



Universidad
Politécnica
de Cartagena

25
Aniversario UPCT
1998-2023

Sociedad Española de
INGENIERÍA BIOMÉDICA



Tecnología
Sanitaria



Co-funded by the
European Union

Región de Murcia



f SéNeCa(+)

Agencia de Ciencia y Tecnología
Región de Murcia

22 - 24 NOVIEMBRE 2023 | CARTAGENA



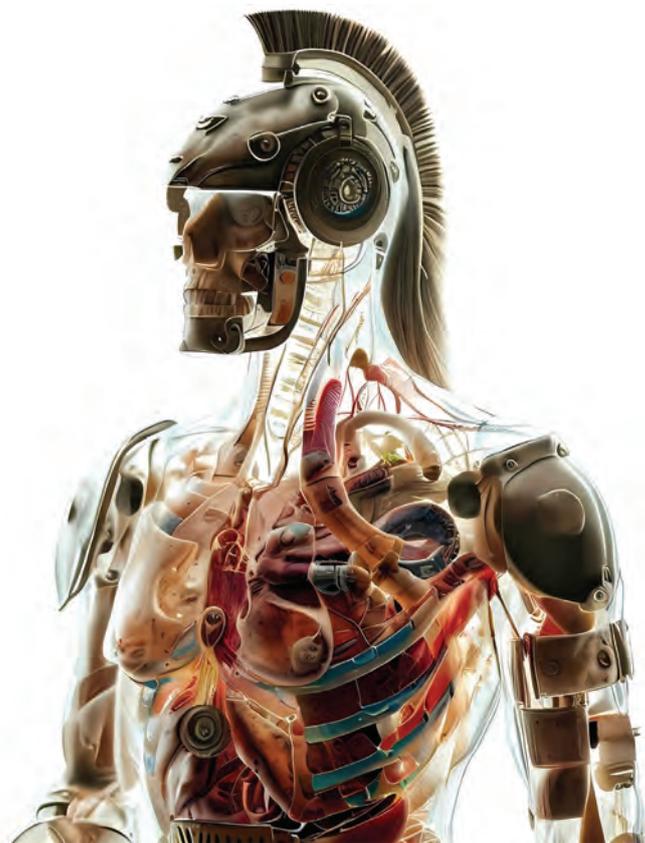
CASEIB 2023 XLI

Congreso Anual de la Sociedad Española de

Ingeniería Biomédica

Contribuyendo a la salud basada en valor

LIBRO DE ACTAS



AITADIS



FF

Fundación para la Formación
e Investigación Sanitarias
de la Región de Murcia



FABLAB
UPCT



renfe

CONGRESO (EXPEDIENTE 22193/OC/23) FINANCIADO POR LA CONSEJERÍA DE MEDIO AMBIENTE, MAR MENOR, UNIVERSIDADES E INVESTIGACIÓN, A TRAVÉS DE LA FUNDACIÓN SÉNECA-AGENCIA DE CIENCIA Y TECNOLOGÍA DE LA REGIÓN DE MURCIA CON CARGO AL PROGRAMA REGIONAL DE MOVILIDAD, COLABORACIÓN E INTERCAMBIO DE CONOCIMIENTO "JIMÉNEZ DE LA ESPADA"

Los trabajos incluidos en esta publicación han sido evaluados por el Comité Científico que en ella se relaciona y según el procedimiento que se recoge en www.caseib.es/2023/

Presidente del Comité Organizador:

Joaquín Roca González

Secretaria del Comité Organizador:

Dolores Ojados González

Editores:

Joaquín Roca González

Dolores Ojados González

Juan Suardiaz Muro

Maquetación:

Lucía Martínez Abellán

Marta García Fuentes

Diseño de portada:

Lucía Martínez Abellán

ISBN: 978-84-17853-76-1

Cita bibliográfica:

Roca González, J., Ojados González, D. y Suardiaz Muro, J. Eds. CASEIB 2023. Libro de Actas del XLI Congreso Anual de la Sociedad Española de Ingeniería Biomédica. Cartagena: Universidad Politécnica de Cartagena, 2023. 743 p. ISBN: 978-84-17853-76-1.



