



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Estrategia de procesamiento de señales EEG en sistemas BCI utilizando aprendizaje profundo y medidas de conectividad

Yessica Alejandra Gomez Rivera

Universidad Nacional de Colombia
Facultad de Ingeniería y Arquitectura
Departamento de Eléctrica, Electrónica y Computación
Manizales, Colombia

2023

Estrategia de procesamiento de señales EEG en sistemas BCI utilizando aprendizaje profundo y medidas de conectividad

Yessica Alejandra Gomez Rivera

Tesis presentada para optar al título de:
Magister en Ingeniería - Automatización Industrial

Director:

Prof. Andrés Marino Álvarez-Meza, Ph.D.

Co-director:

Prof. Germán Castellanos-Domínguez, Ph.D.

Grupo de Investigación:

Grupo de Control y Procesamiento Digital de Señales

Universidad Nacional de Colombia
Facultad de Ingeniería y Arquitectura
Departamento de Eléctrica, Electrónica y Computación
Manizales, Colombia

2023

EEG Signal Processing Strategy in BCI Systems Using Deep Learning and Connectivity Measures

Yessica Alejandra Gomez Rivera

Dissertation submitted as a partial requirement to receive the grade of:

Master in Engineering - Industrial Automation

Advisor:

Prof. Andrés Marino Álvarez-Meza, Ph.D.

Co-advisor:

Prof. Germán Castellanos-Domínguez, Ph.D.

Academic research group:

Signal Processing and Recognition Group - SPRG

Universidad Nacional de Colombia

Faculty of Engineering and Architecture

Department of Electric, Electronic and Computing Engineering

Manizales, Colombia

2023

AGRADECIMIENTOS

Expreso mi sincero agradecimiento a mis padres y hermano por su inquebrantable apoyo y aliento.

También agradezco a Andrés Marino Álvarez Meza, Germán Castellanos Domínguez y Yeison Cardona Álvarez por brindarme una invaluable dirección durante mi investigación, sin la cual no hubiera sido posible.

Además, agradezco a Juan Carlos Aguirre Arango y a los demás miembros del Grupo de Control y Procesamiento de Señales (GCPDS) en la sede de Manizales de la Universidad Nacional de Colombia por su constante apoyo, motivación en momentos adversos y enriquecedoras discusiones educativas que me permitieron alcanzar mi meta.

Finalmente, reconozco el apoyo brindado por los proyectos “Sistema prototipo de procesamiento de bioseñales en unidades de cuidado intensivo neonatal utilizando aprendizaje de máquina - Fase 1: Validación en ambiente simulado” con código Hermes 55063, financiado por la “Convocatoria para el fortalecimiento de la investigación, creación e

innovación articulado con la formación en la universidad Nacional de Colombia 2020-2021” y “Sistema de integración de EEG, ECG y SpO2 para seguimiento de neonatos en unidad de cuidados intensivos del Hospital Universitario de Caldas - SES HUC” con código Hermes 57414, financiado por la “Convocatoria nacional para el fortalecimiento de la formación a través del apoyo a proyectos de investigación, creación artística e innovación de la Universidad Nacional de Colombia 2022-2024 ”. Sin su respaldo, este logro no habría sido posible.

Yessica Alejandra Gomez Rivera

2023

RESUMEN

Las Interfaces Cerebro Computadora (BCI) basadas en Electroencefalografía (EEG) crean una conexión directa entre el cerebro humano y una computadora. Los paradigmas de Imaginación Motora (MI) permiten que los usuarios controlen el movimiento de un agente en el mundo físico o virtual al detectar y decodificar patrones cerebrales asociados con movimientos reales e imaginados. Estas interfaces poseen un amplio potencial de aplicaciones clínicas y no clínicas.

A pesar de ello, desarrollar sistemas BCI basados en EEG conlleva ciertos desafíos debido a problemas como la baja relación señal-ruido (SNR), la no estacionariedad y no linealidad de las señales EEG que causa la variabilidad intersujeto dificultando la identificación de características distintivas. Además, las capacidades limitadas de los sujetos para llevar a cabo tareas de MI en condiciones de baja SNR generan dificultades adicionales en la implementación de estos sistemas.

Con el fin de abordar estos desafíos, en este trabajo de tesis, se presenta dos nuevas metodologías para el procesamiento de señales EEG. La primera de ellas consiste en i) una metodología para el procesamiento de señales de EEG para la

clasificación de tareas de MI en alta y baja densidad de canales, con la representación y clasificación de señales de EEG basada en imágenes para reducir el efecto de la variabilidad intersujeto y mejorar la interpretabilidad espacio-frecuencia en modelos de Aprendizaje Profundo (DL). Además, se presenta un protocolo de adquisición de datos para un sistema BCI-MI basado en EEG, que es de bajo costo, portátil y diseñado para abordar las restricciones inherentes en la captura de la actividad neuronal con electrodos en el cuero cabelludo. Se utiliza un marco de DL para mejorar la precisión y exactitud de las BCIs-MI, al mismo tiempo, ii) se introduce un novedoso sistema de bajo costo y pocos canales que permite la clasificación de tareas de MI en tiempo real, superando desafíos computacionales. Este sistema garantiza que los bloques de datos EEG estén disponibles para el usuario en un tiempo menor a su duración. Esta innovación ofrece perspectivas prometedoras para mejorar la accesibilidad y eficacia de las interfaces cerebro-computadora en aplicaciones prácticas.

Para concluir las metodologías propuestas en esta tesis contribuyen a mejorar la variabilidad intersujeto, la interpretabilidad espacio-frecuencia en modelos DL y el rendimiento de clasificación de los paradigmas de MI en sistemas BCI basados en EEG.

La representación de EEG basada en imágenes permite obtener interpretabilidad espacio-frecuencia al combinar la representación espacial de los pares de canales EEG para construir un mapa topográfico (topoplot) en diferentes bandas de frecuencia. Esto codifica relaciones no lineales relevantes mediante similitud basada en la distribución Gaussiana, lo que a su vez mejora la precisión y exactitud de las BCI. Además, se complementa con análisis por grupo, Mapas de Activación de Clase (CAMS) e Incrustación Estocástica de Vecinos con Distribución t (t-SNE), para brindar una mayor interpretación de los resultados de la clasificación. El procesamiento de señales de EEG para la clasificación de tareas de MI, tanto en alta como baja densidad de canales, aborda eficientemente los efectos de la variabilidad y los artefactos en la señal, así como la baja SNR. Este enfoque se dirige especialmente a los sujetos que no logran obtener un control suficiente sobre el BCI.

Por otro lado, la adquisición y procesamiento de señales de EEG en tiempo real nos permite realizar todas las etapas de un sistema de bucle cerrado utilizando métodos de ML y lograr resultados competitivos en nuestra base de datos adquirida mediante un sistema BCI distribuido, económico, portátil y con poca cantidad de canales. Al compararlo con bases de datos públicas, podemos afirmar que somos capaces de enfrentar los desafíos relacionados con la variabilidad, interpretabilidad y tiempo real en sistemas BCI.

Sin embargo, persisten desafíos por abordar para mejorar el rendimiento y exactitud de las BCI. En particular tenemos previsto para investigaciones futuras, i) realizar pruebas utilizando una variedad más amplia de bases de datos públicas de MI; ii) seguir explorando en técnicas de extracción de características, iii) explorar arquitecturas de vanguardia, como por ejemplo los modelos basados en Transformer, como el EEG-transformer; iv) aumentar la densidad de canales para la adquisición de nuestras bases de datos.

Palabras claves: Interfaz cerebro computador, Imaginación motora, Electroencefalografía, Tiempo real, Aprendizaje profundo, Conectividad Gaussiana, Topogramas, Interpretabilidad

ABSTRACT

Brain-Computer Interfaces (BCIs) based on Electroencephalography (EEG) establish a direct connection between the human brain and a computer. Motor Imagery (MI) paradigms enable users to control the movement of an agent in the physical or virtual world by detecting and decoding brain patterns associated with real and imagined movements. These interfaces have a wide range of potential clinical and non-clinical applications.

However, developing EEG-based BCI systems comes with certain challenges due to issues such as low signal-to-noise ratio (SNR), non-stationarity, and non-linearity of EEG signals, causing inter-subject variability that hinders the identification of distinctive features. Additionally, subjects' limited abilities to perform MI tasks in low SNR conditions pose additional difficulties in implementing these systems.

To address these challenges, this thesis work presents two new methodologies for EEG signal processing. The first one includes i) a methodology for processing EEG signals for MI task classification in high and low channel density, with EEG signal representation and classification based on images to reduce the inter-subject

variability effect and improve the spatial-frequency interpretability in Deep Learning (DL) models. Additionally, a data acquisition protocol is introduced for a low-cost, portable EEG-based BCI-MI system designed to address the inherent constraints in capturing neuronal activity with scalp electrodes. A DL framework is used to enhance the accuracy and precision of BCIs-MI, while ii) a novel low-cost, few-channel system is introduced that allows real-time MI task classification, overcoming computational challenges. This system ensures that EEG data blocks are available to the user in less time than their duration. This innovation holds promising prospects for improving the accessibility and effectiveness of brain-computer interfaces in practical applications.

In conclusion, the proposed methodologies in this thesis contribute to improving inter-subject variability, spatial-frequency interpretability in DL models, and the classification performance of MI paradigms in EEG-based BCI systems.

Image-based EEG representation enables spatial-frequency interpretability by combining the spatial representation of EEG channel pairs to construct a topographical map in different frequency bands. This encodes relevant nonlinear relationships through Gaussian-distribution-based similarity, thereby enhancing the accuracy and precision of BCIs. It is further complemented with group-wise analysis, Class Activation Maps (CAMs), and t-distributed Stochastic Neighbor Embedding (t-SNE) embedding to provide better interpretation of classification results. EEG signal processing for MI task classification, in both high and low channel density, efficiently addresses the effects of signal variability and artifacts, as well as low SNR. This approach is particularly aimed at subjects who struggle to achieve sufficient control over the BCI.

On the other hand, real-time EEG signal acquisition and processing allow us to perform all stages of a closed-loop system using ML methods and achieve competitive results in our acquired database through a distributed, cost-effective, portable, and low-channel BCI system. When compared to public databases, we can assert that we are capable of addressing challenges related to variability, interpretability, and real-time requirements in BCI systems.

Nevertheless, there are challenges that remain to be addressed in order to enhance BCI performance and accuracy. In particular, for future research, we plan to i) conduct tests using a broader range of public MI databases; ii) continue exploring feature extraction techniques; iii) explore cutting-edge architectures, such as Transformer-based models, like the EEG-transformer; iv) increase channel density for data acquisition in our databases.

Keywords: Brain-Computer Interface, Motor Imagery, Electroencephalography, Real-time, Deep Learning, Gaussian Connectivity, Topoplots, Interpretability.

Índice general

Agradecimientos	VII
Resumen	IX
Abstract	XIII
Contenido	XVII
Lista de figuras	XIX
Lista de tablas	XXI
Abreviaciones	XXIII
1. Preliminares	1
1.1. Motivación	1
1.2. Planteamiento del problema	7
1.2.1. Variabilidad intersujeto en sistemas BCI	10
1.2.2. Interpretabilidad espacio-frecuencia en modelos DL	12
1.2.3. BCI en tiempo real	13
1.3. Estado del arte	15
1.3.1. Abordaje de la variabilidad intersujeto en BCI-MI basados en EEG	15
1.3.2. Enfoques de interpretabilidad en BCI-MI basadas en EEG en modelos ML	22
1.3.3. BCI en tiempo real	26

1.4.	Objetivos	33
1.4.1.	Objetivo general	33
1.4.2.	Objetivos específicos	33
1.5.	Contribuciones	35
1.5.1.	Representación y clasificación de EEG basada en imágenes y DL	36
1.5.2.	Adquisición y procesamiento en tiempo real	36
1.6.	Bases de datos electroencefalografía	37
1.6.1.	Giga Motor Imagery - DBIII MI	38
1.6.2.	BCI-Framework Unal	39
1.7.	Estructura de la tesis	41
2.	Representación y clasificación de EEG basada en imágenes y DL	43
2.1.	Métodos	44
2.1.1.	Filtrado Laplaciano de Superficie	44
2.1.2.	Conectividad Funcional Gaussiana (GFC) a partir de EEG . . .	45
2.1.3.	Flujo de conectividades en topogramas	48
2.1.4.	Topograma	49
2.1.5.	Mapas de Activación de Clase (CAMs)	50
2.1.6.	Red neuronal WDCNN	52
2.2.	Marco Experimental	56
2.2.1.	Preprocesamiento de EEG	56
2.2.2.	Transformación de la señal de EEG a topogramas	58
2.2.3.	Entrenamiento y clasificación con WDCNN	58
2.2.4.	Análisis a nivel de grupo para la base de datos Giga Motor Imagery - DBIII MI	59
2.3.	Resultados y discusión	60
2.3.1.	Resultados del Análisis de Grupo para la base de datos Giga Motor Imagery - DBIII MI	60
2.3.2.	Protocolo de adquisición de datos y las herramientas	65

2.3.3. Análisis de rendimiento por sujeto base de datos BCI-Framework Unal	75
2.4. Interpretabilidad espacio-frecuencia	78
2.4.1. Mapas de conectividad de base de datos Giga Motor Imagery - DBIII MI	78
2.4.2. Análisis con t-SNE de base de datos Giga Motor Imagery - DBIII MI	82
2.4.3. Mapas de conectividad de base de datos BCI-Framework Unal	84
2.4.4. Análisis con t-SNE de base de datos BCI-Framework Unal . .	88
2.5. Conclusiones	90
2.6. Resumen	92
3. Adquisición y procesamiento en tiempo real	95
3.1. Marco experimental	96
3.1.1. Preprocesamiento de EEG	97
3.2. Entrenamiento fuera de línea con CSP	100
3.3. Entrenamiento fuera de línea con EEGNet	101
3.4. Resultados y discusión	103
3.4.1. Análisis por grupos base de datos Giga Motor Imagery - DBIII MI	104
3.4.2. Análisis de rendimiento por sujeto base de datos BCI-Framework Unal	106
3.5. Clasificación en Tiempo Real	107
3.6. Latencias	108
3.7. Clasificación fuera de línea sobre ventanas deslizantes	110
3.8. Conclusiones	111
3.9. Resumen	113
4. Observaciones finales	115
4.1. Conclusiones	115
4.2. Trabajo futuro	116
4.3. Productos académicos	118

4.3.1. Artículo	118
4.3.2. Patente	118
4.3.3. Registro de software y repositorios	118
Apéndice A. Electroodos de copa para EEG	119
A.1. Electroencefalografía	120
A.1.1. Electroodos de copa para EEG	121
Apéndice B. Electrooculografía	127
Apéndice C. Memoria de trabajo visuoespacial: tarea de detección de cambios	135
Apéndice D. Estado de reposo y adquisición de ruido	139
Bibliografía	142

Índice de figuras

1-1. Enfoques para el problema de Variabilidad	22
1-2. Enfoques para el problema de Interpretabilidad	24
1-3. Enfoques para el problema de BCI-Tiempo real	28
1-4. Diagrama de las soluciones propuestas	35
1-5. Mapa topográfico de la base de datos Giga Motor Imagery - DBIII MI	38
1-6. Ensayo del experimento de MI	39
1-7. Mapa topográfico de la base de datos BCI-Framework Unal	40
1-8. Paradigma experimental	41
2-1. Topograma de flujo de conectividades	48
2-2. Esquema principal de la red WDCNN	55
2-3. Marco experimental Capitulo 2	56
2-4. Comparación del método CSP+LDA y WDCNN+GFC	60
2-5. Resultados de rendimiento	61
2-6. Resultados de rendimiento de EEGnet y GFC+WDCNN	62
2-7. Comparación en acierto para todos los sujetos de la base de datos Giga Motor Imagery - DBIII MI	65
2-8. Sistema de distribución de OpenBCI y Raspberry pi 4.	65
2-9. Sistema de distribución de OpenBCI ensamblado.	67
2-10. Sistemas y materiales necesarios para la adquisición de los datos. . .	68
2-11. Vista posterior del gorro de electrodos.	69
2-12. Vista lateral del gorro de electrodos.	70
2-13. Interfaz gráfica para visualizar impedancias en tiempo real	73
2-14. Ejecución del paradigma de imaginación motora	74

2-15. Paradigma de MI, 4 clases con flechas.	75
2-16. Comparación de acierto CSP y WDCNN	76
2-17. Comparación de acierto EEGNet y WDCNN	77
2-18. Mapas de conectividad	79
2-19. Representación gráfica de la Conectividad sujeto 43	80
2-20. Representación gráfica de la Conectividad sujeto 51	81
2-21. Proyección 2D de t-SNE de CAMS sujeto 43	82
2-22. Proyección 2D de t-SNE de CAMS sujeto 51	83
2-23. Mapas de conectividad para los sujetos con mejor y peor rendimiento de la base de datos BCI-Framework Unal.	84
2-24. Conectividades al 70 % del sujeto 3, en sus cuatro bandas de frecuencia.	86
2-25. Conectividades al 70 % del sujeto 7, en sus cuatro bandas de frecuencia.	87
2-26. Proyección 2D de t-SNE de los CAMs para el sujeto 3	88
2-27. Proyección 2D de t-SNE de los CAMs para el sujeto 7	89
2-28. Comparación en acierto para la base de datos BCI-Framework Unal	90
3-1. Esquema principal del marco experimental capítulo 3	96
3-2. Visualización de la señal de EEG sin preprocesamiento	98
3-3. Visualización en tiempo real de la adquisición de señales de EEG.	99
3-4. Visualización de la densidad espectral de potencia para la clase 0	100
3-5. Visualización de la densidad espectral de potencia para la clase 1	100
3-6. Esquema principal de EEGnet	102
3-7. Comparación de métodos, CSP y EEGNet con base de datos GIGA.	104
3-8. Gráfica de pérdida y ganancia entre métodos	105
3-9. Comparación de métodos, CSP y EEGNet	107
3-10. Modelo de prueba de MI en tiempo real	108
3-11. Gráfica de Latencias	109
3-12. Gráfica de clasificación con ventana deslizante	111
3-13. Gráfica de clasificación no supervisada con ventana deslizante	111
3-14. Umbral de clasificación	112
A-1. Generación de EEG, tomada de [Ros et al., 2014]	121

A-2. Montaje 10-20 para adquisición de EEG, tomada de [Li et al., 2018]	122
A-3. Fotografía electrodos de copa vista frontal	123
A-4. Fotografía electrodos de copa vista superior	124
A-5. Fotografía electrodos de copa vista posterior	125
B-1. Sistema de medición EOG	128
B-2. Montaje de electrodos para EOG	129
B-3. Electrodos de copa de vista frontal	130
B-4. Electrodos de copa de vista lateral	131
B-5. Fotografía de electrodo en el mastoides derecho.	132
B-6. Electrodos secos vista lateral	133
B-7. Electrodos secos vista lateral	134
C-1. Línea de tiempo para la ejecución del paradigma memoria de trabajo visuoespacial.	136
C-2. Presentación de estímulos para el paradigma memoria de trabajo visuoespacial.	137
C-3. Adquisición de datos de EEG para memoria visual de trabajo.	138
D-1. Línea de tiempo para la ejecución del paradigma estado de reposo y adquisición de ruido.	140
D-2. presentación de estímulos para el paradigma estado de reposo y adquisición de ruido.	140
D-3. Adquisición de datos, con los ojos cerrados.	141

Índice de cuadros

1-1. Comparación de latencias en diferentes sistemas BCI	29
2-1. Arquitectura WDCNN	54
2-2. Análisis de rendimiento por grupos para CSP+LDA y GFC+WDCNN .	62
2-3. Análisis de rendimiento por grupos para EEGNet y el GFC+WDCNN .	63
2-4. Comparación de métodos	64
2-5. Comparación de métodos	90
2-6. Comparación de métodos	91
3-1. Arquitectura EEGNet	103
3-2. Resultados para la base de datos Giga Motor Imagery	106
3-3. Comparación de configuraciones en diferentes sistemas BCI	110

ABREVIACIONES

- BCI** Interfaces cerebro computador 1-5, 7-16, 20-23, 26-34, 36, 41, 43, 52, 56, 60, 66, 67, 73, 91-93, 95, 109, 113-117
- CAM** Mapas de Activación de Clase 25, 44, 50-52
- CNN** Red neuronal con arquitectura de Convolutional Neural Network 21, 27, 31, 53
- CSP** Patrones Espaciales Comunes 4, 18, 23, 27, 30, 53, 59-64, 91, 92, 96, 97, 100, 101, 104-107, 113
- DL** Aprendizaje Profundo 4, 6, 8, 9, 12-14, 20-22, 25, 27, 30-33, 35, 36, 41, 43, 52, 80, 91-93, 115-117
- EEG** Electroencefalografía 3, 4, 6-12, 14-23, 26, 27, 30-36, 39-41, 43-46, 52, 57, 63, 64, 66, 68, 71-73, 77, 90, 92, 95, 98, 101, 107, 113-116
- GCPDS** Grupo de Control y Procesamiento Digital de Señales 5-7
- MI** Imaginación Motora 1-4, 7-9, 11, 12, 15, 16, 19, 20, 22, 23, 26, 27, 30-34, 36-41, 43, 52, 53, 56, 57, 60, 61, 63, 64, 73, 74, 78-86, 88, 89, 91-93, 95, 98, 105, 108-110, 113, 115-117
- ML** Aprendizaje Automático 3, 4, 6, 7, 13, 15, 31-33, 37, 41, 96, 112, 114
- SAE** Autoencoders Apilados 21, 27
- SNR** Baja Relación Señal-Ruido 8, 10, 11, 15, 17, 64, 106
- t-SNE** Incrustación Estocástica de Vecinos t-Distribuidos 78
- VWM** Memoria visoespacial de trabajo 116

PRELIMINARES

1.1 Motivación

Las Interfaces cerebro computador (BCI), por sus siglas en inglés, establecen una conexión directa entre el cerebro humano y una computadora, permitiendo así, la captura de las actividades neuronales asociadas con estímulos externos o tareas mentales sin requerir la participación de los nervios periféricos y los músculos [Padfield et al., 2019]. Este enfoque se debe a su amplio potencial de aplicaciones clínicas y no clínicas, en áreas como el neuromarketing y la neuroeconomía [Tremmel et al., 2019, Polat et al., 2021], en marcos para el desarrollo de protocolos médicos como el análisis del estado cognitivo [Choi et al., 2020a], diagnóstico de trastornos mentales, análisis basados en emociones [Fraiwan et al., 2021], neurorrehabilitación, neuroprótesis, control de videojuegos [Padfield et al., 2019], educación [Taherian and Davies, 2018], rehabilitación funcional y asistencia motora [Miao et al., 2020].

En los sistemas BCI, es común el uso de tres paradigmas: Imaginación Motora (MI), P300 y los potenciales evocados (PE). Las BCI basadas en P300 pueden operar más rápidamente que otros enfoques, ya que la señal P300 se produce aproximadamente 300 ms después del estímulo [Wolpaw and McFarland, 1994, Yuan and He, 2014, Shin et al., 2022]. Los PE proporcionan una evaluación objetiva de la función neuronal, lo que puede ser útil en la personalización y ajuste de los sistemas BCI. Sin embargo, al igual que con el P300, los PE pueden variar considerablemente entre individuos, lo que requiere una calibración individualizada y puede limitar la eficacia del sistema BCI [Kundu and Ari, 2022]. Por otro lado, la MI permite a los usuarios controlar el movimiento de un agente en el mundo físico o virtual mediante la detección y decodificación de patrones cerebrales asociados con movimientos reales e imaginados. Este ámbito ha sido objeto de extensa investigación debido a su impacto en aplicaciones médicas [Anderson, 2004, He and Wu, 2019]. Las BCI han demostrado ser efectivas en sistemas protésicos neuronales, mejorando la calidad de vida de pacientes que sufren condiciones que afectan la función motora, como lesiones de la médula espinal, esclerosis lateral amiotrófica e ictus. Sumado a esto, estas interfaces han mostrado su eficacia en áreas como la mejora de la comprensión del lenguaje en niños y adultos mayores [Bonnet et al., 2022], en terapias de entrenamiento con retroalimentación neuronal para personas con enfermedad de Parkinson [Marcos-Martínez et al., 2021], y en la reducción de las manifestaciones de conductas asociadas al Trastorno por Déficit de Atención e Hiperactividad (TDAH) o epilepsia [Arns et al., 2013].

También se ha demostrado que las BCI son útiles en la mejora de la concentración y el enfoque atencional [Djamal and Putra, 2020]. Estas interfaces ofrecen oportunidades para mejorar la calidad de vida de las personas y contribuir al desarrollo sostenible en áreas clave. Además, favorecen una educación inclusiva, equitativa y de calidad, promoviendo oportunidades de aprendizaje a lo largo de la vida, tal como dicta la ONU [de Bogotá et al., 2018]. Recientemente, se ha ampliado el uso de la tecnología BCI en contextos educativos [Taherian and Davies, 2018, Cardona-Álvarez et al., 2023]. Esto comprende un

conjunto robusto de competencias fundamentales para que las personas contribuyan activamente al desarrollo humano, como parte de la metodología de Alfabetización en Medios e Información (AMI) de la UNESCO [Collazos-Huertas et al., 2020, García-Murillo et al., 2023].

La actividad cerebral se puede registrar a través de varios métodos de neuroimagen [Nicolas-Alonso and Gomez-Gil, 2012]. Los métodos se clasifican en dos grupos: invasivos y no invasivos. Los invasivos como, electrocorticografía (ECoG) y Electroencefalografía (EEG) intracraneal. Las características espaciales y temporales de alta calidad de estas señales conducen al éxito, sin embargo, los electrodos invasivos tienen importantes inconvenientes debido al riesgo de realizar la cirugía y la degradación gradual de los electrodos. Por lo tanto los enfoques no invasivos como la resonancia magnética funcional (fMRI), magnetoencefalografía (MEG), espectroscopia de infrarrojo cercano (NIRS) y EEG son los más comunes [Abiri et al., 2019]. Las señales de EEG son utilizadas en los sistemas BCI basados en MI debido a su naturaleza no invasiva, alta resolución temporal, costo relativamente bajo, portabilidad, bajos riesgos para los usuarios y facilidad de adquisición de señales cerebrales [Miao et al., 2020].

Sin embargo, las señales de EEG presentan desventajas significativas, como la no estacionariedad, una baja SNR y una baja resolución espacial. Además, se requieren habilidades adecuadas por parte del usuario para implementar protocolos clínicos, lo que implica que el BCI debe utilizarse en condiciones de laboratorio controladas [Becker et al., 2022, Cardona-Álvarez et al., 2023], asimismo, las señales de EEG pueden verse afectadas por la postura y el estado de ánimo de un sujeto [Padfield et al., 2019].

Recientemente, los enfoques respaldados por Aprendizaje Automático (ML) han suscitado un interés creciente como estrategia para abordar las problemáticas inherentes a las señales captadas por EEG. Por lo general, estos métodos comprenden etapas como el preprocesamiento, la extracción de características y la fase de clasificación. El propósito subyacente a las técnicas de preprocesamiento

consiste en mitigar la influencia de la SNR, que puede verse afectada por artefactos de señal tales como contracciones musculares involuntarias, las cuales pueden ser generadas por diversas bioseñales, así como por movimientos pulsátiles vinculados al ritmo cardíaco y la respiración [Shoka et al., 2019]. Todo esto con el fin de mejorar la calidad de las señales y facilitar la identificación de patrones distintivos relacionados con la MI.

Sumado a ello, los algoritmos de inteligencia artificial y Aprendizaje Profundo (DL) se han aplicado a los sistemas BCI para lograr clasificaciones más rápidas y precisas de la entrada sensorial y mejorar el rendimiento del usuario en diversas tareas [Martini et al., 2020]. Sumado a esto, comprender y explicar estas respuestas permite el diagnóstico médico preciso y el desarrollo de estrategias de ML más efectivas. Los avances en la interpretabilidad del DL tienen el potencial de aumentar la confianza y aceptación de las BCI por parte de los usuarios finales, especialmente en aplicaciones médicas y clínicas donde la confianza en los resultados y la interpretación de la actividad cerebral son fundamentales [Collazos-Huertas et al., 2020, García-Murillo et al., 2023].

En este contexto, en el dominio tiempo-frecuencia, se utilizan técnicas clásicas para la extracción de características como el enfoque de Filtros Espaciales Comunes basados en Bancos de Filtros FBPatrones Espaciales Comunes (CSP), se utiliza para extraer características espaciales en bandas de frecuencia relevantes para los datos de MI [Luo et al., 2018]. Siendo un derivado de CSP, el análisis de componentes principales, es un método eficaz para la reducción de dimensiones en señales de EEG, con un tiempo de entrenamiento corto y bajo costo computacional. Esta caracterización también involucra la representación de las relaciones entre áreas cerebrales o canales, denominada conectividad, que aporta información valiosa sobre la estructura, función y causalidad cerebral [Farahani et al., 2019]. En lo que respecta a las medidas de conectividad, los estudios computacionales han concentrado su atención en la conectividad funcional y efectiva [Friston et al., 1991, Farahani and Karwowski, 2019].

La conectividad funcional (FC) se refiere a las correlaciones temporales entre eventos neurofisiológicos que ocurren a distancias espaciales en la red

cerebral [Friston, , Zhang et al., 2015]. Por otro lado, la conectividad efectiva se enfoca en las interacciones causales entre unidades neuronales dentro de la misma red cerebral, lo que significa que se centra en la influencia causal que un sistema neural ejerce sobre otro sistema [Rolls et al., 2022]. Esta distinción entre conectividad funcional y conectividad efectiva se ha destacado en estudios previos [Friston, , Zhang et al., 2015, Rolls et al., 2022].

Por otra parte, la implementación de sistemas en tiempo real se ha vuelto cada vez más necesaria en el sector de las tecnologías de la información. Este factor es especialmente crucial en áreas donde la efectividad y la eficiencia son críticas. En los campos de la neurociencia y la medicina, la importancia del tiempo real se acentúa, especialmente en la operación de los sistemas BCI [Alvarez and Rossetti, 2015], [Muñiz et al., 2009].

La capacidad de realizar análisis en tiempo real facilita el ajuste de algoritmos y la calibración de sistemas durante su funcionamiento. Esta funcionalidad resulta vital para el desarrollo eficaz y la implementación de la tecnología BCI [Muñiz et al., 2009]. Los sistemas BCI en tiempo real también posibilitan una interacción fluida con sistemas de prótesis motoras o aplicaciones de rehabilitación, proporcionando una respuesta inmediata a los usuarios y permitiendo su adaptación y aprendizaje [Pires et al., 2022], [Cho et al., 2021].

No obstante, existen diversos desafíos asociados con la implementación de sistemas BCI en tiempo real. Entre ellos se encuentran la necesidad de métodos de procesamiento de señales eficientes y efectivos que puedan manejar el gran volumen de datos generados, y la demanda de sistemas en tiempo real que sean capaces de adaptarse a las condiciones variables y dinámicas asociadas con la actividad cerebral del usuario [Choi et al., 2020b]. Por lo tanto, es esencial garantizar que los sistemas sean seguros, y confiables, dada su aplicación en áreas sensibles como la medicina y la rehabilitación [Alvarez and Rossetti, 2015].

En un contexto local, el Grupo de Control y Procesamiento Digital de Señales Grupo de Control y Procesamiento Digital de Señales (GCPDS) de la Universidad

Nacional de Colombia ha estado trabajando en el análisis de datos neurofisiológicos para proponer y desarrollar metodologías de ML para el diagnóstico asistido de condiciones mentales [Cárdenas-Peña et al., 2017, Collazos-Huertas et al., 2019], análisis automatizado de reconocimiento de actividad humana [Pulgarin-Giraldo et al., 2017] y análisis de datos biomédicos [Hurtado-Rincón et al., 2016]. El GCPDS ha mostrado interés en trabajar en interfaces cerebro-computador y actividad eléctrica cerebral en diferentes aplicaciones, con una variedad de proyectos de investigación (respaldados por Minciencias, Dirección Nacional de Investigaciones de Manizales (DIMA) y Vicerrectoría de Investigaciones de la Universidad Nacional de Colombia, entre estos proyectos se encuentran:

- Herramienta de apoyo al diagnóstico del TDAH en niños a partir de múltiples características de actividad eléctrica cerebral desde registros EEG.
- Desarrollo de un sistema integrado de monitoreo de actividad cerebral a partir de registros EEG en pacientes bajo anestesia general para ambientes quirúrgicos.
- Prototipo de interfaz cerebro-computador de bajo costo para la detección de patrones relevantes de actividad eléctrica cerebral relacionados con TDAH.
- Prototipo de interfaz cerebro-computador multimodal para la detección de patrones relevantes relacionados con trastornos de impulsividad.
- Interfaz cerebro-computador basada en aprendizaje de máquina y teoría de información como soporte a la detección de trastornos de déficit de atención e hiperactividad.
- Procesamiento de señales de electroencefalografía en Interfaz cerebro-computador orientado a la detección de imaginación motora utilizando modelos de DL y medidas de conectividad.

En particular, el GCPDS ha ampliado recientemente sus esfuerzos de investigación mediante la alianza con el SES-HUC Hospital Universitario de Caldas para desarrollar una estrategia innovadora en el marco del proyecto “*Sistema prototipo de procesamiento de bioseñales en unidades de cuidado intensivo neonatal utilizando aprendizaje de máquina - Fase 1: Validación en ambiente simulado*” con código Hermes 55063, financiado por la “*Convocatoria para el fortalecimiento de la investigación, creación e innovación articulado con la formación en la universidad Nacional de Colombia 2020-2021*” y “*Sistema de integración de EEG, ECG y SpO2 para seguimiento de neonatos en unidad de cuidados intensivos del Hospital Universitario de Caldas - SES HUC*” con código Hermes 57414, financiado por la “*Convocatoria nacional para el fortalecimiento de la formación a través del apoyo a proyectos de investigación, creación artística e innovación de la Universidad Nacional de Colombia 2022-2024*”. El impacto potencial de esta investigación es significativo, ya que este sistema prototipo de procesamiento de registros de actividad cardio-cerebro-pulmonar, como soporte al seguimiento individualizado de pacientes en Unidades de Cuidado Intensivo Neonatal (UCIN), permitirá reducir la mortalidad perinatal y neonatal, teniendo en cuenta que es un factor persistente durante la estadía del paciente en UCIN, y mejorar la calidad de la atención materno-infantil en el SES Hospital Universitario de Caldas.

