

Decodificación de la imaginación motora del pedaleo a partir de señales electroencefalográficas

Juan, J. V.^{a,b,*}, Iáñez, E.^{a,c}, Ortiz, M.^{a,c}, Tornero, J.^b, Azorín, J. M.^{a,c,d}

^aBrain-Machine Interface Systems Lab, Universidad Miguel Hernández de Elche, Avinguda de la Universitat d'Elx, s/n, 3202, Elche, España

^bCenter for Clinical Neuroscience Hospital Los Madroños, Hospital Los Madroños, M-501, Km 17, 900, 28690, Brunete, España

^cInstituto de Investigación en Ingeniería de Elche-I3E, Universidad Miguel Hernández de Elche, Avinguda de la Universitat d'Elx, s/n, 3202, Elche, España

^dValGRAI: Valencian Graduated School and Research Network of Artificial Intelligence, Camí de Vera, s/n, Edificio 3Q, 46022 Valencia, España

To cite this article: Juan, J. V., Iáñez, E., Ortiz, M., Tornero, J., Azorín, J. M. 2023. Pedaling motor imagery decodification through electroencefalographic signals
XLIV Jornadas de Automática, 47-52. <https://doi.org/10.17979/spudc.9788497498609.047>

Resumen

El principio clave de la decodificación de la imaginación motora (MI, *Motor Imagery*) para las Interfaces Cerebro-Máquina (BMIs, *Brain-Machine Interfaces*) basadas en electroencefalogramas (EEG) consiste en extraer características discriminativas de tarea de los dominios espectrales, espaciales y temporales de manera conjunta y eficiente. A este respecto, la no estacionalidad de las señales EEG y su alta relación señal/ruido representan un desafío para el diseño avanzado de algoritmos de decodificación efectivos. Por su parte estos algoritmos permiten el control de dispositivos en tareas de neurorrehabilitación, activando la corteza motora del paciente y contribuyendo a su recuperación. Por estas razones, este estudio ha optimizado un algoritmo de decodificación de MI basado en características espaciales, el cual ha sido probado en dos sujetos sanos alcanzando rangos de acierto de hasta el 80 %, lo que supone una mejora respecto a estudios previos.

Palabras clave: Interfaz Cerebro-Máquina, Imaginación motora, Patrones Espaciales Comunes, Análisis Discriminante Lineal

Pedaling motor imagery decodification through electroencefalographic signals

Abstract

The fundamental principle behind the decoding of motor imagery (MI) for electroencefalogram (EEG)-based Brain-Machine Interfaces (BMIs) is to effectively and simultaneously extract task-discriminative features from spectral, spatial, and temporal domains. In this regard, the non-stationarity of EEG signals and their high signal-to-noise ratio pose challenges for the advanced design of effective decoding algorithms. These algorithms enable device control in neurorehabilitation tasks by activating the motor cortex of patients, contributing to their neural disease recovery. For these reasons, this study has optimized a spatial feature-based MI decoding algorithm, which has been tested on two able-bodied subjects, achieving accuracy rates of up to 80 %, which represents an improvement compared to previous studies.

Keywords: Brain-Machine Interface, Motor Imagery, Common Spatial Patterns, Linear Discriminant Analysis

1. Introducción

Las Interfaces Cerebro-Máquina o BMIs por sus siglas en inglés permiten a los especialistas registrar la actividad neuronal del cerebro del usuario (Slutzky, 2019). Estos aparatos registran los impulsos eléctricos cerebrales bien a través de méto-

dos invasivos (intracorticales) como la electrocorticografía (conocida como ECoG) (Leuthardt et al., 2006) o bien mediante métodos no invasivos (directamente desde el cuero cabelludo), como la Imagen por Resonancia Magnética Funcional (fMRI, del inglés *Functional Magnetic Resonance Imaging*) (Misaki and et al., 2021) o la que probablemente sea la técnica más ex-

