llevó a cabo una sesión experimental en modo *offline* para la construcción de dos conjuntos de datos correspondientes a las dos transiciones de: (A) sedente-bípedo (del inglés, *sit-to-stand*) y (B) bípedo-sedente (del inglés, *stand-to-sit*). Los datos de EEG del participante se recogieron de las 90 secuencias del conjunto de datos A (45 ensayos de tareas MotorImageryA y 45 ensayos de tareas IdleStateA) y de las 90 secuencias del conjunto de datos B (45 ensayos de tareas MotorImageryB y 45 ensayos de tareas IdleStateB). En total, la duración de la sesión experimental *offline* fue de al menos 1 hora para la captura de los dos conjuntos de datos de EEG.

6.3.1.1 Preprocesamiento de datos de EEG


Los dos conjuntos de datos de EEG registrados en los experimentos en *offline* se sometieron cada uno de forma independiente a las siguientes etapas de preprocesamiento automático (Mendoza-Montoya, 2017). En primer lugar, los datos de EEG se dividieron en épocas (segmentos de datos de 2 s de muestras contiguos de cada ensayo) desde 1 s antes hasta 1 s después de comenzar la tarea experimental del paso 3 en la secuencia de un ensayo. En segundo lugar, cada época se separó y etiquetó según una de las cuatro tareas experimentales: MotorImageryA, IdleStateA, MotorImageryB, o IdleStateB. Por cada participante, el número total de épocas fue 90

para la transición (A) de sedente-bípido y 90 para la transición (B) de bípido-sedente. En tercer lugar, cada época de EEG de 17 electrodos (o canales de EEG) y 500 muestras se filtró utilizando filtros digitales de respuesta al impulso finita (FIR, por sus siglas en inglés, *finite impulse response*) con frecuencias de corte entre 20-40 Hz y 4-40 Hz. El resultado de este paso de filtrado fue la señal de 20-40 Hz para detectar los artefactos musculares y la señal de 4-40 Hz para abarcar las bandas de frecuencia relacionadas con la actividad motora. Por último, se calcula la potencia normalizada entre 20-40 Hz / 4-40 Hz de cada canal de EEG.

Por cada tarea experimental hubo una colección de épocas \times muestras \times canales ($45 \times 500 \times 17$). Se aplicaron los siguientes criterios de exclusión para identificar y descartar las épocas contaminadas por: (i) valores pico a pico superiores a $100 \mu\text{V}$; (ii) desviaciones estándar de amplitud superior a $50 \mu\text{V}$; y (iii) potencias normalizadas superiores a 0.7. Estos criterios pueden indicar si el sujeto está parpadeando, el amplificador está saturado, los electrodos no están haciendo buen contacto con el cuero cabelludo o hay algunos artefactos musculares, como se sugiere en (Luis G. Hernandez-Rojas *et al.*, 2022). Finalmente, cualquier época en la que al menos un electrodo cumplía estos criterios se inspeccionaba visualmente para descartar ensayos contaminados por ruido (como doble comprobación) y se etiquetaba como “artefacto” manualmente (ver Figura 9).

Figura 9.

Artefactos típicos que contaminan las tomas de EEG.



Nota: Tomado de (Mendoza-Montoya, 2017).

Los ensayos con épocas etiquetadas como “artefactos” se descartaron y no se utilizaron en los siguientes análisis. Por el contrario, las épocas por debajo de los niveles de umbral pasaban la

validación y se utilizaban para investigar las características discriminativas usando métodos de extracción de características.

6.3.1.2 Análisis de las señales de EEG

El análisis de tiempo-frecuencia (TF) de las series temporales de EEG es una técnica adecuada para estudiar los eventos cognitivos, como las tareas de imaginación motora (IM), que inducen modulaciones transitorias de potencia del espectro de EEG (Zhiguo Zhang, 2019). Las modulaciones de este tipo aparecen como una disminución (desincronización relacionada con eventos o ERD) o un aumento (sincronización relacionada con eventos o ERS) de la potencia espectral en bandas de frecuencia específicas (G. Pfurtscheller & Lopes da Silva, 1999). La ERD/ERS también se conoce como perturbación espectral relacionada con eventos o ERSP, que mide los cambios espectrales correspondientes a eventos espontáneos del usuario en relación con un intervalo de referencia utilizado como línea base de las señales de EEG en una amplia gama de frecuencias (Makeig, 1993). Por consiguiente, se realizó el análisis de TF en los ensayos preprocesados antes mencionados para visualizar los patrones ERD/ERS utilizando la caja de herramientas de EEGLAB (versión 2021.1) (Delorme & Makeig, 2004).

La fase de descanso de cada ensayo se descartó y no se consideró en el presente estudio, ya que no contiene actividad de EEG relevante para el análisis. La ERSP se calculó en los rangos de frecuencia de 4 a 30 Hz para todos los canales con el fin de calcular el espectro de potencia aplicando la transformada Morlet wavelet con ciclos incrementales (7 ciclos en la frecuencia más baja hasta 14 en la más alta), lo que dio como resultado 200 puntos de muestras (- 6.03, 3.02) s. La referencia de la línea de base se tomó entonces de - 3.5 a - 3 s (que corresponde al intervalo de no movimiento) al comienzo del paso 3 en la secuencia de cada ensayo. Los cambios de potencia espectral se promediaron en cada punto de tiempo y se normalizaron por los espectros de la línea de base. Las desviaciones de ERSP significativas respecto a la línea de base se analizaron mediante el método Bootstrap ($\alpha = 0.05$) (Grimann & Pfurtscheller, 2006). En consecuencia, con el ERSP se podría identificar la ERD y la ERS significativas como cambios espectrales negativos (de color azulado en el mapa de TF) y positivos (del color rojizo en el mapa de TF), respectivamente (Zhiguo Zhang, 2019).

6.3.1.3 Extracción y selección de características

Se implementaron algunos de los métodos de extracción de características que más se utilizan en la literatura de ICC en relación con el análisis de señales de EEG. Los algoritmos de extracción de características implementados se basan en el análisis de tiempo con el modelo autorregresivo (AR, por sus siglas en inglés, *autoregressive model*) (Moreno Arévalo, 2021), frecuencia con la densidad espectral de potencia (PSD, por sus siglas en inglés, *power spectral density*) (Oikonomou *et al.*, 2017), tiempo-frecuencia con la transformada wavelet discreta (DWT, por sus siglas en inglés, *discrete wavelet transform*) (Virgilio G. *et al.*, 2020) y espacio con el método de patrón espacial común (CSP, por sus siglas en inglés, *common spatial pattern*) (Triana-Guzman *et al.*, 2022). Uno de los algoritmos más exitosos en la investigación de ICC para la extracción de características es el patrón espacial común (CSP) (Padfield *et al.*, 2019). Este método encuentra filtros espaciales que proyectan los datos de EEG en un nuevo espacio en el que las varianzas correspondientes a una clase se maximizan mientras que las varianzas de una segunda clase se minimizan (Lotte & Cuntai Guan, 2011). En este estudio, se implementó una versión mejorada del algoritmo CSP original, conocido como el algoritmo de patrón espacial común con un banco de filtros espectrales (FBCSP, por sus siglas en inglés, *filter bank common spatial pattern*) (Ang *et al.*, 2012), utilizando cinco filtros digitales pasa-banda de respuesta finita (FIR) centrados en las bandas de frecuencia de EEG (Theta: 4-8 Hz, Alfa: 8-12 Hz, Beta-Baja: 12-16 Hz, Beta-Media: 16-20 Hz, Beta-Alta: 20-30 Hz) (Chen *et al.*, 2018). Todos los filtros del banco de filtros se diseñaron en el dominio de la frecuencia utilizando una función gaussiana con ganancia unitaria.

El enfoque más directo para obtener características por época consiste en calcular en cada canal de EEG la potencia de cada banda de frecuencia y sus correspondientes armónicos. Una opción para estimar el contenido espectral de la señal de cada canal de EEG es el método de Welch (Oikonomou *et al.*, 2017). Este algoritmo divide los datos de EEG en segmentos superpuestos y calcula la función de densidad espectral de potencia (PSD) de cada subventana utilizando la transformada rápida de Fourier (FFT) y los periodogramas modificados. La potencia de cada banda de frecuencia por canal se obtiene promediando los valores de los periodogramas. Sólo las frecuencias de interés (4-30 Hz) se consideran características, ignorando el resto de los valores calculados. En el algoritmo implementado, se utiliza una ventana de tipo Hamming y se divide en ocho segmentos con un 50% de solapamiento. En total, por cada época se obtiene un vector de 17 características.

Un enfoque diferente para la extracción de características hace uso de estadísticas de orden superior y la descomposición multirresolución con la transformada wavelet discreta (DWT)

(Virgilio G. *et al.*, 2020). En el análisis wavelet, podemos distinguir las aproximaciones y los detalles de la señal de EEG. Las aproximaciones son los componentes de baja frecuencia de la señal. Los detalles son los componentes de alta frecuencia. La DWT se calcula mediante el filtrado sucesivo en una subbanda de aproximación con información de baja frecuencia de la señal en el dominio del tiempo y una subbanda de detalle con la señal en el dominio del tiempo de alta frecuencia hasta alcanzar cinco niveles de descomposición (Virgilio G. *et al.*, 2020). Así mismo, se utiliza la combinación de wavelet Daubechies de orden 10 (B. Xu & Song, 2008). Finalmente, se calcula la varianza, la asimetría y la curtosis de la última subbanda de aproximación y de las cinco subbandas de detalles de las descomposiciones de la señal de EEG. También en este caso se divide la señal de EEG en bloques consecutivos superpuestos en ventanas de un segundo de longitud con un 50% de solapamiento. Para cada bloque se calcula la transformada wavelet. Por último, para reducir el número de características, se usa el criterio de separabilidad de Fisher para ordenar cada característica en función de la puntuación y se seleccionan las 50 características con mayor puntuación.

Otro enfoque frecuentemente utilizado para la extracción de características de cada época de EEG se basa en el modelo autorregresivo (AR). Las técnicas de procesamiento a través del modelo AR en el análisis de tiempo en EEG, son herramientas que definen un modelo de estudio para la identificación de características a través de series de tiempo en donde el modelo matemático se ajusta al modelo deseado para la etapa de clasificación (Moreno Arévalo, 2021). La señal de EEG puede considerarse como la salida de un promedio lineal de datos que se filtran con un ruido blanco. Este filtro, denominado AR, es una combinación lineal de la propia salida anterior (B. Xu & Song, 2008). Este método pertenece al grupo de fórmulas de predicción lineal en las que una muestra $x[n]$ se predice utilizando las muestras anteriores ($x[n-1], x[n-2], \dots, x[n-p]$). La notación $AR(p)$ se refiere al modelo autorregresivo de orden p . Un modelo $AR(p)$ de media cero se representa mediante (Kołodziej *et al.*, 2010):

$$x_n = - \sum_{i=1}^p \varphi_i x_{n-i} + \varepsilon_n, \quad (1)$$

donde $\varphi_1, \dots, \varphi_p$ son los parámetros (o coeficientes) del modelo AR, x_n es la señal en un punto de muestra n y ε_n es un ruido blanco de media cero. Las características de la señal de EEG se calculan como los parámetros del modelo. Se utilizó el orden seis y el método de Burg para estimar los coeficientes del modelo AR basado en las sugerencias (B. Xu & Song, 2008). Para reducir el número de características, se seleccionan las 50 características con mayor puntuación según el criterio de separabilidad de Fisher.

El enfoque de CSP es útil cuando los componentes de frecuencia de las señales moduladas pueden variar entre los sujetos. Por ejemplo, en el principio de imaginación motora (IM), una determinada frecuencia del ritmo sensoriomotor no es la misma para todos los usuarios (Saha & Baumert, 2020). Por esta razón, cada época preprocesada de un conjunto de datos de entrenamiento se filtra utilizando el banco de filtros FIR para obtener épocas filtradas espectralmente $Y = [y_{e,f}(t)]_{n_e \times n_f \times n_t}$, donde n_e es el número de electrodos de EEG, n_t es el número de muestras de la señal de EEG y n_f es la subbanda de frecuencia de EEG (4-8 Hz, 8-12 Hz, 12-16 Hz, 16-20 Hz, 20-30 Hz).

En este trabajo, se estudia la clasificación bi-clase de dos pares de tareas experimentales: MotorImageryA vs. IdleStateA para la transición de sentado a parado y MotorImageryB vs. IdleStateB para la transición de parado a sentado (Triana-Guzman *et al.*, 2022). A continuación, se aplica el algoritmo CSP a cada subbanda y a cada par de tareas experimentales. El algoritmo CSP proporciona una matriz de tamaño $n_e \times n_e$ de proyección $W = [w_1, w_2, \dots, w_{n_e}]'$ para cada par de tareas experimentales. Esta matriz es un conjunto de patrones espaciales dependientes del sujeto, que reflejan la activación específica de las áreas corticales durante la tarea experimental. Con la matriz de proyección W , la descomposición de una época Y se describe mediante $Z = WY$, donde esta transformación proyecta la varianza de las señales de EEG filtradas de Y en las filas de Z y da lugar a n_e nuevas series de tiempo. Las columnas de W^{-1} son un conjunto de CSP que pueden considerarse distribuciones de fuentes de EEG invariables en el tiempo (Ortner *et al.*, 2015).

El número de filtros espaciales retenidos se eligió como seis para todos los sujetos y conjuntos de entrenamiento, como se recomienda para conseguir un buen desempeño (Blankertz, Tomioka, *et al.*, 2008). Los tres primeros filtros espaciales son los que más contribuyen a la varianza de los datos de una clase, y los tres últimos filtros espaciales son los que más contribuyen a la varianza de los datos de la otra clase. Si $n_m = 6$ representa el número de filtros espaciales retenidos por subbanda de frecuencia, las épocas filtradas espectralmente Y se transforman en épocas filtradas espacialmente $Y^{CSP} = [y_{e,f}^{CSP}(t)]_{n_m \times n_v \times n_f \times n_s}$, donde n_v es el número de ventanas de tiempo de n_s muestras para cada época de EEG. Durante la extracción de características en modo *offline*, cada época de EEG se divide en dos ventanas de tiempo de intervalos $[-1, 0)$ s y $[0, 1)$ s, donde 0 s es el tiempo de inicio del paso 3 en la secuencia de un ensayo. Para cada subbanda de frecuencia y canal proyectado, la ICC calcula el logaritmo de la

varianza. Esto da como resultado 30 características ($n_m \times n_f$) por 180 observaciones ($n_{\text{epocas}} \times n_v$), donde n_{epocas} es el número de épocas de entrenamiento del modelo de clasificación para la transición (A) de sedente-bípedo ($n_{\text{epocas}} = 90$) y para la transición (B) de bípedo-sedente ($n_{\text{epocas}} = 90$) de cada participante. Por último, se aplica el criterio de Fisher para evaluar las características extraídas.

6.3.1.4 Clasificación de patrones

Los clasificadores lineales han demostrado ser una opción eficiente para la detección de ritmos cerebrales de la EEG en paradigmas de imaginación motora (IM) para aplicaciones de ICC (Oikonomou *et al.*, 2017). En esta categoría, el análisis discriminante lineal (LDA, por sus siglas en inglés, *linear discriminant analysis*) y la máquina de soporte vectorial (SVM, por sus siglas en inglés, *support vector machine*) pueden proporcionar resultados óptimos y superar a las técnicas de clasificación más complejas. Además, el LDA es relativamente fácil de entrenar y evaluar y requiere un bajo costo computacional para clasificar nuevas observaciones. Por lo tanto, se utilizan dos modelos de clasificación binaria basados en LDA con covarianzas regularizadas (RLDA, por sus siglas en inglés, *regularized linear discriminant analysis*) para discriminar con un primer modelo, MotorImageryA vs. IdleStateA para el escenario de clasificación de sentado a parado, y con un segundo modelo, MotorImageryB vs. IdleStateB para el escenario de clasificación de parado a sentado (Triana-Guzman *et al.*, 2022).

Adicionalmente, se implementaron otros dos clasificadores utilizando la SVM con función de base radial (RBF, del inglés, *radial basis function*). Este algoritmo ha mostrado un buen rendimiento en aplicaciones *offline* de decodificación de IM para los movimientos de ponerse de pie y sentarse con señales de EEG (Chaisaen *et al.*, 2020). Tanto el RLDA como la SVM-RBF toman una decisión en función de una combinación lineal del vector de características. Si x representa un vector real de n_c características para una época de EEG, estos tipos de modelos de clasificación evalúan la función lineal

$$f(x) = g \left(\sum_{i=1}^{n_c} b_i x_i + d \right), \quad (2)$$

donde $b = [b_1, b_2, \dots, b_{n_c}]'$ y d son los coeficientes del modelo lineal, y $g(a)$ es una función escalar. Entonces, el modelo de clasificación devuelve una etiqueta o categoría $l \in \{1, -1\}$ a la observación dada en función de la evaluación de $f(x)$. Un criterio típico es utilizar un valor de

umbral tal que los valores por encima de él tengan la etiqueta de clase $l = 1$. Por el contrario, los valores por debajo de este umbral corresponden a la otra clase ($l = -1$).

LDA encuentra la clase l que maximiza la condición de probabilidad $p(L = l|X = x)$ (Ng & Jordan, 2001). Asume que las funciones de densidad de probabilidad $p(X = x|L = -1)$ y $p(X = x|L = 1)$ están ambas distribuidas normalmente con vectores de media m_{-1} , m_1 y matrices de covarianza C_{-1} , C_1 . En este caso, se utilizó LDA con covarianzas regularizadas (RLDA) como modelo de clasificación, que tiene la ventaja de encontrar los parámetros de regularización automáticamente utilizando solo los datos originales de las matrices de covarianza (Lotte & Cuntai Guan, 2011). Bajo estas asunciones, la regla de decisión $p(L = 1|X = x) > p(L = -1|X = x)$ se expresa como sigue (Mendoza-Montoya, 2017):

$$b'x + d > 0, \quad (3)$$

donde

$$b = 2C^{-1}(m_1 - m_{-1}), \quad (4)$$

$$d = \ln\left(\frac{P(L = -1)}{P(L = 1)}\right) + m_{-1}'C_{-1}^{-1}m_{-1} - m_1'C_1^{-1}m_1, \quad (5)$$

y $P(L = l)$ es la probabilidad de la etiqueta de clase l . Estos clasificadores son sencillos y tienen un bajo requerimiento computacional, lo que los hace adecuados para la ICC *online* (Mao *et al.*, 2017).