Libro de Actas del XLI Congreso Anual de la Sociedad Española de Ingeniería Biomédica Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.

Sesión Neurotecnologías (I)

Presentación Oral

8:30 - 10:00

Aula Sebastián Ferignan

Moderan: Mario Ortiz García y Roberto Hornero Sánchez

Metodología de análisis de la actividad cerebral en pacientes con ictus en fase de rehabilitación	377
Análisis de señales EEG en movimientos de flexión plantar y dorsal mediante el empleo de un exoesqueleto de bajo coste para la caracterización de la acción motora.	381
Aplicación de modelo de Deep Learning IFNet en decodificación de imaginación motora del pedaleo para señales EEG	385
Evaluación de una interfaz cerebro-ordenador basada en potenciales relacionados con eventos para la detección de estímulos visuales en una tarea de vigilancia	389
Propuesta de BCI basado en RSVP con número reducido de estímulos usando el modo de escritura T9	393
Evaluación del Impacto del Aprendizaje Auto-Supervisado en la Precisión de Interfaces Cerebro-Ordenador basadas en Imaginación Motora	397

Sesión Impresión 3D

Presentación Oral

8:30 - 10:00

Aula PB3

Moderan: Lola Ojados González y Dolores Parras Burgos

Metodología de planificación, diseño y fabricación de modelos anatómicos y guías quirúrgicas a medida mediante impresión 3D en caso de hemipelvectomía por osteosarcoma	402
3D printed implant structure for breast reconstruction and systematic drug delivery for preventing the reoccurrence of cancer	406
Simulador de bronoscopias mediante fabricación aditiva para la exploración médica personalizada	410
Obtención de modelos 3D de nuevos prototipos de hisopos nasofaríngeos mediante la tecnología de impresión 3D en materiales biocompatibles	414
Adaptación de pieza para tubos de respirador - tubuladora segura para la ventilación no invasiva	418
Asiento o lecho de posición infantil personalizado mediante técnicas de escaneado 3D y fabricación aditiva	422

Aplicación de modelo de Deep Learning IFNet en decodificación de imaginación motora del pedaleo para señales EEG

J. V. Juan^{1,2}, R. Martínez^{2,3,4}, E. Iáñez^{1,5}, M. Ortiz^{1,5}, J. Tornero^{2,4}, J. M. Azorín^{1,5,6}

¹ Brain-Machine Interface Systems Lab, Universidad Miguel Hernández de Elche,

Elche, España, {javier.juanp,eianez,mortiz,jm.azorin}@umh.es, <http://bmi.edu.umh.es/>

² Center for Clinical Neuroscience HLM, Hospital Los Madroños, Brunete, España, jesus.tornero@lmh.es

³ Universidad Autónoma de Madrid, Madrid, España, ruben.martinez01@estudiante.uam.es

⁴ INNTEGRA, Hospital Los Madroños, Brunete, España

⁵ Instituto de Investigación en Ingeniería de Elche-I3E, Universidad Miguel Hernández de Elche, Elche, España

⁶ ValGRAI: Valencian Graduated School and Research Network of Artificial Intelligence, España

Resumen

El principio fundamental para decodificar la Imaginación Motora (MI, Motor Imagery) en interfaces cerebro-máquina (BMIs, Brain-Machine Interfaces) basadas en electroencefalogramas (EEG) radica en la extracción eficiente de características discriminativas de tareas, abarcando los dominios espectrales, espaciales y temporales de manera conjunta. Sin embargo, las señales EEG presentan desafíos debido a su no estacionalidad y a la fuerte presencia de ruido habitual en los registros, lo que dificulta el diseño de algoritmos de decodificación altamente efectivos. Estos algoritmos son esenciales para el control de dispositivos en tareas de neurorrehabilitación, ya que activan la corteza motora del paciente y contribuyen a su recuperación. Debido a estas razones, este estudio plantea un algoritmo de decodificación de MI en señales EEG fundamentado en características espaciales, y una mejora del mismo basada en técnicas de aprendizaje profundo o Deep Learning. Estos métodos han propiciado un acierto promedio del 72.5% y de hasta un 85% en algunos sujetos sanos. Estos avances son prometedores para el control preciso de dispositivos en tareas de neurorrehabilitación y podrían tener un impacto positivo en la recuperación de pacientes.