*Autor para correspondencia: javier.juanp@umh.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

tendida, la electroencefalografía o EEG (Garipelli et al., 2013; Ortiz et al., 2020). Todas estas técnicas, apoyadas en las BMIs, son un apoyo especialmente útil en los procedimientos de rehabilitación neuronal (Mak and Wolpaw, 2010; Slutzky, 2019), ya que brindan la oportunidad de analizar e interpretar las señales EEG de los pacientes. Para pacientes que requieren rehabilitación neural motora (principalmente pacientes con lesiones de médula espinal y accidentes cerebrovasculares), este apoyo es aún mayor, ya que una correcta interpretación de la actividad neuronal supone la detección de la intención de movimiento del paciente. Estas detecciones son esenciales para asegurar un control consciente de los dispositivos clínicos utilizados en la rehabilitación motora, como un exoesqueleto de miembros inferiores o un cicloergómetro. De acuerdo a la literatura (Cramer, 2008; Gharabaghi, 2016), una mayor implicación neuronal por parte de los pacientes durante su rehabilitación motora conlleva una inmersión más realista y profunda en sus tareas motoras, lo que se traduce en un rendimiento y resultados de rehabilitación más satisfactorios. Si a su vez, esta implicación mental se basa en la imaginación motora o MI, es decir, la imaginación del movimiento, ya sea visual o cinestésica, se activa el área motora cerebral, aumentando más aún las ventajas de esta clase de terapias ya que se estimula el área cerebral afectada.

Siguiendo estas líneas, muchas investigaciones se han centrado en asegurar un control seguro y preciso de los dispositivos rehabilitadores a partir de las señales EEG (Li and Hsiao-Weckler, 2013; Millán, 2010). Respecto a esto, estudios recientes afirman que la corteza motora está particularmente activa durante fases concretas del ciclo de la marcha humana (Castermans and Duvinage, 2013). En consecuencia, se han multiplicado los estudios que tratan de controlar dispositivos de rehabilitación mediante BMIs, ya sean para miembro superior (Mansour et al., 2022; Vidaurre et al., 2016), o bien para miembro inferior, principalmente exoesqueletos (Contreras-Vidal and Grossman, 2013; Li and Hsiao-Weckler, 2013; Millán, 2010) aunque también los hay que emplean dispositivos clínicos de pedaleo como cicloergómetros debido a su menor coste y mayor facilidad de uso (Ambrosini and et al., 2016; Ortiz et al., 2019). Debido a la activación de la corteza motora, la mayoría de estas BMIs se basan en MI.

A la hora de decodificar esta MI de las señales de EEG, al igual que en otras numerosas aplicaciones de BMIs el enfoque clásico se basa en extraer una serie de características discriminantes, ya sean temporales (en relación con la evolución de las señales en el tiempo), espaciales (en relación con la posición de cada electrodo) o frecuenciales (en relación con la evolución de las señales en el dominio de la frecuencia) y alimentar un algoritmo clasificador con ellas (generalmente buscan definir el hiperplano que separe los conjuntos) (Lotte and et al., 2018). El aprendizaje automático o *Machine Learning* también está comenzando a hacer presencia en el campo, mayoritariamente con redes neuronales convolucionales basadas en aprendizaje profundo o *Deep Learning*, método que se está postulando como una posible solución al problema que plantea la decodificación correcta y acertada de la MI en tiempo real (Lawhern and et al., 2018; Liang and et al., 2023), existiendo incluso desarrollos de redes neuronales exclusivamente para la decodificación de MI partiendo de EEG (Autthasan and et al., 2022; Wang et al., 2023). Sin embargo, esta tecnología es relativamente nueva y,

aunque todo indica que acabará siendo así, todavía no existen evidencias absolutas de que mejore los resultados que pueden llegar a alcanzarse haciendo uso de técnicas de clasificación basadas en la extracción de características de la señal. Además, las redes neuronales tienen una fuerte desventaja, ya que requieren de una gran cantidad de datos para su entrenamiento, necesario para optimizar su rendimiento.

En cuanto al empleo de técnicas de extracción de características para decodificación de MI partiendo de EEG, la tendencia en los últimos años ha centrado el camino en las características espaciales, pues parece ser lo que mejor resultados está dando (Ang et al., 2012; Blankertz et al., 2008). En concreto, los modelos basados en el algoritmo de Patrones Espaciales Comunes (CSP, *Common Spatial Patterns* en inglés) como en (Ang et al., 2012). Además, estudios como Ortiz et al. (2020) sugieren que una clasificación en cascada mediante Análisis Discriminante Lineal (LDA del inglés *Linear Discriminant Analysis*) mayoriza el acierto en la clasificación. Para acabar, el concepto de división por bandas de frecuencia parece representar también una mejora robusta para los modelos decodificadores de MI. Debido principalmente a la alta relación señal/ruido que caracteriza a las señales EEG es fundamental afinar bastante el preprocesamiento cuando se desea extraer información válida de ellas; por tanto, es muy habitual aplicar filtros, transformaciones, normalizaciones etc. a estas señales antes de analizarlas. La división por bandas de frecuencia aboga por seleccionar un rango de frecuencias de interés y dividirlo en varias bandas, analizando cada una por separado, o bien aplicando relaciones entre ellas. Estudios como (Ortiz et al., 2020) demuestran la eficacia de este método, incluso aplicado con redes neuronales (Wang et al., 2023). Este último estudio sugiere además que la relación entre bandas que proporciona mejores resultados de decodificación es la suma elemento a elemento.