La SVM toma como entrada n_k observaciones etiquetadas del conjunto de entrenamiento $x = [x_1, x_2, \dots, x_{n_k}]$ de vectores de características junto con sus etiquetas $l = [l_1, l_2, \dots, l_{n_k}]$. La idea de este método es encontrar el hiperplano de separación óptimo que maximiza la distancia (o margen máximo) entre las observaciones más cercanas (conocidas como vectores de soporte) de las dos clases $\{1, -1\}$ (Luis Guillermo Hernandez-Rojas *et al.*, 2020). El margen óptimo es la región delimitada por los dos hiperplanos paralelos que se encuentran entre las clases. Los hiperplanos pueden describirse mediante las ecuaciones $b'x + d = 1$ y $b'x + d = -1$, mientras que el hiperplano en el medio está definido por la expresión $b'x + d = 0$. Geométricamente, el tamaño del margen viene dado por $2/\|b\|$. Si los datos de entrenamiento son linealmente separables, el hiperplano óptimo se obtiene minimizando $\|b\|$ (que maximiza el tamaño del margen) y previniendo que una observación caiga dentro del margen. Este método se conoce como margen duro (del inglés, *hard-margin*). La versión de margen suave (del inglés, *soft-margin*) de este

algoritmo es una extensión para datos que no son linealmente separables. El hiperplano de separación óptimo se obtiene encontrando una solución al problema de minimización (Manyakov *et al.*, 2011; Mendoza-Montoya, 2017):

$$\arg \min_{(b,d)} \left[\frac{1}{n_k} \sum_{k=1}^{n_k} \max(0, 1 - l_k(b'x_k + d)) + \lambda \|b\|^2 \right] \quad (6)$$

bajo la condición

$$l_k(b'\Phi(x_k) + d) \geq 1 - \xi_k, \quad \forall k \in \{1, 2, \dots, n_k\}, \quad (7)$$

donde b' es la normal al hiperplano, $\xi_k \geq 0$ son las variables $l_k(b'x_k + d)$ que miden el error en la clasificación errónea de x_k , λ es el parámetro de regularización que se utiliza para controlar el equilibrio entre el aumento del margen y la disminución del error de clasificación y d es el término de sesgo (del inglés, *bias*). $\Phi(x_k)$ es la función de base radial (RBF) que se define como (Manyakov *et al.*, 2011):

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right), \quad (8)$$

donde γ es un parámetro que controla la dispersión de la función. Teniendo en cuenta las recomendaciones (Luis Guillermo Hernandez-Rojas *et al.*, 2020), los hiperparámetros λ y γ se fijaron en 0.01 y 1.0, respectivamente.

Para comparar, se considera una red neuronal artificial (ANN, por sus siglas en inglés, *artificial neural network*) como un clasificador no lineal (Triana Guzmán *et al.*, 2019). Se emplea el modelo de perceptron multicapa (MLP, por sus siglas en inglés, *multilayer perceptron*) conforme a su uso extendido para las tecnologías de ICC (Lotte, Bougrain, *et al.*, 2018). La red MLP sólo tiene conexiones de alimentación directa (del inglés, *feedforward*) y se entrena de forma supervisada. La arquitectura del MLP consta de una capa de entrada, una capa oculta y una capa de salida que son, generalmente, suficientes para resolver problemas de clasificación (Haykin, 2009). El número de nodos en la entrada viene dado por el número de características n_c . Se aplicó el algoritmo de retropropagación resiliente (Rprop, por sus siglas en inglés, *resilient backpropagation*) para el entrenamiento del MLP debido a su convergencia rápida y estable (Riedmiller & Braun, 1993). Se utilizaron funciones tangentes hiperbólicas en las neuronas ocultas como funciones de activación, las cuales son eficaces para salidas binarias y permiten un rango amplio de la salida de la red (Karlik & Olgac, 2011). El clasificador tiene la forma

$$f(\mathbf{x}, \mathbf{b}, \mathbf{d}) = \sum_{j=1}^{n_r} b_j^2 \tanh\left(\sum_{i=1}^{n_c} b_{ij}^1 x_i + d_j\right) + d, \quad (9)$$

donde n_r es el número de neuronas en la capa oculta con funciones de activación tangentes hiperbólicas, siendo $\mathbf{b} = \{b_1^2, b_2^2, \dots, b_{n_r}^2, b_{11}^1, \dots, b_{n_c n_r}^1\}$ y $\mathbf{d} = \{d_1, d_2, \dots, d_{n_c}, d\}$ los conjuntos de coeficientes de pesos y umbrales, respectivamente. En la capa de salida, se utilizó la función de transferencia exponencial normalizada (también conocida en inglés como *softmax*) para calcular la probabilidad de tener los eventos +1 o -1 de cada clase de la ICC.

Para cada neurona oculta se asignaron 100 inicializaciones de los pesos sinápticos al azar para evitar el efecto de las condiciones iniciales en el entrenamiento de la red. El entrenamiento de los modelos de MLP se realizó con el 80% de todos los eventos o instancias, el cual se empleó como un conjunto de ejemplos de calibración (el 70% para el entrenamiento y el 30% para la validación y la parada temprana). El número máximo de ciclos (también conocidos como “epochs”) necesarios para la parada de entrenamiento del MLP se fijó en 1000. Por otro lado, otro criterio para la parada temprana se produce cuando el desempeño de la validación ha aumentado más de 200 veces desde la última vez que disminuyó (una condición que utiliza los fallos de validación máximos). De todas las capas ocultas experimentadas, probando de 1 a 10 el número de neuronas en la capa oculta, se seleccionan los mejores modelos a partir de los valores máximos del desempeño en términos de la tasa de clasificación (clasificaciones correctas para todas las clases) dados por un conjunto de datos de prueba correspondientes al 20% restante de todos los eventos.

El objetivo de los modelos de clasificación anteriores (RLDA, SVM-RBF, MLP) era la discriminación de los diferentes pares de tareas experimentales para devolver un estado de imaginación motora o etiqueta de clase l que representara cuándo el participante estaba imaginando ($l = 1$) o no imaginando ($l = -1$) un movimiento basado en las observaciones o características resultantes correspondientes para cada época de EEG. Para ello, la ICC incorpora los dos mejores clasificadores para completar los dos modelos de aprendizaje automático que se utilizarían en las transiciones de sentado a parado y de parado a sentado, respectivamente.

6.3.1.5 Evaluación de los modelos de clasificación

En los últimos pasos de la fase *offline*, se evaluaron los dos modelos completos de aprendizaje automático de los sujetos de estudio para las acciones de transición: (i) Sedente-bípedo y (ii) Bípedo-sedente. La evaluación de estos modelos depende de los datos recolectados y etiquetados que se obtienen de los conjuntos de datos A y B en los experimentos *offline*. Para esta evaluación, los modelos de aprendizaje automático i y ii para cada participante se evaluaron

independientemente aplicando un procedimiento de validación cruzada de cinco iteraciones (del inglés, *five-fold cross-validation*) para evitar el sobreajuste (del inglés, *overfitting*) y medir la generalización en cada modelo (Berrar, 2019). En este procedimiento, el conjunto de ensayos de A y B se dividió aleatoriamente en cinco subconjuntos de igual tamaño cada uno, respectivamente. Para cada iteración, la ICC utiliza cuatro subconjuntos para entrenar los modelos $m \in \{i, ii\}$. Al mismo tiempo, el subconjunto restante se utiliza para probar el modelo m correspondiente. Este proceso se repitió con subconjuntos de entrenamiento y prueba mutuamente excluyentes hasta completar las cinco validaciones cruzadas. La exactitud de la clasificación $acc_{m,c}$ de cada clase $c \in \{\text{MotorImagery}, \text{IdleState}\}$ se calcula como se describe a continuación:

$$acc_{m,c} = \frac{n_{\text{correct}}}{n_{\text{total}}} \times 100\%, \quad (10)$$

donde $acc_{m,c}$ es la exactitud *offline*, n_{total} es el número total de eventos de la clase c , y n_{correct} es el número de eventos o instancias clasificadas correctamente en la clase c por el modelo m . Además, se calcula $acc_{m,\text{overall}} = 0.5 \times (acc_{m,\text{MotorImagery}} + acc_{m,\text{IdleState}})$ para describir la exactitud global (del inglés, *overall accuracy*) del modelo y también se calculan las matrices de confusión.

6.3.1.6 Análisis estadístico

Adicionalmente, se aplicó una prueba de permutación para evaluar el nivel de significancia de las exactitudes globales de los modelos (Good, 2006). Esta prueba repite el procedimiento de validación cruzada de cinco iteraciones mezclando las etiquetas de las clases de forma aleatoria durante el entrenamiento de los clasificadores para calcular la exactitud de la clasificación empírica. En esta metodología, la hipótesis nula (H_0) indica que las observaciones de ambas clases son intercambiables, de modo que cualquier permutación aleatoria de las etiquetas de clase produce exactitudes globales similares a las obtenidas con los datos no permutados. La hipótesis alternativa (H_1) se acepta cuando la exactitud global del modelo es un valor extremo en la distribución empírica construida con varias permutaciones aleatorias de las etiquetas. Cuando se acepta la hipótesis alternativa, podemos decir que la exactitud global del modelo está por encima del nivel de azar.

6.3.2 Fase *online*

Para cada participante, los dos modelos de aprendizaje automático obtenidos en la fase *offline* se utilizan para realizar dos experimentos *online*: (I) Sedente-bípido y (II) Bípido-sedente. A cada participante se le indicó que seleccionara, sin ningún orden concreto, 30 secuencias para el experimento I (15 ensayos de tareas MotorImageryA y 15 ensayos de tareas IdleStateA) y otras 30 secuencias para el experimento II (15 ensayos de tareas MotorImageryB y 15 ensayos de tareas IdleStateB). Cada ensayo es único y se genera de forma pseudoaleatoria antes del experimento.

La línea de tiempo de las secuencias *online* es indicada por la interfaz de usuario de la misma manera que se muestra en la Figura 8. Sin embargo, la diferencia entre las líneas de tiempo *offline* y *online* está en el paso 3. En el tercer paso de la línea de tiempo *online*, el participante debe realizar una tarea experimental en respuesta a la figura mostrada en el paso 2, y la ICC intenta detectar esta tarea en tiempo real durante 3-15 s al mismo tiempo que proporciona retroalimentación visual de la tarea que detecta.

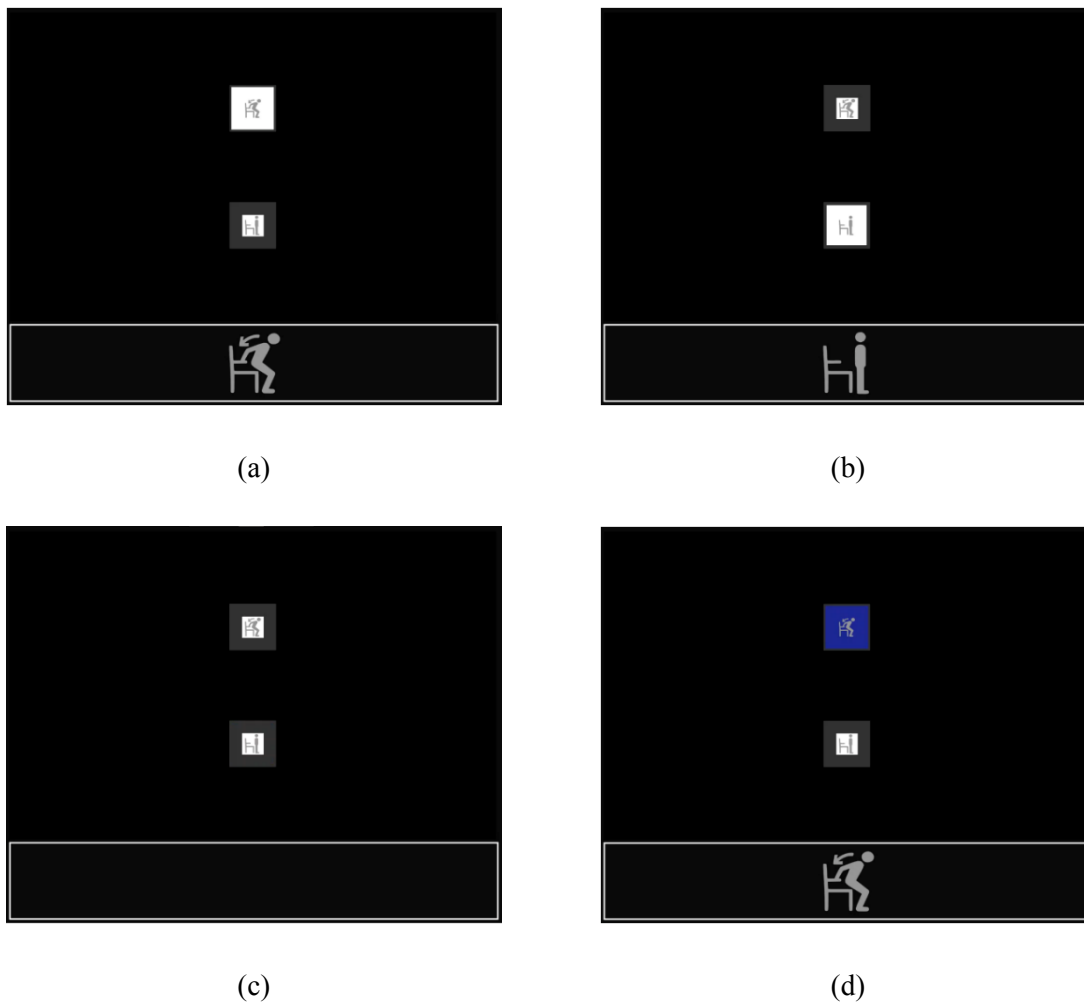
Técnicamente, la clasificación *online* de los datos de EEG de un solo ensayo podría hacerse como en la fase *offline*, ya que los clasificadores entrenados pueden aplicarse a vectores de características calculados a partir de una ventana de tiempo arbitraria. Sin embargo, es probable que esto conduzca a resultados poco fiables, ya que en la clasificación *offline* esos clasificadores se ajustan para detectar señales con un tiempo específico indicado para realizar la tarea (Blankertz *et al.*, 2001). No hay garantía de que el clasificador se comporte de forma similar cuando no se indique el instante para realizar la tarea, como en la fase *online* donde el usuario es libre para autoiniciar y autoseleccionar la tarea a realizar a su propio ritmo. Como se sugiere en (Blankertz *et al.*, 2001; Blankertz, Losch, *et al.*, 2008; Mendoza-Montoya, 2017; Syan & Harnarinesingh, 2010), se suelen utilizar ventanas deslizantes para aumentar la robustez de la clasificación *online* frente a las señales continuas (no fijas) y desplazadas (desfasadas) a lo largo del tiempo. Siguiendo dichas recomendaciones, durante la extracción de características *online*, la longitud de los datos de cada época es de 1 s, es decir, 250 muestras, y la ICC las divide en cinco ventanas deslizantes (50 muestras cada una), lo que da lugar a cinco vectores de características de cada ensayo.

La ICC procesa y proporciona retroalimentación visual continua sobre los resultados obtenidos tras clasificar cinco ventanas deslizantes consecutivas (50 muestras cada una) de una época (250 muestras). Si una tarea experimental produce una alta actividad relacionada con la imaginación motora (MotorImagery), la ICC hace que el fondo blanco de la figura correspondiente se vea más grande (ver Figura 10a). Si la actividad relacionada con el estado de reposo o inactividad

(IdleState) es mayor, la ICC hace que el fondo blanco de esa figura se vea más grande (ver Figura 10b). En caso contrario, la ICC mantiene los fondos de ambas figuras del mismo tamaño (véase la Figura 10c). Esta retroalimentación visual notifica al participante cuando la ICC está detectando la actividad relacionada con la tarea experimental y ayuda a aumentar o disminuir las modulaciones espontáneas en base a la imaginación de los movimientos previstos (Yu *et al.*, 2015).

Figura 10.

Retroalimentación visual continua durante el experimento online bípedo-sedente.



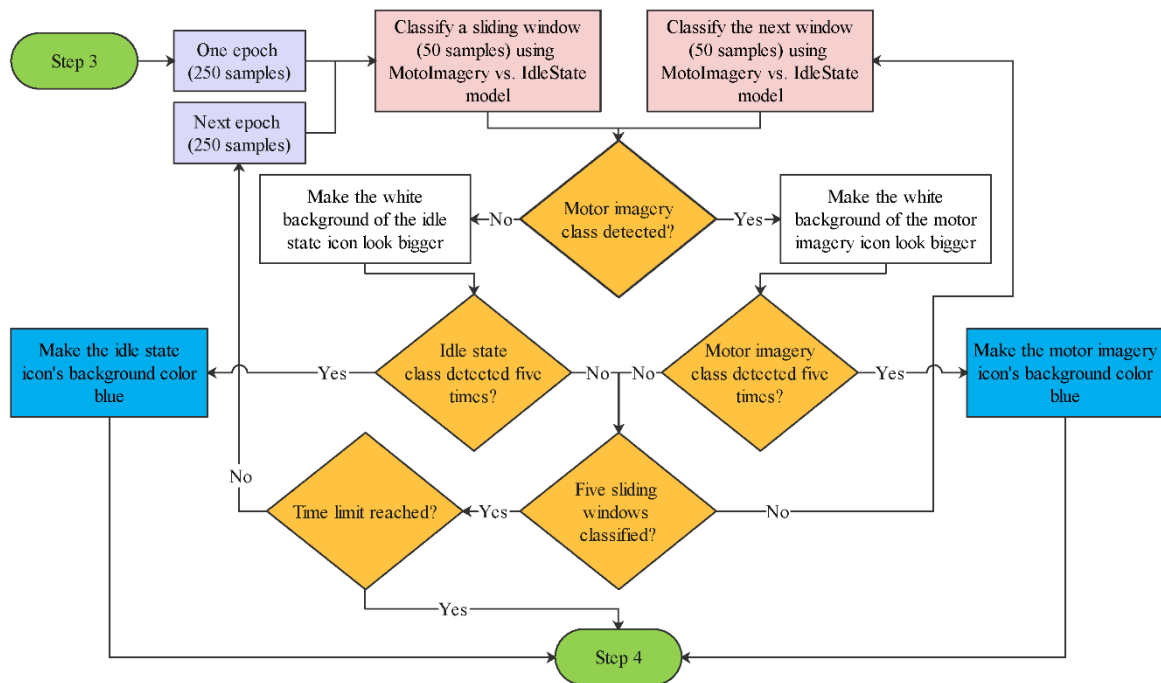
Nota: Tomado de (Triana-Guzman *et al.*, 2022).

Como se muestra en la Figura 11, el clasificador etiqueta cada una de las ventanas deslizantes de 50 muestras con el nombre de una de las tareas experimentales que detecte. La etiqueta podría utilizarse directamente para determinar la acción o el comando de control que se debe producir con la ICC. Sin embargo, debido a que la exactitud de una ICC basada en IM es

típicamente inferior al 90%, el riesgo de ejecutar la acción incorrecta es alto (Irimia *et al.*, 2018). Por este motivo, la ICC solo genera señales de comando o acción cuando se ha detectado una tarea experimental varias veces durante unos segundos. El tiempo mínimo requerido es de unos 3 s: 1 s para adquirir una época completa de señales de EEG, otro segundo para clasificar las cinco ventanas deslizantes de la época, y un tercer segundo para seleccionar un comando o acción a ejecutar basado en el resultado de la clasificación de las cinco ventanas deslizantes.

Figura 11.

Diagrama de flujo de la clasificación online.



Nota: Tomado de (Triana-Guzman *et al.*, 2022).

Cuando se detecta la misma etiqueta de tarea experimental cinco veces consecutivas en una época, la ICC hace que el fondo de la figura correspondiente sea de color azul (véase la Figura 10d). De lo contrario, si la ICC no la detecta cinco veces consecutivas, entonces espera nuevas etiquetas y descarta las más antiguas. Si la ICC detecta la tarea experimental solicitada en menos de 15 s, la secuencia se interrumpe para proporcionar retroalimentación visual (véase la Figura 10d) y continúa con el paso 4 (véase la Figura 11). Por otro lado, si la ICC no reconoce la tarea experimental y alcanza el límite de tiempo de 15 s, la ICC simplemente continúa con el paso 4.