En consecuencia, resulta necesario desarrollar nuevas estrategias de procesamiento de señales EEG en sistemas BCI mediante un sistema de bajo costo, pocos canales y portable, con el empleo de técnicas de ML y herramientas que faciliten la extracción de características relevantes de la MI, así como la interpretabilidad en ML. Estas mejoras permitirán fortalecer la confianza en los resultados obtenidos, especialmente en aplicaciones médicas y clínicas donde la confianza y la interpretabilidad de la actividad cerebral son fundamentales.

1.2 Planteamiento del problema

Las señales de EEG son empleadas en los sistemas BCI basados en MI debido a su alta resolución temporal, bajo costo, portabilidad elevada, reducidos riesgos para

los usuarios y la facilidad en la adquisición de señales cerebrales [Miao et al., 2020]. Sin embargo, estas presentan desafíos de procesamiento por las limitaciones inherentes a la captura de actividad neuronal con electrodos en el cuero cabelludo: su naturaleza no estacionaria, no linealidad, baja resolución espacial, susceptibilidad a la interferencia de ruido externo y la propensión a artefactos de señal. Esta situación conlleva al efecto de conducción de volumen, en el cual los campos eléctricos generados en un único punto del cerebro se propagan a través de los tejidos y son detectados por más de un sensor [Xygonakis et al., 2018]. En consecuencia, los canales de EEG pueden proporcionar información incorrecta sobre la fuente en la corteza, es decir, el efecto de dispersión del campo. Además, las señales de EEG pueden verse afectadas por la postura y el estado de ánimo del sujeto [Padfield et al., 2019]. Su rendimiento subóptimo puede generar frustración, imprecisiones y una funcionalidad reducida [Han et al., 2019].

Estos factores contribuyen a una (Baja Relación Señal-Ruido (SNR), por sus siglas en inglés), crucial en el desempeño de las BCIs basadas en EEG. A su vez, el grado de aprendizaje de nuevas habilidades motoras varía entre individuos, siendo la variabilidad intersujetos un factor significativo que contribuye al bajo rendimiento [Saha and Baumert, 2020]. El estado mental, la atención y la fatiga también pueden influir considerablemente en la eficacia de las BCIs. Por otra parte, la variabilidad en la estructura y función cerebral capturada por los registros de EEG añade complejidad al proceso [Tobón-Henao et al., 2022].

Por otro lado, a causa de las restricciones relacionadas con la resolución espacial y temporal de los electrodos utilizados para capturar la señal de EEG, la distribución espacial y el contenido de frecuencia de la señal pueden carecer de una claridad [Bozhokin and Suslova, 2021], dificultando la extracción de características discriminantes [Tobón-Henao et al., 2022]. Esto limita la interpretabilidad de los modelos de DL en áreas críticas como la atención médica. La falta de transparencia genera preocupaciones sobre la seguridad y confiabilidad del sistema, especialmente en decisiones clínicas, y presenta desafíos en la optimización del rendimiento de las BCIs basadas en EEG para tareas de MI.

Las BCI requieren llevar a cabo tareas complejas como la adquisición de señales, la extracción, clasificación de características, y la traducción de comandos, lo cual exige una elevada capacidad de procesamiento y computación [Sugiarto and Putro, 2009]. Dado que operan bajo sistemas operativos que no son en tiempo real, donde el término *tiempo real* se refiere a la transmisión de bloques de muestreo, los bloques de datos de EEG, con una duración de P segundos, estarán a disposición del usuario en un intervalo temporal inferior a P segundos, independientemente de la longitud del bloque. En este contexto, el concepto de *disponibilidad* implica que los datos están preparados para su utilización en el entorno de desarrollo [Cardona-Álvarez et al., 2023]. Teniendo esto en consideración, el empleo de recursos computacionales puede influir en cada componente del sistema [Sugiarto and Putro, 2009]. Dicha influencia puede resultar en demoras y variabilidad en la latencia, especialmente en sistemas centralizados, tal como se observa en [Assran et al., 2020], [Deshmukh et al., 2021]. Los desafíos relacionados con la latencia y la variabilidad tienen el potencial de disminuir la estabilidad del sistema y restringir su capacidad para gestionar un número creciente de procesos, lo que plantea obstáculos al rendimiento y a la confiabilidad de los sistemas BCI.

A pesar de las ventajas de las BCI basadas en EEG, es evidente que existen limitaciones que deben ser superadas. Para abordar estos desafíos, se propone una metodología empleando un sistema de bajo costo, portátil y con pocos canales utilizando OpenBCI. Para concretar el concepto de tiempo real mencionado, se plantea una metodología que abarca la adquisición y el procesamiento de señales de EEG mediante algoritmos de DL, con el propósito de no generar una carga computacional excesiva. Al mismo tiempo, se busca preservar la interpretabilidad espacio-frecuencia en el modelo DL y la variabilidad intersujeto.

A continuación se describen en detalle los principales desafíos de los BCI-MI basados en EEG, abordados en este trabajo: i) la variabilidad intersujeto, ii) la interpretabilidad espacio-frecuencia en modelos BCI y iii) BCI en tiempo real.

1.2.1 Variabilidad intersujeto en sistemas BCI

Las BCI basadas en EEG enfrentan el desafío de la variabilidad intersujeto, lo que dificulta la creación de BCI precisos y confiables en aplicaciones médicas y no médicas [Tremmel et al., 2019, Polat et al., 2021]. Esta variabilidad se debe a diversos factores que afectan la baja SNR, lo que plantea desafíos en el análisis de EEG. Sumado a esto, la captura de la actividad neuronal con electrodos en el cuero cabelludo enfrenta restricciones inherentes, como la no estacionariedad, no linealidad y baja resolución espacial [Bozhokin and Suslova, 2021]. Esto produce el efecto de conducción de volumen, donde los campos eléctricos generados en una ubicación cerebral se propagan y son detectados por múltiples electrodos [Xygonakis et al., 2018]. Esto resulta en una asociación espacial entre los canales de EEG, lo que a su vez influye en el número de electrodos utilizados y en el espacio entre ellos durante la captura de las señales de EEG. La interconexión espacial puede dar lugar a interpretaciones erróneas de las fuentes en la corteza y a la aparición de componentes topográficos que se extienden en el espacio, conocido como el efecto de dispersión del campo [Alotaiby et al., 2015, Kim and Im, 2021].

Respecto a la cantidad de canales, se ha encontrado que para tareas como la clasificación de emociones, la precisión de la clasificación aumenta significativamente al aumentar el número de canales más allá de 102 [Sharma et al., 2023a]. En esta investigación, los participantes realizaron una tarea de detección de estímulos visuales mientras registraban datos EEG con 2 electrodos. Sus resultados demostraron que podían capturar y cuantificar los componentes potenciales cerebrales relacionados con eventos N200 y P300 utilizando un sistema EEG montado en la frente con una disposición mínima de electrodos, concluyendo así, que el número y la selección óptimos de canales dependen directamente de la tarea específica. [Boere et al., 2023].

En el caso de la tarea de MI, no es claro cuántos canales son necesarios y varía entre sujetos. Un estudio analizó señales EEG correspondientes a la actividad fisiológica sensoriomotora utilizando 16 canales [Klein et al., 2022]. Este estudio

trabajó con una base de datos de 60 canales EEG y utilizó los canales C3 y C4 para trabajar con la imaginación motora [Liu et al., 2022]. En ambos estudios se obtuvieron resultados competitivos. En resumen, el número óptimo de canales a utilizar en el paradigma de la imaginación motora puede depender de la pregunta de investigación y del dispositivo EEG específico utilizado. Sin embargo, algunos estudios han utilizado desde un solo canal hasta 60 canales para capturar señales EEG durante la imaginación motora [Padfield et al., 2019].

Otro factor que contribuye a los bajos valores de SNR es la captura de interferencia de ruido externo por parte del montaje del sensor, que se mezcla con la información de la actividad cerebral [Tobón-Henao et al., 2022]. Sumado a esto, las señales de EEG pueden verse afectadas por artefactos de señal, como contracciones musculares involuntarias, generadas por diversas bioseñales, incluyendo electrooculografía (EOG), electrocardiografía (ECG), electromiografía del cuero cabelludo (EMG) y movimientos pulsátiles relacionados con el corazón y la respiración [Shoka et al., 2019]. Por otro lado, la postura y el estado de ánimo del sujeto también pueden afectar las señales de EEG [Padfield et al., 2019], lo que puede generar rendimientos subóptimos, frustración e imprecisiones en el BCI [Han et al., 2019] resultando en fluctuaciones de rendimiento, obstaculizando el desarrollo de BCI confiables y precisas [Vidaurre and Blankertz, 2010].

La baja SNR también está influenciada por las diferencias individuales en la estructura y función cerebral, que quedan reflejadas en los registros de EEG [García-Murillo et al., 2021]. Como resultado de la variabilidad entre sesiones y sujetos, aproximadamente el 15-30% de los usuarios no logran obtener un control suficiente sobre el BCI, lo que significa que deben aprender a modular sus señales cerebrales para asegurar un funcionamiento confiable del sistemas BCI. Las características extraídas de patrones cerebrales variantes en el tiempo entre sujetos puede ser diferente para las mismas tareas [Wriessnegger et al., 2020]. Esta habilidad individual para producir patrones de actividad cerebral distintos entre diferentes tareas mentales y estables dentro de una misma tarea, conocida como habilidad BCI, limita significativamente la adopción generalizada de BCI basados en MI [Duan et al., 2021].

Se ha estudiado que el cerebro contiene alrededor de cien mil millones de neuronas, cada una estableciendo varias miles de conexiones sinápticas entre ellas [Rossini et al., 2019], es relevante codificar esas relaciones espacio tiempo y frecuencia entre esas conexiones [Fu et al., 2019]. Además es bien conocido que el patrón de conexión entre neuronas puede variar de sujeto a sujeto y es relevante codificarlo, algunos estudios han planteado que apartir de estas relaciones, las diferencias de conectividad entre humanos han contribuido a la comprensión de la evolución del cerebro y de los perfiles cognitivos [Thiebaut de Schotten and Forkel, 2022].

1.2.2 Interpretabilidad espacio-frecuencia en modelos DL

La interpretabilidad es esencial en los modelos DL utilizados en sistemas BCI basados en EEG, especialmente en contextos como la tarea de MI. Es de vital importancia que esta interpretación pueda ser explicada mediante la resolución espacial en la zona de los canales [Bozhokin and Suslova, 2021]. Sin embargo, debido a las limitaciones en la resolución espacial de los electrodos empleados para registrar la señal EEG, la distribución espacial y el contenido de frecuencia de la señal pueden no presentar una claridad absoluta [Bozhokin and Suslova, 2021], lo que, a su vez, puede afectar la precisión de los sistemas BCI. Además, dado el carácter no estacionario de la señal EEG y su propensión a cambiar con el tiempo, podría resultar complicado analizar la señal en términos de su contenido de frecuencia o ritmos cerebrales [Bozhokin and Suslova, 2021].

Por otra parte, los modelos DL enfrentan diversos problemas relacionados con la interpretabilidad, como el alto número de espacios latentes [Chen and Stouffs, 2021]. Uno de los enfoques más comunes para abordar este problema es el Aprendizaje de Prototipos, donde las similitudes con prototipos latentes aprendidos se utilizan como base para clasificar puntos de datos no vistos

[Hoffmann et al., 2021]. Sin embargo, existe una brecha semántica entre la similitud en el espacio latente y la similitud en el espacio de entrada, lo que puede afectar la interpretabilidad y dar lugar a decisiones incomprensibles [Yang et al., 2021].

Esta falta de interpretabilidad obstaculiza la aplicación amplia de modelos de ML en áreas críticas como la atención médica, donde la interpretación adecuada de las respuestas de actividad cerebral es crucial. La falta de transparencia genera preocupaciones sobre la seguridad y confiabilidad del sistema, especialmente en la toma de decisiones clínicas [Meng et al., 2022].

Además, los sesgos presentes en los conjuntos de datos o modelos pueden llevar a decisiones injustas en el uso de algoritmos de ML, favoreciendo a ciertos individuos o grupos debido a sus características inherentes. Esto puede resultar en una subutilización o mala interpretación de los resultados, afectando la atención al paciente y poniendo en riesgo vidas humanas [Meng et al., 2022].

Para abordar este problema, la interpretabilidad en el campo del DL ha experimentado un rápido desarrollo en los últimos años [Liang et al., 2021]. Estos avances en la interpretabilidad podrían mejorar la confianza y aceptación de las BCI por parte de los usuarios finales. Por otro lado, las técnicas de interpretación en enfoques temporales, de frecuencia y espaciales también pueden proporcionar información valiosa sobre las razones detrás de un mal funcionamiento del modelo, facilitando así la mejora del rendimiento del mismo [Collazos-Huertas et al., 2021a].

1.2.3 BCI en tiempo real

El sistema BCI se compone de tres tareas fundamentales: la adquisición de señales, la extracción y clasificación de características, y la traducción o mapeo de comandos [Sugiarto and Putro, 2009]. Para llevar a cabo estas tareas, se necesita

una computadora de alto rendimiento capaz de ejecutar múltiples procesos bajo sistemas operativos que no son en tiempo real. Una forma de mejorar la complejidad computacional del marco de BCI y aumentar la fiabilidad del rendimiento general del sistema es distribuir estos tres procesos, que son intensivos en recursos de CPU, en un sistema distribuido [Sugiarto and Putro, 2009].

En un experimento médico basado en EEG estándar, se trabajan en conjunto al menos tres componentes de abstracción de datos: adquisición de datos, base de datos de señales y visualización de señales [Alvarez and Rossetti, 2015], [Beniczky et al., 2017]. Sin embargo, un sistema BCI de bucle cerrado requiere al menos siete componentes principales que deben sincronizarse de manera adecuada: adquisición de datos, base de datos/almacenamiento de señales, procesamiento de características (extracción y clasificación), visualización (temporal o espacial), generación de comandos para actuadores/agente, base de datos de comandos y adquisición de retroalimentación [Sugiarto and Putro, 2009].

En ciertos contextos, como el ámbito de la investigación, los sistemas centralizados son propensos a retrasos debido a imprevistos costos de procesamiento [Assran et al., 2020], [Deshmukh et al., 2021]. Los sistemas BCI generalmente no operan bajo un sistema operativo en tiempo real, lo que significa que la utilización de recursos computacionales afectará a cada componente del sistema. Por esta razón, es importante que la latencia no solo sea reducida, sino también que presente pequeñas variabilidades (bajo jitter). Ambas medidas son indicativas de la estabilidad del sistema y su capacidad para gestionar un mayor número de procesos [Deshmukh et al., 2021].

Por lo tanto, surge la pregunta de investigación:

¿Cómo desarrollar una estrategia de procesamiento de señales de EEG en sistemas BCI-MI con DL y medidas de conectividad para abordar de manera efectiva los desafíos de la variabilidad intersujeto, la interpretabilidad espacio frecuencia en modelos DL y permitiendo su despliegue en tiempo real?

1.3 Estado del arte

A continuación, se describen en detalle los principales enfoques del estado del arte utilizados para resolver los problemas que se han abordado en este trabajo: i) abordaje de la variabilidad intersujeto en BCI-MI basados en EEG, ii) enfoques de interpretabilidad en BCI-MI basadas EEG y iii) BCI en tiempo real.

1.3.1 Abordaje de la variabilidad intersujeto en BCI-MI basados en EEG

Recientemente, los métodos fundamentados en ML han captado creciente interés como una estrategia para enfrentar el problema de la variabilidad intersujeto en BCI basados en EEG para MI. Estos métodos generalmente incluyen las etapas de preprocesamiento, extracción de características y la clasificación. El propósito de las técnicas de preprocesamiento es reducir la influencia de la SNR causada por artefactos de señal, como contracciones musculares involuntarias, generadas por diversas bioseñales y movimientos pulsátiles relacionados con el corazón y la respiración [Shoka et al., 2019], mejorando la calidad de las señales y facilitando la detección de patrones distintivos relacionados con la tarea de MI .

Además, los métodos de preprocesamiento abordan el reto de la baja resolución espacial, consecuencia del fenómeno de conducción de volumen [Xygonakis et al., 2018]. Esto hace necesario seleccionar canales de EEG, dependiendo del paradigma a realizar, de la pregunta de investigación y del dispositivo EEG utilizado [Boere et al., 2023, Padfield et al., 2019] , con el objetivo de: (i) reducir la complejidad computacional de cualquier tarea de procesamiento realizada en las señales de EEG mediante la selección de los canales relevantes y, por lo tanto, extrayendo las características de mayor importancia; (ii) reducir la cantidad de sobreajuste que puede surgir debido a la utilización de canales

innecesarios con el fin de mejorar el rendimiento; y (iii) reducir el tiempo de configuración en algunas aplicaciones [Alotaiby et al., 2015, Kim and Im, 2021].

En contraste, los enfoques de extracción de características se esfuerzan por convertir las señales de EEG sin procesar en patrones cerebrales pertinentes que sean independientes de las particularidades individuales de cada sujeto [Ince et al., 2007], facilitando la identificación de patrones compartidos entre personas, lo cual mejora la capacidad generalizada de BCI basados en MI [Duan et al., 2021].

En diversas investigaciones se han propuesto múltiples enfoques para enfrentar diversas fuentes de interferencia, abarcando tanto artefactos como la propagación volumétrica. Para extraer componentes valiosas de MI a partir de las señales de EEG, generalmente se realiza un preprocesamiento en tres etapas principales: selección de canales, filtrado de frecuencia de la señal y eliminación de artefactos [Zhao et al., 2019, Yang et al., 2020].

En la etapa de elección de canales, se selecciona un subconjunto de datos de MI-EEG a partir de un grupo de electrodos EEG que contiene las características más distintivas de la MI. Este enfoque busca reducir la complejidad del sistema, los tiempos de cálculo y el costo del equipo, con la posibilidad de mejorar el rendimiento general del sistema. Varios estudios revisados han examinado cómo afecta la precisión de la clasificación de la MI la selección de canales con diferentes números de electrodos [Zhao et al., 2019, Yang et al., 2020].

Para el preprocesamiento, se ha empleado el filtrado de frecuencia para identificar las bandas de frecuencia más relevantes para las tareas de MI y eliminar artefactos. La actividad ERD/ERS se refiere a la Respuesta Desincronización de Rango (ERD, por sus siglas en inglés) y a la Respuesta Sincronización de Rango (ERS, por sus siglas en inglés), de los ritmos sensoriomotores en señales MI-EEG se encuentra principalmente en las bandas de frecuencia μ (8-12 Hz) y β (18-26 Hz). Por lo tanto, prácticamente todos los estudios revisados incluyeron estas dos bandas de frecuencia en su análisis debido a que contienen las características más distintivas

relacionadas con las actividades de MI. El filtrado de frecuencia también ayuda a eliminar gran parte del ruido, como artefactos de baja frecuencia, por ejemplo, Electrooculografía (EOG), causados por los movimientos sacádicos de los ojos y ruido de alta frecuencia, por ejemplo, Electromiografía (EMG) por encima de 35 Hz [Chu et al., 2018].

Para abordar el ruido eléctrico y ambiental, así como las bandas de frecuencia donde la información neurofisiológica es irrelevante, se utilizan filtros pasa banda y filtros notch [Singh et al., 2021]. Además, las técnicas de separación ciega de fuentes, como el Análisis de Correlación Canónica (CCA), el Análisis de Componentes Principales (PCA) y el Análisis de Componentes Independientes (ICA), se emplean comúnmente para descomponer el EEG contaminado en componentes estadísticamente independientes y eliminar o corregir artefactos [Stergiadis et al., 2022]. El ICA, en particular, es ampliamente reconocido por su éxito en eliminar diversos tipos de artefactos [Rashid et al., 2020].

Asimismo, se han propuesto diversos filtros espaciales para superar el efecto de conducción de volumen, entre ellos la Referencia Promedio Común (CAR) y el Laplaciano de Superficie (SL). La filtración espacial CAR resta la actividad eléctrica promedio medida en todos los sensores de cada sensor con el fin de reducir el ruido registrado [Uribe et al., 2019]. Sin embargo, no aborda el ruido específico del sensor y puede introducir ruido en un sensor que, de otro modo, estaría limpio [Mridha et al., 2021]. Por otro lado, el SL busca eliminar la actividad cerebral común de los sensores vecinos debido al efecto de conducción de volumen, mejorando así las características topográficas locales, facilitando el análisis de conectividad a nivel de sensor y ayudando a mejorar el SNR [Xu et al., 2018]. No obstante, aplicar estos métodos a todos los sujetos independientemente de su nivel individual de ruido podría tener un efecto perjudicial para aquellos con EEG limpio [Tobón-Henao et al., 2022].

Por otro lado, los métodos de extracción de características pueden clasificarse ampliamente en tres dominios: tiempo, tiempo-frecuencia y espacial. En el

dominio temporal, se utilizan características temporales, como medidas estadísticas [Wang et al., 2018]. En el dominio de la frecuencia, se emplean técnicas como la transformada rápida de Fourier (FFT) [Hassanpour et al., 2019], transformada discreta de coseno (DCT) [Taheri et al., 2020] y densidad espectral de potencia (PSD) [Ma et al., 2020]. Estas técnicas son esenciales en el análisis y procesamiento de señales, ya que permiten descomponer y representar señales complejas en términos de sus componentes de frecuencia, facilitando la interpretación y el tratamiento de la información contenida en las señales. Sin embargo, la FFT presenta limitaciones en señales no estacionarias, la DCT puede llevar a la pérdida de información debido a la transformación que realiza, y la PSD muestra sensibilidad al tamaño de la ventana y pérdida de información temporal.

En el dominio tiempo-frecuencia, se utilizan técnicas como la descomposición de paquetes de wavelet (WPD), la transformada discreta de wavelet (DWT) [Ma et al., 2020], la descomposición de modo empírico (EMD) [Taheri et al., 2020] y la transformada de Hilbert-Huang (HHT) [Huang et al., 2020]. La WPD es una extensión de la DWT que permite una mayor flexibilidad al descomponer una señal en diferentes subbandas. En lugar de obtener una única descomposición en escalas y frecuencias específicas, la WPD genera múltiples descomposiciones en subbandas con diferentes características, lo que permite una representación más detallada de la señal y una mejor capacidad para capturar diferentes componentes en diferentes niveles de resolución [Ma et al., 2020]. La DWT proporciona información sobre diferentes frecuencias presentes en la señal y es ampliamente utilizada en aplicaciones de compresión de señales, eliminación de ruido y análisis de señales no estacionarias. Ambas técnicas, EMD y HHT, son poderosas herramientas para analizar señales complejas y no lineales, permitiendo una mayor comprensión de las características intrínsecas de las señales y su variación en el tiempo. Sin embargo, son sensibles al ruido, lo que puede dificultar la interpretación y el análisis preciso de los resultados.

El enfoque FBCSP (Filtros Espaciales Comunes basados en Bancos de Filtros) se utiliza para extraer características espaciales en bandas de frecuencia relevantes

para los datos de MI [Luo et al., 2018]. Siendo un derivado de CSP, el análisis de componentes principales, es un método eficaz para la reducción de dimensiones en señales de EEG, con un tiempo de entrenamiento corto y bajo costo computacional. Sin embargo, algunas de las características extraídas aún pueden ser redundantes y carecer de interpretabilidad, además de que es sensible a la variabilidad intersujeto.

Por otro lado, se han estudiado medidas de conectividad con el fin de comprender las asociaciones entre el cerebro y el comportamiento: Las medidas de conectividad cerebral pueden ayudar a identificar patrones de conexiones anatómicas, dependencias estadísticas y procesamiento de información entre diferentes regiones del cerebro [Miraglia et al., 2022]. Estas medidas se pueden utilizar para entender cómo se comunican entre sí las distintas regiones cerebrales y cómo esta comunicación se relaciona con el comportamiento y la cognición [Thiebaut de Schotten and Forkel, 2022]. Entre las técnicas de conectividad, la conectividad funcional y efectiva han sido el enfoque de los estudios computacionales en los últimos años [Friston et al., 1991, Farahani and Karwowski, 2019].

La FC captura la similitud entre diferentes canales de EEG, proporcionando información sobre qué regiones del cerebro interactúan cuando un sujeto realiza la tarea de MI [Hsu, 2014]. Mediante esta técnica, es posible detectar relaciones relevantes entre los diferentes canales que resultan útiles para lograr una clasificación efectiva de la tarea de MI. La conectividad efectiva se refiere a las interacciones causales entre unidades neuronales de la red cerebral [Farahani et al., 2019]. Para el análisis de la conectividad efectiva del cerebro, métodos como la causalidad de Granger, la modelización causal dinámica y las redes bayesianas han sido de interés para los investigadores [Friston, , Zhang et al., 2015].

En este sentido, la incorporación de técnicas de aprendizaje de máquina podría eliminar la información redundante presente en los datos de EEG, retener mejores

características y obtener un mejor desempeño con respecto a la tarea que se va a llevar a cabo [Cheng et al., 2020].

La clasificación de señales de EEG en MI se divide en el uso de métodos de aprendizaje supervisado y no supervisado. se utilizan métodos de aprendizaje supervisado como la máquina de soporte vectorial (SVM) y el análisis discriminante lineal (LDA) para la clasificación de características, o el método de aprendizaje no supervisado de los k vecinos más cercanos (KNN) para la clasificación de características [Xie et al., 2022]. Sin embargo, la información útil del EEG puede perderse durante la extracción de características. Con las capacidades de extracción automática de características y representación robusta de características, el modelo de DL puede recibir directamente los datos de EEG preprocesados y establecer un modelo de extremo a extremo sin la necesidad de extracción de características [Xie et al., 2022].

Los modelos de DL, tales como EEGNet [Lawhern et al., 2018], ShallowConvNet [Qayyum et al., 2022], DeepConvNet [Li and Song, 2023], EEG-transformer [Song et al., 2021], y red neuronal de convolución de grafos (GCN) [Sun et al., 2022], presentan un potencial significativo en la resolución de los desafíos relacionados con la variabilidad en BCI-MI basados en EEG. Mientras que EEGNet y ShallowConvNet utilizan capas convolucionales para extraer patrones espaciales y temporales de los datos EEG, se ha observado que EEGNet puede enfrentar dificultades en capturar dependencias temporales a largo plazo [He et al., 2022], y ShallowConvNet puede no ser tan eficiente como arquitecturas más profundas para identificar patrones complejos. De igual manera, DeepConvNet se destaca por su habilidad en la identificación de patrones espaciales y temporales, aunque es necesario contar con una cantidad considerable de datos de entrenamiento para prevenir el sobreajuste [Tobon-Henao et al., 2023].

Estos modelos de DL pueden ser propensos al sobreajuste cuando son demasiado complejos o los datos de entrenamiento son ruidosos o insuficientes [Zhang et al., 2019]. Para abordar este desafío, se han propuesto diversas técnicas

de regularización. La adaptación de dominio tiene como objetivo reducir la variabilidad entre diferentes sujetos mediante el aprendizaje de una asignación entre dominios fuente y objetivo [Phunruangsakao et al., 2022]. El Dropout es una técnica que se aplica durante el entrenamiento de una red neuronal y consiste en aleatoriamente “desactivar” un porcentaje de neuronas en cada iteración. Esto evita que las neuronas se vuelvan demasiado dependientes de otras y ayuda al modelo a aprender características más robustas y generalizables [Roy et al., 2020]. Por otro lado, la Batch Normalization es una técnica que normaliza las activaciones de cada capa de la red neuronal, de modo que tengan una media cercana a cero y una varianza cercana a uno. Esto ayuda a estabilizar el proceso de entrenamiento y reduce la dependencia de los valores iniciales de los pesos, lo que resulta en una mejora del rendimiento y la generalización de los modelos de DL [Huang et al., 2019].

Los autoencoders apilados, también conocidos como Stacked Autoencoders Autoencoders Apilados (SAE), son un tipo de red neuronal artificial que consta de múltiples capas de autoencoders. Cada capa funciona como un autoencoder independiente, donde la capa de entrada se codifica y se decodifica para obtener una representación latente o código intermedio. La representación del código en cada capa se utiliza como entrada para la siguiente capa [Altaheri et al., 2023]. Por otro lado, los modelos basados en Transformer, como el EEG-transformer, pueden procesar secuencias de EEG de longitud variable utilizando un mecanismo de auto-atención para capturar las dependencias entre diferentes segmentos. No obstante, es importante tener en cuenta que estos modelos conllevan costos computacionales más elevados [Kong et al., 2021].

Los modelos de aprendizaje profundo DL híbridos que integran dos o más DL modelos en una sola red para la clasificación de BCI, aprovechan las fortalezas de diferentes tipos de redes y mejoran el rendimiento en tareas complejas que no podrían ser resueltas eficazmente por un único modelo. La combinación de varias arquitecturas de redes permite abordar características y desafíos específicos de un conjunto de datos o problema particular, por ejemplo, el RCNN (red neuronal

convolucional recurrente), Red neuronal con arquitectura de Convolutional Neural Network (CNN)/SAE, CNN/MLP y CNN/LSTM, y han obtenido resultados prometedores en tareas de clasificación de BCI [Altaheri et al., 2023]. La Figura 1-1 resume la discusión anterior sobre el problema de la variabilidad intersujeto.

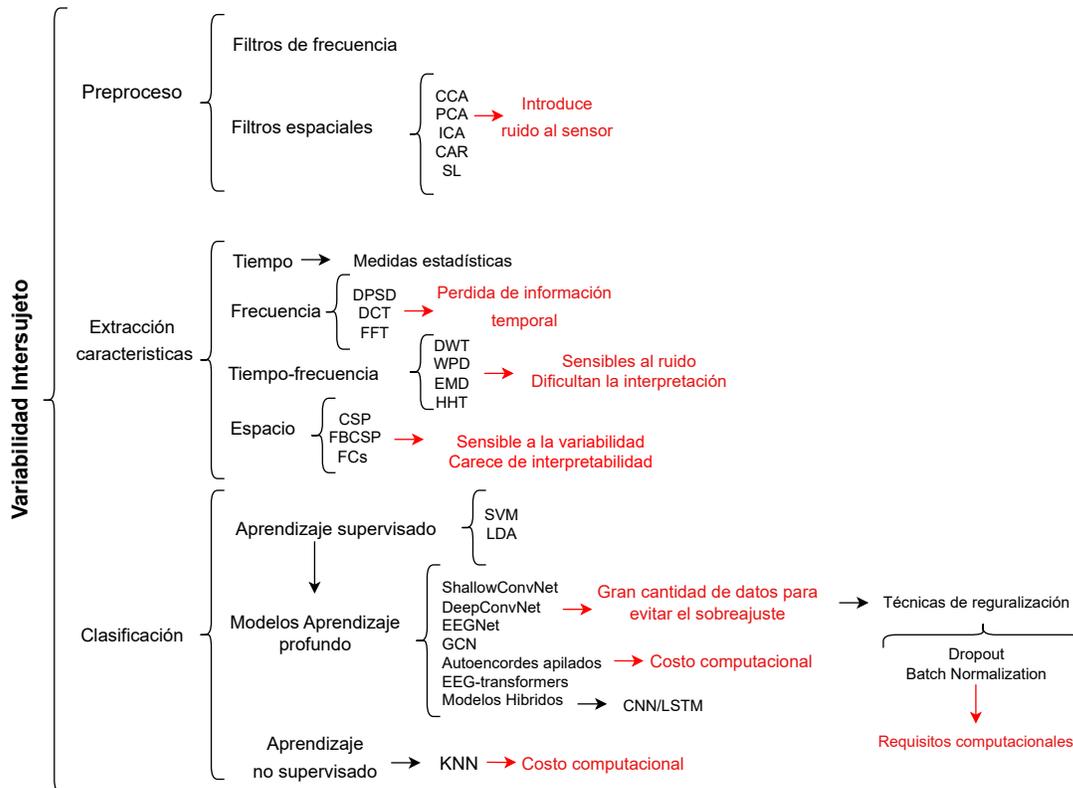


Figura 1-1. Resumen de los principales enfoques utilizados para abordar el problema de la Variabilidad intersujeto y sus desventajas resaltadas en rojo.

1.3.2 Enfoques de interpretabilidad en BCI-MI basadas en EEG en modelos ML

Es de vital importancia entender los mecanismos neuronales involucrados en la MI para optimizar completamente el diseño de BCI que se basen en señales EEG [Velasquez-Martinez et al., 2020b]. La carencia de claridad en la interpretación

dificulta la amplia aplicación de modelos de DL en campos críticos como la atención médica, donde una adecuada comprensión de las respuestas de la actividad cerebral es crucial. La falta de claridad del sistema genera inquietudes en relación a la seguridad y confiabilidad del mismo, especialmente cuando se trata de decisiones clínicas, lo que plantea dudas sobre su desempeño [Meng et al., 2022].