1. Introducción

Las Interfaces Cerebro-Máquina (BMIs) permiten registrar la actividad neuronal del cerebro del usuario y emplearla como elemento de control de dispositivos [1]. Se pueden utilizar métodos invasivos, como la electrocorticografía (ECoG) [2], o no invasivos, como las señales electroencefalográficas (EEG) [3-4] o la Imagen por Resonancia Magnética Funcional (fMRI, *functional Magnetic Resonance Image*) [5].

En el campo de la rehabilitación motora, las BMIs desempeñan un papel crucial al detectar la intención de movimiento del paciente [6], lo que facilita el control de dispositivos clínicos, como exoesqueletos de miembros inferiores [7] o cicloergómetros [8-9]. Los primeros aportan una experiencia más cercana a la marcha natural del individuo, mientras que los segundos son más seguros, fáciles de usar y considerablemente más baratos. La Imaginación Motora (MI) es una técnica comúnmente utilizada en estas BMIs para activar el área motora cerebral

y mejorar los resultados de la rehabilitación. Esto es debido principalmente a dos razones. La primera es que ciertos estudios sugieren que la corteza motora humana se haya particularmente activa durante la marcha [9]. La segunda es que una mayor inmersión del paciente en sus tareas puede propiciar una activación superior de esta área motora afectada, contribuyendo no solo a su terapia muscular mediante el movimiento real de sus miembros (apoyado por un cicloergómetro, un exoesqueleto, etc.), sino también a su rehabilitación neuronal. Esta mayor implicación mental se propicia al aplicar un control basado en MI.

Los enfoques para decodificar la MI de las señales EEG suelen implicar la extracción de características discriminantes, ya sean temporales, espaciales o frecuenciales, y alimentar un clasificador con ellas [10]. También se han explorado las redes neuronales convolucionales basadas en aprendizaje profundo o *Deep Learning* (DL) como posibles soluciones, pero todavía se necesita más evidencia para determinar si superan a los métodos basados en características [11].

En el caso específico de la decodificación de MI a partir de EEG, se ha observado que las características espaciales basadas en el algoritmo de Patrones Espaciales Comunes (*Common Spatial Patterns*, CSP) han dado buenos resultados [4]. Además, la división por bandas de frecuencia ha demostrado ser efectiva para mejorar los modelos decodificadores de MI [4]. Aún más, en el caso de [4] parece demostrarse que estas características casan especialmente bien con algoritmos de clasificación lineales bayesianos como el Análisis Discriminante Lineal o LDA (*Linear Discriminant Analysis*). Por su parte, existen también algunas redes neuronales optimizadas para la decodificación de MI en señales EEG, como [12], basada en características espaciales, o [13], la cual aplica el concepto de banco de filtros sumado a un análisis basado en características espaciales.

Por todas estas razones, en este estudio se ha comparado el rendimiento del método basado en clasificación de características espaciales desarrollado en [14] con el que ofrece otra aproximación basada en DL, desarrollada bajo el marco de la red neuronal IFNet [13].

2. Materiales y métodos.

2.1. Sujetos

Para este caso de estudio han sido empleado los datos de cuatro sujetos sanos, dos mujeres, U01 y U04, y dos hombres, U02 y U03, todos sin ningún tipo de disfunción motora ni neuronal diagnosticada, comprendidos entre los 18 y los 51 años (32 ± 14). 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 de manera estratégica para entrenar dos tipos de control: el control en reposo (con el cicloergómetro inactivo) y el control en movimiento (con el cicloergómetro activo). Esto implicó tener fases de relajación (sin Imaginación Motora, MI) y fases de MI, tanto en reposo como durante el pedaleo (con el dispositivo asistiendo al usuario como en una terapia real).