6.3.2.1 Evaluación de la interfaz cerebro-computadora

La evaluación *online* tiene como finalidad investigar la viabilidad de la interfaz cerebro-computadora (ICC) para decodificar en tiempo real las dos clases de tareas mentales (MotorImagery vs. IdleState) durante los experimentos I y II. En ese sentido, el procedimiento de evaluación *online* se lleva a cabo para cada participante de forma independiente utilizando sus dos modelos de aprendizaje automático respectivos. El desempeño de la ICC se evalúa en términos de las siguientes métricas de detección que se calculan utilizando las ecuaciones (11)-(15).

$$TVP = \frac{VP}{VP+FN}, \quad (11)$$

$$TVN = \frac{VN}{VN+FP}, \quad (12)$$

$$acc_{online} = \frac{VP+VN}{VP+VN+FP+FN}, \quad (13)$$

$$VPP = \frac{VP}{VP+FP}, \quad (14)$$

$$VPN = \frac{VN}{VN+FN}, \quad (15)$$

donde:

- La sensibilidad (del inglés, *sensitivity*) o tasa de verdaderos positivos (TVP) indica el porcentaje de veces que la clase MotorImagery es detectada correctamente (VP son los verdaderos positivos y FN los falsos negativos).
- La especificidad (del inglés, *specificity*) o tasa de verdaderos negativos (TVN) denota el porcentaje de veces que la clase IdleState es detectada correctamente (VN son los verdaderos negativos y FP los falsos positivos).
- La exactitud *online* (acc_{online}) representa la probabilidad de detectar correctamente las clases MotorImagery y IdleState dado el número total de intentos para detectarlas.
- El valor predictivo positivo (VPP), también llamado precisión, es la probabilidad de que la detección de la clase MotorImagery sea correcta dado el número total de veces que se detecta esa clase.
- El valor predictivo negativo (VPN) es la probabilidad de que la detección de la clase IdleState sea correcta dado el número total de veces que se detecta esa clase.

La tasa de transferencia de información (ITR, por sus siglas en inglés, *information transfer rate*) también se utiliza como métrica de desempeño para la evaluación *online* de la ICC. El cálculo de esta métrica se basa en la cantidad de información transferida por unidad de tiempo. La ITR se calcula para cada participante en bits/min utilizando la siguiente fórmula (Y. He *et al.*, 2018):

$$ITR = \frac{60}{T} \times [1 + (acc_{online}) \log_2(acc_{online}) + (1 - acc_{online}) \log_2(1 - acc_{online})], \quad (16)$$

donde T es el tiempo promedio desde la realización de la tarea hasta su detección (tiempo de detección en segundos). En estas condiciones, la máxima tasa de transferencia de información posible es de 20 bits/min para cada experimento *online* (Wolpaw *et al.*, 2002).

Capítulo 7. Resultados y Análisis


La perturbación espectral relacionada con eventos o ERSP, se ha estudiado ampliamente para medir la desincronización/sincronización relacionada con eventos (ERD/ERS) como uno de los marcadores de actividad cerebral para las tareas de imaginación motora (IM). No obstante, solamente una pequeña cantidad de estudios han tratado el comportamiento del cerebro en los ritmos de ERD/ERS durante la imaginación de los movimientos de ponerse de pie y sentarse y los efectos de la complejidad de la tarea de imaginar dichos movimientos (Bulea *et al.*, 2014; Chaisaen *et al.*, 2020; Choi *et al.*, 2020; Mashat *et al.*, 2019; B. Singh & Natsume, 2022; Z. Zhou *et al.*, 2007). Para superar estas limitaciones, se propuso un nuevo paradigma de interfaz cerebro-computadora (ICC) utilizando información del estado de reposo o inactivo, una condición neutral, para facilitar el reconocimiento de las características distintivas de las tareas de imaginación motora.

La Figura 12 representa la ERSP agrupada para todos los 32 participantes en los mapas de tiempo-frecuencia (TF) promediados de todos los electrodos y todas las topografías del cuero cabelludo en 2-D a nivel de grupo durante cada etapa de los experimentos de sedente-bípedo y bípedo-sedente (excluyendo el período de descanso). La ERSP estima la ERD/ERS de toda la duración de los ensayos en relación con los espectros de la línea de base de 4 a 30 Hz. Todos los valores de ERSP que fueron significativos en comparación con la línea de base ($\alpha = 0.05$), se ilustran en la Figura 12 hacia el color azul (ERD) y rojo (ERS).

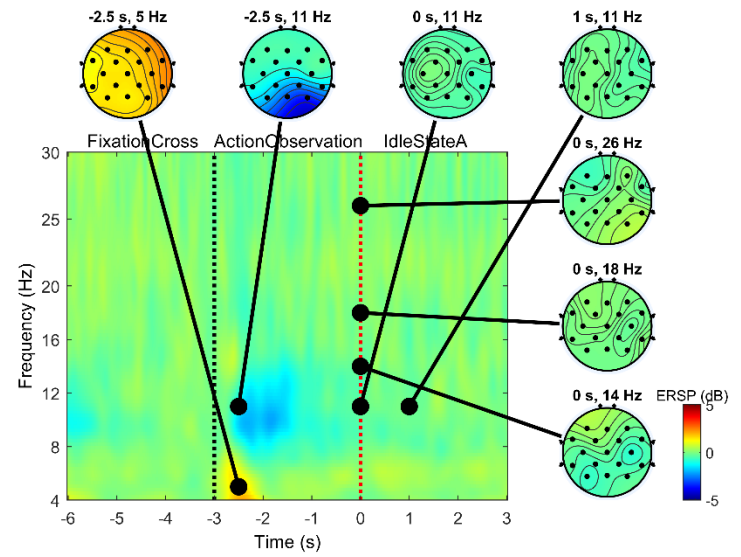
En la Figura 12 se puede ver una tendencia a la disminución de la potencia de la banda Alfa para la etapa de observación de la acción (ActionObservation, de -3 a 0 s) en todos los ensayos de sedente-bípedo y bípedo-sedente, indicando ERD principalmente en las regiones parietal y parieto-occipital. Sólo para la etapa de imaginación motora (ver Figura 12a y Figura 12c), se encuentra que la ERD se sostiene hacia las posiciones de los electrodos centro-parietales y centrales. Sin embargo, esta ERD no está presente en el estado de reposo (ver Figura 12b y Figura 12d) en todos los ensayos de ambos experimentos. Además, se evidencia un aumento significativo en la potencia de la banda Beta, que indica ERS, en las etapas de imaginación motora (MotorImageryA y MotorImageryB) de todos los ensayos en comparación con las etapas de los estados de reposo (IdleStateA y IdleStateB), respectivamente.

Figura 12.


Mapas de tiempo-frecuencia y topografías espectrales de EEG: (a) *MotorImageryA*, (b) *IdleStateA*, (c) *MotorImageryB*, y (d) *IdleStateB*.



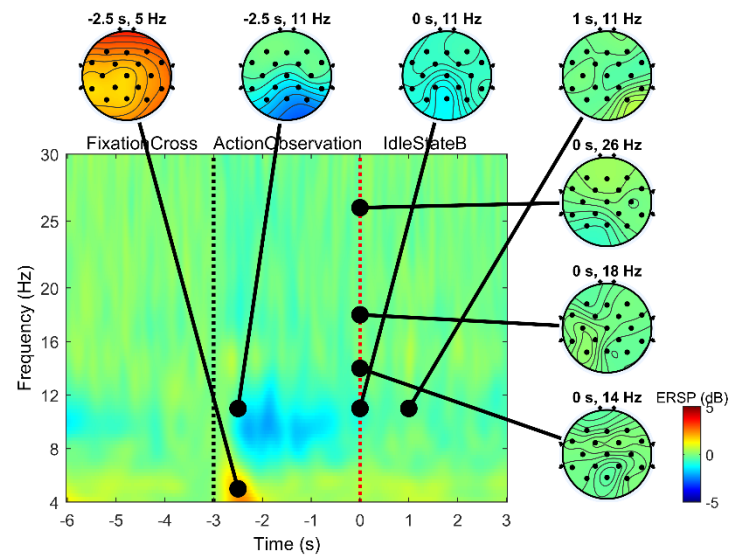
(a)



(b)



(c)



(d)

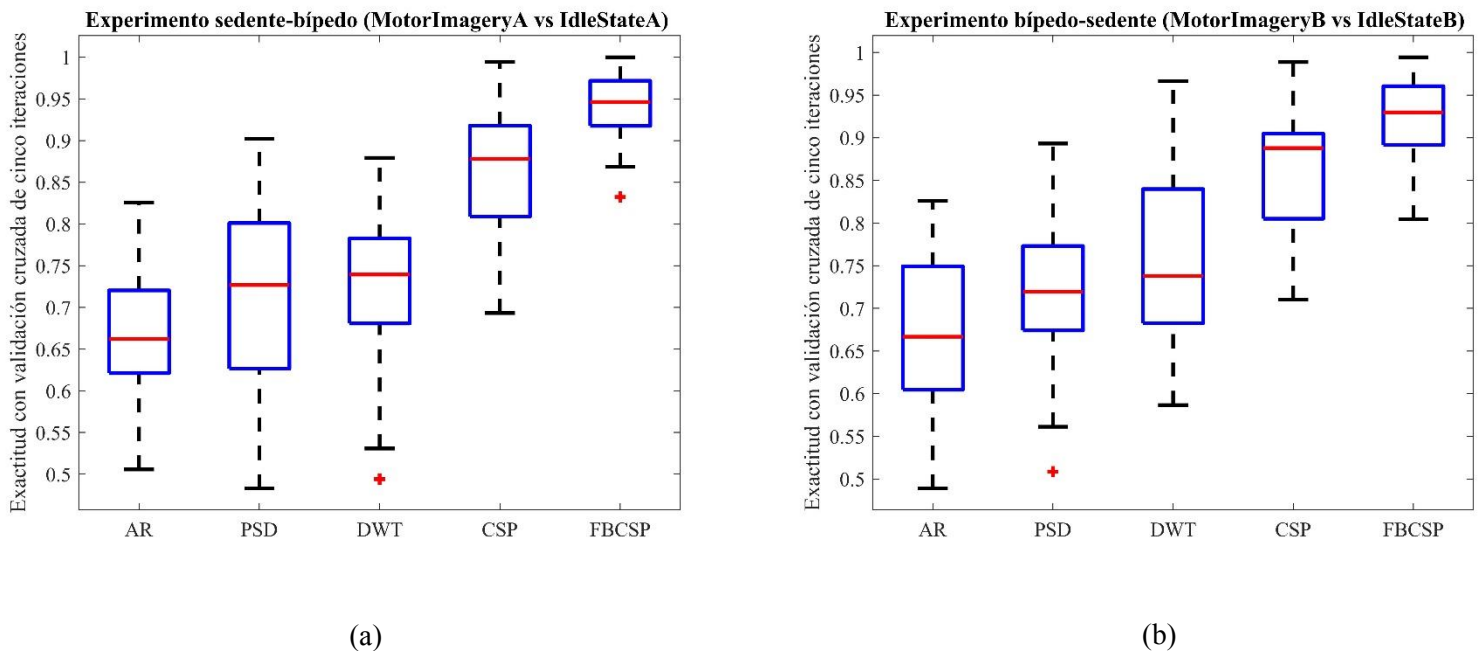
Nota: Se muestran los resultados de todos los participantes agrupados durante cada etapa (excepto descanso) de los experimentos de sedente-bípodo (paneles a y b) y bípodo-sedente (paneles c y d).

Tomado de (Triana-Guzman *et al.*, 2022).

La Figura 13 muestra la comparación entre las exactitudes de clasificación obtenidas con validación cruzada de cinco iteraciones de forma independiente para todos los participantes con cada uno de los diferentes métodos de extracción de características. Con cada método, se utilizó el criterio de Fisher para evaluar las características extraídas y la técnica de análisis discriminante lineal (LDA) como clasificador binario para encontrar los modelos de aprendizaje automático de MotorImageryA vs. IdleStateA y MotorImageryB vs. IdleStateB por separado por cada método. Los métodos comparados fueron: modelo autorregresivo (AR), densidad espectral de potencia (PSD), transformada wavelet discreta (DWT), patrón espacial común (CSP) sin y con un banco de filtros espectrales (FBCSP) en las bandas de frecuencia de EEG (Theta: 4-8 Hz, Alfa: 8-12 Hz, Beta-Baja: 12-16 Hz, Beta-Media: 16-20 Hz, Beta-Alta: 20-30 Hz).

Figura 13.

Exactitud de clasificación (a) MotorImageryA vs. IdleStateA y (b) MotorImageryB vs. IdleStateB.



La ICC logró las mejores exactitudes del 94.63% y 92.97% en promedio con el algoritmo de FBCSP en los experimentos de sedente-bípido (ver Figura 13a) y bípido-sedente (ver Figura 13b), respectivamente. Seguidamente, CSP sin el banco de filtros espectrales tuvo exactitudes promedio de 88.79% y 87.82% para los experimentos de bípido-sedente y sedente-bípido, respectivamente. Luego, la DWT y la PSD tuvieron exactitudes promedio similares en los

experimentos de sedente-bípido (DWT: 73.94%, PSD: 72.67%) y bípido-sedente (DWT: 73.80%, PSD: 71.94%). No obstante, en los experimentos de sedente-bípido, la DWT tuvo una variabilidad menor que la PSD, y lo contrario ocurrió en los experimentos de bípido-sedente, en donde la PSD tuvo una variabilidad menor que la DWT. Por último, la ICC obtuvo tasas de clasificación más bajas en promedio con el modelo AR tanto en los experimentos de bípido-sedente (66.66%) como de sedente-bípido (66.20%). Es posible que la no estacionariedad de las señales de EEG tenga un efecto negativo en las estimaciones calculadas por el método AR.

Una vez más, el filtrado espacial ha demostrado ser un método fiable para las aplicaciones de ICC. El algoritmo de CSP aplicado a los datos filtrados en pasa-banda con el banco de filtros espectrales (FBCSP) es, sin lugar a duda, la mejor opción entre las técnicas de extracción de características implementadas. Por este motivo, se realizaron las siguientes pruebas con este método.

Se aplicó el criterio de Fisher para evaluar las características extraídas con el método de FBCSP de cada participante y mostrar las características de mayor rango, como se indica en la Tabla 7. Las características más comunes a todos los participantes para los escenarios de clasificación de sedente-bípido y de bípido-sedente fueron la banda de frecuencia Beta-Baja con el quinto filtro espacial y la banda de frecuencia Alfa con el sexto filtro espacial, respectivamente. En ambos escenarios de clasificación de sedente-bípido y de bípido-sedente, los valores más altos de la puntuación de Fisher fueron, respectivamente, 5.08 y 9.65 en la banda de frecuencia Beta-Baja del participante de identificación P25. Los valores más bajos de la puntuación de Fisher fueron de 0.32 para el escenario de clasificación de sedente-bípido en la banda de frecuencia Theta del participante de identificación P03 y de 0.34 para el escenario de clasificación de bípido-sedente en la banda de frecuencia Alfa del participante de identificación P13.

Tabla 7.

Comparación de las características de mayor rango de cada participante.

Identificación de participante	Sedente-bípido			Bípido-sedente		
	Característica		Puntuación de Fisher	Característica		Puntuación de Fisher
	Banda de frecuencia	Filtro espacial		Banda de frecuencia	Filtro espacial	
P01	Alfa	1	3.64	Beta-Alta	2	2.03
P02	Beta-Baja	4	1.23	Beta-Media	1	0.52
P03	Theta	5	0.32	Alfa	4	0.40
P04	Beta-Baja	6	2.61	Alfa	6	2.01

P05	Beta-Alta	6	1.65	Beta-Alta	2	1.13
P06	Alfa	5	2.71	Alfa	4	1.98
P07	Beta-Media	2	1.31	Beta-Alta	2	1.68
P08	Beta-Media	6	0.58	Beta-Baja	6	0.54
P09	Beta-Baja	5	2.32	Beta-Baja	5	1.93
P10	Alfa	5	3.97	Alfa	6	1.75
P11	Beta-Alta	5	1.13	Alfa	6	1.70
P12	Beta-Media	2	0.57	Theta	1	0.88
P13	Alfa	6	0.67	Alfa	5	0.34
P14	Alfa	5	0.87	Alfa	1	1.00
P15	Alfa	1	0.79	Alfa	5	0.54
P16	Theta	1	3.04	Alfa	2	3.33
P17	Beta-Media	1	2.14	Beta-Media	1	1.61
P18	Beta-Alta	6	0.71	Alfa	5	0.57
P19	Beta-Baja	6	0.84	Alfa	6	0.72
P20	Beta-Baja	1	1.04	Beta-Baja	2	2.45
P21	Theta	6	0.62	Beta-Media	6	0.55
P22	Beta-Baja	4	1.00	Theta	1	0.95
P23	Beta-Baja	5	4.82	Beta-Alta	2	0.63
P24	Beta-Baja	1	0.90	Beta-Alta	1	1.15
P25	Beta-Baja	5	5.08	Beta-Baja	6	9.65
P26	Beta-Alta	2	1.30	Theta	2	0.99
P27	Beta-Baja	6	2.39	Alfa	5	1.63
P28	Alfa	6	0.72	Alfa	1	1.51
P29	Beta-Baja	5	3.10	Beta-Baja	5	2.16
P30	Beta-Baja	5	0.98	Alfa	6	0.80
P31	Beta-Baja	6	2.19	Alfa	6	1.24
P32	Theta	6	1.61	Alfa	3	1.05

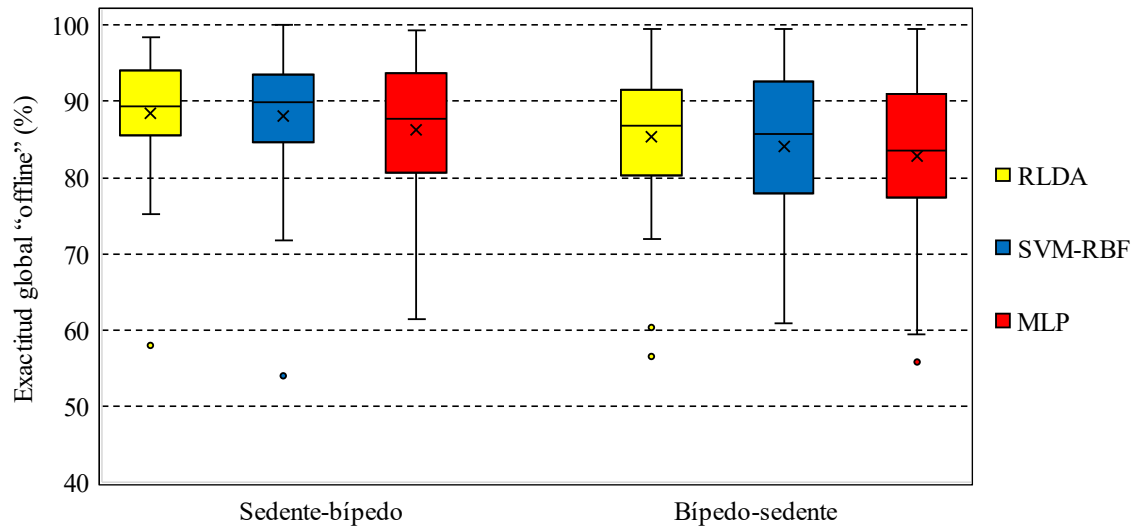
Nota: Las características se clasificaron mediante el criterio de separabilidad de Fisher.