Se han empleado diversos enfoques temporales, de frecuencia y espaciales para investigar las actividades cerebrales asociadas con la MI. Estos enfoques han contribuido a lograr una mayor precisión y confiabilidad en el rendimiento de las BCI [Collazos-Huertas et al., 2021b]. Dentro de las técnicas de análisis tiempo-frecuencia, se encuentra la transformada wavelet siendo útil para procesar señales que varían en el tiempo, ya que puede separar la información de frecuencias bajas y altas. Por otro lado, la descomposición empírica en modos (EMD) se utiliza para descomponer señales no lineales en sus componentes intrínsecos [Deriche et al., 2019]. Asimismo, la transformada de Fourier (FT) puede extraer características más abundantes [Deriche et al., 2019]. Mediante el análisis de la densidad espectral de potencia (PDS), es posible identificar las bandas de frecuencia más relevantes para la MI y cómo varía su potencia en el tiempo [Feradov et al., 2020]. Es importante tener en cuenta que estas técnicas a menudo proporcionan espacios de representación con alta redundancia y, en ocasiones, poca relevancia. También son sensibles al ruido, a artefactos, y presentan limitaciones en la resolución espacial. En contraste, los métodos espaciales buscan localizar las áreas cerebrales en las que se evidencia una actividad cerebral significativa [Marks and Isaac, 1995]. El algoritmo CSP se basa en la diagonalización simultánea de dos matrices de covarianza para encontrar los filtros espaciales óptimos sin la necesidad de extraer características de una banda de frecuencia particular; sin embargo, requiere análisis multicanal y es muy sensible al ruido [Nasihatkon et al., 2009]. Por último, el análisis de componentes principales es un método efectivo para la reducción de dimensionalidad, se puede realizar en señales EEG con un corto tiempo de entrenamiento y un bajo costo computacional [Chavan and Kolte, 2015]. No obstante, algunas de las características extraídas aún son redundantes y carecen de interpretabilidad. Por otro lado, los topoplots se

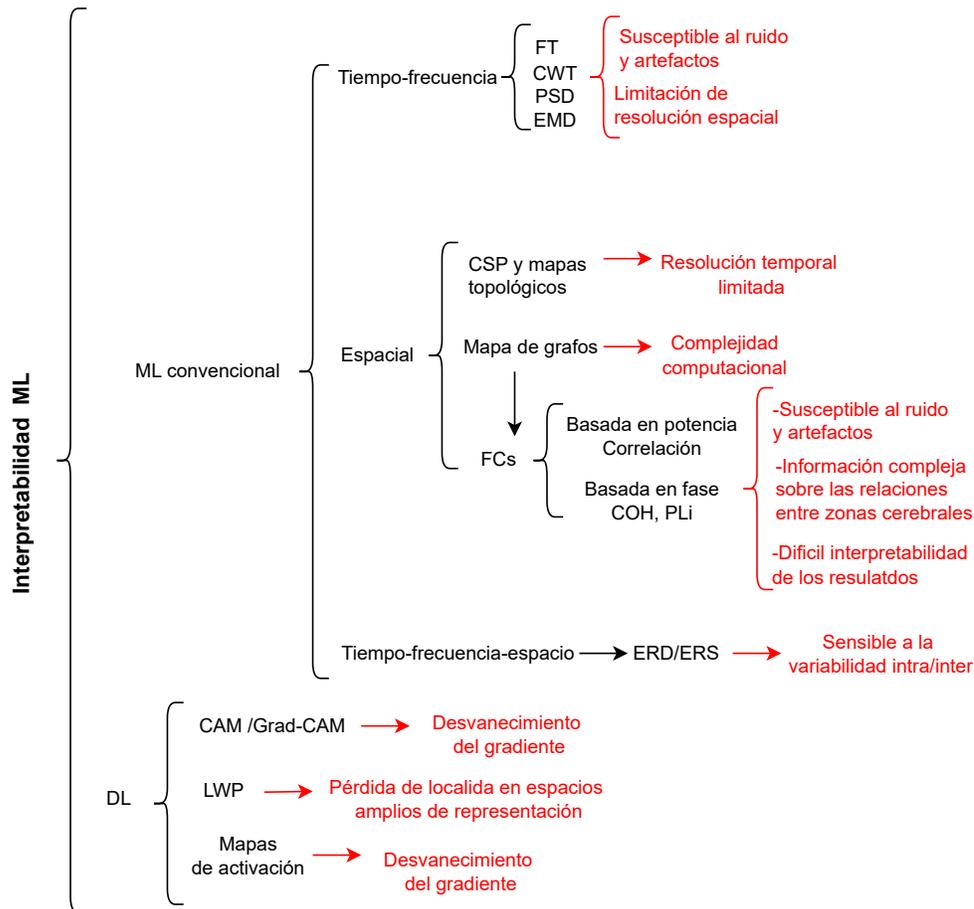


Figura 1-2. Resumen de los principales enfoques utilizados para abordar el problema de la interpretabilidad y sus desventajas resaltadas en rojo.

utilizan para representar la amplitud o potencia de las señales EEG en puntos de tiempo específicos o en bandas de frecuencia determinadas basadas en la topología espacial de los electrodos, es decir, la posición de los electrodos en el cuero cabelludo [Altaheri et al., 2023], facilitando la identificación de las regiones donde la actividad neuronal está más relacionada con la tarea de MI. En cuanto a sus limitaciones, no proporcionan una interpretación directa y explícita de las relaciones entre las características de los datos. Aunque los datos se organizan de manera topológica en el mapa, no siempre está claro qué significan exactamente las relaciones espaciales entre las conexiones [Altaheri et al., 2023].

Con el fin de abordar dichas limitaciones, se han empleado diferentes enfoques de conectividad cerebral FCS, tales como la correlación [Šverko et al., 2022], coherencia espectral (COH) [Ashenaei et al., 2022] y el índice de desfase de fase (PLI) [Feng et al., 2020], para evaluar cómo se relacionan distintas regiones cerebrales en términos de frecuencia y fase. No obstante, estos métodos presentan vulnerabilidad ante diversas fuentes de ruido y artefactos, como la conducción de volumen, elección de referencia y la variabilidad temporal de las señales [Ruiz-Gómez et al., 2019]. En el enfoque tiempo-espacio-frecuencia tenemos la desincronización relacionada con eventos (ERD) y sincronización relacionada con eventos (ERS), siendo importantes para entender cómo la actividad cerebral se modula en diferentes situaciones y tareas mentales. Por ejemplo, en ciertas tareas motoras o cognitivas, podemos observar una disminución de ciertas frecuencias cerebrales (ERD), mientras que, durante el reposo o la relajación, podemos observar un aumento en dichas frecuencias (ERS) [Cona et al., 2009]. Sin embargo, estos enfoques son susceptibles a la variabilidad inter/intra sujeto. Estas limitaciones pueden afectar tanto la precisión como la interpretación de los resultados obtenidos. En consecuencia, ha surgido la necesidad de implementar enfoques basados en DL.

Los CAMs son una técnica visual ampliamente utilizada que proporciona interpretabilidad para tareas de clasificación de imágenes. Esta técnica genera mapas de activación de clase, que permiten a los investigadores identificar las regiones más discriminativas en una imagen [Zhou et al., 2015]. El concepto subyacente de los Mapas de Activación de Clase (CAM)s implica la generación de regiones destacadas para una clase específica mediante una combinación lineal de mapas de características provenientes de una capa específica de una red neuronal convolucional. Posteriormente, se distinguen entre todos los enfoques de métodos de CAMs, como es el caso de Grad-CAM [Selvaraju et al., 2016]. Sumado a esto, los enfoques de CAMs son agnósticos al modelo, simples de implementar e interpretar, eficientes y producen visualizaciones intuitivas [Teng et al., 2022]. Estos beneficios hacen de los CAMs una herramienta potente y versátil para investigadores y profesionales que deseen comprender mejor las características de

los modelos basados en redes neuronales convolucionales. La Figura 1-2 resume la discusión previa sobre las técnicas de interpretabilidad para comprender los procesos cerebrales.

Un método adicional es la propagación de relevancia por capas LRP. Su objetivo es proporcionar una mayor transparencia y explicabilidad en los modelos de DL para comprender cómo el modelo toma decisiones y realiza predicciones. También, se pueden visualizar los mapas de activación para obtener una comprensión más profunda del comportamiento de la red y descubrir qué características son aprendidas en cada nivel [Li and Ruan, 2021]. Estas técnicas resaltan tanto los momentos específicos como los canales particulares en las señales EEG que más contribuyen a la distinción entre las diferentes clases de BCI-MI, y pueden ser significativas para entender las diferencias en el rendimiento de los individuos [Sturm et al., 2016].

1.3.3 BCI en tiempo real

Actualmente, la mayoría de los sistemas BCI utilizan algoritmos sofisticados para entrenar los datos en etapas fuera de línea y luego realizar únicamente la clasificación en tiempo real. Este enfoque ha motivado un considerable esfuerzo para minimizar el costo computacional asociado al procesamiento de señales en BCI [Netzer et al., 2020], [Hasan et al., 2020]. Constantemente se debate la relación entre el costo computacional y la precisión [Ahmadi et al., 2012], dado que la aparición de procesadores más avanzados a menudo conlleva técnicas de análisis más costosas. En consecuencia, el objetivo perpetuo es identificar métodos computacionales de bajo costo [Changoluisa et al., 2020].

En cuanto a otro componente esencial, el clasificador, se han explorado diversas técnicas para las señales de EEG en MI. Estas incluyen el análisis discriminante lineal (LDA), los vecinos más cercanos (KNN) [Xie et al., 2022], la red neuronal de retropropagación (BPNN) y la máquina de soporte vectorial (SVM). Entre estos, la

SVM es la técnica más utilizada en el campo de la EEG, gracias a su excepcional capacidad de generalización y mapeo no lineal. No obstante, es importante señalar que el proceso de entrenamiento de los algoritmos KNN y SVM puede conllevar un costo computacional elevado, especialmente al tratar con conjuntos de datos voluminosos. A su vez, el LDA es susceptible a características irrelevantes y puede presentar dificultades en la clasificación en dimensiones elevadas [Tang et al., 2019].

Recientemente, han surgido nuevas propuestas que exploran alternativas a los clasificadores comúnmente utilizados, como las SVMs, en favor de técnicas más avanzadas. Kumar et al. recomendó el uso de un perceptrón multi-capas (MLP), preservando los mecanismos de extracción de características especializados [Kumar et al., 2016]. En una línea similar, An et al. aplicó un modelo de red de creencias profundas (DBN) para la clasificación de dos clases de MI, demostrando que el DBN era más exitoso que el método SVM [An et al., 2014].

Por otro lado, otras investigaciones están adoptando enfoques que combinan técnicas avanzadas de clasificación. Yousef et al. combinaron redes neuronales convolucionales (CNN) y autoencoders apilados (SAE) para clasificar señales de MI en EEG [Echtioui et al., 2021]. Asimismo, los autores de [Shen et al., 2017] propusieron un enfoque de DL de extremo a extremo utilizando CNNs y células de memoria a corto y largo plazo (LSTMs) para clasificar datos EEG, sin aplicar ningún preprocesamiento.

A su vez, algunas investigaciones se han enfocado en la mejora de las etapas de entrada a los modelos. Schirrmeister et al., por ejemplo, utilizaron un modelo con etapas de entrada de CNN para separar el filtrado temporal y espacial. A pesar de que la estructura del modelo es bastante simple y superficial, ha demostrado producir excelentes resultados [Tibor Schirrmeister et al., 2017]. Por otro lado, Yang H et al. generaron características de patrón espacial común aumentado (ACSP) basadas en matrices de proyección par a par [Yang et al., 2015]. Este enfoque puede considerarse como la extracción de características CSP a partir de

una descomposición de múltiples niveles de diferentes rangos de frecuencia. Finalmente, Bashivan P et al. propusieron una nueva forma de características que preservan la estructura espacial, espectral y temporal del EEG [Bashivan et al., 2015]. Estas investigaciones demuestran la diversidad y la innovación en la exploración de nuevas técnicas de clasificación y extracción de características, apuntando a mejorar la precisión y eficiencia de los sistemas BCI.

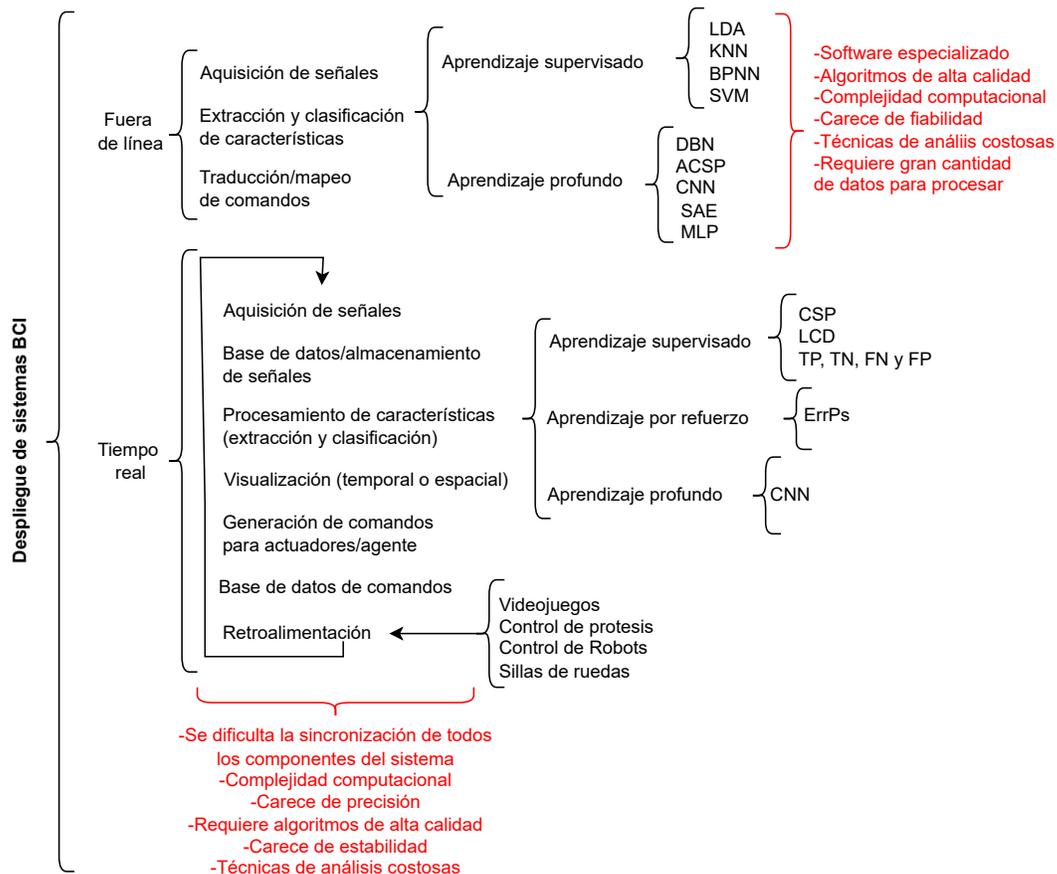


Figura 1-3. Resumen de los principales enfoques utilizados para afrontar el problema del Tiempo real y sus desventajas resaltadas en rojo.

En el cuadro 1-1 Se observa la comparación de latencia en sistemas BCI con diferentes configuraciones, cabe aclarar que los sistemas con cable tienen fluctuaciones significativamente más bajas que los inalámbricos. Aunque la

latencia también depende del paradigma; por lo tanto, la misma configuración tiene respuestas de latencia diferentes.

Sistema BCI	Frecuencia	Jitter	Comunicación	Tamaño de bloque	Latencia
BCI2000 + DT3003 [Schalk et al., 2004]	160 Hz	0.67 ms	Cableado	6.35 ms	51.9 %
BCI2000 + NI 6024E [Schalk et al., 2004]	25 kHz	0.75 ms	Cableado	40 ms	27.5 %
BCI2000 + g.USBamp [Wilson et al., 2010]	1200 Hz	5.91 ms	Cableado	83.3 ms	14, 30, 48 %
OpenViBE + TMSi Porti32 [Kisakye, 2013]	512 Hz	3.07 ms	Multiplexor óptico	62.5 ms	100.4 %
BCI-Framework [Cardona-Álvarez et al., 2023]	1000 Hz	5.7 ms	Inalámbrico	100 ms	56 %

Cuadro 1-1. Comparación de latencias entre diferentes configuraciones de sistemas BCI.

En lo que respecta a las plataformas de software utilizadas para desarrollar sistemas BCI en tiempo real, resulta evidente que su eficacia está intrínsecamente vinculada a la capacidad del sistema para adquirir y procesar señales con precisión y eficiencia. Tanto BCI2000 como OpenViBE, dos de las plataformas más reconocidas en este campo, comparten la meta de lograr un rendimiento óptimo al adquirir y analizar señales cerebrales en tiempo real, además, es crucial que el sistema proporcione retroalimentación coherente al usuario con baja latencia y mínima fluctuación, como se discute en el artículo de Wilson et al [Wilson et al., 2010].

Aunque BCI2000 [Schalk et al., 2004] ofrece muchas ventajas como una plataforma versátil para el desarrollo de sistemas BCI, también tiene algunas limitaciones y desventajas, BCI2000 está diseñado para ofrecer capacidades en tiempo real, pero en el caso de BCI2000 + DT3003 y BCI2000 + NI 6024E podría haber cierta latencia en la adquisición de señales cerebrales, procesamiento y generación de comandos. Esta latencia podría ser crítica en aplicaciones donde se requiere una respuesta muy rápida y precisa, a pesar de los esfuerzos por minimizar la latencia, en situaciones de alta carga computacional o interrupciones del sistema, podría haber fluctuaciones en la latencia, lo que podría afectar la sincronización y el rendimiento en tiempo real. [Schalk et al., 2004]

Específicamente, en el caso de BCI2000 + g.USBamp [Wilson et al., 2010], se presenta un procedimiento detallado para medir y caracterizar las latencias en sistemas BCI. Se observa una variabilidad en las latencias en diferentes etapas del procesamiento de señales en sistemas BCI. Estas variaciones en las latencias pueden afectar la precisión y la calidad de la interacción usuario-computadora en sistemas BCI. Esta variabilidad en las latencias puede resultar en respuestas inconsistentes y tiempos de reacción impredecibles en las aplicaciones BCI en tiempo real, lo que a su vez afecta negativamente la experiencia del usuario y reduce la confiabilidad de los resultados en aplicaciones BCI. Las latencias pueden variar según el hardware utilizado, el sistema operativo, el software de procesamiento de señales y otros factores. Esta variabilidad en las latencias puede resultar en respuestas inconsistentes y tiempos de reacción impredecibles en las aplicaciones BCI en tiempo real [Wilson et al., 2010].

Similar a los otros sistemas BCI, OpenViBE + TMSi Porti32 [Kisakye, 2013] puede experimentar latencia y fluctuaciones de sincronización (jitter) en la adquisición, procesamiento y presentación de señales cerebrales. Esto podría impactar la capacidad de respuesta en tiempo real de las aplicaciones, y la eficacia así como el rendimiento en tiempo real de OpenViBE podrían depender en gran medida del hardware utilizado.

El desarrollo y la aplicación de sistemas de BCI en tiempo real con DL están en constante evolución, presentando un panorama diverso y emocionante. Se propuso un nuevo método de extracción de características para clasificar cuatro clases de señales de MI mediante la combinación de CSP [Aghaei et al., 2015, Netzer et al., 2020], LCD [Zheng et al., 2013, Ai et al., 2019] y redes cerebrales funcionales. Se extrajeron características en el dominio de la frecuencia y el dominio espacial a partir de señales EEG de MI utilizando los algoritmos CSP y LCD. Posteriormente, se construyeron redes cerebrales utilizando las señales EEG de cada sujeto.

Las medidas de grado de las redes cerebrales se extrajeron para caracterizar las actividades cerebrales de los sujetos. El método propuesto se integró en un

sistema de control de robot BCI en tiempo real diseñado para experimentos en el mundo real [Ai et al., 2019]. Asimismo, este estudio [Choi et al., 2020b] tuvo como objetivo desarrollar un controlador intuitivo de BCI híbrida basado en MI relacionada con la marcha para un exoesqueleto de extremidades inferiores e investigar la viabilidad del controlador en un escenario práctico que incluye levantarse, caminar y sentarse. Para el decodificador en línea, se registraron los verdaderos positivos (TP), verdaderos negativos (TN), falsos positivos (FP) y falsos negativos (FN) de los dos clasificadores mientras los sujetos estaban ejecutando el escenario de la marcha.

Aunque este estudio presenta la viabilidad del controlador BCI híbrido en tiempo real y basado en MI con un exoesqueleto portátil en sujetos sanos, el costo y la accesibilidad presentan limitaciones. La tecnología de BCI y los exoesqueletos pueden ser costosos y no estar fácilmente disponibles para todos los pacientes que podrían beneficiarse de ella [Choi et al., 2020b]. La accesibilidad y la asequibilidad son factores importantes a considerar en su implementación práctica.

Recientemente, los avances en BCI han comenzado a adoptar el marco de DL, capaz de proporcionar una decodificación precisa de los pensamientos del usuario. Se ha demostrado, por ejemplo, que el sistema MI-BCI tiene un alto rendimiento de decodificación, como la clasificación de movimientos de extremidades superiores en una sesión fuera de línea. Sin embargo, sólo unos pocos estudios han demostrado un sistema BCI en tiempo real basado en un marco de DL. Esta limitación se debe principalmente al hecho de que dicha metodología requiere más tiempo de entrenamiento del modelo durante la sesión de calibración, en comparación con los enfoques de ML convencionales [Cho et al., 2021].

Para superar este desafío, en este estudio, se propone NeuroGrasp, un marco de DL de dos etapas que decodifica múltiples tipos de agarre de la mano a partir de señales EEG bajo el paradigma de MI. El método propuesto utiliza eficazmente el aprendizaje basado en EEG y electromiografía (EMG). Empleando una red neuronal convolucional (CNN), se usa la información de señal correspondiente de los seis músculos como etiqueta para extraer características del EEG [Cho et al., 2021].

Además, las BCI han empezado a explorar otros paradigmas interesantes, como la BCI basada en la expresión facial emocional controlada por un agente inteligente. Este agente realiza acciones correctas e incorrectas, mientras que el usuario observa y evalúa las acciones del agente. A través de un proceso de aprendizaje por refuerzo (RL), el agente aprende una estrategia óptima si el participante genera potenciales relacionados con el error (ErrPs) cuando se producen acciones incorrectas del agente. Este tipo de interacción de biofeedback podría ser muy relevante en el desarrollo de futuros sistemas BCI más avanzados e intuitivos [Pires et al., 2022].

Por lo general, para aumentar la precisión de decodificación, los marcos de DL requieren más muestras de entrenamiento y capas más profundas. Sin embargo, esto puede resultar en un tiempo inaceptable para los usuarios del sistema BCI en tiempo real. Por lo tanto, aún existen desafíos significativos para equilibrar la necesidad de precisión y eficiencia en los sistemas BCI en tiempo real. La figura 1-3 resume los enfoques en el despliegue de sistemas BCI.

En la actualidad, el uso de enfoques de ML y DL han ganado cada vez más atención como una estrategia para abordar el desafío de la variabilidad entre sujetos en los BCI basados en EEG para MI. Estos enfoques típicamente involucran etapas de preprocesamiento, extracción de características y clasificación. El objetivo de las técnicas de preprocesamiento es disminuir el impacto del ruido de señal, especialmente causado por artefactos, en el rendimiento del BCI. Los más usados son FBCSP, es un método eficaz para la reducción de dimensiones en señales de EEG y CFCs estas técnicas resultan útiles para lograr una clasificación efectiva de la tarea de MI, al integrar arquitecturas bien establecidas de DL, como EEGNet presentan un potencial significativo en la resolución de los desafíos relacionados con la variabilidad en BCI-MI basados en EEG.

Así mismo, para abordar el desafío de la interpretabilidad en BCI basados en EEG para la MI los métodos más usados son los mapas de grafos y mapas topológicos facilitando la identificación de las regiones donde la actividad neuronal está más

relacionada con la tarea de MI, estos métodos permiten identificar las áreas cerebrales donde la actividad neuronal está más vinculada con la tarea de MI. Para lograr una evaluación más efectiva de las diferencias en los patrones cerebrales entre los sujetos, es crucial utilizar métodos de discriminación de clases basados en FC. Estos enfoques se centran especialmente en las variaciones en las conexiones y canales clave involucrados en la clasificación de MI.

En el ámbito del despliegue de sistemas BCI para afrontar el desafío del tiempo real con DL, se encuentran en constante evolución, presentando un panorama diverso y emocionante en la neurociencia. Al adoptar el marco de DL, se logra una decodificación precisa de los pensamientos del usuario, extrayendo características en el dominio de la frecuencia y el dominio espacial a partir de señales de EEG para la tarea de MI utilizando los algoritmos CSP.

Siendo estos aspectos el fundamento para nuestra propuesta de metodologías novedosas que aborden los desafíos a los que se enfrentan las señales de EEG en sistemas BCI-MI. Nuestro principal objetivo es desarrollar estrategias para el procesamiento de señales de EEG que puedan lidiar con los problemas de la variabilidad intersujeto en alta y baja densidad de canales, desarrollar la representación de EEG basada en imágenes, para enfrentar la baja resolución espacial y obteniendo interpretabilidad. Aspiramos a desarrollar una metodología de adquisición y procesamiento de datos en un entorno de tiempo real, cerrando el lazo con la tarea de MI, con un sistema BCI de bajo costo y portable.

1.4 Objetivos

1.4.1 Objetivo general

Desarrollar una estrategia de procesamiento de señales de EEG, basado en ML y medidas de conectividad, para codificar información relevante en la clasificación de tareas de MI en sistemas BCI lidiando adecuadamente con la variabilidad entre sujetos, preservando la interpretabilidad en el dominio espacio-frecuencia en modelos DL y permitiendo su despliegue en tiempo real.

1.4.2 Objetivos específicos

- Desarrollar una metodología de procesamiento de señales de EEG para la clasificación de tareas de MI en configuraciones de alta y baja densidad de canales, con el fin de mitigar el impacto de la variabilidad intersujeto.
- Desarrollar una metodología de representación y clasificación de MI basada en medidas de conectividad y modelos DL que preserve la interpretabilidad espacio-frecuencia.
- Implementar un modelo de entrenamiento y clasificación de señales EEG que permita adquirir y procesar las señales en tiempo real, proporcionando una herramienta práctica para sistemas BCI en la detección de tareas de MI.

1.5 Contribuciones

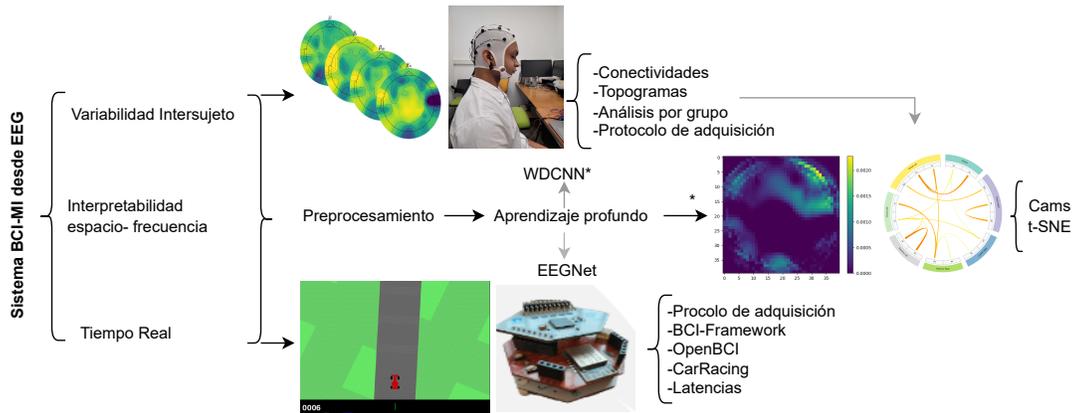


Figura 1-4. Diagrama esquemático que ilustra las soluciones propuestas para los problemas de Variabilidad intersujeto, interpretabilidad espacio-frecuencia en modelos DL y tiempo real.

En esta sección, se presenta un breve resumen de las contribuciones significativas que abordan aspectos clave en el campo de estudio, como se observa en la Figura 1-4. A lo largo de este trabajo de investigación, se han realizado esfuerzos para abordar y resolver los desafíos identificados, y se han desarrollado enfoques y soluciones innovadoras. A continuación, se proporcionará una visión general de las principales contribuciones presentadas en esta tesis, destacando su relevancia y aportes al conocimiento existente.

Las contribuciones se han estructurado en base a las siguientes áreas temáticas: i) Representación y clasificación de EEG basada en imágenes y DL, ii) Adquisición y Procesamiento en tiempo real.

1.5.1 Representación y clasificación de EEG basada en imágenes y DL

Se propone una metodología de representación y clasificación de señales EEG basada en imágenes a partir de conectividades, para la clasificación de tareas de MI. Se utiliza un marco de aprendizaje profundo para mejorar la precisión y exactitud de las BCI-MI. Además, para lograr una mejor interpretación de los resultados, se recurre a técnicas de interpretación y visualización. Esta metodología ha sido probada en bases de datos públicas con múltiples canales (64 canales) y en bases de datos propias con pocos canales (16 canales).

La principal ventaja de este enfoque radica en su capacidad para superar los desafíos inherentes a la variabilidad intersujeto y a la interpretabilidad espacio-frecuencia, que a menudo son obstáculos en los enfoques basados en DL. Para abordar estos desafíos, se ha desarrollado un protocolo de adquisición de datos para el sistema BCI-MI basado en señales EEG. Este protocolo se ha implementado utilizando herramientas como OpenBCI y el BCI-Framework, lo que permite superar las restricciones asociadas con la captura de la actividad neuronal a través de electrodos en el cuero cabelludo. Este enfoque de bajo costo y portátil es especialmente valioso en entornos de investigación y aplicaciones prácticas, ya que facilita la recopilación de datos en diversas situaciones y contextos.

1.5.2 Adquisición y procesamiento en tiempo real

Se desarrollo un enfoque para el entrenamiento y la clasificación de señales EEG, que involucra la captura y el procesamiento en tiempo real. El sistema BCI incorporado se caracteriza por ser de bajo costo y portátil, a la vez que que aborda los desafíos fundamentales relacionados con el tiempo real y los costos computacionales inherentes a los sistemas BCI-MI basados en señales EEG.

Este enfoque se ha evaluado exhaustivamente utilizando bases de datos públicas y ha demostrado resultados competitivos en comparación con otras soluciones disponibles. La combinación de técnicas de ML y el enfoque integral en todas las fases del sistema, desde la captura hasta la clasificación, garantiza un rendimiento óptimo en términos de precisión y confiabilidad.

El enfoque propuesto también tiene en cuenta los desafíos económicos al abordar la cuestión de los costos computacionales y la necesidad de equipos especializados. Al ser altamente eficiente en términos de recursos, este sistema no solo logra una excelente velocidad de procesamiento, sino que también minimiza los requisitos técnicos y económicos. Esto se traduce en una solución accesible que se adapta a una variedad de contextos y entornos, lo que potencialmente amplía su aplicabilidad a áreas más allá de la investigación en laboratorios.

Además, se contribuye con una patente, registro de software, bases de datos de MI, memoria visoespacial de trabajo (WM) y estado de reposo, se encuentra disponible un repositorio en GitHub para que los experimentos puedan ser replicados.

1.6 Bases de datos electroencefalografía

En el presente estudio, se emplearon bases de datos específicas con el propósito de llevar a cabo pruebas y validaciones del trabajo propuesto en esta tesis. A continuación, se proporcionará una descripción detallada de las bases de datos utilizadas, incluyendo información relevante sobre los sujetos participantes, la configuración experimental y los parámetros de adquisición de datos. Esta descripción nos permitirá obtener una comprensión más completa del contexto en el cual se llevaron a cabo las pruebas.

1.6.1 Giga Motor Imagery - DBIII MI

Disponible públicamente en [Cho et al., 2017], contiene los registros de EEG de cincuenta y dos (52) sujetos utilizando una distribución de electrodos basada en el montaje de 64 canales según el sistema internacional 10-10, como se observa en la Figura 1-5.

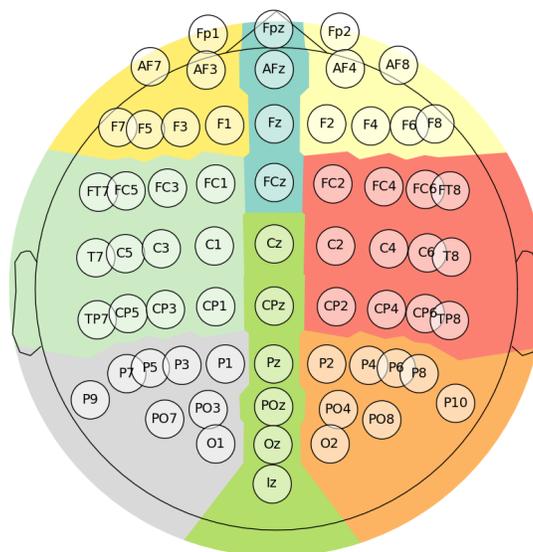


Figura 1-5. Mapa topográfico para representación del EEG de la base de datos GigaScience montaje estándar 10-10, 64 canales. Además, resalta en color las principales partes del cerebro (Frontal izquierda, Frontal, Frontal derecha, Central derecha, Posterior derecha, Posterior, Posterior izquierda, Central izquierda).

Cada prueba tuvo una duración de 7 segundos y se muestreó a una frecuencia de 512 Hz. Al inicio de la prueba, se mostró una cruz fija en una pantalla negra durante 2 segundos. Luego, apareció de manera aleatoria en la pantalla una instrucción de señal vinculada a una de las etiquetas MI [0, 1] durante 3 segundos. A cada sujeto se le solicitó imaginar el movimiento de sus dedos, comenzando desde el dedo índice hasta el dedo meñique, tocando cada uno con el pulgar, en la Figura 1-6 se puede observar un ensayo del experimento de MI. Posteriormente, se

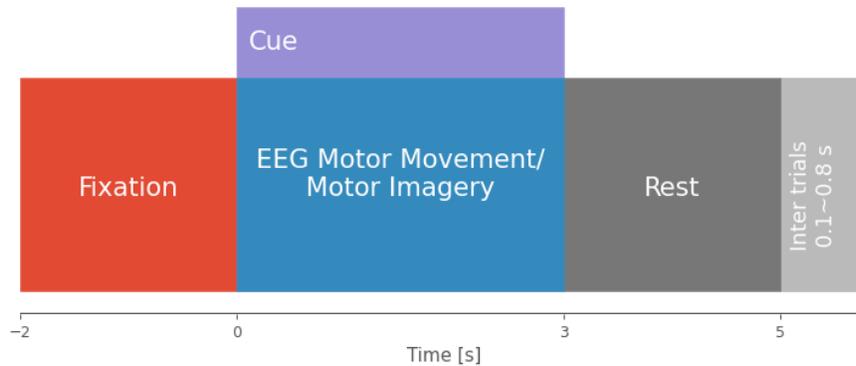


Figura 1-6. Un ensayo del experimento de MI, 4 clases (flechas) para la base de datos Giga Motor Imagery - DBIII MI.

mostró una pantalla en blanco al comienzo de un período de descanso, que varió de forma aleatoria entre 4,1 y 4,8 segundos. Este procedimiento se repitió más de 20 veces para completar una sola ejecución y se detuvo al finalizar para completar una prueba cognitiva escrita. Cada sujeto llevó a cabo entre 100 y 120 ensayos de las tareas etiquetadas, adquiridas en cinco o seis ejecuciones. Sumado a esto, se recopilaron 233 grabaciones de un solo estado de reposo, con una duración de 60 segundos, de cada sujeto.

1.6.2 BCI-Framework Unal

La adquisición de datos de EEG se llevó a cabo en diez (10) sujetos durante las pruebas del paradigma de MI, se les proporcionó instrucciones detalladas sobre las tareas y se les permitió practicar brevemente para familiarizarse con el procedimiento.