Por todos estos motivos, se ha optado por elaborar un algoritmo de detección de MI basado en características espaciales y clasificación mediante Análisis Discriminante Lineal para control de un cicloergómetro clínico mediante imaginación motora del pedaleo. Este esquema de control podría incurrir una mayor inmersión e implicación cerebral consciente de los pacientes, lo que presuntamente supondría una mejora en los resultados del proceso rehabilitador. El uso del cicloergómetro, a su vez, y no alternativas más avanzadas como exoesqueletos, hace más económicamente viable esta posible terapia. Del mismo modo, el empleo exclusivamente de EEG y no de también otras posibles técnicas para el control como electromiografía abarata costes y disminuye tiempos de instrumentación. En un trabajo previo (Juan et al., 2022) se diseñó un algoritmo preliminar y se realizaron algunos registros piloto alcanzando un acierto de en torno al 60 %. En este texto se presenta una versión optimizada del algoritmo, añadiendo el concepto de segmentación en bandas de frecuencia, en la que se han alcanzado porcentajes de acierto en la clasificación de alrededor del 80 % en los nuevos registros.

2. Materiales y métodos

En la presente sección del escrito se detalla el proceso seguido para la experimentación y el registro de datos EEG, indicando los equipos utilizados. A continuación, se explica el

procedimiento llevado a la hora de procesar los datos y obtener resultados.

2.1. Sujetos

Con el objetivo de validar y poner a prueba el algoritmo desarrollado, han sido seleccionados dos sujetos totalmente sanos (26.0 ± 4.2 años de edad) para este trabajo, todos ellos mayores de edad y sin presentar ninguna condición que pueda alterar la calidad de las señales EEG registradas, como pueden ser bruxismo, embarazo o lactancia, o poseer implantes eléctricos como marcapasos. Los sujetos están formados por una mujer (S1) y un hombre (S2). Por su parte, todos los sujetos recibieron información clara sobre el estudio, y firmaron el consentimiento informado planteado en el comité de ética aprobado por el Comité de Ética de la Investigación con medicamentos del Hospital Universitario Severo Ochoa de Leganés (Madrid) con código HLM-CYCLING-EEG.

2.2. Protocolo experimental

El protocolo fue diseñado estratégicamente para poder entrenar dos paradigmas de control: control en parado (cicloergómetro inactivo) y control en movimiento (cicloergómetro activo). Esto requiere de fases de relax (no MI) y fases de MI, tanto en estático como durante el pedaleo (siempre en modo pasivo, el dispositivo asiste al usuario como en una terapia real). Partiendo de estos principios, cada sesión de pruebas ha consistido de 22 repeticiones, consistiendo cada una de ellas en 15s de relax, seguidos de 30s de MI del pedaleo, más 15s de relax. Se añadieron algunos segundos en cada cambio de tarea que fueron descartados para el análisis con el fin de evitar perturbaciones en la señal. De estas 22 repeticiones, las 11 impares se realizan con el cicloergómetro inactivo y las 11 pares con el cicloergómetro activo. De esta manera, se poseen datos sobre los comandos de arranque (MI en estático) y parada (relax en movimiento) del dispositivo rehabilitador en una posible terapia. El número de repeticiones se fijó en 22 para poder descartar la peor de cada paradigma y quedarse con un número más redondo, 10 de cada, y poder alimentar una posible futura red neuronal para decodificación de MI.