Los clasificadores binarios RLDA, SVM-RBF y MLP descritos en el capítulo anterior también se evaluaron en este estudio. Las exactitudes globales obtenidas con estos clasificadores bi-clase se presentan en la Figura 14 para los escenarios *offline* de sedente-bípedo (MotorImageryA vs. IdleStateA) y de bípedo-sedente (MotorImageryB vs. IdleStateB). × representa la media. En esta ocasión, el método de RLDA superó a los demás (sedente-bípedo: 88.51%, bípedo-sedente: 85.29%). A este clasificador le siguió el método de SVM-RBF (sedente-bípedo: 88.07%, bípedo-sedente: 84.07%). Por último, las exactitudes más bajas se obtuvieron con el método de MLP (sedente-bípedo: 86.22%, bípedo-sedente: 82.86%). Todas las tasas de clasificación son casi similares, sin embargo, es interesante observar que los métodos lineales obtuvieron mejores resultados que las funciones no lineales. Las diferencias observadas no son muy significativas, por lo que no es posible concluir que las técnicas lineales sean mejores en este tipo de ICC. La exactitud

media del método lineal de RLDA es suficiente para lograr un buen rendimiento en condiciones *offline*. Por esta razón, en los siguientes análisis se usa RLDA como método de clasificación.

Figura 14.

Comparación de los métodos de clasificación offline de sedente-bípedo y bípedo-sedente.



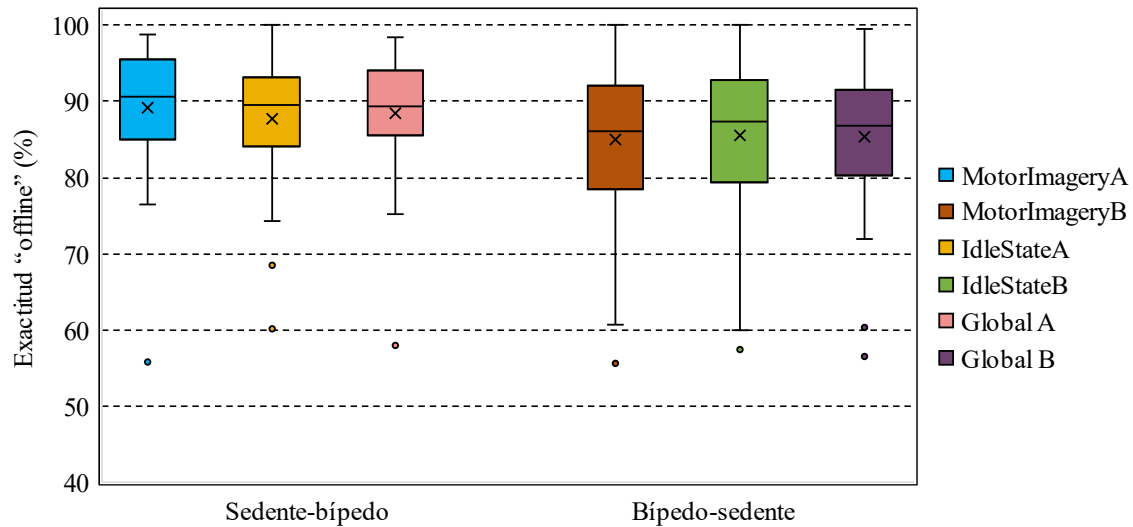
Se utilizaron gráficos de cajas y bigotes para presentar los resultados de las exactitudes de las clasificaciones *offline* estimadas con los modelos FBCSP-RLDA de cada participante mediante procedimientos de validación cruzada de cinco iteraciones independientemente con cada uno de los participantes (véase la Figura 15). En particular, las exactitudes medias (indicadas por ×) de las clases MotorImageryA, IdleStateA y global A fueron, respectivamente, del 89.21%, 87.81% y 88.51% en el escenario de clasificación de sedente-bípedo. Asimismo, las medianas de las clases MotorImageryA, IdleStateA y global A fueron de 90.58%, 89.60% y 89.36%, respectivamente. Los peores desempeños del clasificador fueron inferiores al 80% (2 mujeres y 1 hombre), mientras que 15 participantes obtuvieron desempeños del clasificador superiores al 90% (7 mujeres y 8 hombres). El mejor desempeño de los modelos fue del 98.49% y el peor del 58.02%.

La Figura 15 también muestra los resultados para el escenario de clasificación *offline* de bípedo-sedente, en donde las medias de las clases MotorImageryB, IdleStateB y global B fueron, respectivamente, del 84.99%, 85.60% y 85.29%. Asimismo, las medianas de las clases MotorImageryB, IdleStateB y global B fueron de 86.12%, 87.43% y 86.83%, respectivamente. Además, 7 participantes obtuvieron desempeños del clasificador inferiores al 80% (4 mujeres y 3

hombres) y 10 participantes superiores al 90% (6 mujeres y 4 hombres). En este caso, el mejor desempeño de los modelos fue del 99.44% y el peor del 56.51%.

Figura 15.

Exactitudes de las clasificaciones offline estimadas con los modelos FBCSP-RLDA.



Las exactitudes globales de clasificación de los modelos FBCSP-RLDA (véase la Figura 15), estimadas con validación cruzada en los escenarios de clasificación *offline*, son similares a las reportadas en la literatura relacionada con la ICC (Chaisaen *et al.*, 2020; Choi *et al.*, 2020; C. Wang *et al.*, 2018). Por ejemplo, en el análisis *offline* de (Chaisaen *et al.*, 2020), la clasificación de la observación de la acción (OA) vs. imaginación motora (IM) proporcionó una exactitud global promedio \pm error estándar del $82.73 \pm 2.54\%$ en la transición de sedente-bípido, la cual es más baja en comparación con el $85.29 \pm 1.83\%$ de la clasificación de las tareas mentales de MotorImageryA vs. IdleStateA en este estudio. En el presente estudio, la mayor exactitud promedio \pm error estándar fue del $88.51 \pm 1.43\%$ entre las clases MotorImageryB vs. IdleStateB en la transición de bípido-sedente, la cual es más alta en comparación con el $76.14 \pm 3.14\%$ en la clasificación de la OA vs. IM de (Chaisaen *et al.*, 2020). Además, en los 60 minutos de entrenamiento, 30 de los 32 participantes lograron una exactitud global por encima del nivel de azar.

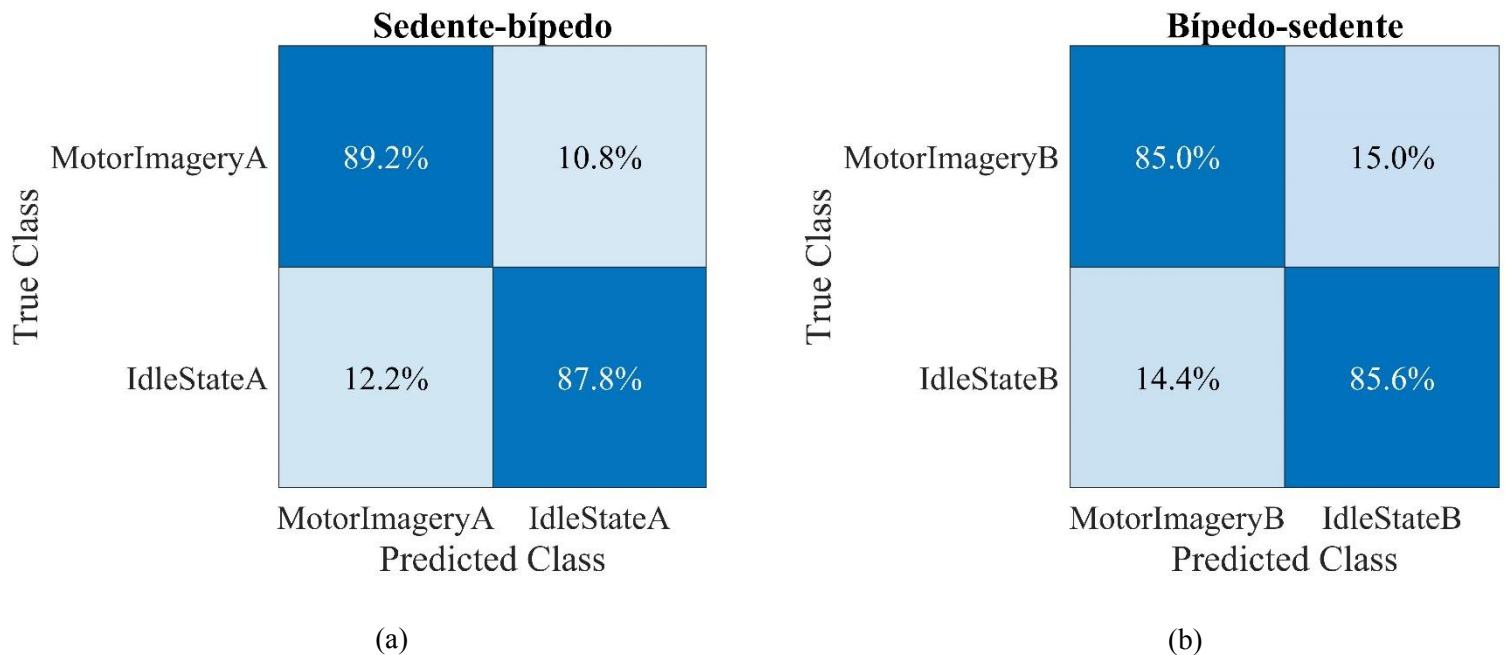
En las pruebas de permutación, las exactitudes globales de la clasificación *offline* en 30 de los 32 participantes fueron estadísticamente significativas ($p < 0.05$, 1000 permutaciones aleatorias) para los escenarios de clasificación de sedente-bípido y de bípido-sedente. Sólo el participante de identificación P03 presentó valores p superiores a 0.05 para ambos escenarios de

clasificación ($p = 0.1731$ de sedente-bípedo y $p = 0.0949$ de bípedo-sedente), lo que significa que sus exactitudes globales no fueron estadísticamente significativas. Asimismo, para el escenario de clasificación de sedente-bípedo, el valor p del participante de identificación P13 fue superior a 0.05, $p = 0.2422$ no significativo desde el punto de vista estadístico, e indica una fuerte evidencia de la hipótesis nula. En conjunto, los resultados de la clasificación *offline* mostraron la factibilidad de los modelos FBCSP-RLDA para la detección de las tareas de imaginación motora (MotorImageryA y MotorImageryB) estudiadas frente al estado de reposo (IdleStateA y IdleStateB) por encima del nivel de azar empírico. La sección de material suplementario de (Triana-Guzman *et al.*, 2022) proporciona los resultados individuales de cada participante.

La Figura 16 muestra los resultados de las matrices de confusión obtenidas en los escenarios de clasificación *offline* de sedente-bípedo y de bípedo-sedente para las clases MotorImageryA vs. IdleStateA y MotorImageryB vs. IdleStateB, respectivamente.

Figura 16.

Matrices de confusión obtenidas en los escenarios de clasificación offline de sedente-bípedo (a) y de bípedo-sedente (b) para todos los participantes.



En cuanto a la matriz de confusión de la Figura 16a, correspondiente al escenario de clasificación de sedente-bípedo, la tasa de verdaderos positivos (TVP), la tasa de falsos negativos

(TFN), la tasa de falsos positivos (TFP) y la tasa de verdaderos negativos (TVN) fueron, respectivamente, del 89.2%, 10.8%, 12.2% y 87.8%. En cuanto a la matriz de confusión de la Figura 16b, para el escenario de clasificación de bípedo-sedente, la TVP, TFN, TFP y TVN fueron 85.0%, 15.0%, 14.4% y 85.6%, respectivamente. En general, los escenarios de clasificación *offline* de sedente-bípedo y de bípedo-sedente mostraron resultados comparables y un rendimiento relativamente balanceado entre las diferentes clases.

Las matrices de confusión (véase la Figura 16) mostraron que los modelos FBCSP-RLDA entrenados generaron resultados equilibrados para las distintas clases. Los resultados de las exactitudes globales obtenidos en estos modelos entrenados con el método de prueba de permutación también confirman empíricamente esta situación (Triana-Guzman *et al.*, 2022). Estos resultados muestran que los clasificadores no estaban muy sesgados hacia ninguna tarea experimental. Sin embargo, la sensibilidad, la precisión, la especificidad, el valor predictivo negativo y la exactitud en la fase *online* no se miden mediante validación cruzada como en los experimentos *offline*. Por lo tanto, debido a la heurística descrita para detectar una tarea experimental y calcular las métricas de desempeño en los experimentos *online*, estas métricas no son directamente comparables entre las fases *online* y *offline*.

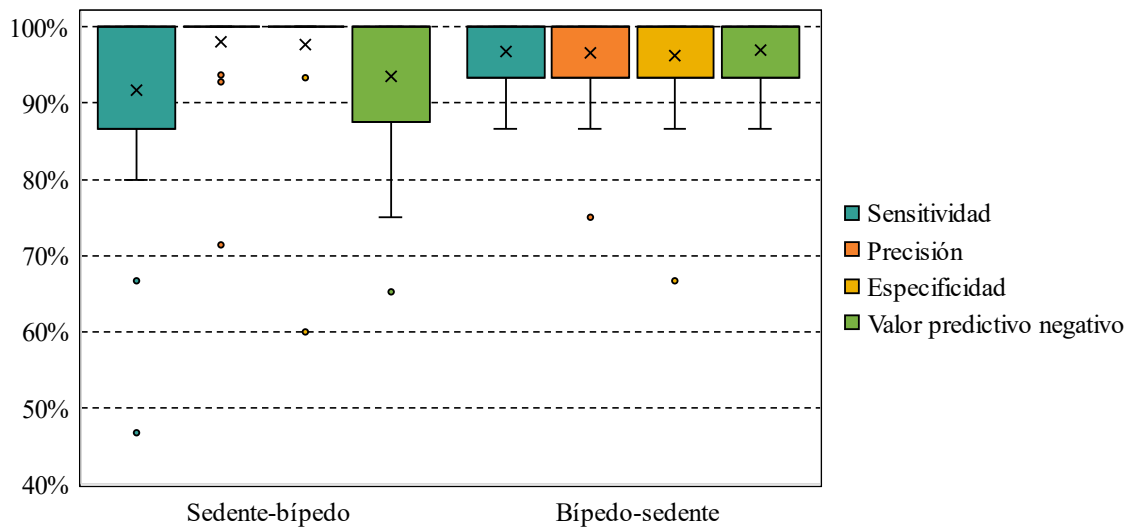
Los gráficos de cajas y bigotes de la Figura 17 muestran los resultados de las métricas de la sensibilidad, la precisión, la especificidad y el valor predictivo negativo calculados para todos los participantes en los escenarios de clasificación *online* de sedente-bípedo y de bípedo-sedente. En el escenario de sedente-bípedo, la mayoría de las métricas tienen una media (indicada por \times) de entre el 90 y el 100% y una mediana del 100% tanto para el grupo de mujeres como para el de hombres. Con respecto al escenario de bípedo-sedente, estas métricas también tienen una media de entre el 90 y el 100% y una mediana del 100%. Estos resultados indican que los modelos FBCSP-RLDA para el escenario de clasificación *online* de sedente-bípedo pueden discriminar entre las épocas de EEG de las clases MotorImageryA vs. IdleStateA tan bien como los modelos FBCSP-RLDA para las clases MotorImageryB vs. IdleStateB del escenario de clasificación *online* de bípedo-sedente.

Los resultados de la clasificación *online* (véase la Figura 17) demostraron la viabilidad de la ICC para decodificar los ritmos cerebrales a partir de las señales de EEG en tiempo real durante las tareas de imaginación motora estudiadas. Mientras que los estudios anteriores normalmente sólo presentaban la exactitud de la clasificación, en este trabajo también se calculó la sensibilidad, la precisión, la especificidad y el valor predictivo negativo para ilustrar la capacidad de detección

online de la ICC. Al considerar a todos los participantes como un solo grupo, las exactitudes promedio \pm error estándar de los experimentos *online* de sedente a parado y de parado a sedente fueron del $94.69 \pm 1.29\%$ y del $96.56 \pm 0.83\%$, respectivamente, que están por encima del rango de los estudios anteriores (Choi *et al.*, 2020; Noda *et al.*, 2012; C. Wang *et al.*, 2018).

Figura 17.

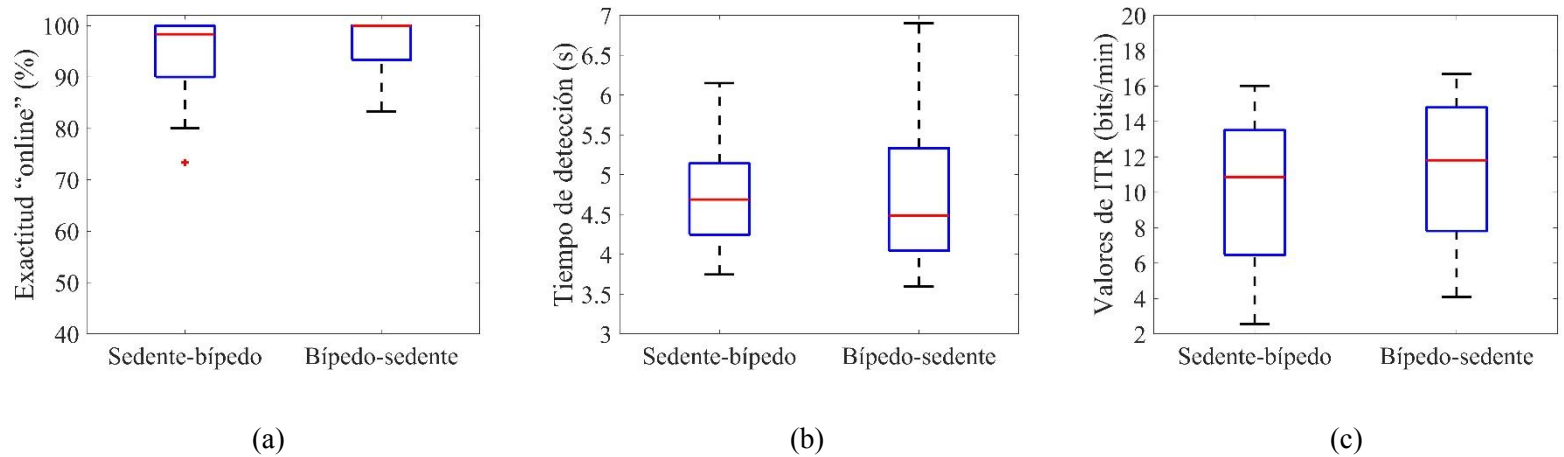
Distribuciones (%) de la sensibilidad, precisión, especificidad y valor predictivo negativo de todos los participantes, obtenidas en los experimentos online de sedente-bípido y bípido-sedente.