Al inicio de la prueba, se mostró una cruz fija en una pantalla negra durante 2 segundos. Luego, apareció de manera aleatoria en la pantalla una instrucción de señal vinculada a una de las etiquetas MI [0, 1] durante 3 segundos. A cada sujeto se le solicitó realizar el movimiento de sus manos, antes de iniciar con la

imaginación, en la Figura 1-6 se puede observar un ensayo del experimento de MI, cada prueba tuvo una duración de 7 segundos.

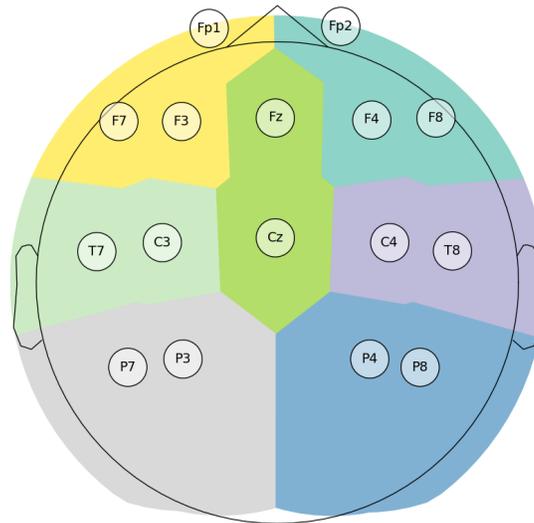


Figura 1-7. Mapa topográfico para representación del EEG de la base de datos BCI-Framework-Unal estándar 10-20, 16 canales. Además, resalta en color las principales partes del cerebro (Frontal izquierda, Frontal, Frontal derecha, Central derecha, Posterior derecha, Posterior, Posterior izquierda, Central izquierda).

El paradigma de MI utilizado se basó en la ampliamente utilizada técnica de señales de flecha, que ha demostrado ser efectiva para inducir y registrar respuestas cerebrales asociadas con la MI [Cho et al., 2017]. Cada tarea de MI se representó mediante una secuencia de flechas direccionales que indicaban el tipo de movimiento a imaginar, como la mano izquierda, la mano derecha, ambos pies o la lengua.

Para llevar a cabo la adquisición de datos, se utilizó un gorro de EEG estándar con sistema de colocación de electrodos 10-20, como se puede observar en la figura 1-7, asegurando una ubicación precisa y consistente de los electrodos en el cuero cabelludo. Se seleccionaron un total de 16 canales de EEG, que abarcaban áreas cerebrales relevantes para la tarea de MI. La señal de EEG se registró con una

frecuencia de muestreo de 1000 Hz para capturar de manera precisa las fluctuaciones temporales de la actividad cerebral.

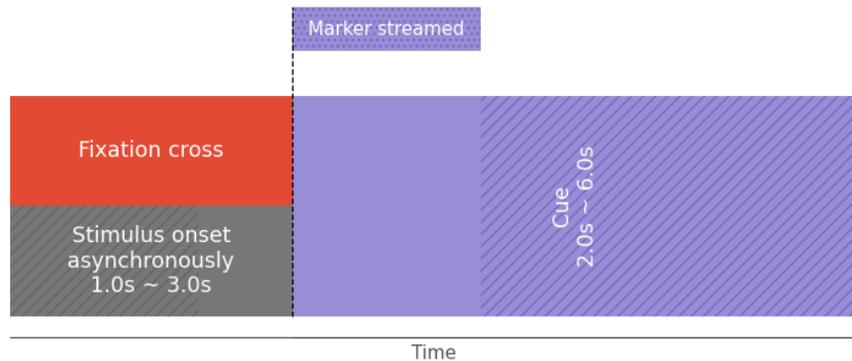


Figura 1-8. Paradigma experimental. Un ensayo del experimento de MI 4 clases (flechas) para la base de datos BCI-Framework-Unal.

1.7 Estructura de la tesis

En el segundo capítulo se presenta una metodología para representar y clasificar señales de EEG basada en imágenes a partir de conectividades, con el propósito de abordar desafíos relacionados con la variabilidad intersujeto y la interpretabilidad espacio-frecuencia en métodos DL. Además, se describe el protocolo de adquisición de datos utilizado para capturar las señales de EEG usado en los experimentos. Esta metodología emplea un marco de DL para mejorar la precisión y exactitud de las BCI-MI.

En el tercer capítulo, se presenta un enfoque innovador con una metodología para el entrenamiento y la clasificación de señales EEG en tiempo real. Este enfoque consiste en un sistema BCI distribuido, de bajo costo y portátil, diseñado para abordar los desafíos de tiempo real y los costos computacionales en sistemas BCI-MI basados en EEG. Esta metodología abarca cada una de las etapas necesarias para un sistema de bucle cerrado, e incorpora métodos de ML.

Finalmente, en el cuarto capítulo se concluye la tesis al resumir las observaciones finales, las principales contribuciones del trabajo presentado y las conclusiones. Además, se discuten posibles direcciones para futuros trabajos y se proporciona una lista de productos académicos y resultados asociados a esta tesis.

REPRESENTACIÓN Y CLASIFICACIÓN DE EEG BASADA EN IMÁGENES Y DL

En este capítulo se presenta una metodología de representación y clasificación de señales de EEG basada en imágenes, con el objetivo de afrontar desafíos relacionados con la variabilidad intersujeto y la interpretabilidad espacio-frecuencia en modelos DL. Utilizando la representación de canal de EEG en pares, se construye un topoplot en diferentes bandas de frecuencia, codificando relaciones no lineales relevantes a través de una similitud basada en la distribución Gaussiana. Además, se emplea un marco de aprendizaje profundo para mejorar la precisión y exactitud de las BCI-MI, y para lograr una mejor interpretación de los resultados se recurre a técnicas como CAMs y t-SNE. El conjunto de datos utilizado en la serie de experimentos incluye alta y baja densidad de canales, y proviene de Giga Motor Imagery - DBIII MI y BCI-Framework Unal. Dado que se usará una base de datos propia, se presenta el protocolo de adquisición y el sistema BCI mediante el cual se recopilaban los datos. Este sistema BCI-MI, basado en señales EEG, se caracteriza por su bajo costo y portabilidad. Con este capítulo se abordan los objetivos 1 y 2 que fueron presentados previamente en esta tesis.

2.1 Métodos

Los fundamentos matemáticos de los métodos utilizados en esta investigación son los siguientes: i) filtrado Laplaciano de superficie; ii) conectividad Funcional Gaussiana a partir de EEG, iii) flujo de conectividades en topogramas, iv) topogramas, v) CAMs y vi) redes neuronales.

2.1.1 Filtrado Laplaciano de Superficie

Se considera una señal de EEG $\mathbf{X} \in \mathbb{R}^{C \times T}$ con $C \in \mathbb{N}$ y $T \in \mathbb{N}$ como el número de canales y muestras de tiempo, respectivamente. El filtrado Laplaciano de superficie calcula la segunda derivada espacial del flujo subyacente de corriente eléctrica producido por la actividad cerebral en el electrodo $c \in C$ con respecto a los potenciales vecinos del cuero cabelludo $c' \in C, c \neq c'$ [Tobón-Henao et al., 2022]. Para ello, se emplean splines esféricos para proyectar las posiciones de los sensores del cuero cabelludo sobre una esfera, interpolando sus potenciales eléctricos reales iterativamente en las nuevas coordenadas mediante Polinomios de Legendre con los elementos:

$$p(c, c') = \frac{1}{4\pi} \sum_{n \in o} \frac{\alpha(2n+1)P_n(\cos \theta_{cc'})}{(n(n+1))^{\rho-\alpha}} \quad (2-1)$$

Donde P_n es el Polinomio de Legendre de orden n , $o \in \mathbb{N}$ es el orden del polinomio más alto considerado, $\rho \in \mathbb{R}^+$ es una constante de suavidad, $\cos \theta_{cc'} \equiv \frac{|\mathbf{e}_c - \mathbf{e}_{c'}|_2}{2}$ es la distancia del coseno entre un par de posiciones de electrodo, y $\mathbf{e}_c, \mathbf{e}_{c'} \in \mathbb{R}^3[-1, 1]$ son las posiciones de electrodo normalizadas a una esfera de radio unitario. La notación $|\cdot|_2$ representa la distancia de la norma ℓ_2 .

Por lo tanto, el filtrado Laplaciano de los datos de EEG, $\mathbf{X}_L \in \mathbb{R}^{C \times T}$, se calcula como se muestra en [Carvalhoes and De Barros, 2015]:

$$\mathbf{X}_L = \mathbf{H} \left(\mathbf{X}^\top \mathbf{G}_s^{-1} - \frac{\mathbf{X}^\top \mathbf{G}_s^{-1} \mathbf{1} \mathbf{G}_s^{-1}}{\mathbf{1} \mathbf{G}_s^{-1} \mathbf{1}} \right)^\top$$

donde $\mathbf{1} \in \mathbb{N}^{C \times C}$ es una matriz de unos, y $\mathbf{G}_s \equiv \mathbf{G} + \lambda \mathbf{I}$ es una versión suavizada de \mathbf{G} , donde $\mathbf{I} \in \mathbb{R}^{C \times C}$ es la matriz identidad, $\lambda \in \mathbb{R}[0, 1]$ es un parámetro de regularización; y \mathbf{G} y $\mathbf{H} \in \mathbb{R}^{C \times C}$ son las matrices de ponderación que contienen elementos expresados en términos del parámetro α en la Ecuación (2-1), respectivamente, de la siguiente manera:

$$\alpha = \begin{cases} 1, & p(c, c') = g(c, c') \\ -1, & p(c, c') = h(c, c'). \end{cases}$$

2.1.2 Conectividad Funcional Gaussiana (GFC) a partir de EEG

Definida de la siguiente manera:

Consideremos una colección de registros de EEG de múltiples canales, denotada por $\mathbf{X}_n \in \mathbb{R}^{C \times T}$, $y_r \in \mathbb{R}[0, 1]$: para $n = 1, \dots, N$. Aquí, C es el número de canales, T es el número de muestras en cada registro de EEG, N es el número de ensayos y y_r es el conjunto de etiquetas de probabilidad de clase asumido como binario sin pérdida de generalidad, y asignado al ensayo r -ésimo.

A su vez, consideremos dos canales de EEG de un ensayo dado, \mathbf{x}_c y $\mathbf{x}_{c'}$, donde \mathbf{x}_c y $\mathbf{x}_{c'}$ son elementos de la matriz \mathbf{X} . Aquí, c y c' son índices que varían de 1 a C , el número de canales de EEG. La correlación entre pares entre los dos canales de EEG se puede calcular de la siguiente manera:

$$\hat{\rho}_L(\mathbf{x}_c, \mathbf{x}_{c'}) = \frac{1}{T} \langle \mathbf{x}_c, \mathbf{x}_{c'} \rangle_2, \quad (2-2)$$

Donde $\langle \cdot, \cdot \rangle_2$ representa el producto interno. Las relaciones lineales en pares en la Ecuación (2-2) permiten calcular las conexiones funcionales entre los canales de EEG como una representación de grafo no dirigido.

Sin embargo, podemos capturar de manera efectiva las interacciones no lineales entre varios canales mediante el uso de un kernel estacionario generalizado que transforma el espacio de entrada en un Espacio de Hilbert de Núcleo Reproductivo (RKHS, por sus siglas en inglés). Este enfoque nos permite obtener una representación más precisa de la actividad neuronal subyacente. Además, el uso de un kernel estacionario garantiza que la técnica propuesta puede capturar eficazmente las dinámicas temporales de las señales de EEG.

Dadas estas consideraciones, el kernel Gaussiano es ampliamente preferido en análisis de patrones y aprendizaje automático. Puede aproximar cualquier función y ofrece propiedades matemáticamente manejables [Géron, 2022]. Por lo tanto, es una excelente elección para calcular conexiones en pares como una medida de Conectividad Funcional Basada en Gaussiana (GFC) a partir de la función del kernel. $\kappa_G : \mathbb{R}^T \times \mathbb{R}^T \rightarrow [0, 1]$, es definida como [García-Murillo et al., 2023]:

$$\kappa_G(\mathbf{x}_c - \mathbf{x}_{c'}; \gamma) = \exp\left(-\frac{1}{2}\gamma\|\mathbf{x}_c - \mathbf{x}_{c'}\|_2^2\right), \quad (2-3)$$

Donde $\|\cdot\|_2$ denota el operador de norma 2 y $\gamma \in \mathbb{R}^+$ representa un parámetro de escala. La inclusión de una función Gaussiana en la Ecuación (2-3) facilita el cálculo preciso y eficiente de las interacciones no lineales entre \mathbf{x}_c y $\mathbf{x}_{c'}$.

Definido de la siguiente manera:

$$kG\left(c - x_{rn}^{c't}; \sigma\right) = \exp\left(-\left\|x_{rn}^{ct} - x_{rn}^{c't}\right\|_2^2 / 2\sigma^2\right), \quad (2-4)$$

Donde: x_{rn}^{ct} pertenece a \mathbb{R}^T , y $\left(X_{rn}^t [x_{rn}^{ct}]^T\right)$ denota cada canal filtrado c de la prueba r dentro de la banda de frecuencia n , en la ventana de tiempo t , y σ pertenece a

\mathfrak{R}^+ y es el hiperparámetro para la longitud de escala. La notación $|\cdot|_q$ representa la norma q -ésima.

El kernel Gaussiano es preferido en la clasificación de patrones debido a su capacidad de aproximación universal y su facilidad de manejo matemático [Géron, 2022]. Para implementar la extracción de una sola prueba, calculamos la matriz de conectividad funcional \hat{P}_n como una distribución basada en kernel de espectro cruzado. Por lo tanto, los elementos de la matriz de conectividad funcional se extraen de la prueba r , como se muestra a continuación:

$$\hat{P}_{cc'}(r; u^{cc'}, k_G) = \sum_{r \in \Omega} \sum_{t \in \Delta} u_{nt}^{ct} k_G(x_{nt}^{ct} - x_{nt}^{c't}; \sigma), \quad (2-5)$$

Donde $x_{nt}^{ct}, x_{nt}^{c't}$ pertenecen a X_{rn}^{ct} , $\tilde{P}_{cc'}(r; u^{cc'}, k_G)$ pertenece a \hat{P}_r y $u_{cc'}$, donde $u_{cc'}$ pertenece a $\mathbb{R}^{|\Omega|+|\Delta|}$, contiene el valor estimado del peso de relevancia en t , en la división de tiempo-frecuencia n , codificando el par de dependencia no dirigido entre los canales. Utilizando la representación de distribución espectral basada en kernel de una sola prueba en la ecuación (2-5), los autores proponen extraer la conectividad funcional dispersa, con el objetivo de encontrar patrones de actividad cerebral discriminatorios e interpretables. Específicamente, se realiza una correspondencia de normas de bases dispersas después de concatenar vectorialmente los pesos de relevancia en [García-Murillo et al., 2021].

$$v = [u^{cc'}],$$

De la siguiente manera:

$$v^* = \arg \min \mathbb{E} \left\{ \left\| \sum_{c < c'} \tilde{P}_{c, c'}(r; \mathbf{u}^{cc'}, k_G(\cdot, \sigma)) - y_r \right\|_2^2 : \forall_r, c, c' \right\} + \alpha_1 \|v\|_1 + \alpha_2 \|v\|_2 \quad (2-6)$$

2.1.3 Flujo de conectividades en topogramas

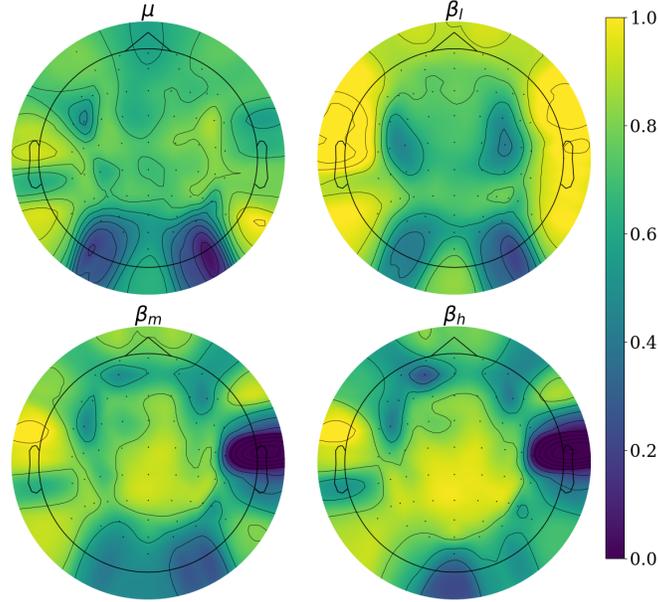


Figura 2-1. Topograma de flujo de conectividades, del sujeto 43 con mejor rendimiento en sus cuatro bandas de frecuencia.

Las conectividades funcionales calculadas anteriormente, se transforman en un flujo de conectividades (un arreglo 4D), donde $X \in \mathbb{R}^{T \times C \times \Delta \times \Omega}$, donde T es el número de muestras, C es el número de canales, Δ es la ventana de tiempo y Ω son las cuatro bandas de frecuencias definidas, se realiza una normalización por T .

Este flujo de conectividades normalizado, se convierten en una interpolación topográfica bidimensional $\mathbb{R}^c \rightarrow \mathbb{R}^{W \times H}$ para preservar su interpretación espacial, donde \mathbb{R}^c es la suma de las conectividades de un canal respecto a los demás canales, mapeando en una vista circular bidimensional cada conjunto de características de prueba extraído. Como resultado, para obtener los datos 2D etiquetados $\{Y_n^z \in \mathbb{R}^{W \times H}, \lambda_n : n \in N\}$, donde Y_n^z es una función $t - f$ de dos dominios de las características de la matriz, denominada topograma, extraída de cada z -ésimo conjunto. Es de destacar que el triplete $z = \{r, \Delta_t, \Delta_f\}$ con $z \in Z$

indexa un topograma estimado para cada principio de dominio incluido $r \in R$ en el segmento de tiempo $\Delta t \in T$ [Collazos-Huertas et al., 2021a].

2.1.4 Topograma

Para la construcción del topograma (imágenes de flujo de conectividades de 40x40 píxeles, representado en la figura 2-1, donde se muestra un topograma por cada banda de frecuencia estudiada y se evidencia las zonas de interacción cerebral), se utiliza la función «viz.plot_topomap» de MNE, que internamente utiliza la función «scipy.interpolate.LinearNDInterpolator» disponible en <https://n9.cl/scipy>, la cual implementa la interpolación lineal en N dimensiones utilizando la triangulación de Delaunay. La ecuación utilizada para la interpolación lineal es la siguiente:

Dado un punto de consulta P , se encuentra el triángulo de la triangulación de Delaunay [Lee and Schachter, 1980] que contiene a P . Luego, se realiza la interpolación lineal dentro de este triángulo utilizando los valores conocidos en los vértices del triángulo. Tomado de: `scipy.interpolate.LinearNDInterpolator`

La fórmula general para la interpolación lineal en un triángulo se puede expresar como:

$$V = (1 - u - v) \cdot V_0 + u \cdot V_1 + v \cdot V_2$$

Donde:

- V es el valor interpolado en el punto de consulta P .
- V_0, V_1 y V_2 son los valores conocidos en los vértices del triángulo.

- u y v son las coordenadas baricéntricas del punto de consulta P dentro del triángulo. Estas coordenadas representan los pesos relativos de los vértices del triángulo en la interpolación.

El algoritmo “*LinearNDInterpolator*” utiliza esta fórmula para realizar la interpolación lineal en cada uno de los triángulos de la triangulación de Delaunay y calcular los valores interpolados en los puntos de consulta.

Es importante tener en cuenta que “*LinearNDInterpolator*” realiza una interpolación lineal, asumiendo una variación lineal entre los valores conocidos en los vértices del triángulo. Si se desea una interpolación más precisa, se pueden utilizar otros métodos de interpolación disponibles en `scipy`, como “`scipy.interpolate.CloughTocher2DInterpolator`” o “`scipy.interpolate.griddata`”, que proporcionan interpolaciones más suaves o basadas en funciones. Tomado de: `scipy.interpolate.LinearNDInterpolator`

2.1.5 Mapas de Activación de Clase (CAMs)

Los CAMs [Torralba et al., 2015] son una técnica de interpretabilidad que resalta las regiones de una imagen que más contribuyen a la predicción del modelo dado un dato de entrada. La intuición detrás de los CAMs es construir las regiones destacadas para una clase específica c utilizando la combinación lineal de activaciones o mapas de características de una capa específica l de la red neuronal convolucional, como se muestra en la Ecuación 2-7.

$$\mathbf{S}_l^c = \Lambda\left(\sum_{d \in D_l} \beta_l^{cd} \odot \mathbf{A}_l^{cd}\right) \in \mathbb{R}^{H \times W} \quad (2-7)$$

donde $\Lambda : \mathbb{R}^{H_l \times W_l} \rightarrow \mathbb{R}^{H \times W}$ es el operador de upsampling, $\mathbf{A}_l^{cd} \in \mathbb{R}^{H_l \times W_l}$ representa el mapa de activación de la capa l para el filtro d , β_l^{cd} representa la matriz de pesos

asociada al filtro d , que depende de $y^c \in \mathbb{R}$, el puntaje devuelto por el modelo para la clase c , y \odot representa la operación de producto elemento a elemento. La tarea de los métodos CAMs es encontrar los valores de β_l^{cd} , y aquí radica la diferencia entre los diferentes métodos CAMs [Zhou et al., 2016, Wang et al., 2020, Jiang et al., 2021].

- Grad-CAM [Selvaraju et al., 2017]

$$[\beta_l^{cd}]_{i,j} = \frac{1}{H_l W_l} \sum_{n \in H_j, m \in W_l} \frac{\partial y^c}{\partial \mathbf{A}_{nm}^{cd}} \forall i, j$$

- Grad-CAM ++ [Chattopadhyay et al., 2018]

$$[\beta_l^{cd}]_{i,j} = \sum_{n \in H_j, m \in W_l} \alpha_{nm}^{cd} ReLU\left(\frac{\partial y^c}{\partial \mathbf{A}_{nm}^d}\right) \forall i, j$$

$$\alpha_{nm}^{cd} = \frac{\frac{\partial^2 y^c}{(\partial \mathbf{A}_{nm}^d)^2}}{2 \frac{\partial^2 y^c}{(\partial \mathbf{A}_{nm}^d)^2} + \sum_a \sum_b \mathbf{A}_{ab}^d \frac{\partial^3 y^c}{(\partial \mathbf{A}_{nm}^d)^3}}$$

- Score-CAM [Wang et al., 2020]

$$[\beta_l^{cd}]_{i,j} = \frac{\exp(\xi_d^c)}{\sum_n \exp(\xi_n^c)} \forall i, j$$

$$\xi_d^c = f^c(\mathbf{I} \circ \mathbf{A}^d) - f^c(\mathbf{I})$$

Donde f^c es una función que devuelve el puntaje y^c del modelo para la clase c , y \mathbf{I} es la entrada del modelo. Además, Score-CAM aplica una función $ReLU$ al CAM calculado antes de usar el operador de upsampling.

- Layer-CAM [Jiang et al., 2021]

$$[\beta_l^{cd}]_{i,j} = ReLU\left(\frac{\partial y^c}{\partial \mathbf{A}_{ij}^d}\right)$$

Layer-CAM también aplica una función $ReLU$ al mapa de activación de clase calculado antes de usar el operador de upsampling.

Como se presenta, los métodos CAMs están diseñados para trabajar con modelos de clasificación. Para adaptarlos a modelos de segmentación semántica, seguimos un enfoque similar a [Vinogradova et al., 2020], utilizando la Ecuación 2-8.

$$y^c = \frac{\mathbf{1}^\top (\hat{\mathbf{M}}^c \odot \mathbf{M}^c) \mathbf{1}}{\mathbf{1}^\top \mathbf{M}^c \mathbf{1}} \quad (2-8)$$

Específicamente, se utilizó Grad-CAM++ [Chattopadhyay et al., 2018] debido a su capacidad mejorada para localizar y visualizar con precisión las regiones de interés, así como su mejora en la interpretabilidad. Grad-CAM++ supera las limitaciones de Grad-CAM, Score-CAM y Layer-CAM en términos de calidad y precisión al visualizar y localizar estas regiones. Esto es especialmente significativo para la visualización de características en bandas de frecuencia relevantes en la tarea de MI. Su uso proporcionó una mejor comprensión de las relaciones entre las características extraídas y las regiones de interés específicas, permitiendo una interpretación más precisa de los resultados.

2.1.6 Red neuronal WDCNN

Para la codificación de datos en el contexto de BCI basada en MI, se han empleado modelos DL como EEGNet [Lawhern et al., 2018], ShallowConvNet [Qayyum et al., 2022], DeepConvNet [Li and Song, 2023]. Estos modelos muestran un potencial significativo para abordar desafíos relacionados con la variabilidad en BCI-MI basados en señales de EEG. DeepConvNet destaca en la identificación de patrones espaciales y temporales, pero requiere una cantidad considerable de datos para evitar el sobreajuste. Por otro lado, EEGNet y ShallowConvNet, aunque utilizan capas convolucionales para extraer patrones, enfrentan desafíos en la captura de dependencias temporales a largo plazo y en la identificación de patrones complejos, respectivamente.

Sin embargo para nuestro trabajo se utilizó la red neuronal profunda convolucional (WDCNN), la cual se basa en una modificación de la red propuesta en [Collazos-Huertas et al., 2021a]. Este modelo se centra en identificar los patrones neurales espaciales más influyentes para mejorar el rendimiento de clasificadores en tareas de MI. Para lidiar con la variabilidad en las señales de EEG, se utiliza una representación bidominio tiempo-frecuencia que combina la transformada continua de wavelet CWT y patrones espaciales comunes CSP. Esta red mantiene la interpretabilidad de las respuestas neuronales y presenta un rendimiento de clasificación adecuado, además de revelar información comprensible sobre los electrodos con mayor relevancia espacial, tal como se describe en [Collazos-Huertas et al., 2021a]. WDCNN se empleó para la clasificación de las imágenes, mientras que para realizar la comparación con el estado del arte, se utilizó la conocida red neuronal EEGNet [Lawhern et al., 2018]. A continuación, se muestra la arquitectura de WDCNN y los parámetros utilizados en la tabla 2-1 y la figura 2-2.

La Red Neuronal WDCNN, es una red neuronal amplia y profunda de arquitectura CNN, a la cual se le ingresa las características de los topogramas adquiridos por la conectividad (40x40 píxeles) en escala de grises para cada banda de interés, brindando información relevante de la actividad antes y durante la actividad de MI, donde la red esta compuesta de dos capas convolucionales permitiendo la detección de la actividad espacial analizada, con una cantidad de neuronas de 400, 800 y 1200, realizando una validación cruzada del 80-20 %, con una regularización l1 y l2 en una rejilla de busca de [1-e1, 1-e2 y 2-e2] y en búsqueda de métricas de acierto y kappa.

# Layer	Layer	Output Shape	Param #
4	InputLayer	40x40x1	0
4	Conv2D	40x40x 2	52
4	BatchNormalization	40x40x2	8
4	MaxPooling2D	20x20x2	0
4	Conv2D	20x20x2	38
4	BatchNormalization	20x20x2	8
4	MaxPooling2D	10x10x2	0
1	Concatenate	10x10x8	0
1	Flatten	800	0
1	Dropout	800	0
1	BatchNormalization	800	3200
1	Dense	400	320400
1	Dropout	400	0
1	BatchNormalization	400	1600
1	Dense	2	802

Cuadro 2-1. Arquitectura WDCNN.

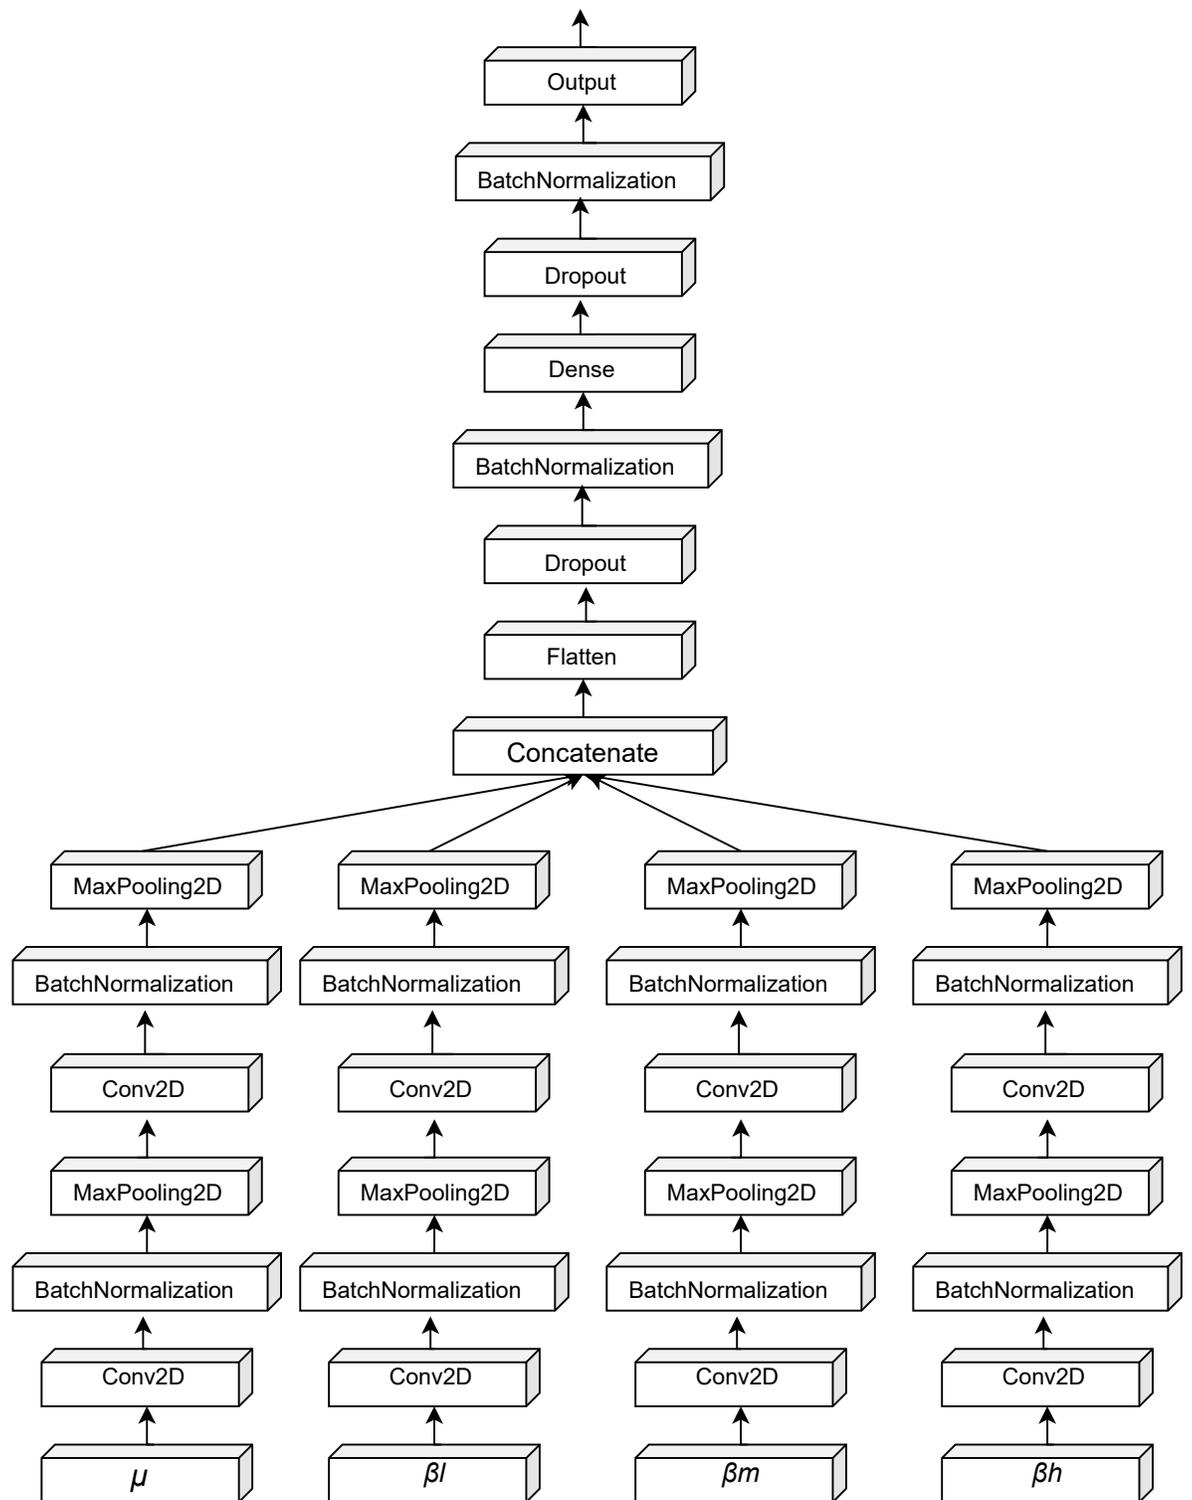


Figura 2-2. Esquema principal de la red WDCNN.

2.2 Marco Experimental

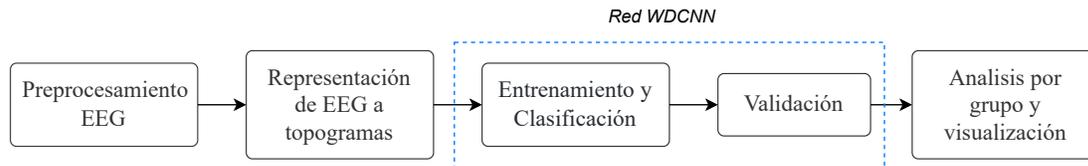


Figura 2-3. Esquema principal del marco experimental

Nuestro marco experimental, como se observa en la Figura 2-3 se compone de los siguientes elementos: i) Preprocesamiento de EEG para Giga Motor Imagery - DBIII MI y BCI-Framework Unal, ii) transformación de la señal de EEG a topogramas, iii) Entrenamiento, clasificación de dos clases (mano izquierda y mano derecha) y validación con WDCNN, iv) Análisis a nivel de grupo para la base de datos Giga Motor Imagery - DBIII MI.