Cada sesión de pruebas consistió en 22 repeticiones, donde cada repetición incluía 15 segundos de relajación, seguidos de 30 segundos de MI durante el pedaleo, y luego otros 15 segundos de relajación. De las 22 repeticiones, las 11 impares se realizaron con el cicloergómetro inactivo, y las 11 pares con el cicloergómetro activo en modo pasivo. De esta manera, se obtuvieron datos sobre los comandos de inicio (MI en reposo) y parada (relajación en movimiento) del dispositivo rehabilitador en una posible terapia. La Figura 1 muestra un esquema del protocolo empleado.

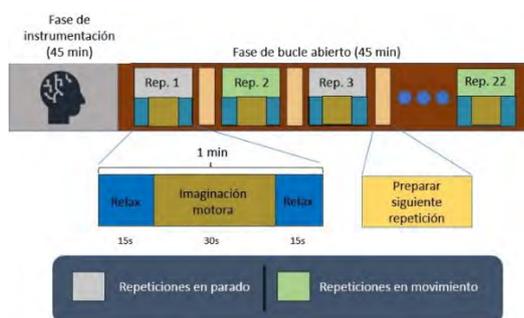


Figura 1. Protocolo experimental. Cada usuario realizó cuatro sesiones de este protocolo.

Se eligió un total de 22 repeticiones para poder descartar la peor de cada paradigma y quedarse con un número más redondo, es decir, 10 de cada tipo de repetición; y para poder ejecutar una validación cruzada 10+1, generando así 11 modelos decodificadores distintos mediante el método I (apartado 2.4) por paradigma y sesión de pruebas y pudiendo descartar la repetición de esas 11 usada como test que ha desencadenado en los peores resultados. Cada usuario realizó cuatro sesiones de prueba, esperando obtener una cantidad de datos aceptable para poder entrenar los modelos convolucionales.

Previamente a la primera sesión de cada usuario, se les dio unas directrices sobre cómo realizar la imaginación motora, tratando de guiarles hacia una imaginación cinestésica y homogénea a lo largo de las sesiones de

pruebas. Además, completaron el Movement Imagery Questionnaire-3 en su versión en castellano [15]. U01 obtuvo un 7.0 en el índice para MI cinestésica, mientras que U02 obtuvo un 4.8, U03 un 5.3 y U04 un 4.5.

2.3. Equipos empleados

El equipo de registro de EEG usado en las sesiones experimentales de este proyecto está formado por un gorro g.NAUTILUSPRO Flexible de 32 canales con la distribución de electrodos g.SCARABEO; junto con el emisor Wi-Fi HEADSET y el receptor BASE STATION, todo el conjunto del fabricante g.tec medical Engineering GmbH. La referencia fue colocada mediante pinza en el lóbulo de la oreja izquierda, previamente limpiado con gel dermoabrasivo, y todos los electrodos fueron acompañados de gel conductor hasta lograr un nivel de impedancia adecuado para el registro que genere una calidad de señal limpia ($\leq 15k\Omega$). Las señales fueron registradas a 500Hz.

Respecto al cicloergómetro, el modelo empleado es el CycleMotus™ A4, de Fourier Intelligence ©. La velocidad de giro fue ajustada al gusto de cada usuario, ya que se desean plantear modelos robustos adaptables a las necesidades de cada paciente de cara a una posible futura implementación en terapia real. El sujeto U01 empleó una velocidad de giro de 30 revoluciones por minuto, mientras que los usuarios U02 y U04 emplearon velocidad de 20 revoluciones por minuto, y U03 de 25 revoluciones.

La Figura 2 muestra el montaje experimental.



Figura 2. Montaje experimental. Se tapó la pantalla del cicloergómetro para evitar estímulos visuales externos en los usuarios.