Por último, los resultados de la exactitud, el tiempo de detección y la ITR en los experimentos *online* de sedente-bípido y de bípido-sedente se exhiben en la Figura 18. Las exactitudes promedio \pm error estándar de los experimentos *online* de sedente-bípido y de bípido-sedente fueron del $94.69 \pm 1.29\%$ y del $96.56 \pm 0.83\%$, respectivamente. Los tiempos promedio de detección fueron de 4.70 ± 0.11 s y 4.77 ± 0.16 s, y la ITR media fue de 10.12 ± 0.73 bits/min y 11.13 ± 0.72 bits/min para los experimentos *online* de sedente-bípido y de bípido-sedente, respectivamente. Los tiempos de detección más cortos fueron de 3.75 s en los experimentos de sedente-bípido y de 3.60 s en los realizados de bípido-sedente. Los tiempos de detección más largos fueron de 6.15 s en los experimentos de sedente-bípido y de 6.90 s en los experimentos de bípido-sedente. Asimismo, la ITR mínima fue de 2.57 bits por minuto en los experimentos realizados de sedente-bípido y de 4.10 bits por minuto en los experimentos realizados de bípido-sedente. La ITR máxima fue de 16.02 bits por minuto en los experimentos de sedente-bípido y de 16.68 bits por minuto en los experimentos de bípido-sedente.

Figura 18.

Distribuciones de las exactitudes (a), los tiempos de detección (b) y los valores de ITR (c) de los experimentos de ICC online para todos los participantes.



En ambos escenarios de clasificación *online* (véase la Figura 18), el número de épocas procesadas y los umbrales para las clases de MotorImageryA vs. IdleStateA y MotorImageryB vs. IdleStateB son personalizables para cada participante con el fin de mejorar la exactitud *online*, el tiempo de detección y la ITR del sistema. Sin embargo, se utilizó los mismos parámetros para todos los participantes, y es esencial mejorar el rendimiento del sistema para los participantes que no pueden alcanzar altas tasas de detección. Una posible estrategia para mejorar el rendimiento del sistema sería modificar los criterios de detección en el tercer paso de la línea de tiempo de los experimentos en la fase *online*. Por ejemplo, la clasificación de múltiples ventanas deslizantes por ensayo proporciona una forma sencilla de encontrar un balance entre la velocidad de detección y la exactitud media del sistema (M. H. Lee *et al.*, 2019).

Capítulo 8. Producción

En el marco del doctorado se gestaron los siguientes productos de propiedad intelectual que hacen parte de las actividades académicas, científicas, tecnológicas, de desarrollo e innovación, llevadas a cabo durante la ejecución del proyecto de I+D+i del DCA. En el proceso de formación doctoral se obtuvo la autoría de una solicitud de patente de invención, tres artículos especializados en el tema de investigación y una ponencia en un congreso internacional.

El primer documento es la solicitud de patente en la cual se presenta una invención que permite que las personas mediante sus funciones cerebrales puedan interactuar con tecnologías de asistencia para la sedestación y bipedestación con la finalidad de movilizarse desde una postura sedente a una bípeda, y viceversa. El segundo documento es un artículo que propone un nuevo proceso de entrenamiento incremental de redes neuronales para el reconocimiento de tareas de imaginación motora (IM) basado en la interfaz cerebro-computadora (ICC). El tercer documento es un artículo que tiene como objetivo determinar las diferencias que existen entre la IM y la ejecución motora a partir de una prueba de concepto, en los movimientos de ponerse de pie y sentarse. El cuarto documento es un artículo en el que se reportan los resultados de la invención con datos en condiciones de laboratorio y se responde a la pregunta de investigación de la tesis. Finalmente, se expone una ponencia en un congreso internacional de reconocimiento de patrones en el que se divulga la propuesta de entrenamiento incremental de la red neuronal para la ICC. El detalle de cada publicación se muestra en la Tabla 8.

Adicionalmente, se realizó una estancia internacional de investigación en el Instituto Tecnológico y de Estudios Superiores de Monterrey, campus Guadalajara, México, a través de la cual se recibió asesorías por parte de expertos en neurotecnología e interfaces cerebro-computadora que contribuyeron a fortalecer los conocimientos adquiridos y establecer contactos internacionales (ver Tabla 9). Por último, en la Tabla 10 se indican los diferentes proyectos de investigación en los que participé que favorecieron mi formación de alto nivel y un proyecto a futuro de CTeI para continuar con los avances en la generación de nuevo conocimiento, de desarrollo tecnológico e innovación, de transferencia de tecnología y de apropiación social del conocimiento.

Tabla 8.

Productos obtenidos durante el doctorado.

Clase de Producto	Título	Medio de publicación	Clasificación	Fecha	Estado	Anexo Nro.
Patente	Sistema y método para la interpretación de la imaginación motora de los movimientos de ponerse de pie y sentarse, basado en interfaz cerebro-computadora	Superintendencia de Industria y Comercio (SIC) de Colombia. Número de patente NC2021/0012295	Solicitud de patente de invención	Septiembre 2021	Publicada bajo examen de fondo	1
Artículo	Incremental Training of Neural Network for Motor Tasks Recognition Based on Brain-Computer Interface	Lecture Notes in Computer Science. DOI: 10.1007/978-3-030-33904-3_57	Q2	Octubre 2019	Publicado	2
Artículo	EEG Analysis During Motor Imagery and Motor Execution for Standing and Sitting	IEEE Journal of Biomedical and Health Informatics. ISSN: 21682194, 21682208	Q1	Diciembre 2021	Sometido	3
Artículo	Decoding EEG rhythms offline and online during motor imagery for standing and sitting based on a brain-computer interface	Frontiers in Neuroinformatics. DOI: 10.3389/fninf.2022.961089	Q1	Septiembre 2022	Publicado	4
Conferencia	Incremental Training of Neural Network for Motor Tasks Recognition Based on Brain-Computer Interface	Iberoamerican Congress on Pattern Recognition. DOI: 10.1007/978-3-030-33904-3	Q2	Octubre 2019	Publicado	5

Tabla 9.

Pasantía internacional.

Institución	País	Año	Justificación
Instituto Tecnológico y de Estudios Superiores	México	2020	Realización de pruebas de validación de la interfaz

de Monterrey, campus Guadalajara			cerebro-computadora en el laboratorio de investigación en neurotecnología (NTLab)
----------------------------------	--	--	---

Tabla 10.

Participación en proyectos de investigación.

Nombre del proyecto	Entidad	Año	Valor (Especie y contrapartida)
Sistema y método para la interpretación de la imaginación motora de los movimientos de ponerse de pie y sentarse basado en interfaz cerebro computadora	Minciencias / Colciencias. Proyecto No. 80740-594-2019. Convocatoria No. 785 de 2017 Doctorados Nacionales	2018-2022	\$255,000,000
Diferencias entre la imaginación y ejecución motora durante los movimientos de ponerse de pie y sentarse a través de modelos autorregresivos	Universidad Antonio Nariño	2021	2 h/semana por 12 meses
Rehabilitación asistida de movimiento de extremidad superior por medio de sistema robótico e interfaz BCI, en usuarios afectados por accidente cerebrovascular (ACV)	Universidad Autónoma de Manizales	2022-2023	4 h/semana por 12 meses

Capítulo 9. Conclusiones

En este trabajo, se encontró que las tareas de imaginación motora (IM) relacionadas con los movimientos de ponerse de pie y sentarse pueden ser interpretadas utilizando un sistema de interfaz cerebro-computadora (ICC) basado en EEG. Según los resultados, un alto porcentaje de participantes sanos (más del 80%) puede controlar la ICC basada en IM. Adicionalmente, se mejora las investigaciones anteriores al proponer un método para la solución del problema de la decodificación *offline* y *online* de las señales de EEG durante la IM para las transiciones de sedente-bípedo y de bípedo-sedente. A continuación, se exponen las conclusiones del trabajo realizado:

- Se planteó un paradigma de ICC para proporcionar una interacción más natural entre el usuario y la interfaz durante la IM para los movimientos de ponerse de pie y sentarse, lo cual constituye un reto actual de los sistemas de ICC tradicionales.
- Este nuevo paradigma con una alta carga cognitiva para las tareas de IM (MotorImageryA y MotorImageryB) y una baja carga cognitiva para los estados de estado de reposo o inactividad (IdleStateA y IdleStateB) podría explicar por qué no se obtuvo la típica ineficiencia de una ICC basada en IM. Adicionalmente, esto puede deberse a la alta motivación de los sujetos de prueba de la investigación.
- Para el análisis de las señales de EEG, el preprocesamiento fue una de las etapas más importantes, dado que permitió obtener información relacionada con la actividad sensoriomotora tanto de forma automática, aplicando filtros digitales en rangos de frecuencia específicos, como de forma manual por inspección visual, permitiendo tener una menor pérdida de información.
- La perturbación espectral relacionada con eventos (ERSP) reveló una desincronización relacionada con eventos (ERD) durante las etapas de observación de la acción (ActionObservation) de los movimientos bajo estudio mientras que la desincronización/sincronización relacionada con eventos (ERD/ERS) ocurrió durante las etapas de imaginación motora (MotorImageryA y MotorImageryB) en la banda Alfa y Beta sobre el área sensoriomotora, a diferencia de las etapas de los estados de reposo (IdleStateA y IdleStateB) donde no hubo esta respuesta.
- Utilizando los mismos parámetros de preprocesamiento y la misma técnica de reconocimiento de patrones para todos los métodos de extracción de características implementados, el algoritmo de patrón espacial común (CSP) con un banco de filtros

espectrales (FBCSP) en los rangos de frecuencias de las ondas Theta (4-8 Hz), Alfa (8-12 Hz), Beta-Baja (12-16 Hz), Beta-Media (16-20 Hz) y Beta-Alta (20-30 Hz) fue el método que alcanzó las mejores exactitudes de clasificación de la imaginación motora y el estado de reposo en los experimentos de sedente-bípedo y bípedo-sedente.

- Las bandas de frecuencia Beta-Baja y Alfa con los filtros espaciales CSP quinto y sexto, respectivamente, indicaron las características extraídas que podrían proporcionar la información más discriminadora para los escenarios de clasificación de sedente-bípedo y de bípedo-sedente.
- Los resultados indicaron que los clasificadores binarios RLDA, SVM-RBF o MLP comparados en este estudio son una buena opción cuando se utiliza el algoritmo de FBCSP, aunque la exactitud media obtenida con RLDA se acerca al 89% (sedente-bípedo: 88.51%, bípedo-sedente: 85.29%), lo que es superior al rendimiento promedio obtenido con los demás clasificadores.
- En la fase *offline*, los modelos FBCSP-RLDA mostraron resultados de la clasificación balanceados entre las distintas clases y por encima del nivel de azar.
- En la fase *online*, los resultados de la sensibilidad, la precisión, la especificidad y el valor predictivo negativo fueron similares en la detección de las tareas de imaginación motora y de los estados de reposo.
- Tanto los resultados de la clasificación *offline* (con validación cruzada) como los de la clasificación *online* (sin validación cruzada) demostraron que la ICC basada en IM podía identificar nuevas observaciones de cada clase con una alta exactitud (superior al 90%).
- La estrategia aplicada para aumentar la exactitud *online* mediante la clasificación de un solo ensayo utilizando ventanas deslizantes permitió reducir los errores de clasificación, pero ralentizó el tiempo de detección y la ITR. Por lo tanto, la elección de los parámetros es crucial para mantener un equilibrio entre la velocidad de detección y la exactitud de clasificación de la interfaz.
- Si tenemos en cuenta los tiempos de respuesta del actual sistema de ICC, serían lentos para un sistema de control que haga mover un dispositivo robótico. Sin embargo, al mejorar los tiempos de respuesta de esta nueva ICC, los usuarios podrían enviar comandos a dispositivos con bipedestación (como las sillas de ruedas bipedestadoras) para ejecutar transiciones completas de sentado a parado o de parado a sentado utilizando la interfaz de control.

Capítulo 10. Bibliografía

- Abdulkader, S. N., Atia, A., & Mostafa, M.-S. M. (2015). Brain computer interfacing: Applications and challenges. *Egyptian Informatics Journal*, *16*(2), 213–230. <https://doi.org/10.1016/j.eij.2015.06.002>
- Abiri, R., Borhani, S., Sellers, E. W., Jiang, Y., & Zhao, X. (2019). A comprehensive review of EEG-based brain–computer interface paradigms. *Journal of Neural Engineering*, *16*(1), 1–43. <https://doi.org/10.1088/1741-2552/aaf12e>
- Aggarwal, S., & Chugh, N. (2019). Signal processing techniques for motor imagery brain computer interface: A review. *Array*, *1–2*, 1–12. <https://doi.org/10.1016/j.array.2019.100003>
- Aggarwal, S., & Chugh, N. (2022). Review of Machine Learning Techniques for EEG Based Brain Computer Interface. *Archives of Computational Methods in Engineering*, *29*(5), 3001–3020. <https://doi.org/10.1007/s11831-021-09684-6>
- Ahn, M., Lee, M., Choi, J., & Jun, S. (2014). A Review of Brain-Computer Interface Games and an Opinion Survey from Researchers, Developers and Users. *Sensors*, *14*(8), 14601–14633. <https://doi.org/10.3390/s140814601>
- Ajiboye, A. B., Willett, F. R., Young, D. R., Memberg, W. D., Murphy, B. A., Miller, J. P., Walter, B. L., Sweet, J. A., Hoyen, H. A., Keith, M. W., Peckham, P. H., Simeral, J. D., Donoghue, J. P., Hochberg, L. R., & Kirsch, R. F. (2017). Restoration of reaching and grasping movements through brain-controlled muscle stimulation in a person with tetraplegia: a proof-of-concept demonstration. *The Lancet*, *389*(10081), 1821–1830. [https://doi.org/10.1016/S0140-6736\(17\)30601-3](https://doi.org/10.1016/S0140-6736(17)30601-3)
- Al-Fahoum, A. S., & Al-Fraihat, A. A. (2014). Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains. *ISRN Neuroscience*, *2014*, 1–7. <https://doi.org/10.1155/2014/730218>
- Al-Saegh, A., Dawwd, S. A., & Abdul-Jabbar, J. M. (2021). Deep learning for motor imagery EEG-based classification: A review. *Biomedical Signal Processing and Control*, *63*, 1–21. <https://doi.org/10.1016/j.bspc.2020.102172>
- Allison, B. Z., & Neuper, C. (2010). Could Anyone Use a BCI? In D. S. Tan & A. Nijholt (Eds.), *Brain-Computer Interfaces: Applying our Minds to Human-Computer Interaction* (1st ed., pp. 35–54). Springer, London. https://doi.org/10.1007/978-1-84996-272-8_3
- Alyasseri, Z. A. A., Khadeer, A. T., Al-Betar, M. A., Abasi, A., Makhadmeh, S., & Ali, N. S. (2019). The Effects of EEG Feature Extraction Using Multi-Wavelet Decomposition for Mental Tasks Classification. *Proceedings of the International Conference on Information and Communication Technology - ICICT '19*, 139–146. <https://doi.org/10.1145/3321289.3321327>
- Ang, K. K., Chin, Z. Y., Wang, C., Guan, C., & Zhang, H. (2012). Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b. *Frontiers in Neuroscience*, *6*, 1–9. <https://doi.org/10.3389/fnins.2012.00039>
- Arpaia, P., Esposito, A., Natalizio, A., & Parvis, M. (2022). How to successfully classify EEG in motor imagery BCI: a metrological analysis of the state of the art. *Journal of Neural Engineering*, *19*(3), 1–23. <https://doi.org/10.1088/1741-2552/ac74e0>
- Asanza, V., Peláez, E., Loayza, F., Lorente-Leyva, L. L., & Peluffo-Ordóñez, D. H. (2022). Identification of Lower-Limb Motor Tasks via Brain-Computer Interfaces: A Topical Overview. *Sensors*, *22*(5), 1–24. <https://doi.org/10.3390/S22052028>
- Baig, M. Z., Aslam, N., Shum, H. P. H., & Zhang, L. (2017). Differential evolution algorithm as a tool for optimal feature subset selection in motor imagery EEG. *Expert Systems with Applications*, *90*, 184–195. <https://doi.org/10.1016/j.eswa.2017.07.033>
- Bansal, D., & Mahajan, R. (2019). Chapter 2 - EEG-Based Brain-Computer Interfacing (BCI). In D. Bansal & R. Mahajan (Eds.), *EEG-Based Brain-Computer Interfaces: Cognitive Analysis and*

- Control Applications* (1st ed., pp. 21–71). Elsevier. <https://doi.org/10.1016/B978-0-12-814687-3.00002-8>
- Beppi, C., Ribeiro Violante, I., Scott, G., & Sandrone, S. (2021). EEG, MEG and neuromodulatory approaches to explore cognition: Current status and future directions. *Brain and Cognition*, *148*, 105677. <https://doi.org/10.1016/j.bandc.2020.105677>
- Berrar, D. (2019). Cross-Validation. In S. Ranganathan, M. Gribskov, K. Nakai, & C. Schönbach (Eds.), *Encyclopedia of Bioinformatics and Computational Biology* (Vol. 1, pp. 542–545). Academic Press. <https://doi.org/10.1016/B978-0-12-809633-8.20349-X>
- Bhardwaj, S., Khan, A. A., & Muzammil, M. (2019). Lower limb rehabilitation using multimodal measurement of sit-to-stand and stand-to-sit task. *Disability and Rehabilitation: Assistive Technology*, *16*(5), 438–445. <https://doi.org/10.1080/17483107.2019.1629701>
- Bigdely-Shamlo, N., Mullen, T., Kothe, C., Su, K.-M., & Robbins, K. A. (2015). The PREP pipeline: standardized preprocessing for large-scale EEG analysis. *Frontiers in Neuroinformatics*, *9*, 1–20. <https://doi.org/10.3389/fninf.2015.00016>
- Blanco-Diaz, C. F., Antelis, J. M., & Ruiz-Olaya, A. F. (2022). Comparative analysis of spectral and temporal combinations in CSP-based methods for decoding hand motor imagery tasks. *Journal of Neuroscience Methods*, *371*, 1–9. <https://doi.org/10.1016/j.jneumeth.2022.109495>
- Blankertz, B., Curio, G., & Müller, K.-R. (2001). Classifying Single Trial EEG: Towards Brain Computer Interfacing. In T. Dietterich, S. Becker, & Z. Ghahramani (Eds.), *Advances in Neural Information Processing Systems* (Vol. 14, pp. 157–164). MIT Press. <https://proceedings.neurips.cc/paper/2001/file/2d579dc29360d8bbfbb4aa541de5afa9-Paper.pdf>
- Blankertz, B., Losch, F., Krauledat, M., Dornhege, G., Curio, G., & Müller, K.-R. (2008). The Berlin Brain-Computer Interface: Accurate Performance From First-Session in BCI-Naive Subjects. *IEEE Transactions on Biomedical Engineering*, *55*(10), 2452–2462. <https://doi.org/10.1109/TBME.2008.923152>
- Blankertz, B., Tangermann, M., Vidaurre, C., Fazli, S., Sannelli, C., Haufe, S., Maeder, C., Ramsey, L., Sturm, I., Curio, G., & Müller, K.-R. (2010). The Berlin Brain-Computer Interface: Non-Medical Uses of BCI Technology. *Frontiers in Neuroscience*, *4*, 1–17. <https://doi.org/10.3389/fnins.2010.00198>
- Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., & Müller, K. (2008). Optimizing Spatial filters for Robust EEG Single-Trial Analysis. *IEEE Signal Processing Magazine*, *25*(1), 41–56. <https://doi.org/10.1109/MSP.2008.4408441>
- Bobrova, E. V., Reshetnikova, V. V., Frolov, A. A., & Gerasimenko, Y. P. (2020). Use of Imaginary Lower Limb Movements to Control Brain-Computer Interface Systems. *Neuroscience and Behavioral Physiology*, *50*(5), 585–592. <https://doi.org/10.1007/s11055-020-00940-z>
- Bulea, T. C., Prasad, S., Kilicarslan, A., & Contreras-Vidal, J. L. (2014). Sitting and standing intention can be decoded from scalp EEG recorded prior to movement execution. *Frontiers in Neuroscience*, *8*(376), 1–19. <https://doi.org/10.3389/fnins.2014.00376>
- Cervera, M. A., Soekadar, S. R., Ushiba, J., Millán, J. del R., Liu, M., Birbaumer, N., & Garipelli, G. (2018). Brain-computer interfaces for post-stroke motor rehabilitation: a meta-analysis. *Annals of Clinical and Translational Neurology*, *5*(5), 651–663. <https://doi.org/10.1002/acn3.544>
- Chaisaen, R., Autthasan, P., Mingchinda, N., Leelaarporn, P., Kunaseth, N., Tammajarung, S., Manoonpong, P., Mukhopadhyay, S. C., & Wilaiprasitporn, T. (2020). Decoding EEG Rhythms During Action Observation, Motor Imagery, and Execution for Standing and Sitting. *IEEE Sensors Journal*, *20*(22), 13776–13786. <https://doi.org/10.1109/JSEN.2020.3005968>
- Chaudhary, S., Taran, S., Bajaj, V., & Sengur, A. (2019). Convolutional Neural Network Based Approach Towards Motor Imagery Tasks EEG Signals Classification. *IEEE Sensors Journal*, *19*(12), 4494–4500. <https://doi.org/10.1109/JSEN.2019.2899645>