2.2.1 Preprocesamiento de EEG

Comenzamos cargando las grabaciones de los sujetos de la base de datos Giga Motor Imagery - DBIII MI, utilizando un módulo personalizado de carga de bases de datos disponible en <https://github.com/UN-GCPDS/python-gcpds.databases>, y para la base de datos BCI-Framework Unal, se cargaron directamente desde el Github del GCPDS. Cada ensayo de la serie temporal se somete a un filtro Laplaciano para mejorar la calidad y especificidad de los datos de MI. Este filtro desempeña un papel crucial al reducir interferencias y ruido no deseado, lo que facilita la obtención de resultados precisos en el análisis de ritmos cerebrales. Adicionalmente, para los 10 sujetos de BCI-Framework Unal, se implementó una función para descartar pruebas que presentaban amplitudes atípicas o artefactos evidentes. Esto ayudó a garantizar la calidad de los datos y a eliminar posibles interferencias en el análisis. Posteriormente, se extrae el intervalo de tiempo

correspondiente a la tarea de MI, con una duración de 2.5 segundos, de las señales EEG correspondientes a la tarea de MI. Estos segmentos se centran en la información relevante para la clasificación.

A continuación, se realiza una caracterización utilizando un banco de filtros que opera en las siguientes bandas de frecuencia: μ (8-12 Hz), β_l (12-15 Hz), β_m (15-20 Hz) y β_h (18-40 Hz).

Es importante tener en cuenta que, dado nuestro enfoque exclusivo en el segmento de tiempo de MI, asumimos que la señal exhibe estacionariedad. Nuestro procesamiento se enfoca en explorar cuatro ritmos cerebrales distintos que abarcan el rango de 8 a 40 Hz, incluyendo ondas alfa y tres variaciones de ondas beta. Por otro lado, la actividad de la banda alfa μ (8-13 Hz) se ve suprimida debido a la estimulación sensorial y el movimiento. Está modulada por la atención, la memoria de trabajo y las tareas cognitivas, lo que la convierte en un posible indicador de funciones de control motor de alto nivel.

Además, nuestro procesamiento abarca tres categorías de ondas beta: ondas beta bajas β_l (12-15 Hz), comúnmente conocidas como “beta uno”, asociadas principalmente con enfoque concentrado e introvertido. En segundo lugar, las ondas beta de rango medio β_m (15-20 Hz), o “beta dos”, se correlacionan con mayor energía, ansiedad y rendimiento. Por último, las ondas beta altas β_h (18-40 Hz), o “beta tres”, están vinculadas a un estrés significativo, ansiedad, paranoia, elevada energía y aumento de la alerta [García-Murillo et al., 2023].

En conclusión, nuestros esfuerzos de preprocesamiento y caracterización de la señal EEG nos permiten extraer información pertinente sobre los ritmos cerebrales asociados con la tarea de MI, lo que nos proporciona una comprensión mejorada de los procesos cognitivos y motores subyacentes.

2.2.2 Transformación de la señal de EEG a topogramas

A la señal resultante de cada una de las bandas de frecuencia se les aplicó la conectividad funcional Gaussiana (GFC). Se calculó el flujo de conectividades y se realizó la normalización por ensayos, a partir de las matrices de conectividad de cada una de las bandas de frecuencia y transformándolas en topogramas, teniendo así, topogramas por cada banda de frecuencia en resolución de 40x40 píxeles y en escala de grises.

2.2.3 Entrenamiento y clasificación con WDCNN

Se utilizó la red WDCNN, con el número de entradas igual al número de bandas de frecuencia. La red extrae características a través de dos capas de convolución. Las características extraídas de cada entrada se concatenan y se pasan a través de una capa densa para la clasificación.

Para el caso de los sujetos de la base de datos Giga Motor Imagery - DBIII MI, dividimos los ensayos dentro de los datos de cada sujeto utilizando un esquema de validación cruzada estándar de 5 pliegues, con una división 80-20. Esto implicó mezclar los datos y tomar el 80% para el entrenamiento (conjunto de entrenamiento), dejando el 20% restante para validar los modelos entrenados (conjunto de prueba). Este proceso se repitió cinco veces para asegurar una evaluación robusta. Cabe mencionar que, en el caso de la base de datos BCI-Framework, debido a la falta de datos suficientes, no se formó un conjunto de datos de validación independiente.

En este caso, se utilizó un tamaño de lote igual al número de muestras de entrenamiento. La tasa de aprendizaje se ajustó para disminuir de manera polinómica entre $0.5e-2$ y $0.5e-5$. El número de épocas se estableció en 200. Se empleó GridSearchCV para ajustar los parámetros de regularización $l1$ y $l2$,

utilizando una cuadrícula de valores [1e-1, 1e-2, 2e-3]. Se probaron diferentes números de neuronas en la capa densa: 400, 800, 1200. Además, se consideró un porcentaje de datos de validación dentro del conjunto de entrenamiento, que varió desde 0 hasta 0.1.

2.2.4 Análisis a nivel de grupo para la base de datos Giga Motor Imagery - DBIII MI

Construimos una matriz de puntuación que contiene tantas filas como sujetos en el conjunto de datos, 50 para Giga, y seis columnas que incluyen la precisión, y kappa junto con sus respectivas desviaciones estándar. Posteriormente, utilizando la matriz de puntuación y el algoritmo de agrupamiento k-means [Géron, 2022], con un número fijo de tres particiones, como se ajusta comúnmente [Velasquez-Martinez et al., 2020a, Tobón-Henao et al., 2022], entrenamos un modelo para agrupar los resultados de los sujetos en en uno de tres grupos: mejores, intermedios y peores sujetos en función de los modelos de referencia CSP [Cho et al., 2017] y EEGNet [Lawhern et al., 2018]. A continuación, ordenamos a cada sujeto en función de un vector proyectado obtenido a partir del primer componente del conocido algoritmo de Análisis de Componentes Principales (PCA) aplicado a la matriz de puntuación. Luego, utilizando el k-means entrenado, los sujetos analizados por nuestro método GFC+WDCNN fueron agrupados utilizando la matriz de puntuación, como se realizó en [García-Murillo et al., 2023]. Estos se organizan en orden descendente según su rendimiento relativo a los modelos de referencia CSP y EEGNet. El objetivo es comparar y verificar cómo cambian los sujetos entre los grupos basados en CSP, EEGNet y nuestro método propuesto GFC+WDCNN, denominado así por la conectividad funcional Gaussiana y la red WDCNN utilizada, para obtener información valiosa sobre la efectividad de nuestro enfoque. Si se observan cambios significativos en la distribución de sujetos entre los grupos, indicaría que GFC+WDCNN proporciona resultados diferentes y potencialmente mejorados en comparación con CSP y EEGNet.

2.3 Resultados y discusión

En los resultados se presentarán: i) los resultados del análisis por grupos, representados en gráficas y tablas que muestran los aciertos con pérdidas y ganancias de cada método evaluado para la base de datos Giga Motor Imagery - DBIII MI; ii) el protocolo de adquisición de datos y las herramientas con las que fue tomada la base de datos BCI-Framework, y iii) El análisis de rendimiento por sujeto para el conjunto de datos BCI-Framework Unal, e iv) interpretabilidad espacio frecuencia.

2.3.1 Resultados del Análisis de Grupo para la base de datos Giga Motor Imagery - DBIII MI

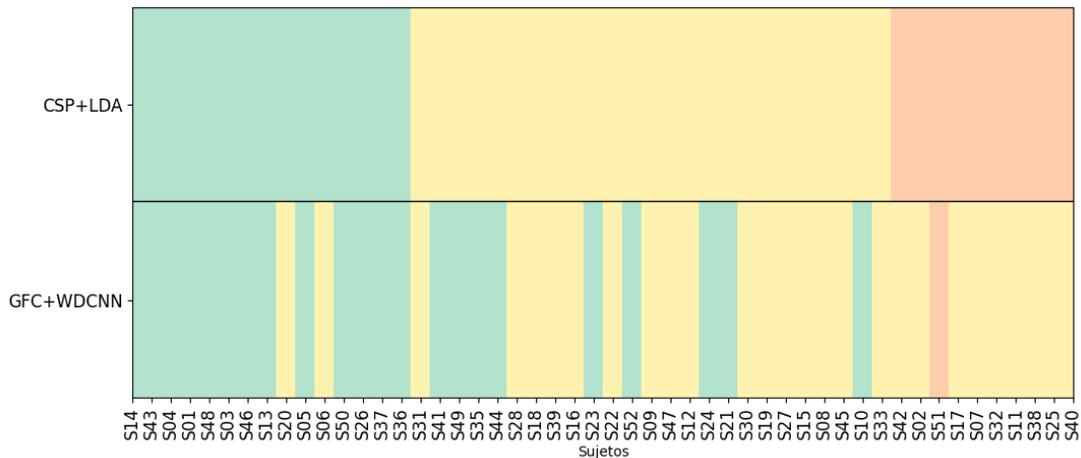


Figura 2-4. Una comparación del método de vanguardia CSP+LDA y el método propuesto WDCNN+GFC para el agrupamiento descendente de sujetos, resaltando la variabilidad de cada uno.

En la Figura 2-4 se ilustra la pertenencia de los sujetos a los grupos y el impacto del método GFC+WDCNN en la clasificación de grupos. La fila superior muestra los sujetos organizados según el método de vanguardia CSP+LDA, mientras que la fila

inferior muestra cómo cada sujeto cambia o mantiene su grupo basado en los resultados de GFC+WDCNN. Por ejemplo, en el grupo rojo de la fila CSP+LDA, comenzando desde el sujeto S42, al examinar la nueva agrupación basada en GFC+WDCNN para el mismo subconjunto de sujetos, es evidente que un total de nueve de cada diez sujetos mejoraron significativamente su rendimiento, pasando al grupo amarillo, mientras que solo uno permaneció en el grupo rojo. Además, nueve sujetos experimentaron un aumento sustancial en el rendimiento y fueron promovidos al mejor grupo (verde), lo que demuestra la efectividad del marco propuesto. Además, los sujetos originalmente en el mejor grupo mantuvieron su estado, excepto dos sujetos, lo que indica que los sujetos con mejor rendimiento tienen menos probabilidades de mejorar. Así, nuestro enfoque logra una mejor discriminación de la MI en comparación con CSP+LDA, especialmente para sujetos con un rendimiento pobre o moderado, lo que es crucial ya que resalta la capacidad del modelo para manejar casos desafiantes.

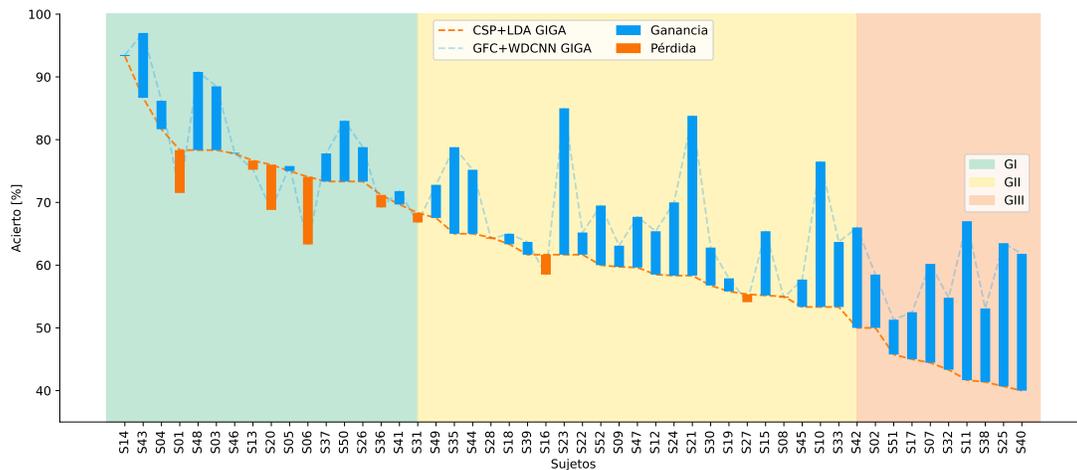


Figura 2-5. Se muestran los resultados de rendimiento específicos del sujeto. Se muestran las precisiones de CSP+LDA y GFC+WDCNN, con los sujetos ordenados en orden descendente según su rendimiento utilizando CSP+LDA. Las barras azules representan la mejora en el rendimiento utilizando GFC+WDCNN, mientras que las barras naranjas indican una disminución en el rendimiento. El fondo indica la pertenencia al grupo (mejor - GI, intermedio - GII y peor - GIII). La división de los grupos de rendimiento se realizó utilizando el algoritmo K-means.

Método	Grupo	Acierto (%)	Ganancia (%)
CSP+LDA	GI	77.82	.
	GII	59.86	.
	GIII	44.23	.
GFC+WDCNN	GI	79.82	2.56
	GII	67.18	12.22
	GIII	58.87	33.11

Cuadro 2-2. Análisis de rendimiento por grupos para CSP+LDA y GFC+WDCNN. Se puede observar que el método propuesto tuvo ganancia en todos los grupos, resaltando que su mayor ganancia fue en GIII.

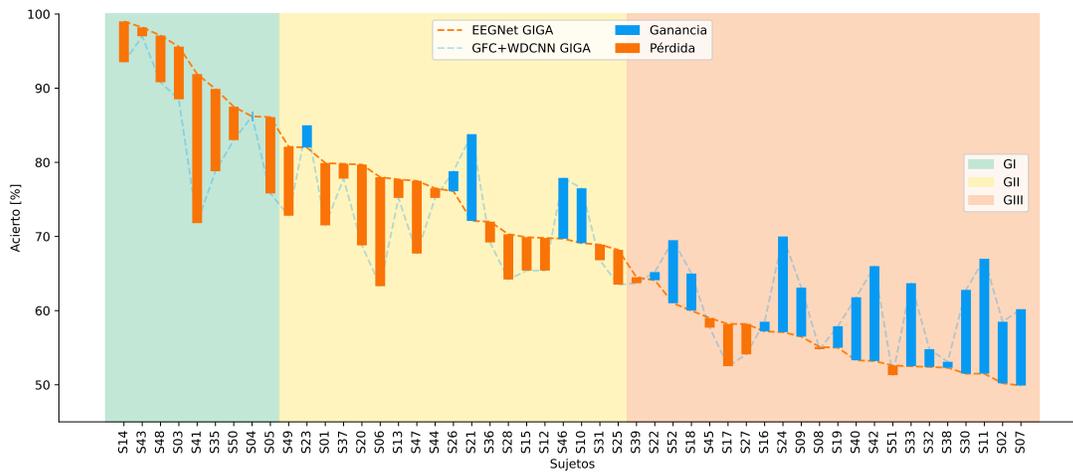


Figura 2-6. Se muestran los resultados de rendimiento específicos del sujeto. Se presentan las precisiones de EEGnet y GFC+WDCNN, con los sujetos ordenados en orden descendente según su rendimiento utilizando EEGnet. Las barras azules representan la mejora en el rendimiento utilizando GFC+WDCNN, mientras que las barras naranjas indican una disminución en el rendimiento. El fondo indica la pertenencia al grupo (mejor - GI, intermedio - GII y peor - GIII). La división de los grupos de rendimiento se realizó utilizando el algoritmo K-means. Precisión promedio de EEGnet: 69.0 %, Precisión promedio de GFC+WDCNN: 69.31 %.

En la figura 2-5 se puede observar la comparación del método propuesto GFC+WDCNN y el método de vanguardia CSP+LDA, donde la distribución de

Método	Grupo	Acierto (%)	Ganancia (%)
EEGnet	GI	92.38	.
	GII	74.7	.
	GIII	55.70	.
GFC+WDCNN	GI	85.04	.
	GII	72.04	.
	GIII	60.50	8.64

Cuadro 2-3. Análisis de rendimiento por grupos para EEGNet y el GFC+WDCNN, se puede observar que solo se obtuvo ganancia en el GIII.

grupos se basa en la precisión de CSP+LDA y se observa una notable mejora en el grupo de sujetos con precisión regular, en amarillo, y en el grupo 3 en rojo, donde pasamos de tener 10 sujetos con baja precisión a solo uno, en lo que respecta a la precisión del grupo de mejores sujetos, en verde, se redujo la precisión en dos sujetos, lo que destaca que el método propuesto GFC+WDCNN ayuda a los sujetos con mayor variabilidad.

La distribución de grupos según la precisión se observa en la Figura 2-5, la línea punteada representa la precisión del método de vanguardia CSP+LDA y la línea roja representa la precisión del método propuesto GFC+WDCNN y en el caso de la Figura 2-6, la línea punteada representa la precisión del método de vanguardia EEGNet. Las barras muestran las mejoras de precisión para cada grupo; Mejora del GI:2.56 %, mejora del GII:12.2 %, mejora del GIII: 33.1 %, con el modelo de comparación EEGNet solo se obtuvo una de ganancia para el GIII: 8.64 % grupo con bajo acierto. Ver el cuadro 2-3, y 2-2 donde se muestra la comparación de los métodos del estado del arte y el método propuesta, esta distribuido en acierto por grupos y su respectiva ganancia.

Dado que el método WDCNN+GFC tiene como objetivo abordar los desafíos de la interacción de señales EEG mediante la extracción y codificación de características relevantes en la tarea de MI utilizando la representación espacial-frecuencial de

conectividad en 2D, se observa una mejora en el rendimiento para la mayoría de los sujetos como se observa en la 2-2, especialmente para aquellos con un rendimiento más bajo, como se observa en el Cuadro 2-3, donde solo se obtuvo ganancia en el GIII, los puntos en las demás casillas indica que no se obtuvo ganancia, ya que estas representaciones proporcionan más información sobre la tarea de MI.

Sin embargo, es importante destacar que, en ambas comparaciones CSP+LDA y EEGNet, se apreció que algunos sujetos vieron disminuida su tasa de acierto, independientemente del grupo al que pertenecieran. Esta disminución puede deberse a que la aplicación de estos métodos para reducir la SNR a todos los sujetos, independientemente de su nivel individual de ruido, podría resultar perjudicial para aquellos con un EEG limpio [Tobón-Henao et al., 2022].

La Figura 2-7 y el Cuadro 2-4 presentan un resumen de los resultados comparativos de los tres métodos analizados en este trabajo: CSP+LDA, EEGNet y el método propuesto WDCNN. Estos resultados se basan en la evaluación realizada en la base de datos Giga Motor Imagery - DBIII.

Método	Acierto	Kappa
CSP+LDA [Cho et al., 2017]	67.46 ± 13.17	31 ± 19
EEGNet [Lawhern et al., 2018]	69.0 ± 14.6	38 ± 29.1
GFC+WDCNN (propuesto)	69.3 ± 11.1	38 ± 23

Cuadro 2-4. Comparación de resultados obtenidos, en los métodos probados con la base de datos Giga Motor Imagery - DBIII MI y nuestro método propuesto GFC+WDCNN con la media del acierto ± desviación estándar y kappa.

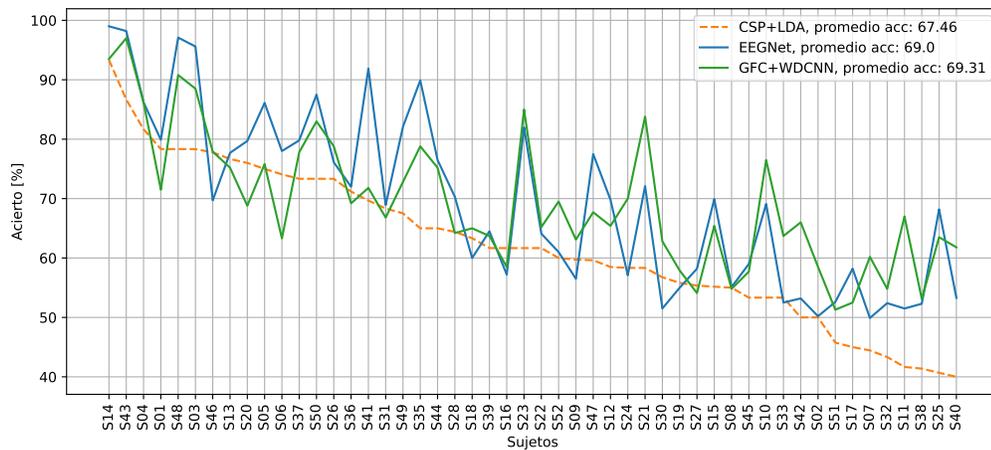


Figura 2-7. Gráfica de comparación en acierto para todos los sujetos de la base de datos Giga Motor Imagery - DBIII MI de los 3 métodos estudiados CSP+LDA, EEGNet y el método propuesto.

2.3.2 Protocolo de adquisición de datos y las herramientas



Figura 2-8. Sistema de distribución de OpenBCI y Raspberry pi 4.

A continuación, nos centraremos en la descripción del protocolo de adquisición de datos utilizado y en las herramientas destacadas: OpenBCI y BCI Framework.

OpenBCI

OpenBCI es una plataforma de interfaz cerebro-computadora de código abierto, disponible en <https://openbci.com> creada por Joel Murphy y Conor Russomanno, después de una exitosa campaña de Kickstarter a finales de 2013.

Las placas OpenBCI se pueden utilizar para medir y registrar la actividad eléctrica producida por el cerebro (EEG), los músculos (EMG) y el corazón (EKG), y son compatibles con electrodos EEG estándar. Las placas OpenBCI se pueden utilizar con la interfaz gráfica de usuario (GUI) de código abierto de OpenBCI, o se pueden integrar con otras herramientas de procesamiento de señales EEG de código abierto.

BCI-Framework

BCI -Framework es una herramienta de código abierto para la adquisición de señales EEG/EMG/ECG, desarrollada para funcionar con la placa Cyton de OpenBCI. El núcleo principal de este software se basa en OpenBCI-Stream, una biblioteca diseñada para manejar todas las características de bajo nivel del hardware y ampliar las capacidades del hardware con bibliotecas de programación de alto nivel.

Se encuentra disponible un paradigma de adquisición y transmisión de datos distribuido opcional para ser implementado. Este enfoque estabiliza la tasa de muestreo en sistemas de adquisición que no funcionan en tiempo real y consiste en delegar el manejo de la placa a un entorno dedicado y transmitir los datos en tiempo real. Las principales características disponibles en esta aplicación incluyen la posibilidad de escribir visualizaciones personalizadas para series de tiempo sin procesar o procesadas, y diseñar experimentos neurofisiológicos personalizados.

BCI-Framework incluye una interfaz gráfica de usuario (GUI) con un conjunto de procesos computacionales individuales (distribuidos o en una sola máquina), que alimentan una visualización, sirven para entregar estímulos, manejan la adquisición y el almacenamiento de datos, o transmiten datos previos (análisis fuera de línea). También cuenta con un entorno de desarrollo integrado y un conjunto de bibliotecas que el usuario puede implementar para crear su funcionalidad específica Disponible en <https://bci-framework.readthedocs.io/> Desarrollamos un protocolo de adquisición de datos para el sistema BCI-MI basado en EEG, el cual se compone de OpenBCI y el BCI-Framework. Para implementar dicho protocolo, es esencial establecer la conexión entre todos los sistemas que lo componen y configurar el sistema de adquisición. Los componentes incluyen:

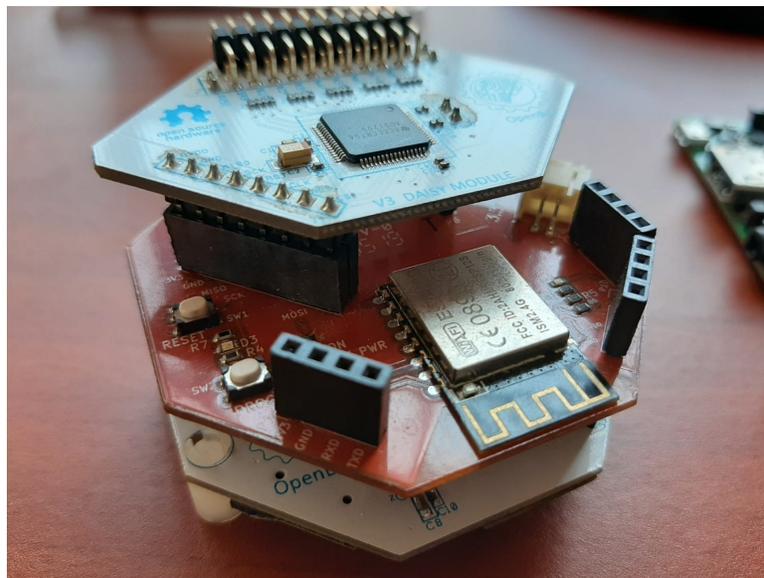


Figura 2-9. Sistema de distribución de OpenBCI ensamblado.

- Sistema de distribución: Se compone de una Raspberry Pi 4, que establece un punto de acceso wifi para la conexión entre todos los sistemas como se observa en la Figura 2-8 y en la Figura ?? el sistema ensamblado.
- Sistema de adquisición: Está compuesto por la tarjeta OpenBCI Cyton, su módulo Wi-Fi y un gorro de EEG con una distribución de electrodos 10-20,

en la Figura 2-10, se observan todos los materiales necesarios para la adquisición.

- Validación de impedancias: Esta se realiza antes de proceder con la adquisición de datos y cuando todos los sistemas están conectados y listos para su uso.



Figura 2-10. Sistemas y materiales necesarios para la adquisición de los datos.

- Sistema de presentación de estímulos: se compone por el computador donde se van a presentar los estímulos al sujeto, debe estar conectado a la red wifi OpenBCIStream generada por el sistema de distribución y conectada con la IP del sistema de adquisición de datos.
- Colocar el gorro al sujeto y conectarlo a la placa Cyton.

Colocación de electrodos

La adquisición de datos se lleva a cabo utilizando el gorro de EEG con el montaje estándar 10-20, y se implementa un protocolo de limpieza específico para los sujetos

y el gorro en sí, con el objetivo de prevenir interferencias provenientes del cuero cabelludo, como el sudor o la grasa, que podrían afectar la impedancia y la calidad de la señal registrada. Este proceso de limpieza es crucial para garantizar una señal lo más clara y libre de ruido posible, lo que a su vez contribuye a la precisión y fiabilidad de los resultados obtenidos.

Gorro de electrodos para EEG con montaje 10-20

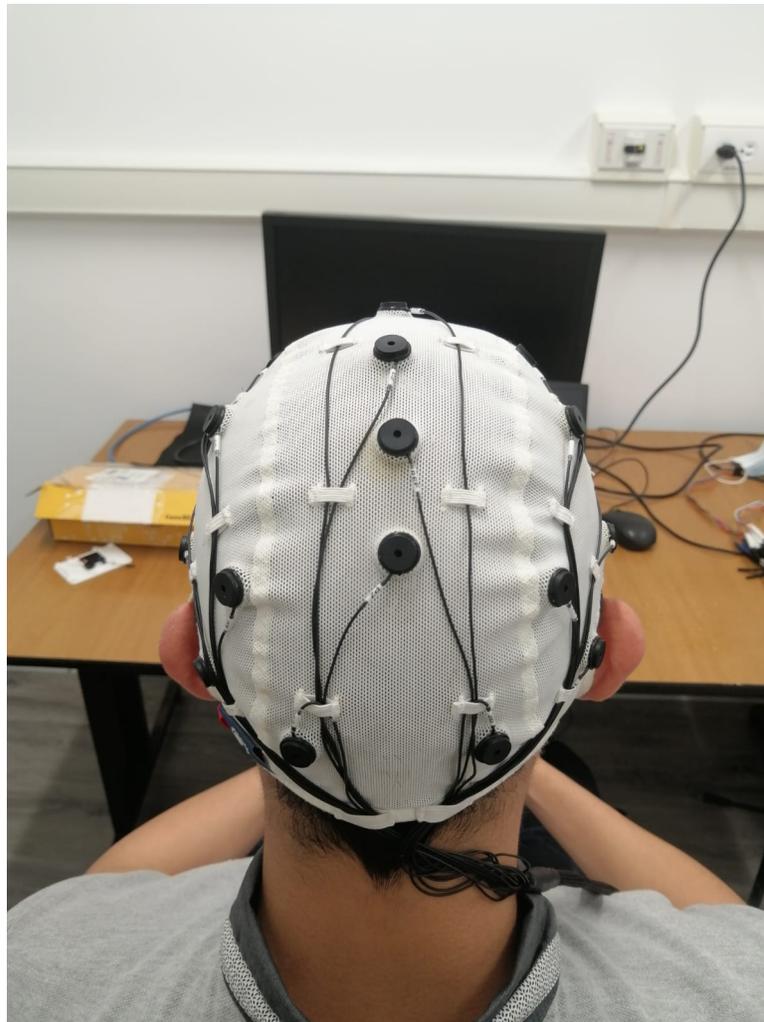


Figura 2-11. Vista posterior del gorro de electrodos.

- Se lava el cabello del sujeto con shampoo sin sal o jabon de coco, para realizar una limpieza profunda del mismo, se seca con una toalla y luego con el secador de cabello o de manera natural.
- Se coloca el gorro en el sujeto de manera que el electrodo de referencia Cz quede en la mitad de la mitad de la cabeza, se usa como referencia las orejas y la nariz vista desde la parte superior. Ver Fig.2-11.

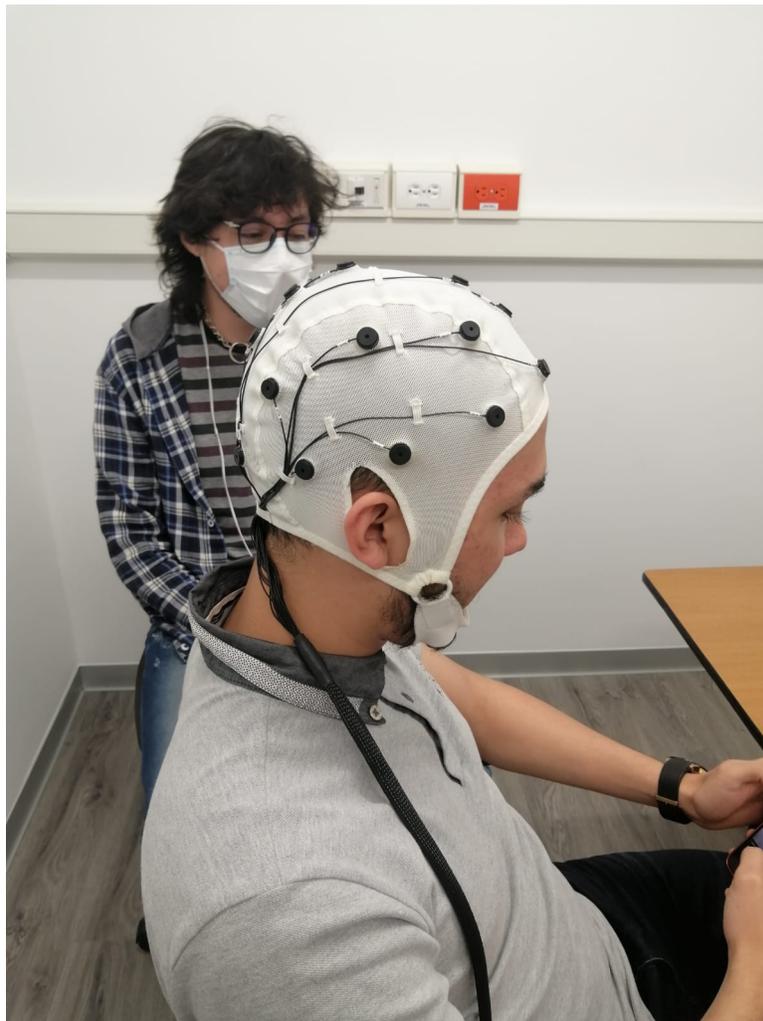


Figura 2-12. Vista lateral del gorro de electrodos.

- Después de estar acomodado el gorro en la cabeza del sujeto, se aplica con una jeringa el gel “*Electro – gel*” de manera que quedé abundante entre el

electrodo y el cuero cabelludo, pero debe fijarse en que no se combine el gel de un electrodo con otro.

- Después de tener puestos todos los electrodos, y verificar la medición de impedancias, se procede a tomar las señales de EEG.
- Para la limpieza de los electrodos del gorro se realiza con un cepillo y alcohol o un copito quitando el exceso de gel y se deja secar.

Impedancia del electrodo

El factor de la impedancia en la interfaz entre el electrodo y la piel es un aspecto clave en las mediciones de biopotenciales, debido a su potencial impacto significativo en la calidad de la señal. Es aconsejable mantener la impedancia en la piel del electrodo en un nivel mínimo para asegurar niveles de amplificación reducidos, incluso inferiores a la resolución del conversor analógico-digital (ADC). En nuestro método, que se basa en OpenBCI, se emplea el ADC ADS1299 para las mediciones de biopotenciales, el cual proporciona un procedimiento para medir la impedancia a través de la utilización de fuentes de corriente de desconexión [Cardona-Álvarez et al., 2023].

La medición de impedancias en el *ADCADS1299* se realizó inyectando una corriente alterna de $6nA$ a $31,2Hz$ y se analiza la señal resultante como una señal *AC*, como ejemplo se medirá la impedancia en las N entradas (como se usa para montajes *EEG* de referencia única). la placa Cyton se conecta un potenciómetro de $10K$ entre la entrada N (inferior) del canal 1 y el *SRB2* (inferior), el pin *BIAS* no se utiliza en este ejemplo con el potenciómetro, pero más adelante se usara este pin ya que se replicara en la cabeza de un sujeto de prueba. Ahora necesitamos el voltaje *RMS*, hay muchas fórmulas para obtener este valor, incluso usando el estándar, se utilizará uno basado en el *VPP*:

$$V_{RMS} = \frac{V_{pp}}{2\sqrt{2}} \sim std(V) \quad (2-9)$$

Nuestro V_{pp} se puede calcular como máximo - mínimo. En algunos enfoques, es muy común encontrar el uso de desviación estándar en lugar de RMS .

$$Z = \frac{V_{RMS}}{I_{RMS}} \quad (2-10)$$

Sabemos que el $ADS1299$ inyecta $6nA$ de corriente alterna, entonces:

$$I_{RMS} = \frac{6nA}{\sqrt{2}} \quad (2-11)$$

Considerando que tenemos μV en una fase de V :

$$Z = \frac{\mu V_{RMS} * 10^{-6} * \sqrt{2}}{6 * 10^{-9}} \quad (2-12)$$

La placa Cyton tiene resistencias de $2,2K\Omega$ en serie con cada electrodo, por lo que se debe eliminar éste valor para obtener el real, se despeja la impedancia del electrodo-sujeto, se fija un rango de impedancia entre $1 - 10K\Omega$ para asegurar que la amplitud de la señal de EEG o EOG no cambie.