2.4. Método de decodificación de MI I: CSP+LDA

Preprocesamiento

Para este primer método de análisis, se aplicó una serie de filtros hardware a todos los canales durante la adquisición de las señales, implementados por el fabricante. Esta está formada por el algoritmo de reducción de ruido que incorpora el dispositivo, un filtro Notch de orden 4 entre 48Hz y 52Hz para eliminar el componente de 50Hz de la alimentación eléctrica, y un filtro pasa-banda de orden 8 con frecuencias de corte de 0.5Hz y de 100Hz, para acotar la señal al rango de frecuencias deseado. Tras ello, se ha realizado una preselección de canales del área motora, formada por 19 electrodos, los cuales, de acuerdo con el estándar 10/20, son: FZ, F4, F3, FC5, FC1, FC2, FC6, T7, C3, CZ, C4, T8, CP5, CP1, CP2, CP6, P3, PZ y P4 (Figura 3).

A continuación, se aplicó una división por bandas de frecuencia para el filtrado, formada por 10 bandas diferenciadas: 2-5Hz, 5-10Hz, 10-15Hz, 15-20Hz, 20-25Hz, 25-35Hz, 35-40Hz, 40-45Hz, 45-50Hz, 50-60Hz. Para cada uno de los canales seleccionados, se filtró la señal paralelamente mediante filtros Butterworth de orden 2 en cada uno de esos rangos, sumando todas las señales obtenidas para cada canal al final y obteniendo así la señal para el análisis, emulando el método empleado en [13], como ilustra la Figura 4a.

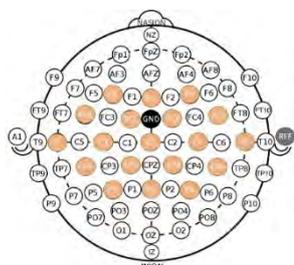


Figura 3. Selección de electrodos. La tierra (GND, Ground) va situada en FCZ.

▪ **Extracción de características**

Esta parte del análisis se ha fundamentado en el filtro CSP. Se ha aplicado para cada uno de los 19 canales seleccionados ya preprocesados, aplicando previamente una división en ventanas temporales, siendo las ventanas de dos segundos de duración y con un solape de segundo y medio, lo que significa que se obtienen características cada medio segundo.

▪ **Clasificación**

Esta se ha llevado a cabo mediante el algoritmo LDA, alimentándolo con las características obtenidas en el paso previo. Este algoritmo devuelve una salida (MI o relax) cada medio segundo, la cual puede compararse con la etiqueta real para comprobar si ha acertado. Se ha aplicado una validación cruzada 10+1 para obtener datos de desviación estándar, entrenando el modelo con 10 registros y testeando con el restante (tanto para pedaleo como para estático) en 11 ocasiones distintas por paradigma y sesión de pruebas, pudiendo probar así 11 modelos distintos.

2.5. Método de decodificación de MI II: IFNet

▪ **Preprocesamiento**

La adquisición de las señales se ha realizado de la misma forma que con el método I, aplicando los mismos filtros hardware y la misma preselección de canales (Figura 3); son los mismos registros. Respecto al banco de filtros, se ha efectuado uno diferente para este modelo, más enfocado al análisis en tiempo real. En este caso, ha consistido en un filtro online triple Butterworth de orden 8 en el espacio de estados, filtrando ventanas de un segundo en serie, paralelamente en estas tres bandas de frecuencia: 2-25Hz, 25-50Hz, y 50-75Hz. Tras el filtrado de cada ventana, se suma el resultado de las tres ramas para obtener la señal final para el análisis (Figura 4b).

▪ **Clasificación**

En este método, se ha efectuado la misma división en ventanas que en el método I (ventanas de dos segundos con

segundo y uno y medio de solape, una salida del clasificador cada medio segundo). Con esta división, se ha alimentado la red IFNet [13], generando un modelo por usuario, dividiendo todos sus datos ya preprocesados en 80% para entrenamiento, 15% para validación y 5% para test. A nivel funcional y de hiperparámetros, no se efectuó ningún cambio en la red por defecto, más allá de ajustar los filtros para que coincidan con los usados en el preprocesamiento. Se ha eliminado el peor trial de cada sesión de registros (quedándose con 10 en estático y 10 durante el pedaleo con sesión), elegido aplicando el método I.