- Chen, W., Wang, S., Zhang, X., Yao, L., Yue, L., Qian, B., & Li, X. (2018). EEG-based Motion Intention Recognition via Multi-task RNNs. In M. Ester & D. Pedreschi (Eds.), *Proceedings of the 2018 SIAM International Conference on Data Mining* (pp. 279–287). Society for Industrial and Applied Mathematics. <https://doi.org/10.1137/1.9781611975321.32>
- Cho, W., Guger, C., Heilinger, A., Ortner, R., Murovec, N., Xu, R., Swift, J., Zehetner, M., Schobesberger, S., & Edlinger, G. (2018). Motor Rehabilitation for Hemiparetic Stroke Patients Using a Brain-Computer Interface Method. *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 1001–1005. <https://doi.org/10.1109/SMC.2018.00178>
- Choi, J., Kim, K. T., Jeong, J. H., Kim, L., Lee, S. J., & Kim, H. (2020). Developing a Motor Imagery-Based Real-Time Asynchronous Hybrid BCI Controller for a Lower-Limb Exoskeleton. *Sensors*, *20*(24), 1–15. <https://doi.org/10.3390/s20247309>
- Congedo, M., Barachant, A., & Bhatia, R. (2017). Riemannian geometry for EEG-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces*, *4*(3), 155–174. <https://doi.org/10.1080/2326263X.2017.1297192>
- Contreras-Vidal, J. L., Prasad, S., Kilicarslan, A., & Bhagat, N. (2018). *Methods for closed-loop neural-machine interface systems for the control of wearable exoskeletons and prosthetic devices* (Patent No. US10092205B2).
- Dagdevir, E., & Tokmakci, M. (2021). Optimization of preprocessing stage in EEG based BCI systems in terms of accuracy and timing cost. *Biomedical Signal Processing and Control*, *67*, 1–9. <https://doi.org/10.1016/j.bspc.2021.102548>
- Dai, G., Zhou, J., Huang, J., & Wang, N. (2020). HS-CNN: a CNN with hybrid convolution scale for EEG motor imagery classification. *Journal of Neural Engineering*, *17*, 1–11. <https://doi.org/10.1088/1741-2552/ab405f>
- Daly, J. J., & Wolpaw, J. R. (2008). Brain-computer interfaces in neurological rehabilitation. *The Lancet Neurology*, *7*(11), 1032–1043. [https://doi.org/10.1016/S1474-4422\(08\)70223-0](https://doi.org/10.1016/S1474-4422(08)70223-0)
- DANE - UNFPA Colombia. (2022). *Caracterización y cambios de la discapacidad a partir de los censos 2005 y 2018 en Colombia*. Una Mirada Desde Los Determinantes Sociales de La Salud. <https://www.dane.gov.co/files/censo2018/estudios-poscensales/12-Caracterizacion-discapacidad-censos-200-2018-Colombia.pdf>
- de Castro-Cros, M., Sebastian-Romagosa, M., Rodríguez-Serrano, J., Opisso, E., Ochoa, M., Ortner, R., Guger, C., & Tost, D. (2020). Effects of Gamification in BCI Functional Rehabilitation. *Frontiers in Neuroscience*, *14*, 1–9. <https://doi.org/10.3389/fnins.2020.00882>
- Delorme, A., & Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, *134*(1), 9–21. <https://doi.org/10.1016/j.jneumeth.2003.10.009>
- Do, A. H., Wang, P. T., King, C. E., Chun, S. N., & Nenadic, Z. (2013). Brain-computer interface controlled robotic gait orthosis. *Journal of NeuroEngineering and Rehabilitation*, *10*(1), 1–9. <https://doi.org/10.1186/1743-0003-10-111>
- Donati, A. R. C., Shokur, S., Morya, E., Campos, D. S. F., Moioli, R. C., Gitti, C. M., Augusto, P. B., Tripodi, S., Pires, C. G., Pereira, G. A., Brasil, F. L., Gallo, S., Lin, A. A., Takigami, A. K., Aratana, M. A., Joshi, S., Bleuler, H., Cheng, G., Rudolph, A., & Nicolelis, M. A. L. (2016). Long-Term Training with a Brain-Machine Interface-Based Gait Protocol Induces Partial Neurological Recovery in Paraplegic Patients. *Scientific Reports*, *6*(1), 1–16. <https://doi.org/10.1038/srep30383>
- Edlinger, G., Allison, B. Z., & Guger, C. (2015). How Many People Can Use a BCI System? In K. Kansaku, L. G. Cohen, & N. Birbaumer (Eds.), *Clinical Systems Neuroscience* (pp. 33–66). Springer, Japan. https://doi.org/10.1007/978-4-431-55037-2_3/COVER/
- Edwardson, M. A., Lucas, T. H., Carey, J. R., & Fetz, E. E. (2013). New modalities of brain stimulation for stroke rehabilitation. *Experimental Brain Research*, *224*(3), 335–358. <https://doi.org/10.1007/s00221-012-3315-1>
- Elsayed, N., Saad, Z., & Bayoumi, M. (2017). Brain Computer Interface: EEG Signal Preprocessing

- Issues and Solutions. *International Journal of Computer Applications*, 169(3), 12–16.
<https://doi.org/10.5120/ijca2017914621>
- Feng, J. K., Jin, J., Daly, I., Zhou, J., Niu, Y., Wang, X., & Cichocki, A. (2019). An Optimized Channel Selection Method Based on Multifrequency CSP-Rank for Motor Imagery-Based BCI System. *Computational Intelligence and Neuroscience*, 2019, 1–10.
<https://doi.org/10.1155/2019/8068357>
- Fleury, M., Lioi, G., Barillot, C., & Lécuyer, A. (2020). A Survey on the Use of Haptic Feedback for Brain-Computer Interfaces and Neurofeedback. *Frontiers in Neuroscience*, 14, 1–16.
<https://doi.org/10.3389/fnins.2020.00528>
- Gao, X., Wang, Y., Chen, X., & Gao, S. (2021). Interface, interaction, and intelligence in generalized brain–computer interfaces. *Trends in Cognitive Sciences*, 25(8), 671–684.
<https://doi.org/10.1016/j.tics.2021.04.003>
- Gao, Z., Wang, Z., Ma, C., Dang, W., & Zhang, K. (2018). A Wavelet Time-Frequency Representation Based Complex Network Method for Characterizing Brain Activities Underlying Motor Imagery Signals. *IEEE Access*, 6, 65796–65802.
<https://doi.org/10.1109/ACCESS.2018.2876547>
- García-Cossio, E., Severens, M., Nienhuis, B., Duysens, J., Desain, P., Keijsers, N., & Farquhar, J. (2015). Decoding Sensorimotor Rhythms during Robotic-Assisted Treadmill Walking for Brain Computer Interface (BCI) Applications. *PLOS ONE*, 10(12), e0137910.
<https://doi.org/10.1371/journal.pone.0137910>
- George, O., Dabas, S., Sikder, A., Smith, R. O., Madiraju, P., Yahyasoltani, N., & Ahamed, S. I. (2022). State-of-the-Art Versus Deep Learning: A Comparative Study of Motor Imagery Decoding Techniques. *IEEE Access*, 10, 45605–45619.
<https://doi.org/10.1109/ACCESS.2022.3165197>
- George, O., Smith, R., Madiraju, P., Yahyasoltani, N., & Ahamed, S. I. (2021). Motor Imagery: A Review of Existing Techniques, Challenges and Potentials. *2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*, 1893–1899.
<https://doi.org/10.1109/COMPSAC51774.2021.00286>
- Good, P. I. (2006). Resampling Methods. In *Resampling Methods: A Practical Guide to Data Analysis*. Birkhäuser Boston. <https://doi.org/10.1007/0-8176-4444-X>
- Graimann, B., & Pfurtscheller, G. (2006). Quantification and visualization of event-related changes in oscillatory brain activity in the time–frequency domain. In C. Neuper & W. Klimesch (Eds.), *Progress in Brain Research* (Vol. 159, pp. 79–97). Elsevier.
[https://doi.org/10.1016/S0079-6123\(06\)59006-5](https://doi.org/10.1016/S0079-6123(06)59006-5)
- Guger, C., Allison, B. Z., Walchshofer, M., & Breinbauer, S. (2019). The BR4IN.IO Hackathons. In A. Nijholt (Ed.), *Brain Art* (pp. 447–473). Springer International Publishing.
https://doi.org/10.1007/978-3-030-14323-7_17
- Guo, X., Wang, J., Shi, B., Wang, L., Liang, W., & Wu, M. (2021). *Wheelchair based on SSMVEP-ERP-OSR hybrid brain-computer interface driving* (Patent No. CN112230768A).
- Hamedi, M., Salleh, S. H., Noor, A. M., & Mohammad-Rezazadeh, I. (2014). Neural Network-based Three-Class Motor Imagery Classification Using Time-Domain Features for BCI Applications. *2014 IEEE REGION 10 SYMPOSIUM*, 204–207.
<https://doi.org/10.1109/TENCONSpring.2014.6863026>
- Hanes, D. P., & Schall, J. D. (1996). Neural Control of Voluntary Movement Initiation. *Science*, 274(5286), 427–430. <https://doi.org/10.1126/SCIENCE.274.5286.427>
- Haykin, S. (2009). *Neural networks and learning machines* (A. Dworkin (ed.); 3rd ed.). Prentice Hall/Pearson.
https://books.google.com.co/books/about/Neural_Networks_and_Learning_Machines.html?id=K7P36lKzI_QC&redir_esc=y
- He, H., & Wu, D. (2018). Spatial Filtering for Brain Computer Interfaces: A Comparison between the Common Spatial Pattern and Its Variant. *2018 IEEE International Conference on Signal*

- Processing, Communications and Computing (ICSPCC)*, 1–6.
<https://doi.org/10.1109/ICSPCC.2018.8567789>
- He, Y., Eguren, D., Azorin, J. M., Grossman, R. G., Luu, T. P., & Contreras-Vidal, J. L. (2018). Brain-machine interfaces for controlling lower-limb powered robotic systems. *Journal of Neural Engineering*, *15*(2), 1–15. <https://doi.org/10.1088/1741-2552/aaa8c0>
- Hernandez-Rojas, Luis 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. (2022). Brain-Computer Interface Controlled Functional Electrical Stimulation: Evaluation With Healthy Subjects and Spinal Cord Injury Patients. *IEEE Access*, *10*, 46834–46852. <https://doi.org/10.1109/ACCESS.2022.3170906>
- Hernandez-Rojas, Luis Guillermo, Montoya, O. M., & Antelis, J. M. (2020). Anticipatory Detection of Self-Paced Rehabilitative Movements in the Same Upper Limb From EEG Signals. *IEEE Access*, *8*, 119728–119743. <https://doi.org/10.1109/ACCESS.2020.3005600>
- Hochberg, L. R., Bacher, D., Jarosiewicz, B., Masse, N. Y., Simeral, J. D., Vogel, J., Haddadin, S., Liu, J., Cash, S. S., van der Smagt, P., & Donoghue, J. P. (2012). Reach and grasp by people with tetraplegia using a neurally controlled robotic arm. *Nature*, *485*(7398), 372–375. <https://doi.org/10.1038/nature11076>
- Hwang, H.-J., Kwon, K., & Im, C.-H. (2009). Neurofeedback-based motor imagery training for brain–computer interface (BCI). *Journal of Neuroscience Methods*, *179*(1), 150–156. <https://doi.org/10.1016/j.jneumeth.2009.01.015>
- Iacoviello, D., Petracca, A., Spezialetti, M., & Placidi, G. (2015). A real-time classification algorithm for EEG-based BCI driven by self-induced emotions. *Computer Methods and Programs in Biomedicine*, *122*(3), 293–303. <https://doi.org/10.1016/j.cmpb.2015.08.011>
- Irimia, D. C., Ortner, R., Poboroniuc, M. S., Ignat, B. E., & Guger, C. (2018). High Classification Accuracy of a Motor Imagery Based Brain-Computer Interface for Stroke Rehabilitation Training. *Frontiers in Robotics and AI*, *5*, 1–9. <https://doi.org/10.3389/frobt.2018.00130>
- Joa, K.-L., Han, Y.-H., Mun, C.-W., Son, B.-K., Lee, C.-H., Shin, Y.-B., Ko, H.-Y., & Shin, Y.-I. (2012). Evaluation of the brain activation induced by functional electrical stimulation and voluntary contraction using functional magnetic resonance imaging. *Journal of NeuroEngineering and Rehabilitation*, *9*(1), 48. <https://doi.org/10.1186/1743-0003-9-48>
- Karlik, B., & Olgac, A. V. (2011). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. *International Journal of Artificial Intelligence And Expert Systems*, *1*(4), 111–122. <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.740.9413&rep=rep1&type=pdf>
- Kawala-Sterniuk, A., Browarska, N., Al-Bakri, A., Pelc, M., Zygarlicki, J., Sidikova, M., Martinek, R., & Gorzelanczyk, E. J. (2021). Summary of over Fifty Years with Brain-Computer Interfaces—A Review. *Brain Sciences*, *11*(1), 1–41. <https://doi.org/10.3390/brainsci11010043>
- Kee, C.-Y., Ponnambalam, S. G., & Loo, C.-K. (2017). Binary and multi-class motor imagery using Renyi entropy for feature extraction. *Neural Computing and Applications*, *28*(8), 2051–2062. <https://doi.org/10.1007/S00521-016-2178-Y>
- Kerous, B., Skola, F., & Liarokapis, F. (2018). EEG-based BCI and video games: a progress report. *Virtual Reality*, *22*(2), 119–135. <https://doi.org/10.1007/s10055-017-0328-x>
- Kevric, J., & Subasi, A. (2017). Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system. *Biomedical Signal Processing and Control*, *31*, 398–406. <https://doi.org/10.1016/j.bspc.2016.09.007>
- Kilicarslan, A., Prasad, S., Grossman, R. G., & Contreras-Vidal, J. L. (2013). High Accuracy Decoding of User Intentions Using EEG to Control a Lower-Body Exoskeleton. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 5606–5609. <https://doi.org/10.1109/EMBC.2013.6610821>
- Klimesch, W. (2018). The frequency architecture of brain and brain body oscillations: an analysis. *European Journal of Neuroscience*, *48*(7), 2431–2453. <https://doi.org/10.1111/ejn.14192>

- Kohlmorgen, J., Dornhege, G., Braun, M. L., Blankertz, B., Curio, G., Hagemann, K., Bruns, A., Schrauf, M., & Kincses, W. E. (2007). Improving human performance in a real operating environment through real-time mental workload detection. In G. Dornhege, J. del R. Millan, T. Hinterberger, D. J. McFarland, & K.-R. Müller (Eds.), *Toward Brain-Computer Interfacing* (pp. 409–422). MIT Press.
https://books.google.es/books?hl=es&lr=&id=V88swGX83ecC&oi=fnd&pg=PA409&dq=Improving+Human+Performance+in+a+Real+Operating+Environment+through+Real-Time+Mental+Workload+Detection&ots=mZ0Csr7KcX&sig=0UfENpR9hzJ_F1uRuLm3QRkY71k
- Kołodziej, M., Majkowski, A., & Remigiusz, J. R. (2010). Matlab FE_Toolbox-an universal utility for feature extraction of EEG signals for BCI realization. *Przegląd Elektrotechniczny*, *86*(1), 44–46. https://dlwqtxts1xzle7.cloudfront.net/32494571/Matlab_FE_Toolbox_-_an_universal_utility_for_feature_extraction_of_EEG_signals_for_BCI_realization-with-cover-page-v2.pdf?Expires=1662074772&Signature=Du9S6fbCIUiYvtrDln6iCXm4xqL6COMCII3eJSL0Xc9wdVAw4YWqm9p2
- Kosmyna, N., Tarpin-Bernard, F., Bonnefond, N., & Rivet, B. (2016). Feasibility of BCI Control in a Realistic Smart Home Environment. *Frontiers in Human Neuroscience*, *10*, 1–10.
<https://doi.org/10.3389/fnhum.2016.00416>
- Krishnan, R. V., Muthusamy, R., & Sankar, V. (2001). Spinal Cord Injury Repair Research: A New Combination Treatment Strategy. *International Journal of Neuroscience*, *108*(3–4), 201–207.
<https://doi.org/10.3109/00207450108986515>
- Krusienski, D. J., McFarland, D. J., & Wolpaw, J. R. (2006). An Evaluation of Autoregressive Spectral Estimation Model Order for Brain-Computer Interface Applications. *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, 1323–1326. <https://doi.org/10.1109/IEMBS.2006.259822>
- Kübler, A., & Mattia, D. (2016). Brain-Computer Interface Based Solutions for End-Users with Severe Communication Disorders. In S. Laureys, O. Gosseries, & G. Tononi (Eds.), *The Neurology of Consciousness* (2nd ed., pp. 217–240). Elsevier. <https://doi.org/10.1016/B978-0-12-800948-2.00014-5>
- Kwak, N.-S., Müller, K.-R., & Lee, S.-W. (2017). A convolutional neural network for steady state visual evoked potential classification under ambulatory environment. *PLoS ONE*, *12*(2), 1–20.
<https://doi.org/10.1371/journal.pone.0172578>
- LaFleur, K., Cassidy, K., Doud, A., Shades, K., Rogin, E., & He, B. (2013). Quadcopter control in three-dimensional space using a noninvasive motor imagery-based brain-computer interface. *Journal of Neural Engineering*, *10*(4), 1–15. <https://doi.org/10.1088/1741-2560/10/4/046003>
- Leaman, J., & La, H. M. (2017). A Comprehensive Review of Smart Wheelchairs: Past, Present, and Future. *IEEE Transactions on Human-Machine Systems*, *47*(4), 486–499.
<https://doi.org/10.1109/THMS.2017.2706727>
- Lee, H. K., & Choi, Y.-S. (2019). Application of Continuous Wavelet Transform and Convolutional Neural Network in Decoding Motor Imagery Brain-Computer Interface. *Entropy*, *21*(12), 1–11. <https://doi.org/10.3390/e21121199>
- Lee, M. H., Kwon, O. Y., Kim, Y. J., Kim, H. K., Lee, Y. E., Williamson, J., Fazli, S., & Lee, S. W. (2019). EEG dataset and OpenBMI toolbox for three BCI paradigms: an investigation into BCI illiteracy. *GigaScience*, *8*(5), 1–16. <https://doi.org/10.1093/gigascience/giz002>
- Leisman, G., Moustafa, A., & Shafir, T. (2016). Thinking, Walking, Talking: Integratory Motor and Cognitive Brain Function. *Frontiers in Public Health*, *4*, 1–19.
<https://doi.org/10.3389/fpubh.2016.00094>
- Leuthardt, E. C., Schalk, G., Moran, D. W., Wolpaw, J. R., & Ojemann, J. G. (2006). *Brain computer interface* (Patent No. US7120486B2).
- Liu, J., Hu, H., Du, H., Hu, Y., Mao, H., Han, J., Feng, S., Liu, D., Li, D., Hu, Z., & Ma, L. (2018).