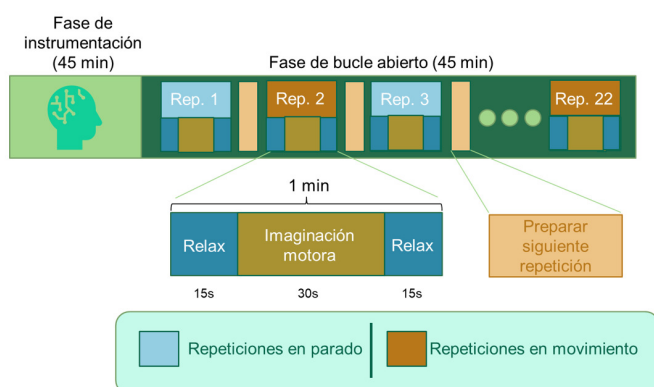


Figura 1: Protocolo experimental. Protocolo seguido en cada una de las sesiones de experimentación. Cada usuario realizó cuatro sesiones.

La gran diferencia respecto a (Juan et al., 2022) es que en esta ocasión se han realizado cuatro sesiones por sujeto, es decir, se disponen de $22 \cdot 4 = 88$ repeticiones por usuario. Esto per-

mite estudiar en cierta medida la progresión de los modelos de codificadores conforme reciben más datos, así como la de los propios usuarios conforme aprenden a usar la BMI. La Figura 1 representa esquemáticamente el protocolo seguido en cada sesión experimental para la recabación de datos EEG.

2.3. Equipos empleados

Para grabar las señales EEG de las sujetos, se ha empleado el equipo g.NAUTILUSPRO Flexible de 32 canales con su distribución g.SCARABEO, de g.tec medical engineering GmbH. Este equipo está formado con un gorro para EEG y 34 electrodos (32 activos más tierra y referencia), un emisor Wi-Fi (HEADSET) y un receptor (BASE STATION), por lo que es parcialmente inalámbrico, lo que permite al usuario pedalear con total libertad de movimiento. Las señales EEG fueron adquiridas a 500Hz, y el gorro fue correctamente instrumentado con gel conductor en todos los registros.

En cuanto al cicloergómetro, este se trata del modelo CycleMotus™ A4 (Fourier Intelligence ©). Los instantes en los que permaneció activo fue siempre en su modo pasivo, con una velocidad de giro de 30 revoluciones por minuto para el usuario S1 y de 20 para el sujeto S2. Estas velocidades se ajustaron a las preferencias de comodidad para cada usuario.

En la Figura 2, perteneciente a una de las sesiones de registro, puede apreciarse con más detalle el montaje descrito.



Figura 2: Montaje de los experimentos realizados. Sujeto de pruebas realizando una de las sesiones de registro de señales EEG. Las señales se capturan mientras pedalea y ejecuta las tareas mentales. Se tapó la pantalla interactiva del cicloergómetro para evitar estímulos externos al protocolo de registro.

2.4. Análisis realizados

En primer lugar, se ha realizado una preselección de electrodos para el análisis. El gorro cuenta con 32 electrodos activos como se describe en la subsección 2.1, pero tan solo 19 han sido tomados para la investigación, los cuales son, de acuerdo con el estándar 10/10: FZ, F4, F3, FC5, FC1, FC2, FC6, T7, C3, CZ, C4, T8, CP5, CP1, CP2, CP6, P3, PZ y P4. Estos se encuentran distribuidos por el área motora cerebral (área central), parte que se estimula al efectuar MI según (Castermans and Duvinage, 2013). En la Figura 3 puede verse un gráfico con la situación de estos electrodos sobre el cráneo.

son superiores a los logrados en (Juan et al., 2022), siendo los conseguidos por S1 muy destacables con un acierto medio superior al 70%. Esto no parece deberse a la mayor velocidad de pedaleo tomada por este usuario durante los registros (30r.p.m. frente a 20r.p.m. para S2), ya que la superioridad en su acierto también está vigente en el paradigma de estático. La Figura 5 muestra gráficamente el nivel de acierto alcanzado en algunos de los registros con mayor acierto, superando el 90% en algunos casos. La línea verde de la figura muestra el índice de MI, que no es más que la media de la salida del clasificador (0 cuando detecta relax, 1 cuando detecta MI) para su muestra actual y las cuatro anteriores (los dos segundos inmediatamente anteriores de señal). En el primer ejemplo, S1, se aprecia como la MI se activa de manera prematura pero se mantiene durante su período hasta la llegada del relax (comando de parada) y se mantiene el relax salvo una leve activación final.

Tabla 1: Resumen de los resultados obtenidos en la decodificación de MI con modelos por sesión. Los valores son de porcentaje de acierto \pm desviación estándar.