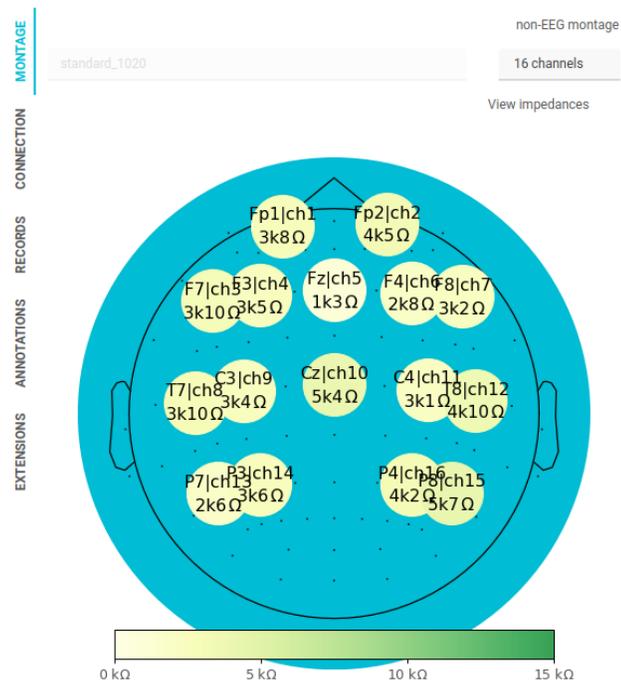


Figura 2-13. Interfaz gráfica para visualizador de impedancias en tiempo real. Se utiliza una gorro EEG de OpenBCI con 16 canales dentro de nuestro paradigma de MI.

- Medir impedancias: Como se mencionó anteriormente, en este protocolo se estableció un rango de $1\text{k}\Omega$ a $15\text{k}\Omega$ (ver Fig.2-13). Si las impedancias no se encuentran dentro de este rango, el electrodo aparecerá de color rojo. En tal caso, es necesario ajustar el gorro o aplicar más gel, asegurándose de que no exista conexión entre los electrodos para garantizar la correcta adquisición de datos.

La adquisición de las señales de EEG se realizaron mientras los sujetos realizaban el paradigma de imaginación motora.

Imaginación motora

Este paradigma de BCI que se basa en señales de estímulo incluía hasta cuatro distintas tareas de MI . Estas se representaban mediante una serie de señales de

estímulo (en forma de flechas) y estaban separadas por un periodo de descanso no sincronizado. En este modelo, se empleó una flecha que podía señalar hacia la izquierda, la derecha, arriba o abajo, lo cual es un método que ha sido ampliamente utilizado en [Choi, 2013],[Llanos et al., 2013].

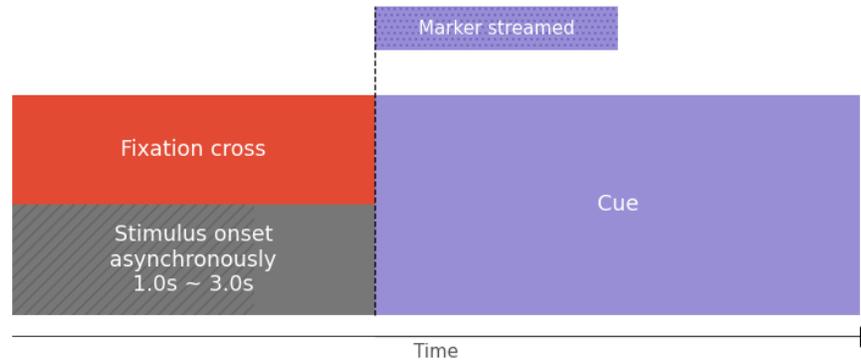


Figura 2-14. Línea de tiempo para la ejecución del paradigma imaginación motora 4 clases.

Parámetros de configuración

Antes de iniciar cualquier prueba utilizando el paradigma de MI, es fundamental establecer correctamente los parámetros de configuración. Al ajustar estos parámetros de manera adecuada, se garantiza que la prueba se adapte a las necesidades específicas del experimento y del sujeto, y que los resultados obtenidos sean precisos y relevantes:

Señales: Se pueden seleccionar hasta 4 clases, representadas por una flecha. Las 4 clases están activas de forma predeterminada.

Ensayos por clase: Este parámetro define cuántas pruebas por clase contendrá la ejecución. El rango va de 1 a 100, siendo 10 el valor predeterminado. Para este experimento, se utilizaron 40 ensayos por clase.

Duración del estímulo: Este parámetro define el tiempo en milisegundos durante el cual se mostrará el indicador en pantalla. El rango va de 2000 a 6000 ms, siendo

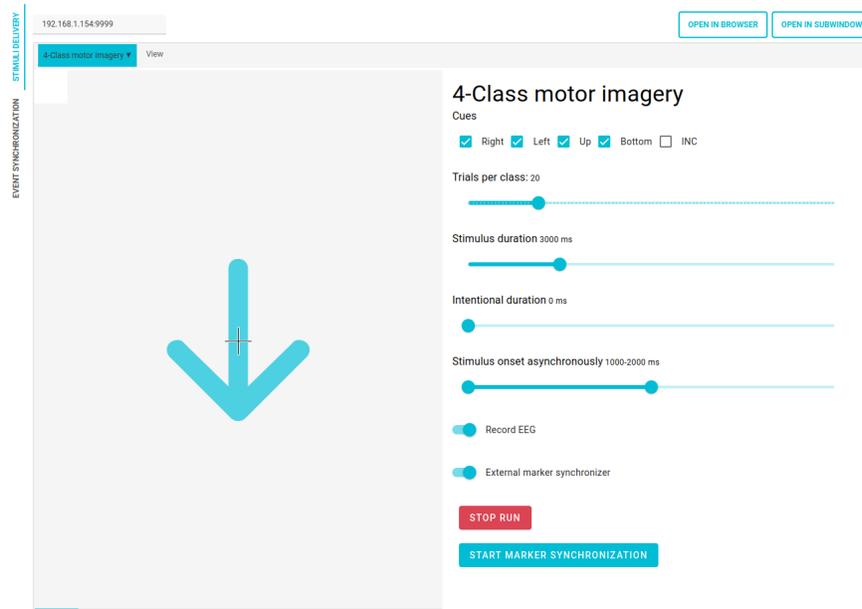


Figura 2-15. Paradigma de MI, 4 clases con flechas.

4000 el valor predeterminado. En este experimento, se utilizaron 6000 ms para la duración del estímulo.

Inicio del estímulo de forma asíncrona: Este parámetro se utiliza para evitar un tiempo fijo entre ensayos. El rango es de 1000 a 3000 ms, siendo (2000-3000) el valor predeterminado. Esto implica que para cada prueba se genera un número aleatorio (con distribución uniforme) dentro de este rango y se usa como intervalo entre estímulos. Para este experimento, se utilizó un rango de 1000 a 1500 ms.

2.3.3 Análisis de rendimiento por sujeto base de datos BCI-Framework Unal

Se llevó a cabo un análisis exhaustivo del rendimiento del método propuesto para cada sujeto individual en el conjunto de datos. Este análisis tenía como objetivo evaluar cómo el método se comportaba en cada caso particular y si había variaciones significativas entre los sujetos.

Los resultados del análisis se presentaron en la figura 2-16, donde se observa claramente que el método propuesto logra una mejora significativa del 14.15 % en el rendimiento en comparación con enfoques anteriores o métodos estándar utilizados para el mismo conjunto de datos.

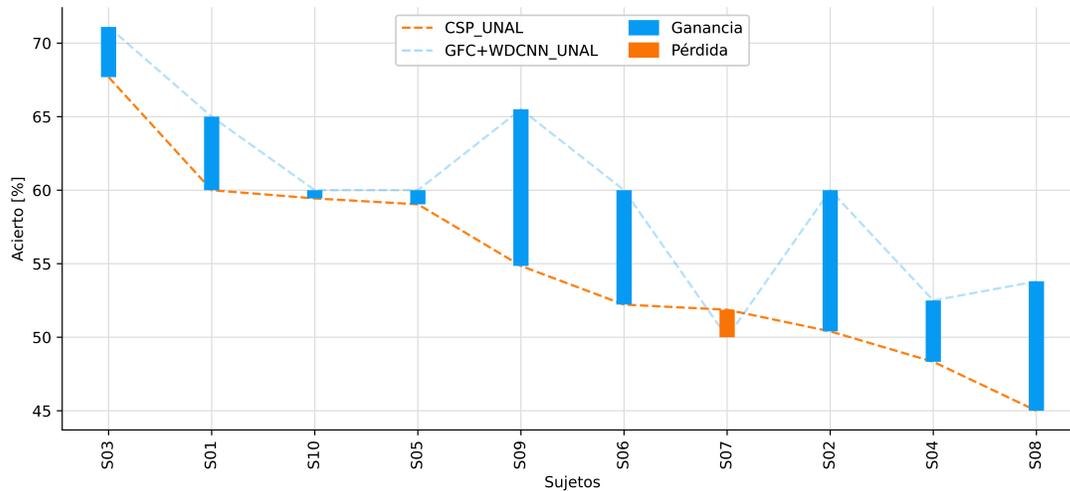


Figura 2-16. Gráfica de comparación de acierto entre el método del estado del arte CSP y el método propuesto.

Es importante destacar que esta ganancia en el rendimiento es consistente en la mayoría de sujetos evaluados en la base de datos BCI-Framework Unal. Esta consistencia respalda la robustez y eficacia del método propuesto, lo que sugiere que puede ser aplicado de manera efectiva en una amplia variedad de casos y sujetos.

Sin embargo, al realizar la comparación con el método EEGNet, en la Figura 2-17, observamos una pérdida del 11.40 % en el rendimiento de los sujetos utilizando nuestro método. Esta disminución en el rendimiento podría ser el resultado de diversas consideraciones.

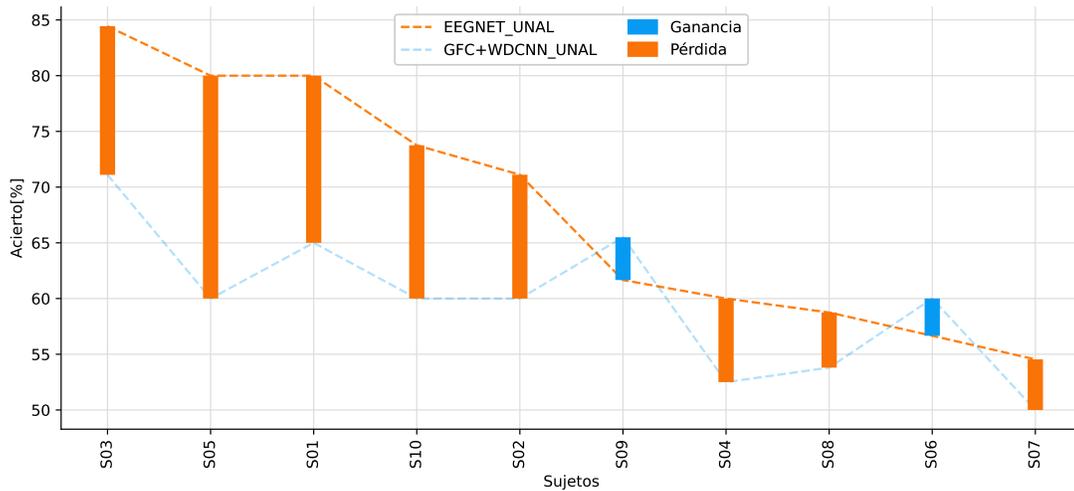


Figura 2-17. Gráfica de comparación de acierto entre el método del estado del arte EEGNet y el método propuesto.

Una de las posibles razones es que la aplicación de métodos generales para reducir el ruido, como el utilizado en nuestro enfoque, puede no ser óptimo para todos los sujetos. Cada individuo puede presentar variaciones únicas en la calidad de las señales EEG debido a diferencias anatómicas y funcionales en su actividad cerebral. Por lo tanto, la aplicación de un filtro de reducción de ruido de manera uniforme para todos los sujetos podría no ser adecuado para aquellos con un EEG inicialmente limpio [Tobón-Henao et al., 2022].

Además, el método EEGNet utilizado para la comparación puede tener características diferentes y, por lo tanto, funcionar mejor en ciertos tipos de señales EEG. Cada método tiene sus ventajas y desventajas, y puede ser más adecuado para ciertas condiciones o tipos específicos de datos. En este sentido, la pérdida de rendimiento que observamos puede deberse a una mejor adaptación de EEGNet a las características particulares de la base de datos BCI-Framework Unal. Esta comparación con EEGNet nos proporciona información sobre las áreas de mejora de nuestro enfoque.

2.4 Interpretabilidad espacio-frecuencia

Se aplicaron técnicas de visualización como GradCAM++ y Incrustación Estocástica de Vecinos t-Distribuidos (t-SNE) para facilitar la interpretabilidad de los datos identificando las regiones cerebrales relevantes en la clasificación y proyectar los datos en un espacio de menor dimensión.

A continuación se mostraran los resultados de visualización, i) Mapas de conectividad para dos sujetos específicos con diferentes niveles de rendimiento para la base de datos Giga Motor Imagery - DBIII MI; ii) Análisis con t-SNE para estos mismos sujetos en la base de datos Giga Motor Imagery - DBIII MI, iii) Mapas de conectividad para dos sujetos de la base de datos BCI-Framework Unal y iv) Análisis con t-SNE para estos mismos sujetos en la base de datos BCI-Framework Unal.

2.4.1 Mapas de conectividad de base de datos Giga Motor Imagery - DBIII MI

Para establecer una base fisiológica para las habilidades motoras, analizamos las respuestas neurales del cerebro desencadenadas por paradigmas de MI a través de patrones de conectividad después de aplicar filtros de señal en bandas de frecuencia relevantes: μ (8-12 Hz), β_l (12-15 Hz), β_m (15-20 Hz) y β_h (18-40 Hz), así como el filtrado Laplaciano y la reducción del tiempo de la señal a 2.5 segundos correspondientes al tiempo de MI. Luego, se calculó el flujo de conectividad que contribuye a la discriminación entre tareas etiquetadas relacionadas con la MI.

Por lo tanto, el análisis de las respuestas neurales se llevó a cabo en sujetos individuales basándonos en su rendimiento, como se observa en la Figura 2-18, junto con un examen de las bandas de frecuencia de interés, como se puede apreciar en la Figura 2-20, y en la Figura 2-19 . Utilizamos un módulo de

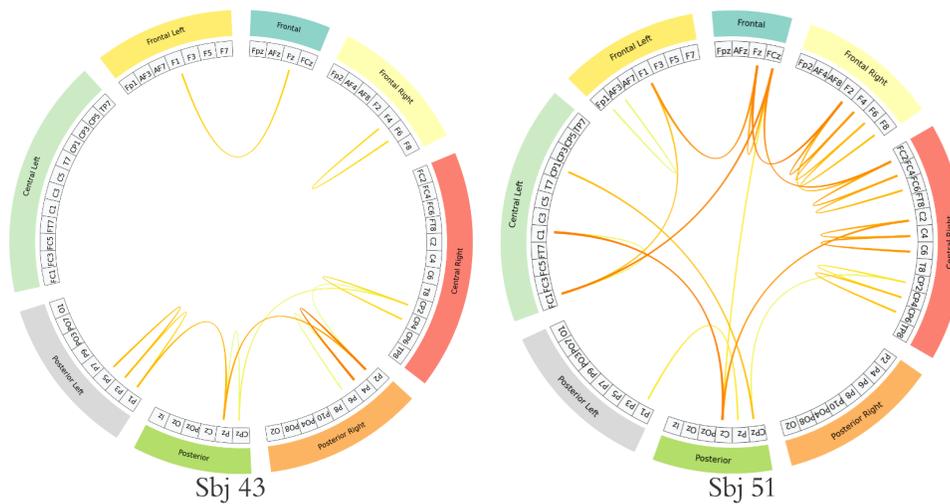


Figura 2-18. Se estiman mapas de conectividad para los sujetos con mejor rendimiento (lado izquierdo) y peor rendimiento (lado derecho). Las correlaciones más fuertes entre los nodos se representan mediante bordes más oscuros que conectan dos canales de EEG. En el exterior de cada gráfico, se muestran las regiones Central Derecha, Central Izquierda, Frontal, Posterior y Posterior Izquierda del cerebro, coloreadas de manera diferente para mejorar la interpretación espacial.

visualización personalizado disponible en <https://github.com/UN-GCPDS/python-gcpds.visualizations> con este propósito.

Como se observa en la Figura 2-19, cada sujeto en sus bandas de frecuencia estudiadas genera diferentes conjuntos de conexiones en términos de nodos y enlaces relevantes, lo que puede dar lugar a cambios específicos en la integración y segregación de la red, afectando así la precisión del sistema. En consecuencia, los grafos de conectividad estimados para el grupo de sujetos con mayores habilidades exhiben amplitudes de respuestas evocadas altas y con conexiones interemisferiales entre las zonas Frontal, Central y Sensorimotor involucradas en la tarea de MI.

En el caso del sujeto con un bajo rendimiento, como se muestra en la Figura 2-20, se observa un conjunto de conexiones que cubren toda la superficie del cuero cabelludo, es decir, sus conexiones más relevantes están en los electrodos vecinos.

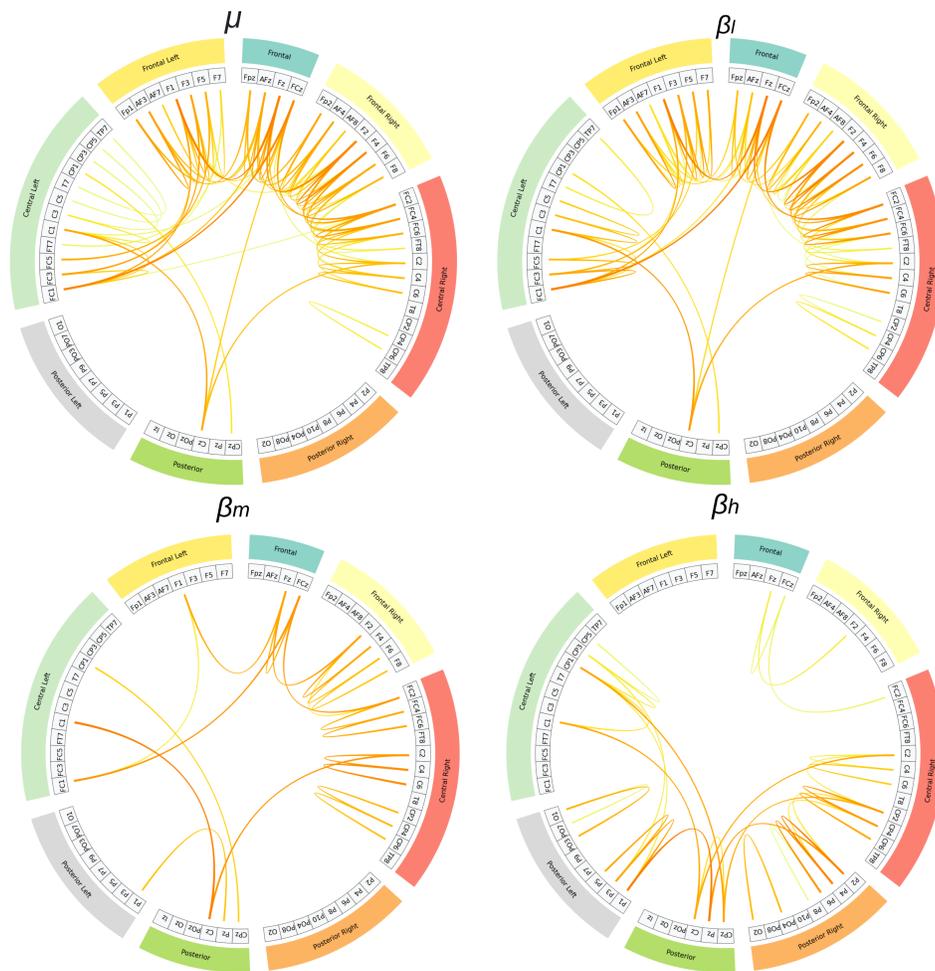


Figura 2-20. Representación gráfica de la Conectividad Funcional Gaussiana estimada en el cerebro a lo largo de las cuatro bandas de frecuencia estudiadas, sujeto 51.

también haya patrones relacionados con artefactos espurios en el proceso de adquisición de datos o asociados con activaciones irregulares en el paradigma de MI.

2.4.2 Análisis con t-SNE de base de datos Giga Motor Imagery - DBIII MI

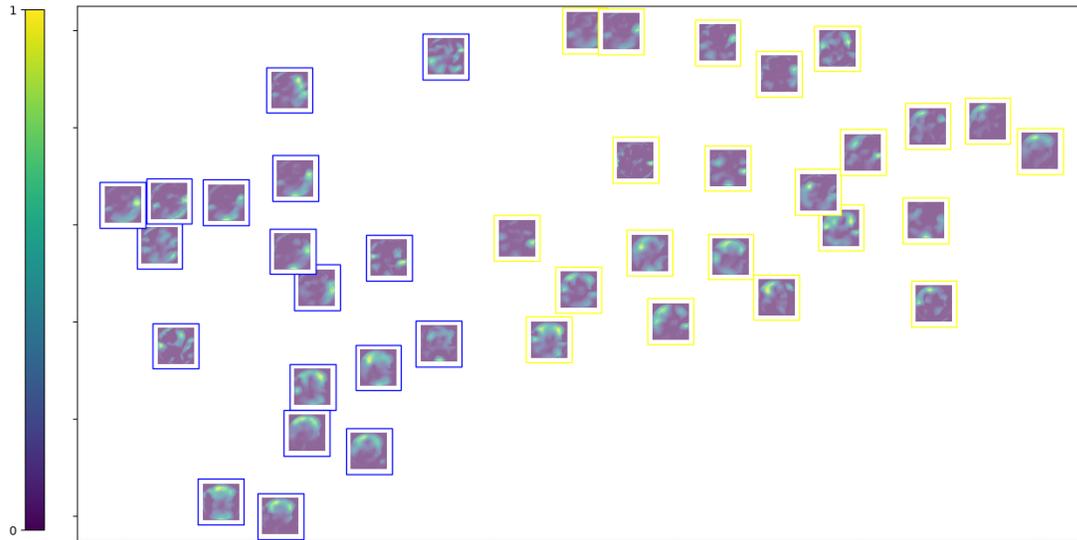


Figura 2-21. Proyección 2D de t-SNE de los Mapas de Activación de Clase (CAMs) para el sujeto 43 (sujeto con la mayor precisión), donde se puede observar la separabilidad de las dos clases estudiadas. El color morado corresponde a los CAMs de la clase 0, y el color amarillo corresponde a los CAMs de la clase 1.

Se realizó el análisis con t-SNE de los sujetos 43 y 51, en la Figura 2-21 y Figura 2-22 con mejor y peor rendimiento respectivamente. El análisis se llevó a cabo utilizando el conjunto de validación, que corresponde al 20% del conjunto de datos. Los resultados proporcionaron información valiosa sobre el proceso de aprendizaje de la red neuronal en relación a las características relevantes de MI.

La clara separación entre las categorías en el espacio de características, visible en la gráfica 2-21 en comparación con la gráfica 2-22, sugiere que la red neuronal ha sido capaz de aprender y extraer con éxito las propiedades que diferencian las dos clases. Esta marcada distinción entre las instancias de MI indica que el proceso de entrenamiento ha sido efectivo y que la red neuronal ha logrado detectar patrones

importantes y discernibles en los datos. Estos resultados respaldan la capacidad del modelo para realizar clasificaciones precisas.

Estos resultados no solo respaldan la capacidad del modelo para realizar clasificaciones precisas, sino que también arrojan luz sobre los rasgos clave que caracterizan el fenómeno de MI, por ejemplo, en la Figura 2-18 se observan los grafos de conectividad para los sujetos con mejor y peor rendimiento evaluado, sin embargo el sujeto con las habilidades más altas exhiben amplitudes de respuesta evocada altas y densamente distribuidas en las áreas Frontal, Central y Sensorimotor involucradas en la tarea de MI, en la Figura del flujo de conectividades 2-1 se observa en las bandas de frecuencia β_m (15-20 Hz) se correlacionan con mayor energía y rendimiento, y β_h (18-40 Hz) están vinculadas a un estrés significativo, y aumento de la alerta [García-Murillo et al., 2023]. En estas dos bandas se presenta relevancia en la zona Sensorimotor directamente relacionada con la tarea de MI.

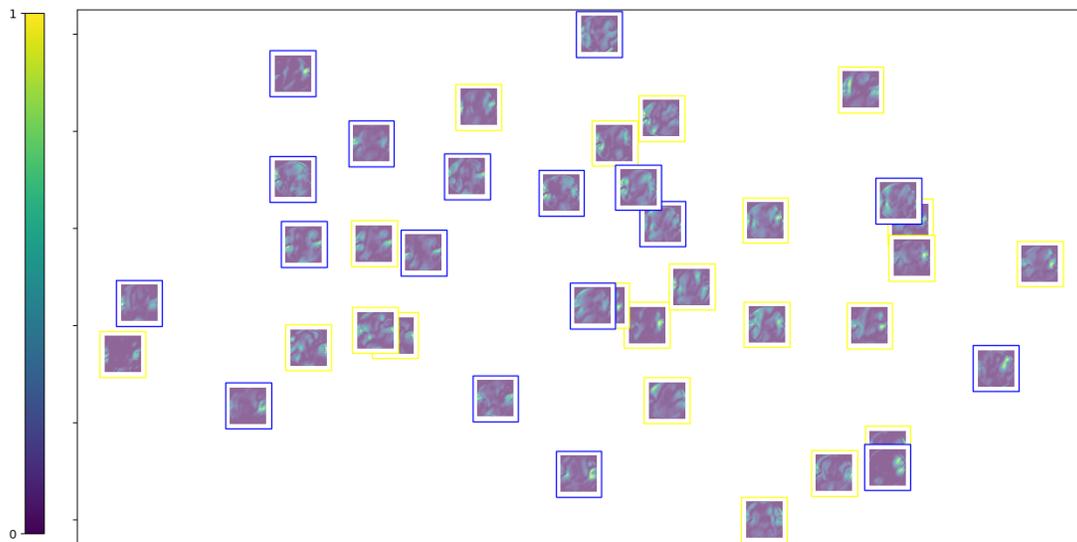


Figura 2-22. Proyección 2D de t-SNE de los CAMs para el sujeto 51 (sujeto con la menor precisión), donde se puede observar que la separabilidad de las dos clases estudiadas no es consistente. El color morado corresponde a los CAMs de la clase 0, y el color amarillo corresponde a los CAMs de la clase 1.

2.4.3 Mapas de conectividad de base de datos BCI-Framework Unal

Se realizó una estimación de los mapas de conectividad para dos sujetos específicos con diferente rendimiento: el sujeto 3, con un acierto de 71.1% que mostró un rendimiento destacado, y el sujeto 7 con un acierto de 50%, que tuvo un rendimiento inferior, como se observa en la Figura 2-23. Adicionalmente un examen de las bandas de frecuencia de interés, como se observa en las Figura 2-24 y la Figura 2-25. Estos mapas de conectividad proporcionaron una representación visual de las interacciones funcionales equivalentes al 70% de las conectividades mas relevantes entre diferentes regiones cerebrales durante la tarea de MI.

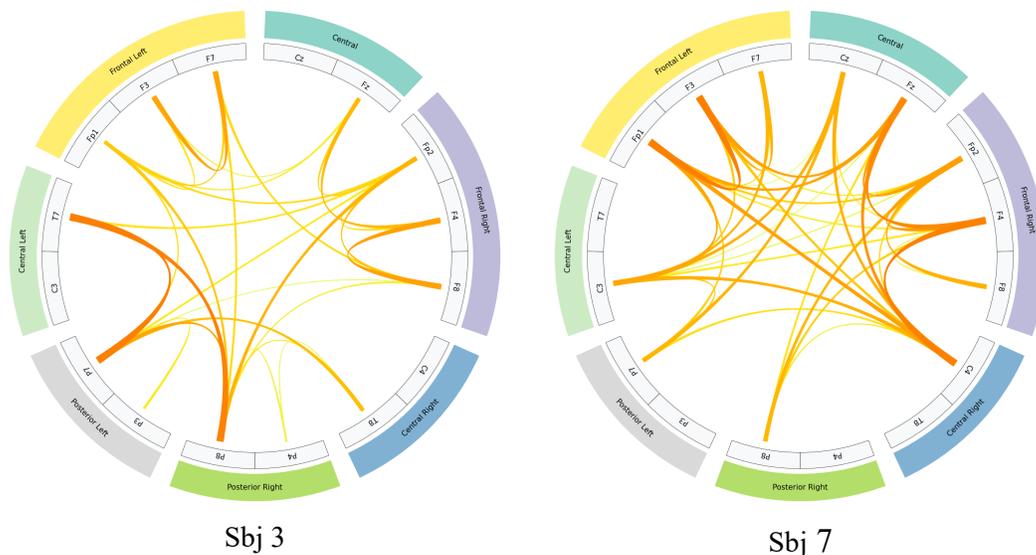


Figura 2-23. Mapas de conectividad para los sujetos con mejor y peor rendimiento de la base de datos BCI-Framework Unal.

En los mapas de conectividad, se destacaron las correlaciones más fuertes entre los nodos mediante bordes más oscuros que conectan los canales EEG. Estos bordes más intensos reflejaron las conexiones más robustas y significativas entre las áreas

cerebrales involucradas en el proceso de MI. Esta representación gráfica permitió identificar patrones de sincronización y comunicación entre las diferentes regiones cerebrales en los sujetos analizados.

Para una mejor comprensión espacial de las regiones cerebrales involucradas, se presentó un gráfico adicional en la parte inferior del gráfico de conectividades, en este gráfico, las diferentes regiones cerebrales, como Central Derecha, Central Izquierda, Frontal, Posterior y Posterior Izquierda, se colorearon de manera distintiva. Esta codificación cromática facilitó la interpretación de las conexiones y ayudó a identificar las áreas específicas que participaron de manera más destacada en la MI.

Se buscó establecer una base fisiológica para comprender las habilidades motoras mediante un análisis de las respuestas neurales desencadenadas por paradigmas de MI. Se prestaron especial atención a los patrones de conectividad resultantes después de aplicar filtros de señal en bandas de frecuencia relevantes, como μ (8-12 Hz), β_l (12-15 Hz), β_m (15-20 Hz) y β_h (18-40 Hz). Además, se emplearon técnicas como el filtrado Laplaciano y la reducción del tiempo de la señal a 2.5 segundos, que corresponde al período de MI. Con el objetivo de evaluar las respuestas neuronales de forma individualizada, se realizó un análisis detallado en sujetos específicos, considerando su rendimiento en la tarea de MI. Para facilitar la visualización y el análisis de los resultados, se hizo uso de un módulo de visualización personalizado, disponible en <https://github.com/UN-GCPDS/python-gcpds.visualizations>. Los resultados mostraron que cada sujeto generaba patrones únicos de conectividad en las bandas de frecuencia estudiadas, evidenciando variaciones en términos de nodos y enlaces relevantes. Estas diferencias en la conectividad podrían impactar la forma en que se integra y se segregan las redes cerebrales, lo cual a su vez podría influir en la precisión de los análisis.