- Intelligent wheelchair control system based on electroencephalogram control* (Patent No. CN107961120B).
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update. *Journal of Neural Engineering*, *15*(3), 1–28. <https://doi.org/10.1088/1741-2552/aab2f2>
- Lotte, F., & Cuntai Guan. (2011). Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms. *IEEE Transactions on Biomedical Engineering*, *58*(2), 355–362. <https://doi.org/10.1109/TBME.2010.2082539>
- Lotte, F., Nam, C. S., & Nijholt, A. (2018). Introduction: Evolution of Brain-Computer Interfaces. In C. S. Nam, A. Nijholt, & F. Lotte (Eds.), *Brain-Computer Interfaces Handbook: Technological and Theoretical Advance* (pp. 1–11). Taylor & Francis (CRC Press). <https://hal.inria.fr/hal-01656743>
- Lu, Y., & Bi, L. (2021). Human Behavior Model-Based Predictive Control of Longitudinal Brain-Controlled Driving. *IEEE Transactions on Intelligent Transportation Systems*, *22*(3), 1361–1374. <https://doi.org/10.1109/TITS.2020.2969444>
- Luo, J., Wang, J., Xu, R., & Xu, K. (2019). Class discrepancy-guided sub-band filter-based common spatial pattern for motor imagery classification. *Journal of Neuroscience Methods*, *323*, 98–107. <https://doi.org/10.1016/j.jneumeth.2019.05.011>
- Makeig, S. (1993). Auditory event-related dynamics of the EEG spectrum and effects of exposure to tones. *Electroencephalography and Clinical Neurophysiology*, *86*(4), 283–293. [https://doi.org/10.1016/0013-4694\(93\)90110-H](https://doi.org/10.1016/0013-4694(93)90110-H)
- Malan, N. S., & Sharma, S. (2019). Feature selection using regularized neighbourhood component analysis to enhance the classification performance of motor imagery signals. *Computers in Biology and Medicine*, *107*, 118–126. <https://doi.org/10.1016/j.combiomed.2019.02.009>
- Mane, R., Chouhan, T., & Guan, C. (2020). BCI for stroke rehabilitation: motor and beyond. *Journal of Neural Engineering*, *17*(4), 1–21. <https://doi.org/10.1088/1741-2552/aba162>
- Manyakov, N. V., Chumerin, N., Combaz, A., & Van Hulle, M. M. (2011). Comparison of Classification Methods for P300 Brain-Computer Interface on Disabled Subjects. *Computational Intelligence and Neuroscience*, *2011*, 1–12. <https://doi.org/10.1155/2011/519868>
- Mao, X., Li, M., Li, W., Niu, L., Xian, B., Zeng, M., & Chen, G. (2017). Progress in EEG-Based Brain Robot Interaction Systems Xiaolian. *Computational Intelligence and Neuroscience*, *2017*, 1–25. <https://doi.org/10.1155/2017/1742862>
- Mashat, M. E. M., Lin, C.-T., & Zhang, Di. (2019). Effects of Task Complexity on Motor Imagery-Based Brain–Computer Interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *27*(10), 2178–2185. <https://doi.org/10.1109/TNSRE.2019.2936987>
- McFarland, D. J., & Wolpaw, J. R. (2017). EEG-based brain–computer interfaces. *Current Opinion in Biomedical Engineering*, *4*, 194–200. <https://doi.org/10.1016/j.cobme.2017.11.004>
- Mellinger, J., Schalk, G., Braun, C., Preissl, H., Rosenstiel, W., Birbaumer, N., & Kübler, A. (2007). An MEG-based brain–computer interface (BCI). *NeuroImage*, *36*(3), 581–593. <https://doi.org/10.1016/j.neuroimage.2007.03.019>
- Mendoza-Montoya, O. (2017). Development of a Hybrid Brain-Computer Interface for Autonomous Systems [Freie Universität Berlin]. In *Dissertation zur Erlangung des Grades eines Doktors der Naturwissenschaften (Dr. rer. nat.) am Fachbereich Mathematik und Informatik der Freien Universität Berlin*. <https://doi.org/10.17169/refubium-13794>
- Middleton, J., Tran, Y., & Craig, A. (2007). Relationship Between Quality of Life and Self-Efficacy in Persons With Spinal Cord Injuries. *Archives of Physical Medicine and Rehabilitation*, *88*(12), 1643–1648. <https://doi.org/10.1016/j.apmr.2007.09.001>
- Miller, K. J., Hermes, D., & Staff, N. P. (2020). The current state of electrocorticography-based brain–computer interfaces. *Neurosurgical Focus*, *49*(1), 1–8.

- <https://doi.org/10.3171/2020.4.FOCUS20185>
- Minguillon, J., Lopez-Gordo, M. A., & Pelayo, F. (2017). Trends in EEG-BCI for daily-life: Requirements for artifact removal. *Biomedical Signal Processing and Control*, *31*, 407–418. <https://doi.org/10.1016/j.bspc.2016.09.005>
- Moffett, S. X., O'Malley, S. M., Man, S., Hong, D., & Martin, J. V. (2017). Dynamics of high frequency brain activity. *Scientific Reports*, *7*(1), 1–5. <https://doi.org/10.1038/s41598-017-15966-6>
- Molla, M. K. I., Saha, S. K., Yasmin, S., Islam, M. R., & Shin, J. (2021). Trial Regeneration With Subband Signals for Motor Imagery Classification in BCI Paradigm. *IEEE Access*, *9*, 7632–7642. <https://doi.org/10.1109/ACCESS.2021.3049191>
- Morash, V., Bai, O., Furlani, S., Lin, P., & Hallett, M. (2008). Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imageries. *Clinical Neurophysiology*, *119*(11), 2570–2578. <https://doi.org/10.1016/j.clinph.2008.08.013>
- Moreno Arévalo, B. S. (2021). Diferencias entre la imaginación y ejecución motora durante los movimientos ponerse de pie y sentarse a través de modelos autorregresivos [Universidad Antonio Nariño]. In *Repositorio Institucional UAN*. <http://repositorio.uan.edu.co/handle/123456789/6624>
- Morimoto, J., Noda, T., Teramae, T., & Furukawa, J. (2012). *External skeleton robot, and rehabilitation device* (Patent No. JP6142146B2).
- Moumgiakmas, S. S., & Papakostas, G. A. (2022). Robustly Effective Approaches on Motor Imagery-Based Brain Computer Interfaces. *Computers*, *11*(5), 61. <https://doi.org/10.3390/computers11050061>
- Müller, K.-R., Tangermann, M., Dornhege, G., Krauledat, M., Curio, G., & Blankertz, B. (2008). Machine learning for real-time single-trial EEG-analysis: From brain–computer interfacing to mental state monitoring. *Journal of Neuroscience Methods*, *167*(1), 82–90. <https://doi.org/10.1016/j.jneumeth.2007.09.022>
- Munce, S. E. P., Perrier, L., Tricco, A. C., Straus, S. E., Fehlings, M. G., Kastner, M., Jang, E., Webster, F., & Jaglal, S. B. (2013). Impact of quality improvement strategies on the quality of life and well-being of individuals with spinal cord injury: a systematic review protocol. *Systematic Reviews*, *2*(14), 1–5. <https://doi.org/10.1186/2046-4053-2-14>
- Naeem, M., Brunner, C., & Pfurtscheller, G. (2009). Dimensionality Reduction and Channel Selection of Motor Imagery Electroencephalographic Data. *Computational Intelligence and Neuroscience*, *2009*, 1–8. <https://doi.org/10.1155/2009/537504>
- Naseer, N., & Hong, K.-S. (2015). fNIRS-based brain-computer interfaces: a review. *Frontiers in Human Neuroscience*, *9*(3), 1–15. <https://doi.org/10.3389/fnhum.2015.00003>
- Neuper, C., & Pfurtscheller, G. (2009). Neurofeedback Training for BCI Control. In B. Graimann, G. Pfurtscheller, & B. Allison (Eds.), *Brain–Computer Interfaces: Revolutionizing Human–Computer Interaction* (1st ed., pp. 65–78). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-02091-9_4
- Neuper, C., Scherer, R., Reiner, M., & Pfurtscheller, G. (2005). Imagery of motor actions: Differential effects of kinesthetic and visual–motor mode of imagery in single-trial EEG. *Cognitive Brain Research*, *25*(3), 668–677. <https://doi.org/10.1016/j.cogbrainres.2005.08.014>
- Ng, A. Y., & Jordan, M. I. (2001). On discriminative vs. Generative classifiers: A comparison of logistic regression and naive bayes. In T. Dietterich, S. Becker, & Z. Ghahramani (Eds.), *Advances in Neural Information Processing Systems* (pp. 841–848). MIT Press. <https://proceedings.neurips.cc/paper/2001/file/7b7a53e239400a13bd6be6c91c4f6c4e-Paper.pdf>
- Nicolas-Alonso, L. F., & Gomez-Gil, J. (2012). Brain Computer Interfaces, a Review. *Sensors*, *12*(2), 1211–1279. <https://doi.org/10.3390/s120201211>
- Niedermeyer, E., & Silva, F. H. L. da. (2005). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (E. Niedermeyer & F. H. L. da Silva (eds.); 5th ed., Vol. 1).

- Lippincott Williams & Wilkins.
<https://books.google.com/books/about/Electroencephalography.html?id=tndqYGPdEC>
- Noda, T., Sugimoto, N., Furukawa, J., Sato, M., Hyon, S.-H., & Morimoto, J. (2012). Brain-controlled exoskeleton robot for BMI rehabilitation. *2012 12th IEEE-RAS International Conference on Humanoid Robots (Humanoids 2012)*, 21–27.
<https://doi.org/10.1109/HUMANOIDS.2012.6651494>
- Nooh, A. A., Yunus, J., & Daud, S. M. (2011). A review of asynchronous electroencephalogram-based brain computer interface systems. *2011 International Conference on Biomedical Engineering and Technology IPCBEE*, 55–59. <http://ipcbee.com/vol11/11-T025.pdf>
- Norman, S. L., Dennison, M., Wolbrecht, E., Cramer, S. C., Srinivasan, R., & Reinkensmeyer, D. J. (2016). Movement Anticipation and EEG: Implications for BCI-Contingent Robot Therapy. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *24*(8), 911–919.
<https://doi.org/10.1109/TNSRE.2016.2528167>
- Oikonomou, V. P., Georgiadis, K., Liaros, G., Nikolopoulos, S., & Kompatsiaris, I. (2017). A comparison study on EEG signal processing techniques using motor imagery EEG data. *2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*, 781–786.
<https://doi.org/10.1109/CBMS.2017.113>
- Omejc, N., Rojc, B., Battaglini, P. P., & Marusic, U. (2018). Review of the therapeutic neurofeedback method using electroencephalography: EEG Neurofeedback. *Bosnian Journal of Basic Medical Sciences*, *19*(3), 213–220. <https://doi.org/10.17305/bjbms.2018.3785>
- Ortiz, M., Iáñez, E., Contreras-Vidal, J. L., & Azorín, J. M. (2020). Analysis of the EEG Rhythms Based on the Empirical Mode Decomposition During Motor Imagery When Using a Lower-Limb Exoskeleton. A Case Study. *Frontiers in Neurorobotics*, *14*, 1–13.
<https://doi.org/10.3389/fnbot.2020.00048>
- Ortner, R., Scharinger, J., Lechner, A., & Guger, C. (2015). How many people can control a motor imagery based BCI using common spatial patterns? *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*, 202–205.
<https://doi.org/10.1109/NER.2015.7146595>
- Padfield, N., Zabalza, J., Zhao, H., Masero, V., & Ren, J. (2019). EEG-Based Brain-Computer Interfaces Using Motor-Imagery: Techniques and Challenges. *Sensors*, *19*(6), 1–34.
<https://doi.org/10.3390/s19061423>
- Pfurtscheller, G., & Lopes da Silva, F. H. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, *110*(11), 1842–1857.
[https://doi.org/10.1016/S1388-2457\(99\)00141-8](https://doi.org/10.1016/S1388-2457(99)00141-8)
- Pfurtscheller, G., Neuper, C., Guger, C., Harkam, W., Ramoser, H., Schlögl, A., Obermaier, B., & Pregenzer, M. (2000). Current trends in Graz brain-computer interface (BCI) research. *IEEE Transactions on Rehabilitation Engineering*, *8*(2), 216–219.
<https://doi.org/10.1109/86.847821>
- Pfurtscheller, G., & Neuper, C. (1997). Motor imagery activates primary sensorimotor area in humans. *Neuroscience Letters*, *239*(2–3), 65–68. [https://doi.org/10.1016/S0304-3940\(97\)00889-6](https://doi.org/10.1016/S0304-3940(97)00889-6)
- Podder, P., Mehedi Hasan, M., Rafiqul Islam, M., & Sayeed, M. (2014). Design and Implementation of Butterworth, Chebyshev-I and Elliptic Filter for Speech Signal Analysis. *International Journal of Computer Applications*, *98*(7), 12–18. <https://doi.org/10.5120/17195-7390>
- Quitadamo, L. R., Cavrini, F., Sbernini, L., Riillo, F., Bianchi, L., Seri, S., & Saggio, G. (2017). Support vector machines to detect physiological patterns for EEG and EMG-based human-computer interaction: a review. *Journal of Neural Engineering*, *14*(1), 1–27.
<https://doi.org/10.1088/1741-2552/14/1/011001>
- Ramos-Murguialday, A., & Birbaumer, N. (2015). Brain oscillatory signatures of motor tasks. *Journal of Neurophysiology*, *113*(10), 3663–3682. <https://doi.org/10.1152/jn.00467.2013>

- Ramos-Murguialday, A., Schürholz, M., Caggiano, V., Wildgruber, M., Caria, A., Hammer, E. M., Halder, S., & Birbaumer, N. (2012). Proprioceptive Feedback and Brain Computer Interface (BCI) Based Neuroprostheses. *PLoS ONE*, *7*(10), 1–10. <https://doi.org/10.1371/journal.pone.0047048>
- Rashid, M., Sulaiman, N., P. P. Abdul Majeed, A., Musa, R. M., Ab. Nasir, A. F., Bari, B. S., & Khatun, S. (2020). Current Status, Challenges, and Possible Solutions of EEG-Based Brain-Computer Interface: A Comprehensive Review. *Frontiers in Neurorobotics*, *14*, 1–35. <https://doi.org/10.3389/fnbot.2020.00025>
- Rejer, I., & Górski, P. (2018). EEG Classification for MI-BCI with Independent Component Analysis. In M. Kurzynski, M. and Wozniak, & R. and Burduk (Eds.), *Proceedings of the 10th International Conference on Computer Recognition Systems CORES 2017* (Vol. 578, pp. 393–402). Springer International Publishing AG. https://doi.org/10.1007/978-3-319-59162-9_41
- Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: the RPROP algorithm. *IEEE International Conference on Neural Networks*, 586–591. <https://doi.org/10.1109/ICNN.1993.298623>
- Robledo Del Castillo, P. F., Londoño Fernández, J. L., & Salazar López, J. L. (2012, December). *GUÍA PARA EXAMEN DE SOLICITUDES DE PATENTE DE INVENCION Y MODELO DE UTILIDAD*. Superintendencia de Industria y Comercio (SIC) de Colombia. https://www.sic.gov.co/sites/default/files/files/Nuestra_Entidad/Publicaciones/121774_Guia_de_patentes.pdf
- Rodríguez-Bermúdez, G., & García-Laencina, P. J. (2012). Automatic and Adaptive Classification of Electroencephalographic Signals for Brain Computer Interfaces. *Journal of Medical Systems*, *36*(1), 51–63. <https://doi.org/10.1007/s10916-012-9893-4>
- Rodríguez-Ugarte, M., Iáñez, E., Ortíz, M., & Azorín, J. M. (2017). Personalized Offline and Pseudo-Online BCI Models to Detect Pedaling Intent. *Frontiers in Neuroinformatics*, *11*, 1–12. <https://doi.org/10.3389/fninf.2017.00045>
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of Neural Engineering*, *16*(5), 1–37. <https://doi.org/10.1088/1741-2552/ab260c>
- Sadiq, M. T., Yu, X., Yuan, Z., Fan, Z., Rehman, A. U., Li, G., & Xiao, G. (2019). Motor Imagery EEG Signals Classification Based on Mode Amplitude and Frequency Components Using Empirical Wavelet Transform. *IEEE Access*, *7*, 127678–127692. <https://doi.org/10.1109/ACCESS.2019.2939623>
- Saha, S., & Baumert, M. (2020). Intra- and Inter-subject Variability in EEG-Based Sensorimotor Brain Computer Interface: A Review. *Frontiers in Computational Neuroscience*, *13*, 1–8. <https://doi.org/10.3389/fncom.2019.00087>
- Samuel, O. W., Geng, Y., Li, X., & Li, G. (2017). Towards Efficient Decoding of Multiple Classes of Motor Imagery Limb Movements Based on EEG Spectral and Time Domain Descriptors. *Journal of Medical Systems*, *41*(12), 1–13. <https://doi.org/10.1007/S10916-017-0843-Z>
- Sanei, S., & Chambers, J. A. (2007). EEG Signal Processing. In *EEG Signal Processing*. John Wiley and Sons Ltd. <https://doi.org/10.1002/9780470511923>
- Sayed, K., Kamel, M., Alhaddad, M., Malibary, H. M., & Kadah, Y. M. (2017). Characterization of phase space trajectories for Brain-Computer Interface. *Biomedical Signal Processing and Control*, *38*, 55–66. <https://doi.org/10.1016/j.bspc.2017.05.007>
- Schenkman, M., Berger, R. A., Riley, P. O., Mann, R. W., & Hodge, W. A. (1990). Whole-Body Movements During Rising to Standing from Sitting. *Physical Therapy*, *70*(10), 638–648. <https://doi.org/10.1093/PTJ/70.10.638>
- Schlögl, A. (2000). *The electroencephalogram and the adaptive autoregressive model: theory and applications* [Technischen Universität Graz]. https://pub.ist.ac.at/~schloegl/publications/EEG_AAR_model.pdf
- Schlögl, A., Lugger, K., & Pfurtscheller, G. (1997). Using adaptive autoregressive parameters for a