Sujeto	Banco de filtros	Paradigma	Relax	MI
S1	Sí	Estático	69.7 \pm 23.0	77.8 \pm 21.3
		Pedaleo	69.4 \pm 16.6	72.0 \pm 19.8
		Valor medio	69.6\pm19.8	74.9\pm20.6
S1	No	Estático	69.3 \pm 21.7	75.3 \pm 19.4
		Pedaleo	66.9 \pm 16.0	69.2 \pm 16.8
		Valor medio	68.1 \pm 18.9	72.2 \pm 18.1
S2	Sí	Estático	62.2 \pm 27.2	57.4 \pm 22.7
		Pedaleo	64.3 \pm 19.1	59.3 \pm 25.9
		Valor medio	63.3\pm23.1	58.3 \pm 24.3
S2	No	Estático	58.7 \pm 5.8	60.4 \pm 19.3
		Pedaleo	61.7 \pm 19.3	59.6 \pm 23.6
		Valor medio	60.2 \pm 22.6	60.0\pm21.5
Valores medios	Sí	Estático	66.0 \pm 25.1	67.6 \pm 22.0
		Pedaleo	66.8 \pm 17.8	65.7 \pm 22.9
		Valor medio	66.4\pm21.5	66.6\pm22.4
Valores medios	No	Estático	64.0 \pm 23.8	67.9 \pm 19.3
		Pedaleo	64.3 \pm 17.6	64.4 \pm 20.2
		Valor medio	64.2 \pm 20.7	66.1 \pm 19.8

De la Tabla 1 puede extraerse alguna conclusión más. Los valores de MI son ligeramente superiores a los de relax; esto puede deberse a que generalmente los sujetos muestran una forma concreta y homogénea de realizar la imaginación motora, mientras que mantener un estado de relajación presenta más variables a nivel mental. También parece haber un mayor nivel de acierto en pedaleo frente al paradigma de estático, aunque la diferencia es pequeña.

Para poder estudiar la influencia de la cantidad de datos empleados para generar los modelos clasificadores, se incluye la Tabla 2. A diferencia de en la Tabla 1, los valores no están obtenidos sacando la media de los resultados de cada sesión, sino que se ha realizado un único modelo por usuario para cada paradigma incluyendo todos los datos de sus cuatro sesiones. En el

caso de la Tabla 2 solo se han considerado los valores obtenidos al aplicar el banco de filtros.

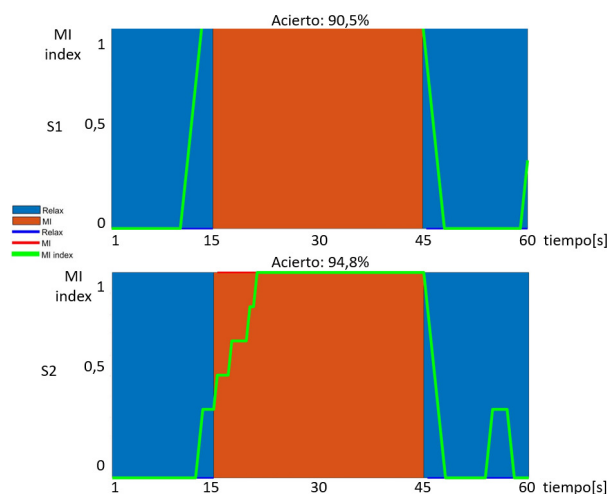


Figura 5: Resultados de decodificación de MI. En la figura se muestran los resultados de la decodificación de algunos de los registros con mayor grado de acierto. En un caso ideal, la línea verde de índice de MI debe valer 0 durante las fases de relax (recuadros azules) y 1 durante la fase de MI (recuadro naranja).

Tabla 2: Resumen de los resultados obtenidos en la decodificación de MI con modelos por usuario. Los valores son de porcentaje de acierto \pm desviación estándar.