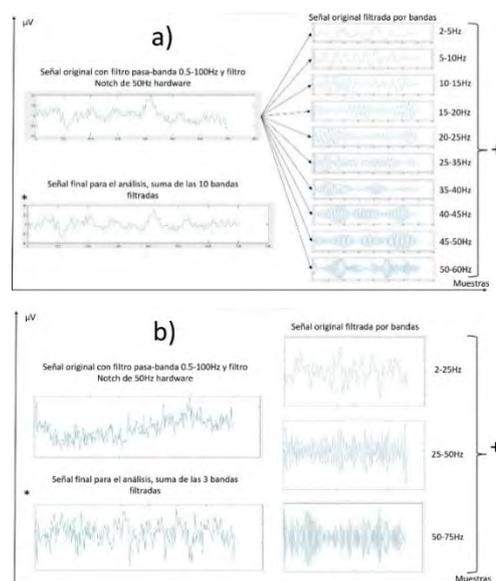


Figura 4. Bancos de filtros empleados en el preprocesamiento. a) se empleó en el método I, b) en el método II.

3. Resultados y discusión

La Tabla 1 muestra un resumen de los valores de acierto obtenidos con el método I. La Tabla 2, los obtenidos con el método II de decodificación. Salta rápidamente a la vista la superioridad en el acierto lograda por la red neuronal, casi un 12% de media. Pese a ello, el relax funciona mejor aplicando la extracción de características convencional en dos de los cuatro usuarios. Sí que se aprecia una importante superioridad del usuario U01 en ambos casos, y las tendencias parecen tener relación directa con los índices de MI cinestésicos obtenidos en el cuestionario MIQ-3 [15].

Tabla 1. Medidas de acierto obtenidas en la decodificación de MI mediante el método I (CSP+LDA).

USUARIO		U01	U02	U03	U04
ACIERTO [%]	Relax	72.0	51.6	66.9	57.7
	MI	74.9	47.0	67.8	56.6
	Total	73.5	49.3	67.4	57.2

Tabla 2. Medidas de acierto obtenidas en la decodificación de MI mediante el método II (IFNet).

USUARIO		U01	U02	U03	U04
ACIERTO [%]	Relax	100.0	38.3	55.5	60.1
	MI	79.1	74.7	78.9	74.1
	Total	85.4	66.3	70.9	67.1

Como gran pega a los modelos generados por la red neuronal, se debe comentar el alto desbalanceo existente en los resultados de acierto entre clases. Los modelos parecen polarizarse hacia una de las clases, obteniendo un acierto bastante más amplio en ella, disminuyendo así el acierto en la otra clase.

4. Conclusiones

El DL se está consolidando como respuesta a la mayoría de los retos que propone la computación moderna, y la decodificación de MI a partir de señales EEG no parece ser una excepción. Este estudio deja constancia de las mejoras que ofrece frente a métodos de decodificación convencionales, mejorando los resultados casi un 12% y alcanzando índices acordes a la literatura previa [4], [8], [10] con un acierto medio superior al 72%, mejorando también la investigación previa [14]. No obstante, se trata de un estudio preliminar con pocos usuarios y será necesaria más investigación para poder llegar a conclusiones más sólidas. El problema del desbalanceo entre clases puede ser la causa de que el relax mejore en algunos usuarios al emplear CSP+LDA, y este es un problema que puede abordarse asegurando un buen ajuste de los parámetros de la red neuronal y probando técnicas de entrenamiento inter-sujetos (*Transfer Learning*).

También parece clara la relación entre la calidad de la ejecución de la MI de los usuarios, y los resultados que obtienen los modelos al decodificarla. Esto refuerza la adecuación de efectuar una preparación o entrenamiento previo de los usuarios en la evocación de MI.