- brain-computer-interface experiment. *Proceedings of the 19th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. "Magnificent Milestones and Emerging Opportunities in Medical Engineering"* (Cat. No.97CH36136), 4, 1533–1535. <https://doi.org/10.1109/IEMBS.1997.757002>
- Schwartz, A. B. (2016). Movement: How the Brain Communicates with the World. *Cell*, 164(6), 1122–1135. <https://doi.org/10.1016/j.cell.2016.02.038>
- Sebastián-Romagosa, M., Cho, W., Ortner, R., & Guger, C. (2021). Brain Computer Interface treatment for gait rehabilitation of stroke patients – Preliminary results. *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2948–2951. <https://doi.org/10.1109/SMC52423.2021.9659297>
- Sebastián-Romagosa, M., Cho, W., Ortner, R., Murovec, N., Von Oertzen, T., Kamada, K., Allison, B. Z., & Guger, C. (2020). Brain Computer Interface Treatment for Motor Rehabilitation of Upper Extremity of Stroke Patients—A Feasibility Study. *Frontiers in Neuroscience*, 14, 1–12. <https://doi.org/10.3389/fnins.2020.591435>
- Si-Mohammed, H., Petit, J., Jeunet, C., Argelaguet, F., Spindler, F., Evain, A., Roussel, N., Casiez, G., & Lecuyer, A. (2020). Towards BCI-Based Interfaces for Augmented Reality: Feasibility, Design and Evaluation. *IEEE Transactions on Visualization and Computer Graphics*, 26(3), 1608–1621. <https://doi.org/10.1109/TVCG.2018.2873737>
- Singh, A., Hussain, A. A., Lal, S., & Guesgen, H. W. (2021). A Comprehensive Review on Critical Issues and Possible Solutions of Motor Imagery Based Electroencephalography Brain-Computer Interface. *Sensors*, 21(6), 1–35. <https://doi.org/10.3390/s21062173>
- Singh, B., & Natsume, K. (2022). Readiness potential reflects the intention of sit-to-stand movement. *Cognitive Neurodynamics*, 1–16. <https://doi.org/10.1007/s11571-022-09864-5>
- Sitaram, R., Caria, A., Veit, R., Gaber, T., Rota, G., Kuebler, A., & Birbaumer, N. (2007). fMRI Brain-Computer Interface: A Tool for Neuroscientific Research and Treatment. *Computational Intelligence and Neuroscience*, 2007, 1–10. <https://doi.org/10.1155/2007/25487>
- Sitaram, R., Ros, T., Stoeckel, L., Haller, S., Scharnowski, F., Lewis-Peacock, J., Weiskopf, N., Blefari, M. L., Rana, M., Oblak, E., Birbaumer, N., & Sulzer, J. (2017). Closed-loop brain training: the science of neurofeedback. *Nature Reviews Neuroscience*, 18(2), 86–100. <https://doi.org/10.1038/nrn.2016.164>
- Škola, F., Tinková, S., & Liarokapis, F. (2019). Progressive Training for Motor Imagery Brain-Computer Interfaces Using Gamification and Virtual Reality Embodiment. *Frontiers in Human Neuroscience*, 13, 1–16. <https://doi.org/10.3389/fnhum.2019.00329>
- Svoboda, K., & Li, N. (2018). Neural mechanisms of movement planning: motor cortex and beyond. *Current Opinion in Neurobiology*, 49, 33–41. <https://doi.org/10.1016/j.conb.2017.10.023>
- Syan, C. S., & Harnarinesingh, R. E. S. (2010). Comparison of Pre-Processing and Classification Techniques for Single-Trial and Multi-Trial P300-Based Brain Computer Interfaces. *American Journal of Applied Sciences*, 7(9), 1219–1225. <https://doi.org/10.3844/ajassp.2010.1219.1225>
- Togha, M. M., Salehi, M. R., & Abiri, E. (2021). An improved version of local activities estimation to enhance motor imagery classification. *Biomedical Signal Processing and Control*, 66, 1–10. <https://doi.org/10.1016/j.bspc.2021.102485>
- Torres-García, A. A., Mendoza-Montoya, O., Molinas, M., Antelis, J. M., Moctezuma, L. A., & Hernández-Del-Toro, T. (2022). Pre-processing and feature extraction. In A. A. Torres-García, C. A. Reyes-García, L. Villaseñor-Pineda, & O. Mendoza-Montoya (Eds.), *Biosignal Processing and Classification Using Computational Learning and Intelligence* (1st ed., pp. 59–91). Elsevier. <https://doi.org/10.1016/B978-0-12-820125-1.00014-2>
- Torres, E. P., Torres, E. A., Hernández-Álvarez, M., & Yoo, S. G. (2020). EEG-Based BCI Emotion Recognition: A Survey. *Sensors*, 20(18), 1–36. <https://doi.org/10.3390/s20185083>
- Tremmel, C., Herff, C., Sato, T., Rechowicz, K., Yamani, Y., & Krusienski, D. J. (2019).

- Estimating Cognitive Workload in an Interactive Virtual Reality Environment Using EEG. *Frontiers in Human Neuroscience*, *13*, 1–12. <https://doi.org/10.3389/fnhum.2019.00401>
- Triana-Guzman, N., Orjuela-Cañón, A. D., Jutinico, A. L., Mendoza-Montoya, O., & Antelis, J. M. (2022). Decoding EEG rhythms offline and online during motor imagery for standing and sitting based on a brain-computer interface. *Frontiers in Neuroinformatics*, *16*, 1–17. <https://doi.org/10.3389/fninf.2022.961089>
- Triana Guzmán, N., Orjuela-Cañón, Á. D., & Jutinico Alarcon, A. L. (2019). Incremental Training of Neural Network for Motor Tasks Recognition Based on Brain-Computer Interface. In I. Nyström, Y. Hernández Heredia, & V. Milián Núñez (Eds.), *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 11896 LNCS* (pp. 610–619). Springer. https://doi.org/10.1007/978-3-030-33904-3_57
- Tsui, C. S. L., & Gan, J. Q. (2007). Asynchronous BCI Control of a Robot Simulator with Supervised Online Training. In H. Yin, P. Tino, E. Corchado, W. Byrne, & X. Yao (Eds.), *Intelligent Data Engineering and Automated Learning - IDEAL 2007: Vol. 4881 LNCS* (pp. 125–134). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-77226-2_14
- Tzagarakis, C., Ince, N. F., Leuthold, A. C., & Pellizzer, G. (2010). Beta-Band Activity during Motor Planning Reflects Response Uncertainty. *Journal of Neuroscience*, *30*(34), 11270–11277. <https://doi.org/10.1523/JNEUROSCI.6026-09.2010>
- Vaid, S., Singh, P., & Kaur, C. (2015). EEG Signal Analysis for BCI Interface: A Review. *2015 Fifth International Conference on Advanced Computing & Communication Technologies (ACCT)*, 143–147. <https://doi.org/10.1109/ACCT.2015.72>
- Vega, R., Sajed, T., Mathewson, K. W., Khare, K., Pilarski, P. M., Greiner, R., Sanchez-Ante, G., & Antelis, J. M. (2016). Assessment of feature selection and classification methods for recognizing motor imagery tasks from electroencephalographic signals. *Artificial Intelligence Research*, *6*(1), 37–51. <https://doi.org/10.5430/air.v6n1p37>
- Virgilio G., C. D., Sossa A., J. H., Antelis, J. M., & Falcón, L. E. (2020). Spiking Neural Networks applied to the classification of motor tasks in EEG signals. *Neural Networks*, *122*, 130–143. <https://doi.org/10.1016/j.neunet.2019.09.037>
- Vourvopoulos, A., Jorge, C., Abreu, R., Figueiredo, P., Fernandes, J.-C., & Bermúdez i Badia, S. (2019). Efficacy and Brain Imaging Correlates of an Immersive Motor Imagery BCI-Driven VR System for Upper Limb Motor Rehabilitation: A Clinical Case Report. *Frontiers in Human Neuroscience*, *13*, 1–17. <https://doi.org/10.3389/fnhum.2019.00244>
- Wan, B., Zhou, Z., Ming, D., Qi, H., & Cheng, L. (2009). *Method for capturing signals and extracting characteristics of stand imagination action brain wave* (Patent No. CN100571617C).
- Wang, C., Wu, X., Wang, Z., & Ma, Y. (2018). Implementation of a Brain-Computer Interface on a Lower-Limb Exoskeleton. *IEEE Access*, *6*, 38524–38534. <https://doi.org/10.1109/ACCESS.2018.2853628>
- Wang, H., Tang, C., Xu, T., Li, T., Xu, L., Yue, H., Chen, P., Li, J., & Bezerianos, A. (2020). An Approach of One-vs-Rest Filter Bank Common Spatial Pattern and Spiking Neural Networks for Multiple Motor Imagery Decoding. *IEEE Access*, *8*, 86850–86861. <https://doi.org/10.1109/ACCESS.2020.2992631>
- Wang, Z., Cao, L., Zhang, Z., Gong, X., Sun, Y., & Wang, H. (2018). Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition. *Concurrency and Computation: Practice and Experience*, *30*(23), 1–9. <https://doi.org/10.1002/cpe.4413>
- Wierzgała, P., Zapala, D., Wojcik, G. M., & Masiak, J. (2018). Most Popular Signal Processing Methods in Motor-Imagery BCI: A Review and Meta-Analysis. *Frontiers in Neuroinformatics*, *12*, 1–10. <https://doi.org/10.3389/fninf.2018.00078>
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., & Vaughan, T. M. (2002).

- Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767–791. [https://doi.org/10.1016/S1388-2457\(02\)00057-3](https://doi.org/10.1016/S1388-2457(02)00057-3)
- Wolpaw, J. R., Millán, J. del R., & Ramsey, N. F. (2020). Brain-computer interfaces: Definitions and principles. In N. F. Ramsey & J. del R. Millán (Eds.), *Brain-Computer Interfaces: Handbook of Clinical Neurology* (3rd ed., Vol. 168, pp. 15–23). Elsevier. <https://doi.org/10.1016/B978-0-444-63934-9.00002-0>
- World Medical Association. (2013). World Medical Association Declaration of Helsinki: Ethical Principles for Medical Research Involving Human Subjects. *JAMA*, 310(20), 2191–2194. <https://doi.org/10.1001/JAMA.2013.281053>
- Xu, B., & Song, A. (2008). Pattern Recognition of Motor Imagery EEG using Wavelet Transform. *Journal of Biomedical Science and Engineering*, 01(01), 64–67. <https://doi.org/10.4236/jbise.2008.11010>
- Xu, M., He, F., Jung, T. P., Gu, X., & Ming, D. (2021). Current Challenges for the Practical Application of Electroencephalography-Based Brain–Computer Interfaces. *Engineering*, 7(12), 1710–1712. <https://doi.org/10.1016/J.ENG.2021.09.011>
- Xu, P., Liu, T., Zhang, R., Zhang, Y., & Yao, D. (2014). Using particle swarm to select frequency band and time interval for feature extraction of EEG based BCI. *Biomedical Signal Processing and Control*, 10(1), 289–295. <https://doi.org/10.1016/j.bspc.2013.08.012>
- Xu, R., Allison, B. Z., Ortner, R., Irimia, D. C., Espinosa, A., Lechner, A., & Guger, C. (2017). How Many EEG Channels Are Optimal for a Motor Imagery Based BCI for Stroke Rehabilitation? In J. Ibáñez, J. González-Vargas, J. M. Azorín, M. Akay, & J. L. Pons (Eds.), *Converging Clinical and Engineering Research on Neurorehabilitation II* (Vol. 15, pp. 1109–1113). Springer International Publishing. https://doi.org/10.1007/978-3-319-46669-9_180
- Yadav, D., Yadav, S., & Veer, K. (2020). A comprehensive assessment of Brain Computer Interfaces: Recent trends and challenges. *Journal of Neuroscience Methods*, 346, 1–20. <https://doi.org/10.1016/j.jneumeth.2020.108918>
- Yi, W., Qiu, S., Qi, H., Zhang, L., Wan, B., & Ming, D. (2013). EEG feature comparison and classification of simple and compound limb motor imagery. *Journal of NeuroEngineering and Rehabilitation*, 10(1), 1–12. <https://doi.org/10.1186/1743-0003-10-106>
- Yu, T., Xiao, J., Wang, F., Zhang, R., Gu, Z., Cichocki, A., & Li, Y. (2015). Enhanced Motor Imagery Training Using a Hybrid BCI with Feedback. *IEEE Transactions on Biomedical Engineering*, 62(7), 1706–1717. <https://doi.org/10.1109/TBME.2015.2402283>
- Yuan, H., & He, B. (2014). Brain–Computer Interfaces Using Sensorimotor Rhythms: Current State and Future Perspectives. *IEEE Transactions on Biomedical Engineering*, 61(5), 1425–1435. <https://doi.org/10.1109/TBME.2014.2312397>
- Zammouri, A., Ait Moussa, A., & Mebrouk, Y. (2018). Brain-computer interface for workload estimation: Assessment of mental efforts in learning processes. *Expert Systems with Applications*, 112, 138–147. <https://doi.org/10.1016/j.eswa.2018.06.027>
- Zhang, J., & Wang, M. (2021). A survey on robots controlled by motor imagery brain-computer interfaces. *Cognitive Robotics*, 1, 12–24. <https://doi.org/10.1016/j.cogr.2021.02.001>
- Zhang, Zhiguo. (2019). Spectral and Time-Frequency Analysis. In L. Hu & Z. Zhang (Eds.), *EEG Signal Processing and Feature Extraction* (pp. 89–116). Springer Singapore. https://doi.org/10.1007/978-981-13-9113-2_6
- Zhang, Zhiwen, Duan, F., Sole-Casals, J., Dinares-Ferran, J., Cichocki, A., Yang, Z., & Sun, Z. (2019). A Novel Deep Learning Approach With Data Augmentation to Classify Motor Imagery Signals. *IEEE Access*, 7, 15945–15954. <https://doi.org/10.1109/ACCESS.2019.2895133>
- Zhou, B., Wu, X., Ruan, J., LV, Z., & Zhang, L. (2019). How many channels are suitable for independent component analysis in motor imagery brain-computer interface. *Biomedical Signal Processing and Control*, 50, 103–120. <https://doi.org/10.1016/j.bspc.2019.01.017>
- Zhou, J., Meng, M., Gao, Y., Ma, Y., & Zhang, Q. (2018). Classification of motor imagery eeg

- using wavelet envelope analysis and LSTM networks. *2018 Chinese Control And Decision Conference (CCDC)*, 5600–5605. <https://doi.org/10.1109/CCDC.2018.8408108>
- Zhou, Z., Ming, D., Wan, B., & Cheng, L. (2007). Event-Related EEG-Changes during Attempted Standing Up Task. *2007 Joint Meeting of the 6th International Symposium on Noninvasive Functional Source Imaging of the Brain and Heart and the International Conference on Functional Biomedical Imaging*, 66–69. <https://doi.org/10.1109/NFSI-ICFBI.2007.4387689>
- 徐圣普, 蒲江波, 陈小刚, 谢小波, 刘明, & 赵秉. (2018). *A kind of method for controlling intelligent wheelchair based on brain-computer interface and artificial intelligence* (Patent No. CN106726209B).
- 鲁守银, 张营, 高诺, 高焕兵, 王涛, & 隋首钢. (2018). *Intelligent wheelchair system and its method of operating based on brain-computer interface* (Patent No. CN106074021B).

Capítulo 11. Anexos

11.1. Solicitud de patente



SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO DELEGATURA PARA LA PROPIEDAD INDUSTRIAL

RESUMEN DE SOLICITUD DE NUEVAS CREACIONES

Fecha Radicación	20 de septiembre de 2021
Expediente No.	NC2021/0012295
Tipo de Trámite:	Patente de Invención Nacional
Título:	SISTEMA Y MÉTODO PARA LA INTERPRETACIÓN DE LA IMAGINACIÓN MOTORA DE LOS MOVIMIENTOS DE PONERSE DE PIE Y SENTARSE, BASADO EN INTERFAZ CEREBRO-COMPUTADORA.
Solicitante:	COLEGIO MAYOR DE NUESTRA SEÑORA DEL ROSARIO, Universidad Antonio Nariño
Inventor:	ANDRÉS LEONARDO JUTINICO ALARCÓN, ALVARO DAVID ORJUELA CAÑON, EDWIN ALFREDO REYES GUZMÁN, NAYID TRIANA GUZMÁN
Apoderado:	HUGO DANIEL GONZALEZ HERNANDEZ
Prioridad:	No priority data or priority not applicable.
Clasificación:	

Página 1 de 1

Señor ciudadano, para hacer seguimiento a su solicitud, la entidad le ofrece los siguientes canales:
www.sic.gov.co - Teléfono en Bogotá: 5920400 - Línea gratuita a nivel nacional: 018000910165
 Dirección: Cra. 13 # 27 - 00 pisos 1, 3, 4, 5, 6, 7 Y 10, Bogotá D.C. - Colombia
 Teléfono: (571) 5870000 - e-mail: contactenos@sic.gov.co



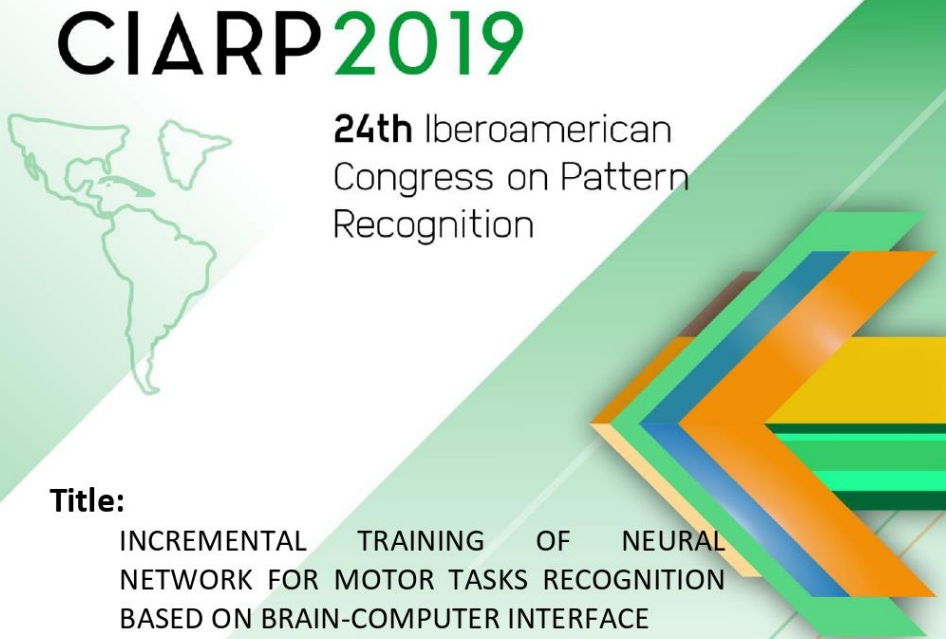
Nuestro aporte es fundamental,
al usar menos papel contribuimos con el medio ambiente



El futuro
es de todos

Gobierno
de Colombia

11.5. Ponencia




CIARP 2019

24th Iberoamerican
Congress on Pattern
Recognition


Title:
INCREMENTAL TRAINING OF NEURAL
NETWORK FOR MOTOR TASKS RECOGNITION
BASED ON BRAIN-COMPUTER INTERFACE

Author (s):
NAYID TRIANA GUZMAN, ALVARO DAVID
ORJUELA CAÑON, ANDRES LEONARDO
JUTINICO ALARCON

Dr. Yanio Hernández Heredia
CIARP co-chair



Dr. Heidy Mendez - Vazquez
CIARP co-chair



OCTOBER
28th-31st, 2019
HAVANA, CUBA