Sujeto	Paradigma	Relax	MI
S1	Estático	74.7 \pm 15.0	71.2 \pm 23.7
	Pedaleo	70.1 \pm 14.3	71.5 \pm 18.1
	Valor medio	72.4 \pm 14.6	71.3 \pm 20.9
S2	Estático	66.6 \pm 15.0	55.8 \pm 20.2
	Pedaleo	69.0 \pm 20.0	52.6 \pm 25.6
	Valor medio	67.8 \pm 17.5	54.2 \pm 22.9
Valores medios	Estático	70.7\pm15.0	63.5\pm21.9
	Pedaleo	69.5\pm17.1	62.1\pm21.9
	Valor medio	70.1\pm16.0	62.8\pm21.9

Realizando una breve comparativa con la Tabla 1, los resultados obtenidos son algo inferiores en MI, aunque mejoran con creces los logrados en relax. A priori, más datos de entrenamiento harán que los modelos decodificadores funcionen mejor; no obstante, mezclar datos de sesiones distintas puede ser contraproducente ya que no es sencillo replicar con exactitud las tareas mentales en días diferentes. A raíz de lo comentado antes, modelos más dinámicos como el de relax parecen presentar un mayor margen de convergencia de modo que se benefician de datasets más amplios, mientras que el modelo de MI satura antes. Todo esto sugiere la necesidad de realizar siempre una pequeña tanda de entrenamiento antes de cada sesión en una posible terapia real para controlar la MI de forma óptima.

Para acabar, queda comentar que en todos los casos, de manera general los datos de desviación estándar son altos, alrededor de 20%. Esto supone un problema ya que el sistema será poco estable y podrá incurrir en activaciones involuntarias, algo que puede ser peligroso con pacientes reales.

4. Conclusiones

Haciendo acopio de todos los datos recabados, parece claro que el sistema no es lo suficientemente preciso para poder llevar a cabo una terapia real en estos momentos. No obstante, se ha logrado un avance gracias al análisis mediante la discriminación por bandas de frecuencia, y eso hace pensar que los resultados pueden seguir mejorando con otros enfoques.

También existe un amplio margen de mejora que podría abarcar el *Deep Learning*. Este planteamiento podría subvertir el problema que genera usar datos de distintas sesiones, ya que se trataría de modelos mucho más genéricos. Todos los registros tomados serán igualmente válidos para entrenar modelos basados en redes neuronales convolucionales, lo que podría aumentar más estas mejoras en el acierto. Además, una red neuronal correctamente entrenada podría presentar un comportamiento más homogéneo, disminuyendo las variaciones en la decodificación y por tanto el riesgo de activaciones indeseadas. Además, aplicar el concepto de *Transfer Learning* mediante un algoritmo de *Fine Tuning* permitiría generar modelos pre-entrenados funcionales, de manera que con una única sesión de entrenamiento podría alcanzar la precisión suficiente para ser empleado por cada usuario. El gran inconveniente del *Deep Learning* es que los modelos requieren de mucho mayor tiempo de entrenamiento, pero esto puede no ser un problema ya que el entrenamiento puede automatizarse y no requiere de una presencia constante del paciente.

En cualquiera de los casos, serán necesarios más investigación y más datos para alcanzar los objetivos propuestos.

Agradecimientos

Esta investigación ha sido llevada a cabo en el Center for Clinical Neuroscience Hospital Los Madroños del Hospital Los Madroños, Madrid, y ha sido financiada por una ayuda para la formación predoctoral en colaboración con empresas - modalidad A: incentivos para contratos predoctorales suscritos por la Universidad Miguel Hernández de Elche y financiados por la Generalitat Valenciana para la elaboración de una tesis con mención industrial.

Referencias

Ambrosini, E., et al., 2016. Neuro-mechanics of recumbent leg cycling in post-acute stroke patients. *Ann. Biomed. Eng.* 44(11), 3238–3251.
DOI: 10.1007/s10439-016-1660-0

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 Neurosci.* 6, p. 39.
DOI: 10.3389/fnins.2012.00039

Autthasan, P., et al., 2022. MIN2Net: End-to-end multi-task learning for subject-independent Motor Imagery EEG classification. *IEEE Transactions on Biomedical Engineering* 69(6), 2105–2118.
DOI: 10.1109/TBME.2021.3137184

Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., Müller, K. R., 2008. Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal Process. Mag.* 25(1), 41–56.
DOI: 10.1155/2013/591216

Castermans, T., Duvinage, M., 2013. Corticomuscular coherence revealed during treadmill walking: further evidence of supraspinal control in human locomotion. *Journal of Physiology* 591, 1407–1408.
DOI: 10.1113/jphysiol.2012.247593

Contreras-Vidal, J. L., Grossman, R. G., 2013. NeuroRex: A clinical neural interface roadmap for EEG-based brain machine interfaces to a lower body robotic exoskeleton. *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, 1579–1582.
DOI: 10.1109/EMBC.2013.6609816