En aquellos sujetos con un rendimiento destacado en MI, se observaron amplitudes de respuesta evocada más altas y densamente distribuidas en áreas

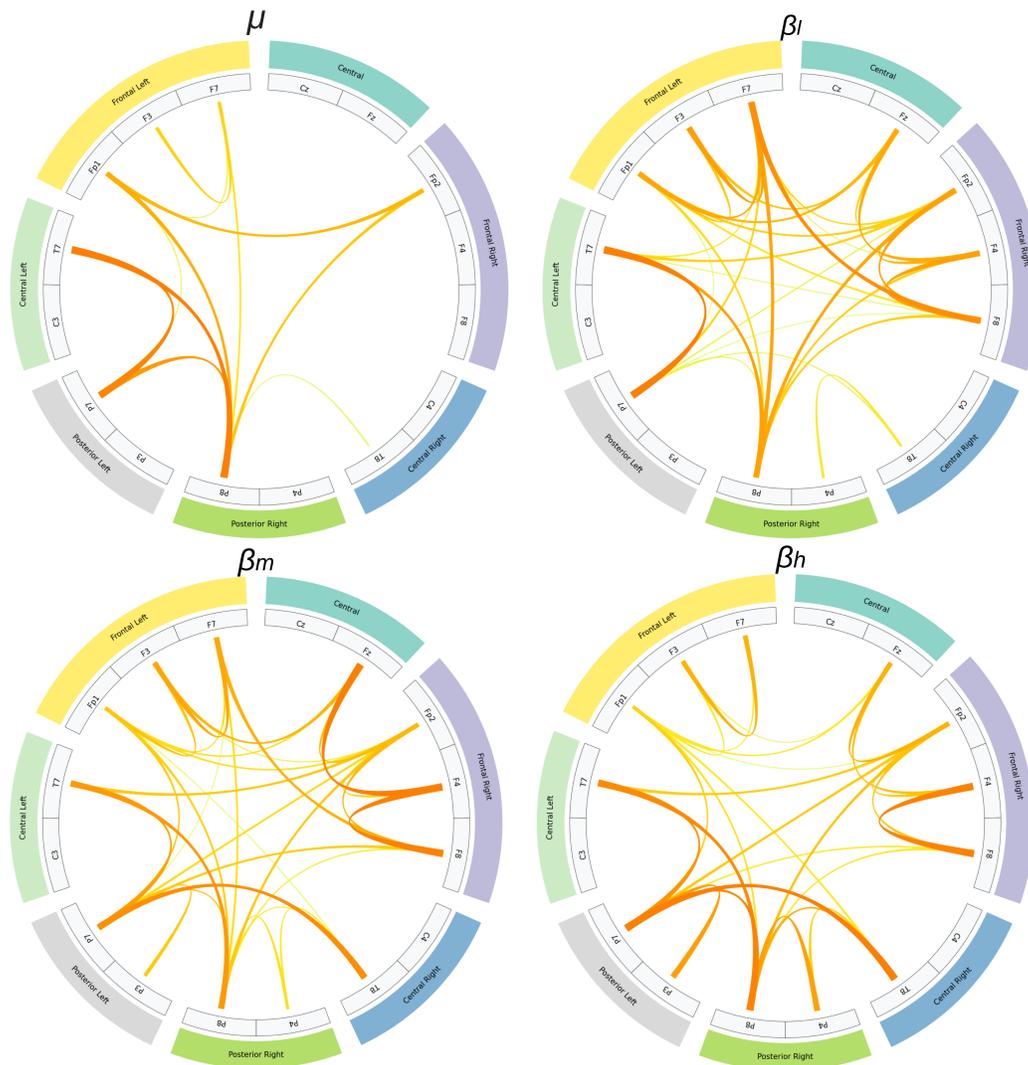


Figura 2-24. Conectividades al 70% del sujeto 3, en sus cuatro bandas de frecuencia.

cerebrales como Frontal, Central y Sensorimotor, que son conocidas por su participación en la ejecución de tareas motoras [Collazos-Huertas et al., 2023]. Por el contrario, en aquellos sujetos con un rendimiento inferior, se detectaron enlaces que abarcaban amplias áreas del cuero cabelludo, sin importar la tarea de MI, particularmente en las bandas β_m (15-20 Hz) y β_h (18-40 Hz). Además, se

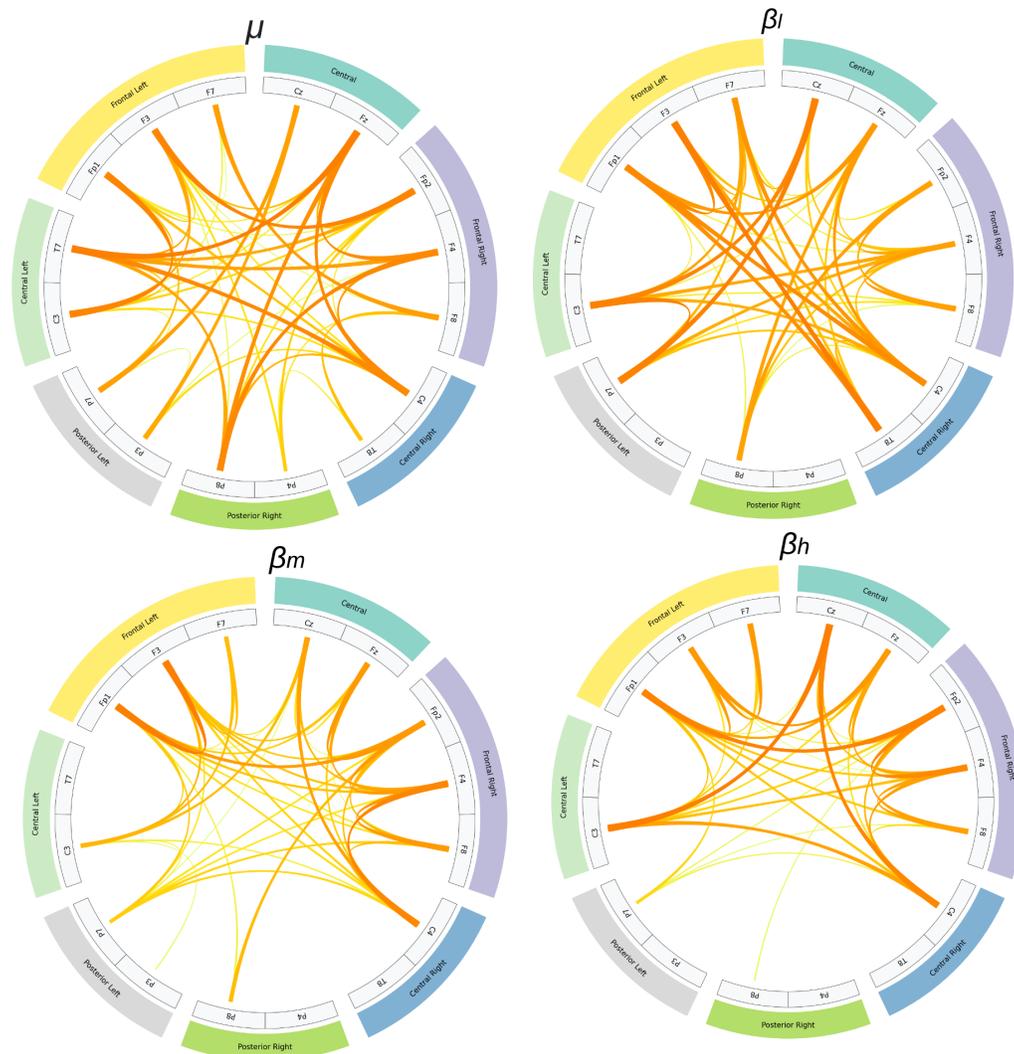


Figura 2-25. Conectividades al 70 % del sujeto 7, en sus cuatro bandas de frecuencia.

encontraron enlaces más fuertes en áreas corticales asociadas con procesos viso-espaciales.

2.4.4 Análisis con t-SNE de base de datos BCI-Framework Unal

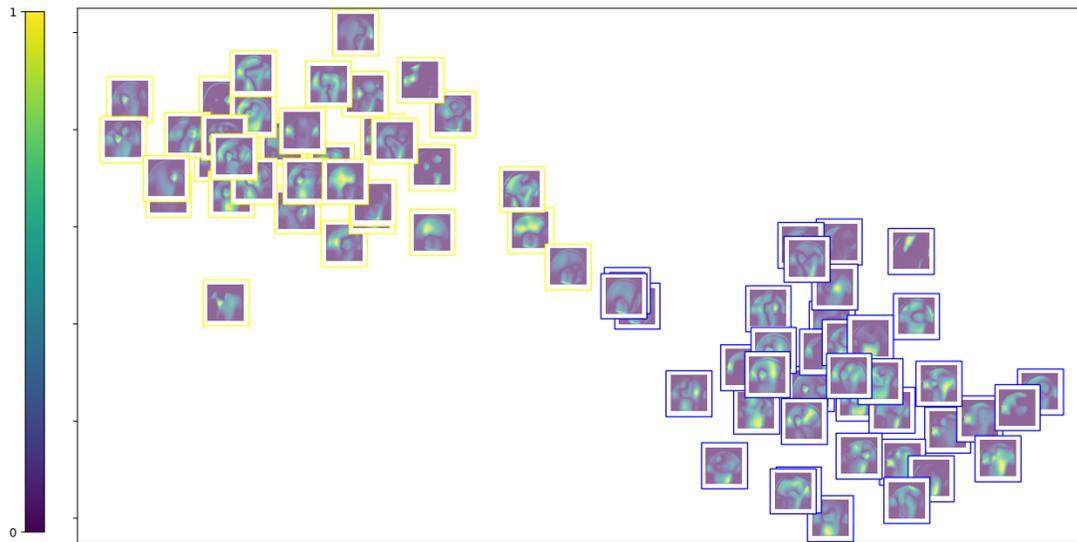


Figura 2-26. Proyección 2D de t-SNE de los CAMs para el sujeto 3, donde se puede observar que la separabilidad de las dos clases estudiadas. El color morado corresponde a los CAMs de la clase 0, y el color amarillo corresponde a los CAMs de la clase 1.

Se realizó el análisis con t-SNE para ambos sujetos, como se observa en la Figura 2-26 y la Figura 2-27, aunque cabe mencionar que debido a la falta de datos suficientes para formar un conjunto de datos de validación independiente, el análisis se llevó a cabo utilizando el conjunto de entrenamiento. A pesar de esta limitación, los resultados proporcionaron información valiosa sobre el proceso de aprendizaje de la red neuronal en relación a las características relevantes de MI. Al examinar las representaciones visuales obtenidas mediante t-SNE, se pudo observar cómo la red neuronal estaba capturando las características distintivas de las clases relacionadas con MI. En particular, las clases se mostraron claramente separables en el espacio de baja dimensión generado por t-SNE, en las Figuras 2-26 y la Figura 2-27. La clase 1 se destacó en color amarillo, mientras que la clase 0 se

representó en color morado.

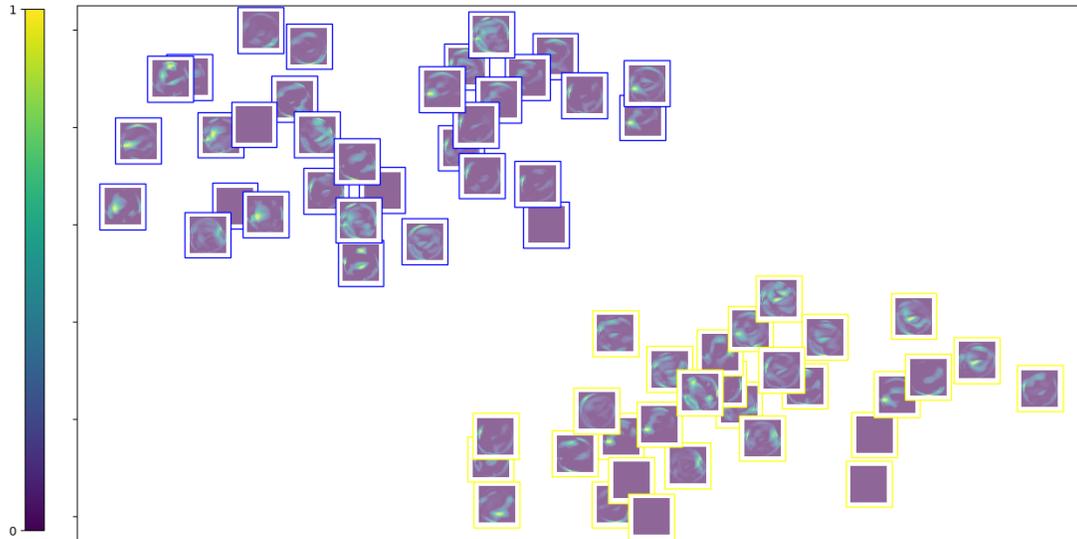


Figura 2-27. Proyección 2D de t-SNE de los CAMs para el sujeto 7, donde se puede observar que la separabilidad de las dos clases estudiadas. El color morado corresponde a los CAMs de la clase 0, y el color amarillo corresponde a los CAMs de la clase 1.

Esta separabilidad en el espacio de características indica que la red neuronal ha logrado aprender y extraer de manera efectiva las características que distinguen las dos clases, permitiendo una discriminación clara entre las instancias de MI. Estos resultados son alentadores, ya que sugieren que el modelo está adquiriendo un entendimiento significativo de las representaciones neuronales asociadas con MI.

Para concluir, se presenta la Figura 2-28 y el Cuadro 2-5, los cuales resumen la comparación de rendimiento de los métodos del estado del arte, CSP+LDA, EEGNet, y el método propuesto WDCNN, utilizando la base de datos BCI-Framework Unal.

Método	Acierto	Kappa
CSP+LDA	54.88 ± 7.10	12.2 ± 10
EEGNet	68.09 ± 10.73	19.5 ± 7.2
GFC+WDCNN	59.79 ± 6.2	18 ± 11

Cuadro 2-5. Comparación de resultados obtenidos, en los métodos probados con la base de datos BCI-Framework Unal y nuestro método propuesto GFC+WDCNN con la media del acierto ± desviación estándar y kappa.

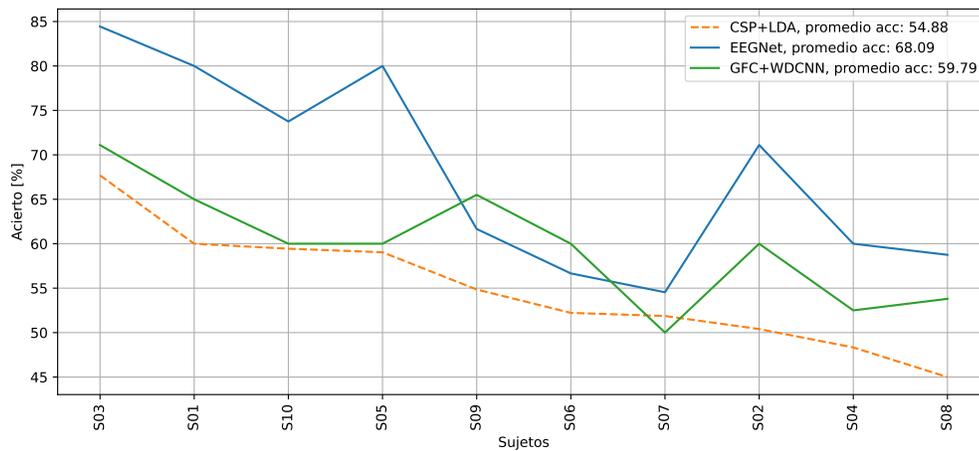


Figura 2-28. Gráfica de comparación en acierto para todos los sujetos 10 sujetos de la base de datos BCI-Framework Unal, de los 3 métodos estudiados CSP+LDA, EEGNet y el método propuesto.

2.5 Conclusiones

Presentamos una metodología de representación y clasificación de señales de EEG basada en imágenes, aprovechando una representación de canales EEG en pares para la posterior construcción de topogramas en diferentes bandas de frecuencia, codificando relaciones no lineales relevantes mediante una similitud basada en

Gauss. Luego, un marco de aprendizaje profundo mejora la precisión y la exactitud de las BCI-MI. Se estudió la conocida base de datos de MI DB III, y nuestra base de datos propia, comparando métodos de vanguardia utilizando métricas como la precisión y kappa, que incluye la evaluación y extracción de características y el aprendizaje profundo.

- Los resultados obtenidos demuestran que WDCNN+GFC es un método eficiente para extraer y clasificar información relevante de la MI superando el método convencional clásico CSP+FLDA[Cho et al., 2017], y el método convencional en DL EEGNet[Lawhern et al., 2018], sería conveniente ser probada con nuevas alternativas basadas en Transformer [Kong et al., 2021], cabe resaltar que en la base de datos BCI-Framework Unal, tenemos una poca densidad de canales y de ensayos, como trabajo futuro se presenta la alternativa de probar con nuevas arquitecturas de DL y aumentar la densidad de canales y mas intentos en nuestra base de datos.

Cuadro 2-6. Métodos de vanguardia, comparación de métodos en relación a la media \pm desviación estándar. Desviación estándar de las medidas de rendimiento consideradas para la base de datos Giga Motor Imagery - DBIII MI.

Método	ACC
CSP+LDA [Cho et al., 2017]	67.7 \pm 13.6
STR connectivity [Rodrigues et al., 2019]	62.00 \pm 13.00
EEGNet [Lawhern et al., 2018]	69.5 \pm 14.6
OPTICAL+ [Kumar et al., 2021]	69.6 \pm 16.3
CCRN [Ko et al., 2021]	<u>72.0 \pm 9.0</u>
GFC + WDCNN (nuestro método)	<u>69.3 \pm 11.1</u>

- La GFC+WDCNN ha demostrado una habilidad destacada al aprender y extraer con eficacia las características distintivas que diferencian las dos clases, lo que le ha permitido realizar una discriminación clara entre las

instancias de MI. Ha demostrado una habilidad destacada al aprender y extraer con eficacia las características distintivas que diferencian las dos clases, lo que le ha permitido realizar una discriminación clara entre las instancias de MI. Esta capacidad de la red para identificar y distinguir entre las clases de MI es un paso importante hacia el desarrollo de un sistema de clasificación sólido y confiable. Al lograr capturar las características relevantes asociadas con la MI, el modelo está adquiriendo una comprensión más profunda de los patrones neurales que caracterizan esta tarea.

- El hecho de que la separabilidad de las clases se muestre claramente en las representaciones generadas por t-SNE es alentador, ya que indica que el modelo ha logrado aprender representaciones de alta calidad. Estas representaciones, basadas en características relevantes de la MI son esenciales para que el modelo pueda tomar decisiones precisas y diferenciar entre tareas de MI. También los resultados obtenidos demuestran que WDCNN+GFC supera métodos convencionales como CSP+FLDA[[Cho et al., 2017](#)].

2.6 Resumen

Este capítulo presenta una metodología innovadora para la representación y clasificación de señales de EEG basada en imágenes y en DL. Esta metodología emplea datos con alta y baja densidad de canales, utilizando una base de datos pública y otra con baja densidad obtenida a través de un sistema BCI basado en EEG. Este sistema se caracteriza por ser portátil, de bajo costo y operar con un número reducido de canales. Uno de los objetivos clave de esta metodología es abordar los desafíos anteriores relacionados con la variabilidad intersujeto y la interpretación espacio-frecuencia en modelos DL para la clasificación de tareas de MI.

Dado que el rendimiento en las tareas de MI depende en gran medida de la interpretación adecuada de las respuestas de la actividad cerebral, lo cual es

beneficioso para el diagnóstico médico, la rehabilitación y las tecnologías de asistencia, se ha enfrentado la problemática en la decodificación de respuestas neuronales relevantes desde las señales EEG en sistemas BCI orientados a la detección de la MI. Se ha observado dificultad en la mejora del rendimiento debido a la variabilidad intra e intersujeto. Los desafíos incluyen la limitada resolución espacial, ya que los patrones no son estacionarios para todos los sujetos, así como una baja SNR, influida por la falta de coordinación en la ejecución de las tareas de MI.

Para afrontar estos desafíos en la interacción de señales EEG en sistemas BCI, se propone una metodología que implementa una estrategia de procesamiento de señales enfocada en la detección de MI, basada en conectividades y en DL. Los resultados obtenidos demuestran que el sistema BCI basado en EEG, con características de portabilidad, bajo costo y pocos canales, logra ofrecer resultados competitivos en comparación con los métodos del estado del arte. La aplicación de la técnica GFC+WDCNN, que involucra una red neuronal profunda, ha sobresalido al aprender y extraer eficazmente las características distintivas que permiten una clara discriminación entre las instancias de MI en ambas bases de datos estudiadas.

ADQUISICIÓN Y PROCESAMIENTO EN TIEMPO REAL

Este capítulo presenta la metodología novedosa de un sistema de bajo costo, portátil y de pocos canales para abordar el problema del tiempo real y los costos computacionales en sistemas BCI-MI basados en EEG. El sistema que utilizamos asegura que los bloques de datos de EEG, con una duración de P , estarán disponibles para el usuario en un tiempo menor a P , sin importar la duración del bloque.

La metodología abarca cada etapa necesaria para la implementación de un sistema de bucle cerrado. Comienza con la adquisición de datos, en la cual se emplea el protocolo de adquisición detallado en el segundo capítulo. Este protocolo aborda las restricciones inherentes a la captura de la actividad neuronal mediante electrodos en el cuero cabelludo. Luego, se procede con el procesamiento de características, que incluye preprocesamiento de datos y la eliminación de pruebas basadas en su amplitud para abordar la variabilidad en los registros.

Para la clasificación y generación de comandos destinados a actuadores o agentes, se emplean dos enfoques de ML, concretamente CSP y EEGnet. Se asegura el almacenamiento adecuado de las señales y comandos generados, y se brinda la opción de visualización temporal o espacial. Además, se incorpora la capacidad de adquirir retroalimentación [Sugiarto and Putro, 2009].

Se utilizó la herramienta BCI-Framework, un sistema distribuido que equilibra los costos computacionales y la precisión, garantizando la fiabilidad del sistema en un tiempo real según la definición. Las pruebas presentadas se realizaron en la base de datos pública Giga Motor Imagery - DBIII MI y la base de datos resultado del trabajo de investigación BCI-Framework-Unal. En este capítulo se aborda el objetivo 3 presentado en esta tesis.

3.1 Marco experimental

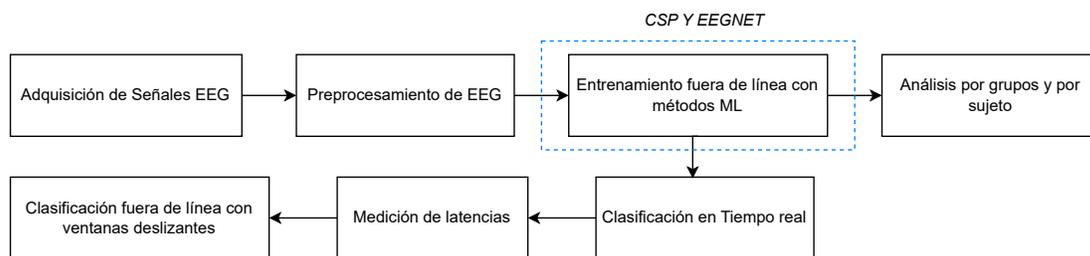


Figura 3-1. Esquema principal del marco experimental.

La metodología propuesta como se observa en la Figura 3-1 para la adquisición y el procesamiento en tiempo real abarca cada etapa necesaria en un sistema de bucle cerrado. Los componentes principales son:

Adquisición de datos: Los datos se adquirieron siguiendo un protocolo diseñado para enfrentar las restricciones inherentes a la captura de la actividad neuronal mediante electrodos en el cuero cabelludo.

Procesamiento de características (extracción y clasificación): Se implementó un preprocesamiento de los datos y se eliminaron pruebas basadas en su amplitud. Para la clasificación y generación de comandos para los actuadores o agentes, utilizamos dos enfoques de ML, CSP y EEGnet.

Base de datos y almacenamiento de señales: Esta etapa cubre el almacenamiento de señales recolectadas.

Visualización: Proporcionamos una visualización temporal de los datos.

Base de datos de comandos y adquisición de retroalimentación

Hemos empleado BCI-Framework en cada una de las etapas. Como culminación de este proceso, presentamos los resultados del entrenamiento fuera de línea, la clasificación en tiempo real junto con la medición de latencias y la clasificación fuera de línea empleando ventanas deslizantes.

3.1.1 Preprocesamiento de EEG

Primero, cargamos las grabaciones de los sujetos utilizando un módulo personalizado para cargar bases de datos desde <https://github.com/UN-GCPDS/python-gcpds.databases>. Luego, reducimos la frecuencia de cada señal de 512Hz a 128Hz utilizando el método Fourier proporcionado por la función de re-muestreo de señales de SciPy en <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.resample.html>.

Luego, cada prueba de series temporales se filtró entre [4, 40]Hz, utilizando un filtro de paso de banda Butterworth de quinto orden. Además, recortamos los registros desde 0.5 segundos hasta 2.5 segundos después del inicio del estímulo para la base de datos Giga Motor Imagery - DBIII MI , y desde 2.5 segundos hasta 4.5 segundos para la base de datos BCI-Framework-Unal, reteniendo solo la información correspondiente a la tarea de imaginación motora. El paso de

preprocesamiento se asemeja al proporcionado por los autores en [Lawhern et al., 2018]. Es importante señalar que, dado que estamos analizando solo el segmento de tiempo de MI, asumimos que la señal es estacionaria. En la Figura 3-2 se muestra la visualización de la señal de EEG sin preprocesamiento y la visualización de la densidad espectral de potencia para las 2 clases estudiadas en la Figura 3-4 y la Figura 3-5.

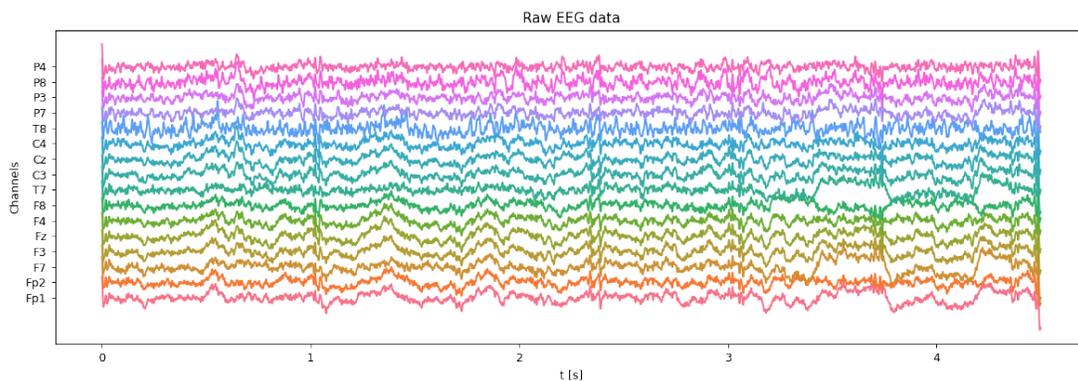


Figura 3-2. Visualización de la señal de EEG sin preprocesamiento, para el sujeto 1 de la base de datos BCI-Framework-Unal.

Nuestro preprocesamiento tiene como objetivo investigar cinco ritmos cerebrales distintos dentro del rango de 4 a 40 Hz, que incluyen theta, alpha y tres ondas beta. Se cree que las ondas theta (4-8 Hz), que se localizan en el hipocampo y varias estructuras corticales, indican un estado en línea y están asociadas con funciones sensoriomotoras y mnemotécnicas, según indican los autores en [Abhang et al., 2016]. En contraste, la actividad de la banda alfa (8-13 Hz) se suprime durante la estimulación sensorial y los movimientos. Está modulada por la atención, la memoria de trabajo y las tareas mentales, y posiblemente sirve como un marcador de funciones de control motor superiores. Además, el preprocesamiento probado también incluye tres tipos de ondas beta: ondas beta bajas (12-15 Hz) o “beta uno”, asociadas principalmente con una concentración enfocada e introvertida. En segundo lugar, las ondas beta de rango medio (15-20 Hz) o “beta dos” están vinculadas a un aumento de energía, ansiedad y

rendimiento. En tercer lugar, las ondas beta altas (18-40 Hz) o “beta tres” están asociadas con un estrés significativo, ansiedad, paranoia, alta energía y alta excitación[[Abhang et al., 2016](#)]. Para la base de datos BCI-Framework-Unal,

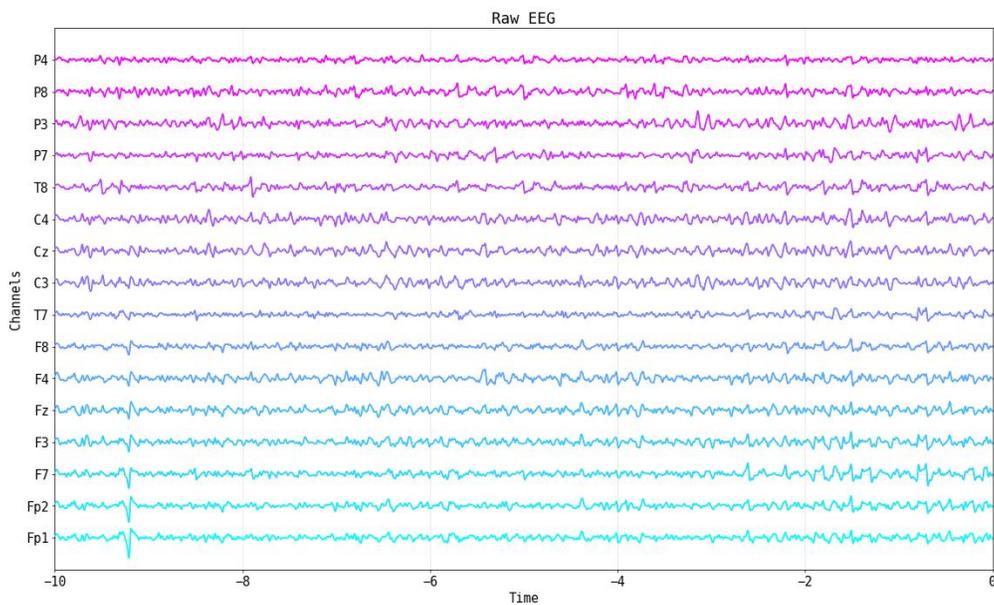


Figura 3-3. Visualización en tiempo real de la adquisición de señales de EEG.

utilizamos una función que permite descartar pruebas basadas en su amplitud. En la Figura 3-3 podemos observar en tiempo real la señal que estamos adquiriendo con el BCI-Framework.

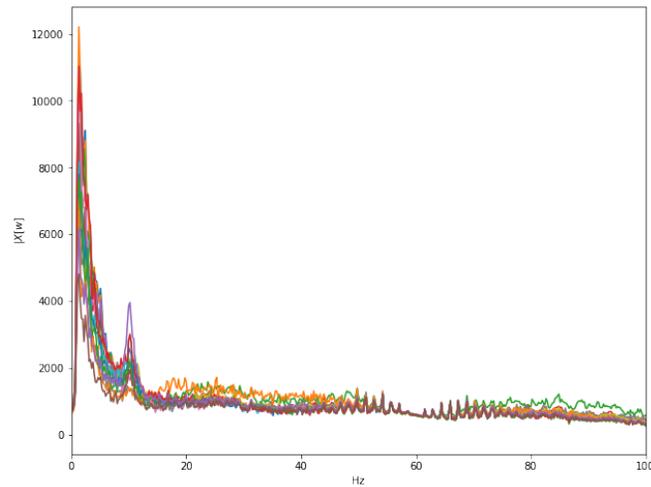


Figura 3-4. Visualización de la densidad espectral de potencia de la señal de EEG cruda, para la clase derecha.

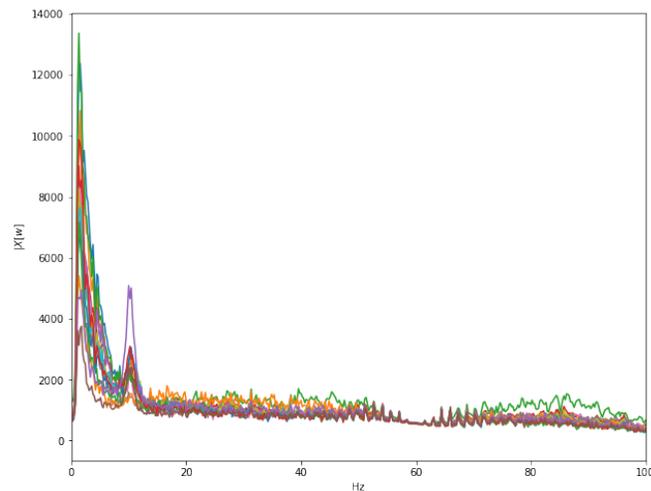


Figura 3-5. Visualización de la densidad espectral de potencia de la señal de EEG cruda, para la clase izquierda.

3.2 Entrenamiento fuera de línea con CSP

Para el entrenamiento fuera de línea se utilizó la metodología CSP+LDA propuesta en [Cho et al., 2017].

- En la base de datos Giga Motor Imagery - DBIII MI , dividimos los ensayos dentro de los datos de cada sujeto utilizando el esquema estándar de 5 divisiones 80-20 . Esto significa mezclar los datos y tomar el 80% para entrenar (conjunto de entrenamiento), dejando el 20% restante para validar los modelos entrenados (conjunto de prueba), y repetir el proceso cinco veces. El CSP integra el Standard Scaler y el clasificador Linear Discriminant Analysis, la métrica utilizada es el Acierto.
- En la base de datos BCI-Framework-Unal, dividimos los ensayos dentro de los datos de cada sujeto utilizando el esquema estándar de 5 divisiones 90-10 . Esto significa mezclar los datos y tomar el 90% para entrenar (conjunto de entrenamiento), dejando el 10% restante para validar los modelos entrenados (conjunto de prueba), y repetir el proceso cinco veces. El CSP integra el Standard Scaler y el clasificador Linear Discriminant Analysis, la métrica utilizada es el acierto.

3.3 Entrenamiento fuera de línea con EEGNet

Para realizar el entrenamiento fuera de línea utilizamos la red neuronal de arquitectura EEGNet propuesta en [Lawhern et al., 2018]. Es una red neuronal diseñada específicamente para el procesamiento y análisis de señales de EEG. EEGNet utiliza capas convolucionales y de agrupación para extraer características relevantes de las señales EEG en múltiples escalas de tiempo y frecuencia. la forma de entrada es $(1, C, T)$, donde C es el número de canales, T - número de puntos de tiempo, F_1 - número de filtros temporales, D - multiplicador de profundidad (número de filtros espaciales), F_2 - número de filtros punto por punto, y N - número de clases, respectivamente. Para la capa de Dropout, utilizamos $p=0,5$ para la clasificación dentro del sujeto. Las notaciones representan $16DF_1 + F_2(DF_1)$ y $(^{**})$ para $N(F_2 * T // 32)$.

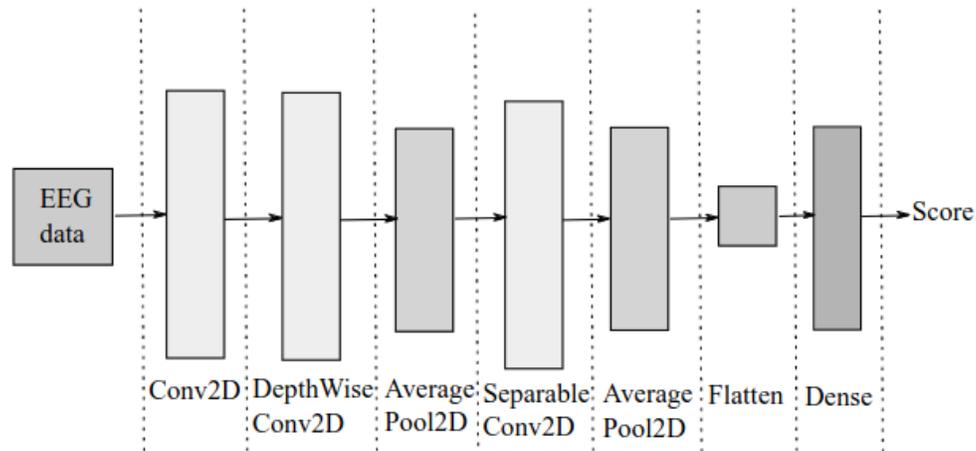


Figura 3-6. Esquema principal de la EEGnet, la primera columna es la entrada de la señal de EEG, la segunda columna es la capa convolución temporal (conjunto de filtros), la tercera y cuarta columnas son las capas de convolución de filtrado espacial. Quinta y sexta columnas es el resumen temporal y para finalizar la última columna es la predicción de etiqueta de salida. Figura tomada de [Collazos-Huertas et al., 2023].

- En la base de datos Giga Motor Imagery - DBIII MI , dividimos los ensayos dentro de los datos de cada sujeto utilizando el esquema estándar de 5 divisiones 80-20% . Esto significa mezclar los datos y tomar el 80% para entrenar (conjunto de entrenamiento), dejando el 20% restante para validar los modelos entrenados (conjunto de prueba), y repetir el proceso cinco veces. Se presenta la arquitectura de EEGNet utilizada en el cuadro 3-1.
- En la base de datos BCI-Framework-Unal, a la arquitectura de la red se le agregó regularización l1 y l2 a las capas densas, dividimos los ensayos dentro de los datos de cada sujeto utilizando el esquema estándar de 5 divisiones 90-10% . Esto significa mezclar los datos y tomar el 90% para entrenar (conjunto de entrenamiento), dejando el 10% restante para validar los modelos entrenados (conjunto de prueba), y repetir el proceso cinco veces.