Agradecimientos

Esta investigación ha sido llevada a cabo en el Center for Clinical Neuroscience HLM 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

- [1] M. W. Slutzky, “Brain-Machine Interfaces: Powerful Tools for Clinical Treatment and Neuroscientific Investigations” *Neuroscientist*, vol. 25, no. 2, pp. 139–154, Apr. 2019, doi: 10.1177/1073858418775355.
- [2] E. C. Leuthardt, G. Schalk, D. Moran, and J. G. Ojemann, “The emerging world of motor neuroprosthetics: a neurosurgical perspective” *Neurosurgery*, vol. 59, no. 1, pp. 1–13, Jul. 2006, doi: 10.1227/01.NEU.0000221506.06947.AC.
- [3] G. Garipelli, R. Chavarriaga, and J. Del R Millán, “Single trial analysis of slow cortical potentials: a study on anticipation related potentials” *J. Neural Eng.*, vol. 10, no. 3, Jun. 2013, doi: 10.1088/1741-2560/10/3/036014.
- [4] M. Ortiz, L. Ferrero, E. Iáñez, J. M. Azorín, and J. L. Contreras-Vidal, “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.*, vol. 0, p. 735, Sep. 2020, doi: 10.3389/FBIOE.2020.00735.
- [5] M. Misaki *et al.*, “Beyond synchrony: The capacity of fMRI hyperscanning for the study of human social interaction” *Soc. Cogn. Affect. Neurosci.*, vol. 16, no. 1–2, 2021, doi: 10.1093/scan/nsaa143.
- [6] J. N. Mak and J. R. Wolpaw, “Clinical Applications of Brain-Computer Interfaces: Current State and Future Prospects” *IEEE Rev. Biomed. Eng.*, vol. 2, p. 187, 2009, doi: 10.1109/RBME.2009.2035356.
- [7] J. Contreras-Vidal *et al.*, “Powered exoskeletons for bipedal locomotion after spinal cord injury” *J. Neural Eng.*, vol. 13, no. 3, Apr. 2016, doi: 10.1088/1741-2560/13/3/031001.
- [8] M. Ortiz, M. Rodríguez-Ugarte, E. Iáñez, and J. M. Azorín, “Analysis of algorithms for detection of pedaling intention in brain-machine interfaces” *RIAI - Rev. Iberoam. Autom. e Inform. Ind.*, vol. 16, no. 2, pp. 222–231, 2019, doi: 10.4995/RIAI.2018.9861.
- [9] T. Castermans and M. Duvinage, “Corticomuscular coherence revealed during treadmill walking: further evidence of supraspinal control in human locomotion” *J. Physiol.*, vol. 591, no. 6, pp. 1407–1408, Mar. 2013, doi: 10.1113/JPHYSIOL.2012.247593.
- [10] F. Lotte *et al.*, “A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update” *J. Neural Eng.*, vol. 15, no. 3, p. 031005, Apr. 2018, doi: 10.1088/1741-2552/AAB2F2.
- [11] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, “EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces” *J. Neural Eng.*, vol. 15, no. 5, 2018, doi: 10.1088/1741-2552/aace8c.
- [12] P. Autthasan *et al.*, “MIN2Net: End-to-End Multi-Task Learning for Subject-Independent Motor Imagery EEG Classification” *IEEE Trans. Biomed. Eng.*, vol. 69, no. 6, 2022, doi: 10.1109/TBME.2021.3137184.
- [13] J. Wang, L. Yao, and Y. Wang, “IFNet: An Interactive Frequency Convolutional Neural Network for Enhancing Motor Imagery Decoding From EEG” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 31, pp. 1900–1911, 2023, doi: 10.1109/TNSRE.2023.3257319.
- [14] J. V. Juan, E. Iáñez, M. Ortiz, J. Tornero, and J. M. Azorín, “Análisis de la Imaginación Motora durante pedaleo a partir de señales EEG” *Congr. Anu. la Soc. Española la Ing. Biomédica, CASEIB*, 2022, no. 8.5.2017, pp. 2003–2005, 2022.
- [15] S. Trapero-Asenjo, T. Gallego-Izquierdo, D. Pecos-Martín, and S. Nunez-Nagy, “Translation, cultural adaptation, and validation of the Spanish version of the Movement Imagery Questionnaire-3 (MIQ-3)” *Musculoskelet. Sci. Pract.*, vol. 51, 2021.