Cramer, S. C., 2008. Repairing the human brain after stroke. ii. restorative therapies. *Ann Neurol* 63(5), 549–560.
DOI: 10.1002/ana.21412

Garipelli, G., Chavarriaga, R., Millán, J. D. R., 2013. Single trial analysis of slow cortical potentials: a study on anticipation related potentials. *J. Neural Eng.* 10(3), pp. 12.
DOI: 10.1088/1741-2560/10/3/036014

Gharabaghi, A., 2016. What turns assistive into restorative brain-machine interfaces? *Front. Neurosci.* 0(OCT), 406.
DOI: 10.3389/FNINS.2016.00456

Juan, J. V., Iáñez, E., Ortiz, M., Tornero, J., Azorín, J. M., 2022. Análisis de Imaginación Motora durante pedaleo a partir de señales EEG. Congreso Anual de la Sociedad Española de Ingeniería Biomédica - CASEIB - ISBN: 978-84-09-45972-8, 188–191.

Lawhern, V. J., et al., 2018. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering* 15.
DOI: 10.1088/1741-2552/aace8c

Leuthardt, E. C., Schalk, G., Moran, D., Ojemann, J. G., 2006. The emerging world of motor neuroprosthetics: A neurosurgical perspective. *Neurosurgery* 59(1), 1–14.
DOI: 10.1227/01.NEU.0000221506.06947.AC

Li, Y. D., Hsiao-Weckler, E. T., 2013. Gait mode recognition and control for a portable-powered ankle-foot orthosis. *IEEE Int Conf. Rehabil. Robot.*
DOI: 10.1109/ICORR.2013.6650373

Liang, X., et al., 2023. Convolutional neural network with a topographic representation module for EEG-based brain-computer interfaces. *Brain Sciences* 13(2), 268.
DOI: 10.3390/brainsci13020268

Lotte, F., et al., 2018. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of Neural Engineering* 15(3).
DOI: 10.1088/1741-2552/aab2f2

Mak, J., Wolpaw, J. R., 2010. Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE Reviews in Biomedical Eng.* 2, 187–199.
DOI: 10.1109/RBME.2009.2035356

Mansour, S., Ang, K. K., Nair, K. P. S., Phua, K. S., Arvaneh, M., 2022. Efficacy of brain-computer interface and the impact of its design characteristics on poststroke upper-limb rehabilitation: A systematic review and meta-analysis of randomized controlled trials. *Clinical EEG and Neuroscience* 53(1), 79–90.
DOI: 10.1177/15500594211009065

Millán, J. D. R., 2010. Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges. *Frontiers in Neuroscience* 4, 161.
DOI: 10.3389/fnins.2010.00161

Misaki, M., et al., 2021. Beyond synchrony: the capacity of fMRI hyperscanning for the study of human social interaction. *Social Cognitive and Affective Neuroscience* 16 (1-2), 84–92.
DOI: 10.1093/scan/nsaa143

Ortiz, M., Ferrero, L., Iáñez, E., Azorín, J. M., Contreras-Vidal, J. L., 2020. Sensory integration in human movement: A new brain-machine interface based on gamma band and attention level for controlling a lower-limb exoskeleton. *Front. Bioeng. Biotechnol.* 0, p. 735.
DOI: 10.3389/FBIOE.2020.00735

Ortiz, M., Rodríguez-Ugarte, M., Iáñez, E., Azorín, J. M., 2019. Analysis of algorithms for detection of pedaling intention in brain-machine interfaces. *RIAI - Rev. Iberoam. Autom. e Inform. Ind.* 16(2), 222–231.
DOI: 10.4995/riai.2018.9861

Slutzky, M. W., 2019. Brain-machine interfaces: Powerful tools for clinical treatment and neuroscientific investigations. *Neuroscientist* 25(2), 139–154.
DOI: 10.1177/1073858418775355

Vidaurre, C., Klauer, C., Schauer, T., Ramos-Murguialday, A., Müller, K. R., 2016. EEG-based BCI for the linear control of an upper-limb neuroprosthesis. *Medical Engineering and Physics* 38(11), 1195–1204.
DOI: 10.1016/j.medengphy.2016.06.010

Wang, J., Yao, L., Wang, Y., 2023. IFNet: An interactive frequency convolutional neural network for enhancing Motor Imagery decoding from EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 31, 1900–1911.
DOI: 10.1109/TNSRE.2023.3257319