Layer name	Conv2D	Depthwise Conv2D	Separable Conv2D	Flatten	Dense
# filters	F_1	$D * F_1$	F_2		(**)
Size	(1, 64)	(C , 1)	(1, 16)		
# params	$64 * F_1$	$C * D * F_1$	(*)		
Output	(F_1, C, T)	($D * F_1, 1, T$)	($F_2, 1, T//4$)	($F_2 * (T//32)$)	N
Options	Activation=Linear Mode=same BatchNorm=True	Activation=Linear Mode=same Depth= D max_norm=1 BatchNorm=True Activation=ELU AvgPool2D=(1, 4) Dropout* - $p = 0,25$ or $p = 0,5$	Activation=Linear Mode=same BatchNorm=True Activation=ELU AvgPool2D=(1, 8) Dropout* - $p = 0,25$ or $p = 0,5$		

Cuadro 3-1. Arquitectura EEGNet.

3.4 Resultados y discusión

En los resultados se presentarán: i) los resultados del análisis por grupos, representados en gráficas y tablas que muestran los aciertos con pérdidas y ganancias de cada método evaluado; ii) análisis de rendimiento por sujeto, iii) la clasificación bi-clase en tiempo real mediante el entrenamiento fuera de línea con métodos de ML; iv) la medición de latencias, con el fin de evaluar y cuantificar el tiempo transcurrido desde la adquisición de la actividad cerebral hasta la detección y traducción de esta actividad en una acción o comando por parte del sistema; y por último, v) se realizará la clasificación bi-clase fuera de línea utilizando ventanas deslizantes para examinar el comportamiento del clasificador ante un flujo continuo de datos.

3.4.1 Análisis por grupos base de datos Giga Motor Imagery - DBIII MI

Realizamos un análisis a nivel de grupo en el cual construimos una matriz de puntuación con un número de filas igual al número de sujetos en el conjunto de datos (50 en el caso de Giga). Esta matriz incluye seis columnas que abarcan la precisión, junto con sus respectivas desviaciones estándar. A continuación, empleamos la matriz de puntuación junto con el algoritmo de agrupación k-means [Géron, 2022], con un valor de k establecido en tres. El propósito es entrenar un modelo que agrupe a los sujetos en uno de los tres grupos: los mejores, los intermedios y los peores, basándose en el rendimiento del modelo de referencia CSP [Cho et al., 2017].

Los sujetos se organizan en orden descendente según su rendimiento en relación con el modelo de referencia CSP. La finalidad de esta fase es comparar y verificar cómo se producen cambios entre los sujetos en los grupos definidos por CSP y EEGnet.

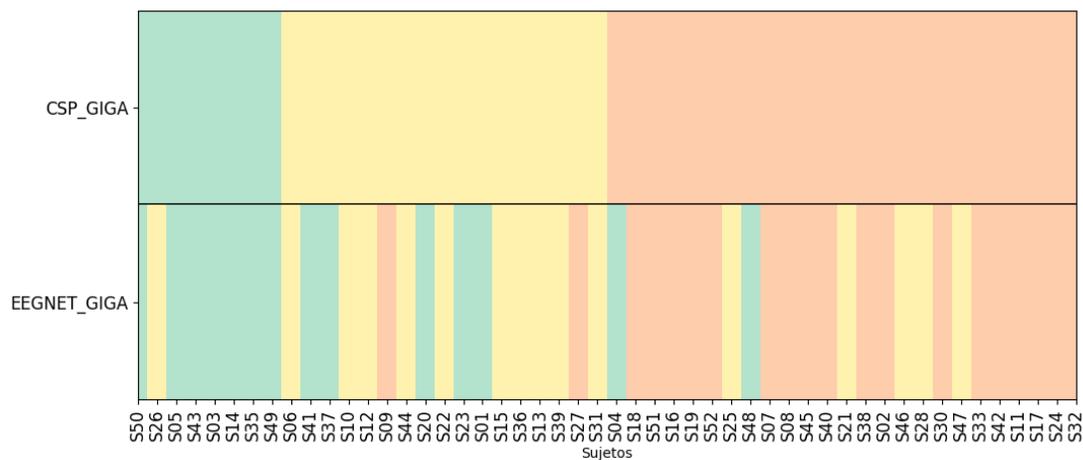


Figura 3-7. Comparación de métodos, CSP y EEGNet con base de datos GIGA.

En la figura 3-7 ilustra la pertenencia del grupo de sujetos y el impacto del método EEGNet en la clasificación de grupos. Cabe aclarar que los resultados obtenidos en

esta gráfica, presentan una gran diferencia a los obtenidos en la gráfica 2-4, esto se debe a que los resultados utilizados en la grafica anterior, son los del estado del arte, en cambio para esta gráfica se replicaron los experimentos desde cero para obtener dichos resultados. La primera fila muestra los sujetos organizados según los resultados de CSP, mientras que la fila inferior muestra cómo cada sujeto cambia o mantiene su grupo basado en los resultados de EEGNet. Por ejemplo, en el grupo rojo de la fila de CSP, al observar el nuevo agrupamiento basado en EEGNet para el mismo subconjunto de sujetos, es evidente que un total de cinco sujetos mejoraron significativamente su rendimiento, pasando al grupo amarillo. Además, siete sujetos experimentaron un gran aumento en su rendimiento y fueron promovidos al mejor grupo (verde), lo que demuestra la efectividad del marco propuesto. Además, los sujetos que originalmente estaban en el mejor grupo, solo uno de ellos pasa al grupo amarillo y el resto mantuvieron su estatus, lo que indica que los sujetos con mejor rendimiento tienen menos probabilidades de mejorar. Nuestro enfoque logra una mejor discriminación de la tarea MI en comparación con CSP, especialmente para los sujetos con rendimiento bajo y medio, lo cual es importante ya que resalta la capacidad del modelo para manejar casos desafiantes.

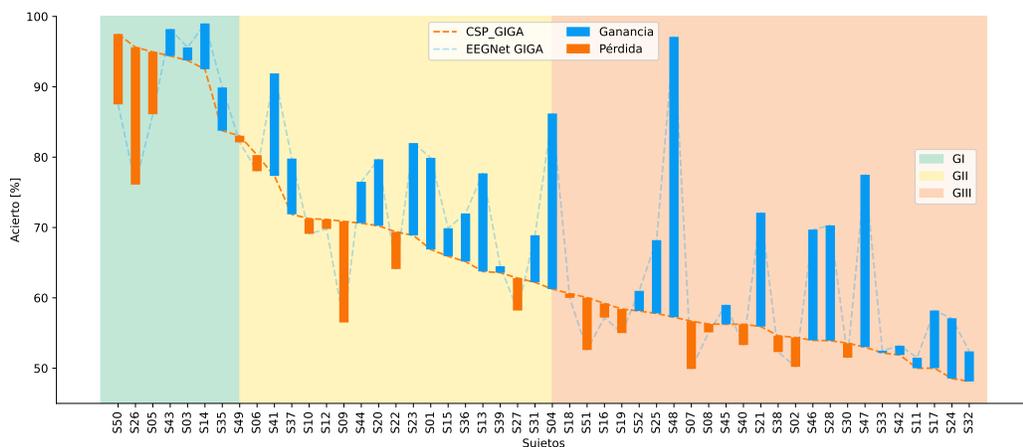


Figura 3-8. Gráfica de pérdida y ganancia entre métodos y división por grupos (G I: pérdida de 2.86 %, G II: Ganancia de 5.65 % y el G III: ganancia de 10.51 %).

Método	Grupo	Acierto (%)	Ganancia (%)
CSP+LDA	GI	91.94 ± 5.95	.
	GII	68.95 ± 10.45	.
	GIII	55.12 ± 11.76	.
EEGNET	GI	89.31 ± 3.74	.
	GII	72.85 ± 2.49	5.65
	GIII	60.92 ± 2.96	10.51

Cuadro 3-2. Resultados para la base de datos Giga Motor Imagery.

En el cuadro 3-2 se presentan los resultados para la base de datos Giga Motor Imagery - DBIII MI utilizando CSP+LDA y EEGNet se presentan en el análisis por grupos. Se muestra la precisión y la desviación estándar por grupo de buenos, malos y regulares rendimientos. En la última casilla, se puede observar la ganancia por grupo, específicamente los grupos GII y GIII.

3.4.2 Análisis de rendimiento por sujeto base de datos BCI-Framework Unal

Realizamos un análisis de rendimiento individual, en el que se compararon los resultados de dos métodos, CSP y EEGnet, revelando una mejora considerable del 21.69%. Esto se tradujo en un promedio de precisión del 56.54% ± 8.78 para el método CSP y para EEGnet 68.09% ± 10.73 para EEGnet. No obstante, es importante destacar que en ambas bases de datos analizadas, se observó una disminución en la tasa de acierto para algunos sujetos, independientemente de su grupo de pertenencia.

Esta disminución podría atribuirse a la aplicación de estos métodos para reducir el nivel de ruido (SNR) en todos los sujetos, sin considerar sus niveles individuales

de ruido, lo que podría afectar negativamente a aquellos con señales EEG de alta calidad [Tobón-Henao et al., 2022].

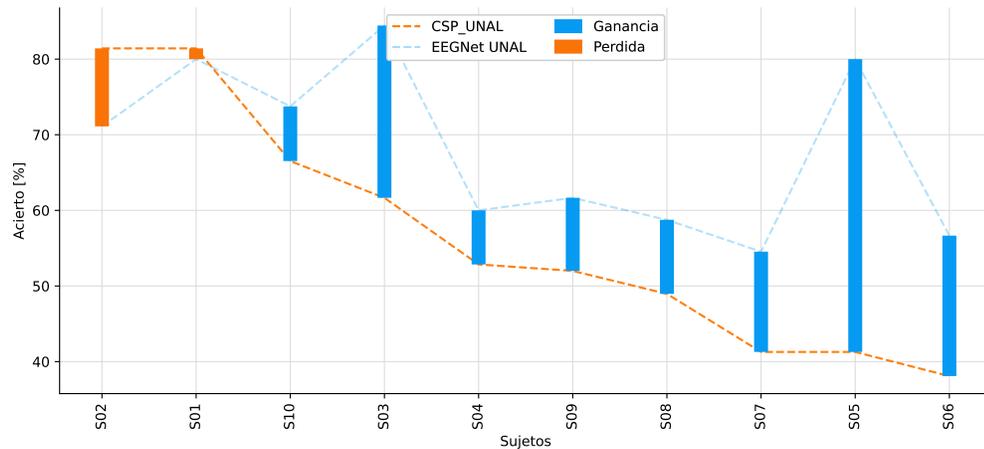


Figura 3-9. Comparación de métodos, CSP y EEGNet con base de datos UNAL (Ganancia de 20.41 %).

3.5 Clasificación en Tiempo Real

El entrenamiento de la Red EEGNet y el CSP resulta en un modelo preparado para la generación de comandos destinados a actuadores/agentes, los cuales se utilizan en un entorno de tiempo real. En este entorno, el sujeto deberá controlar la dirección del carro del videojuego Car-Racing, como se observa en la Figura 3-10, que se encuentra en constante movimiento, para moverlo a la izquierda o derecha. La dirección del juego puede ser accedida en el siguiente enlace: https://www.gymlibrary.dev/environments/box2d/car_racing/. El proceso de adquisición de señales y el entrenamiento se llevan a cabo en tiempo real, utilizando la misma interfaz BCI-Framework y bajo el protocolo de adquisición previamente definido.

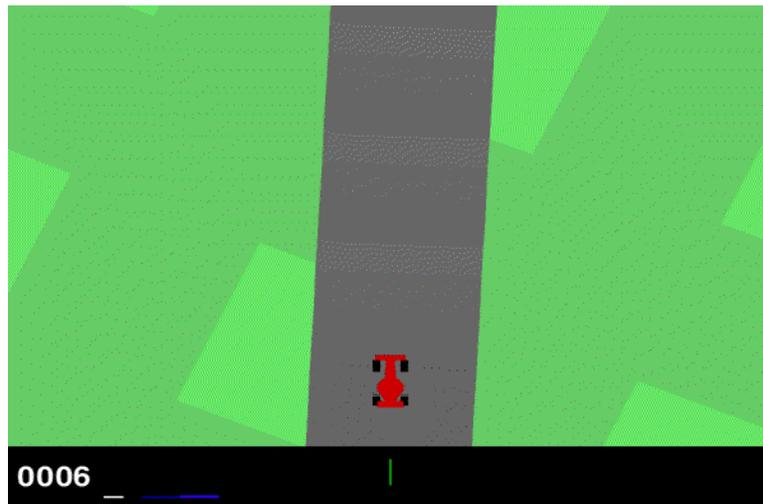


Figura 3-10. Modelo de prueba de MI en tiempo real, para mover la dirección del Car-Racing, izquierda o derecha.

3.6 Latencias

El Framework fue configurado para adquirir 1000 muestras por segundo y transmitir en paquetes de 100 ms. Dado que el modelo de clasificación requiere una ventana de 2.5 s, correspondiente al tiempo de MI, se estableció que el sistema genere un valor de clasificación cada 500 ms.

La latencia comprende el tiempo transcurrido entre la adquisición del último dato del último bloque de 100 ms hasta la realización de la clasificación. Esto incluye las tareas de deserialización, transmisión y lectura que se llevan a cabo internamente en el BCI-Framework, más el tiempo de clasificación.

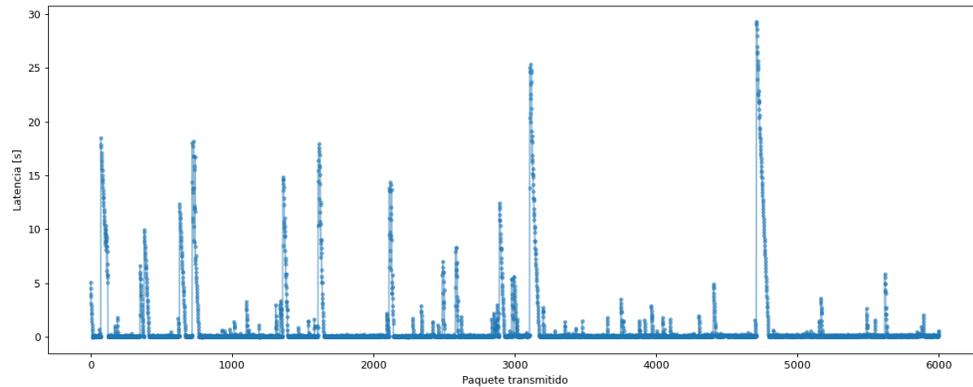


Figura 3-11. Este gráfico muestra las latencias medidas en 6000 ventanas consecutivas de clasificación, junto con sus correspondientes mediciones de latencia.

De acuerdo con el BCI-Framework, la latencia esperada debería ser de 456 ms, correspondiendo a la espera de los primeros cuatro bloques de 100 ms y el procesamiento de toda la ventana en el último bloque.

Para realizar las gráficas de latencias, se utilizó el predictor del modelo entrenado de EEGNet, este modelo fue entrenado con una prueba de MI con una duración del estímulo de 3000 ms y de 1000 a 1500 ms el inicio del estímulo de forma asíncrona, se recortó el tiempo de MI a 2500 ms. Para la prueba de validación se realizó con un estímulo de 10000 ms y 3000 ms el inicio del estímulo de forma asíncrona, teniendo en cuenta que es el mismo sujeto, se utilizó el mismo protocolo y el mismo paradigma, pero son sesiones diferentes y días diferentes.

Podemos observar en la Figura 3-11 que las latencias a veces superan el valor esperado de 56 ms. Esto se debe a las intermitencias en la transmisión de paquetes y a la política de no perder datos del protocolo de transmisión TCP. Sin embargo en la Figura ?? se ajusta la visualización a una ventana más reducida, donde podemos observar que las latencias se agrupan alrededor del valor esperado----- En el cuadro 3-3 se presentan algunos sistemas BCI de tiempo real que utilizan inteligencia artificial, y que tienen diferentes configuraciones de frecuencia y canales, la mayoría de ellos no muestra datos de latencias o la información necesaria para calcularla.

Sistema BCI	Inteligencia Artificial	Frecuencia	Canales	Tiempo real	Latencia
Hybrid BCI+actiCHamp [Choi et al., 2020b]	si	500 Hz	31	si	±1020 ms
NeuroGrasp+BrainAmp [Cho et al., 2021]	si	1000 Hz	20	si	-
BCI-reinforcement learning+g.usBamp [Pires et al., 2022]	si	256 Hz	16	si	-
Functional Brain network+UE-16B [Ai et al., 2019]	si	1000 Hz	16	si	-
BCI-Framework+ EEGNet (propuesto)	si	1000 Hz	16	si	± 150 ms

Cuadro 3-3. Comparación entre diferentes configuraciones de sistemas BCI que utilizan inteligencia artificial.

3.7 Clasificación fuera de línea sobre ventanas deslizantes

Para examinar el comportamiento del clasificador sobre un flujo continuo de datos, representado en la Figura 3-12, se llevó a cabo un experimento en el que se recogieron datos con una duración de MI de 10 segundos, precedidos de 3 segundos sin actividad de MI.

Es importante tener en cuenta que el marco de referencia se sitúa al inicio de cada ventana de clasificación.

Al realizar el mismo experimento pero registrando el porcentaje de aciertos en lugar del porcentaje de clasificación retornado por el modelo, como se observa en la Figura 3-13 y ubicando el marco de referencia al final de la ventana de clasificación, tal como sucedería en un entorno de lazo real, podemos usar estos datos para determinar un umbral para validar la clasificación y la generación de señales de control, representado en la Figura 3-14.

El área sombreada de gris indica la generación de comandos para el agente.

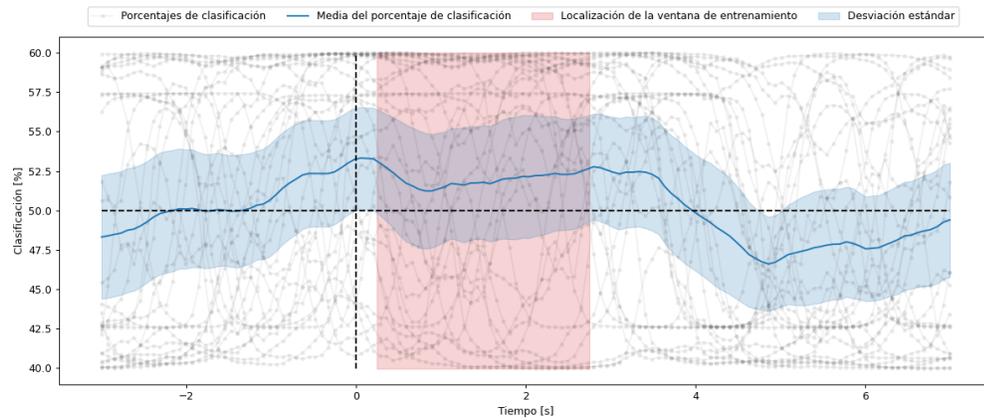


Figura 3-12. Para cada intento, se deslizó una ventana de 2.5 segundos cada 10 muestras, y se registró su porcentaje de clasificación para todos los intentos. La línea azul representa la media del porcentaje de clasificación (supervisado), mientras que el sombreado representa su correspondiente desviación estándar. Se puede observar cómo el porcentaje de clasificación aumenta a medida que la ventana de análisis abarca más datos de MI, alcanzando sus valores máximos en el segmento que se utilizó para entrenar el modelo, resaltado en color rosa.

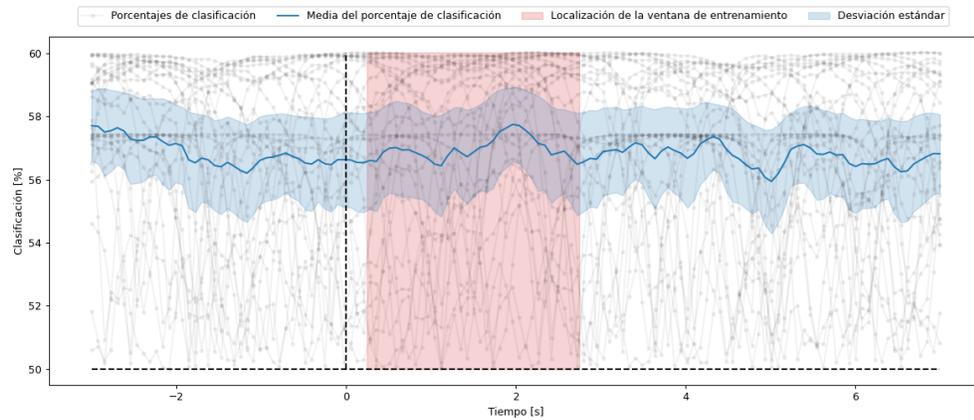


Figura 3-13. Esta figura se asemeja a la figura 3-12. Su única diferencia es que el porcentaje de clasificación no es supervisado.

3.8 Conclusiones

Presentamos una metodología novedosa de un sistema de bajo costo, portátil y de pocos canales para abordar el problema del tiempo real y los costos computacionales

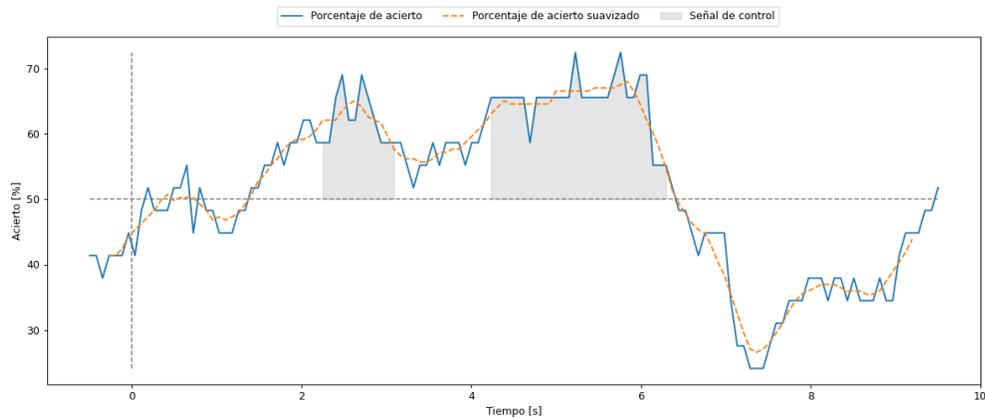


Figura 3-14. El umbral de clasificación se establece cuando el promedio de aciertos en una ventana de 5 datos, se mantiene por encima de 60 % de acierto.

en sistemas BCI-MI basados en EEG, realizando todas las etapas de un sistema de lazo cerrado, desde la adquisición de los datos hasta la obtención de comandos para el agente, empleando técnicas de ML para realizar entrenamientos fuera de línea y en línea con la respectiva medición de latencias para su validación.

- Es relevante señalar que en la realización de este capítulo no se empleó la metodología propuesta en el segundo capítulo 2, debido a que se evidenció una significativa disminución en el rendimiento en comparación con el método EEGNet. Una de las razones posibles es que la aplicación de enfoques genéricos para la reducción de ruido, como se aplicó en nuestro enfoque, podría no resultar óptima para todos los sujetos. Cada individuo puede presentar variaciones únicas en la calidad de las señales EEG debido a diferencias anatómicas y funcionales en su actividad cerebral. Por lo tanto, la aplicación uniforme de un filtro de reducción de ruido podría no ser adecuada para aquellos individuos cuyo EEG inicialmente es limpio [Tobón-Henao et al., 2022]. Además, es importante considerar que para estas pruebas disponemos de aproximadamente entre 70 y 116 intentos por sujeto en nuestra base de datos, lo que puede afectar significativamente el rendimiento de las redes debido al riesgo de sobreajuste [Tobon-Henao et al., 2023].

- Nuestra base de datos de EEG, que se caracteriza por ser de bajo costo y tener una densidad de canales reducida, presenta resultados competitivos en comparación con bases de datos públicas y enfoques previamente probados en estas.
- En el entrenamiento fuera de línea, realizado en la base de datos Giga Motor Imagery - DBIII MI y en BCI-Framework Unal con nuestro enfoque, se evidencia su capacidad sobresaliente al lograr una discriminación más precisa en la tarea de MI en comparación con la técnica tradicional de CSP. Esta mejora es particularmente notoria al considerar a los individuos con niveles de rendimiento más bajos y moderados. Este aspecto adquiere una relevancia especial al resaltar la habilidad del modelo propuesto para enfrentar y superar desafíos sustanciales en la clasificación de señales EEG.
- En el entrenamiento en línea se demuestra que nuestro modelo tiene la capacidad de cumplir con el concepto de tiempo real, garantizando la disponibilidad de los bloques de datos de EEG para el usuario de manera más rápida que su duración original.
- En la clasificación fuera de línea con ventanas deslizantes, se obtuvo resultados de clasificación prometedores, teniendo en cuenta que el experimento se llevó a cabo con sesiones diferentes del mismo sujeto y teniendo en cuenta que la variabilidad intercesiones puede generar una disminución en la precisión de la clasificación.

3.9 Resumen

En este capítulo, se presenta una metodología innovadora que incorpora un sistema BCI, basado en señales de EEG. Este sistema ha sido diseñado teniendo en cuenta la portabilidad, la asequibilidad y la utilización de un número reducido de canales. Un aspecto fundamental de este enfoque es su optimización para operar en tiempo

real y con una eficiencia computacional destacada. El objetivo principal es agilizar la disponibilidad de bloques de datos EEG para el usuario, minimizando el tiempo que transcurre desde la adquisición de los datos hasta que estos se convierten en información útil.

Esta metodología abarca todas las etapas esenciales de un sistema de lazo cerrado BCI, abordando desde la captura inicial de datos hasta la obtención de retroalimentación en tiempo real. Incluye procesos clave como el preprocesamiento de los datos EEG y su posterior clasificación. Para llevar a cabo esta clasificación, se aplican dos enfoques fundamentados en técnicas de ML, lo que confiere a la metodología un alto grado de flexibilidad y adaptabilidad a diferentes contextos y necesidades.

La implementación práctica de esta metodología se llevó a cabo utilizando la herramienta BCI-Framework, proporcionando una base sólida y versátil para la ejecución de todas las fases del sistema. Para validar su efectividad y rendimiento, se realizaron pruebas exhaustivas en dos conjuntos de datos diferentes: la base de datos Giga Motor Imagery - DBIII MI y la base de datos BCI-Framework Unal. Estas pruebas permitieron evaluar el sistema en condiciones variadas y comprobar su capacidad para ofrecer resultados precisos y confiables en una diversidad de escenarios.

OBSERVACIONES FINALES

4.1 Conclusiones

En conclusión, esta tesis presenta una estrategia de procesamiento de señales de EEG en sistemas BCI con DL y medidas de conectividad para abordar de manera efectiva los desafíos de la variabilidad intersujeto, la interpretabilidad espacio frecuencia en modelos DL y el tiempo real en las BCI-MI. Las principales contribuciones de este trabajo se pueden resumir de la siguiente manera:

- En primer lugar, desarrollamos una metodología que utiliza imágenes y DL para representar y clasificar señales EEG, especialmente para tareas de MI, en bases de datos de alta y baja densidad de canales. Además, se desarrolló un protocolo de adquisición de datos para el sistema BCI-MI basado en EEG, utilizando OpenBCI y el BCI-Framework de bajo costo y portátil para lidiar con las restricciones inherentes en la captura de la actividad neuronal con

electrodos en el cuero cabelludo; la variabilidad intersujeto e interpretabilidad espacio-frecuencia en modelos DL, teniendo en cuenta que la interpretabilidad es crucial en áreas críticas como la atención médica, donde la interpretación adecuada de las respuestas de actividad cerebral puede afectar la atención al paciente y poner en riesgo vidas humanas [Meng et al., 2022]. Esta metodología fue probada en bases de datos públicas y propias de alta y baja de canales, obteniendo resultados competitivos con los métodos del estado del arte.

- Finalmente, se desarrollo una metodología novedosa de un sistema de bajo costo, portátil y de pocos canales para abordar el problema del tiempo real y los costos computacionales en sistemas BCI-MI basados en EEG. Este sistema está optimizado para tiempo real y eficiencia computacional, garantizando la disponibilidad de los bloques de datos EEG para el usuario de manera más rápida que su duración original, validado con la medición de latencias y mostrando el comportamiento del clasificador con experimentos en ventanas deslizantes fuera de línea. Además, se contribuye con una base de datos de EEG-MI de 10 sujetos, una base de datos de Memoria visoespacial de trabajo (VWM) de 7 sujetos, y registros de estado de reposo y adquisición de ruido.
- Adicionalmente, se contribuye con una patente, registro de software y la posibilidad de acceder al código de implementación en un repositorio de GitHub simplifica la aceptación por parte de la comunidad de investigación y estimula la evolución continua de estas técnicas. La característica de ser código abierto en este repositorio impulsa la cooperación, viabiliza la capacidad de reproducir los resultados y capacita a los investigadores para desarrollar más estos enfoques de futuros progresos en los sistemas BCI.

4.2 Trabajo futuro

Hemos presentado una estrategia de procesamiento de señales EEG para sistemas BCI-MI que aborda los problemas de variabilidad intersujeto, interpretabilidad

espacio frecuencia en DL y tiempo real en sistemas BCI, sin embargo, persisten desafíos por abordar para para mejorar el rendimiento, la aceptación y la difusión generalizada de nuestra estrategia. En particular, los siguientes aspectos podrían ser de interés para investigaciones futuras:

- Con el fin de validar la efectividad y generalización de la estrategia de procesamiento propuesta, tenemos previsto realizar pruebas utilizando una variedad más amplia de bases de datos públicas de MI, además de nuestras propias bases de datos. Esta ampliación en la diversidad de conjuntos de datos permitirá una validación más completa de la efectividad y generalización de la estrategia, mediante una evaluación más detallada y exhaustiva [Nahmias et al.,].
- Además, se investigarán enfoques innovadores para la extracción de características, con el propósito de incrementar la precisión en la clasificación y garantizar la confiabilidad de los sistemas de BCI [Sharma et al., 2023b].
- Se investigarán arquitecturas contemporáneas de DL, es de vital importancia que los modelos de DL evolucionen constantemente, por lo que el enfoque propuesto debe ser adaptable para aprovechar los avances en técnicas de DL [Wang et al., 2023, Duan et al., 2023].
- La densidad de electrodos ha sido siempre un tema esencial de debate en el ámbito de los sistemas BCI. El método de adquisición propuesto tiene el potencial de ser paralelizado, lo que permitiría aumentar significativamente el número de electrodos [Allouch et al., 2023].

Estos puntos destacan áreas prometedoras para futuras investigaciones que podrían fortalecer aún más nuestra estrategia y avanzar en la eficacia y aplicabilidad de los sistemas BCI-MI.

4.3 Productos académicos

4.3.1 Artículo

- El artículo titulado “Image-based EEG Representation from Gaussian Connectivity to support Motor Imagery Discrimination using Deep Learning” fue enviado a la revista *Computation - Journals* | MPDI.
- El artículo titulado “Real-time processing for BCI-based MI paradigms using Deep Learning Models” fue enviado al congreso CLIEEE 2023.

4.3.2 Patente

El sistema fue sometidos a la convocatoria *Crearlo no es suficiente para un proceso de búsqueda de patentabilidad* con la *Universidad Nacional de Colombia sede Manizales* como beneficiario principal con el título “MÉTODO Y SISTEMA PARA LA SINCRONIZACIÓN DE MARCADORES ASOCIADOS A SISTEMAS DE INTERFAZ CEREBRO-COMPUTADOR”, postulación ID 343 y Número de solicitud NC2022/0007405 del 28 de mayo de 2022.

4.3.3 Registro de software y repositorios

Un script desarrollado con BCI-Framework para el paradigma de imaginación motora basado en estímulo de juegos (interfaz Pacman) fue presentado al registro de software en la *Universidad Nacional de Colombia sede Manizales*.

Repositorio “Image-based EEG Representation from Gaussian Connectivity” disponible en: <https://github.com/alegomezri/Image-based-EEG-Representation>

ELECTRODOS DE COPA PARA EEG

La electroencefalografía (EEG) y la electrooculografía (EOG) son métodos de monitorización electrofisiológica en neurociencia y exploración clínica. EEG y EOG las señales se pueden utilizar en el diseño de interfaces cerebro-computadora (BCI) que interpretan la actividad cerebral. Debido al hecho de que son enfoques sencillos para evaluar las oscilaciones cerebrales y movimientos oculares, y porque utilizan técnicas estándar de laboratorio y/o móviles [Yap et al., 2017].

Las señales de electroencefalograma (EEG) son una representación única de la actividad eléctrica de las neuronas, que pueden respaldar el reconocimiento biométrico. Están relacionadas con las funciones corporales, estas señales son aproximadamente inferiores a $100 \mu V$ y 100 Hz, son las más utilizadas para sistemas BCI debido a su alta resolución temporal, la relativa facilidad y rentabilidad de la adquisición de señales cerebrales en comparación con los otros métodos. Sin embargo, las señales de EEG plantean desafíos de procesamiento; dado que no son estacionarios, pueden sufrir ruido externo y son propensos a los artefactos de señal. Además, las señales de EEG pueden verse afectadas por la postura y el estado de ánimo de un sujeto [Yap et al., 2017].

A.1 Electroencefalografía

Las BCI usan señales cerebrales para recopilar información sobre las intenciones del usuario. A tal efecto, las BCI se basan en un registro que mide la actividad cerebral y traduce la información en señales eléctricas tratables. Dos tipos de actividades cerebrales pueden monitorizarse: (i) electrofisiológicas y (ii) hemodinámicas [Citron, 2012].

La actividad electrofisiológica es generada, ver Figura A-1, por transmisores electroquímicos que intercambian información entre las neuronas, las neuronas generan corrientes iónicas que fluyen dentro y a través de las neuronas, la gran variedad de rutas de corriente se puede simplificar como una corriente de conducción dipolo de una fuente a un sumidero a través del tronco dendrítico. Estas corrientes intracelulares se conocen como corrientes primarias. La conservación de las cargas eléctricas significa que las corrientes primarias están encerradas por energía extracelular, flujos de corriente, que se conocen como corrientes secundarias [Li et al., 2018]. La actividad electrofisiológica se mide por electroencefalografía, electrocorticografía, magnetoencefalografía y señal eléctrica adquisición en neuronas individuales.

Los BCI basados en electroencefalografía consisten en un conjunto de sensores que adquieren señales de electroencefalografía de diferentes áreas del cerebro. Sin embargo, la calidad de las señales de electroencefalografía se ve afectada por el cuero cabelludo, cráneo y muchas otras capas, así como ruido de fondo. El ruido es clave para la electroencefalografía y otros métodos de neuroimagen, en la medida en que reduce la SNR y por lo tanto la capacidad de extraer información significativa de las señales registradas [Ros et al., 2014].

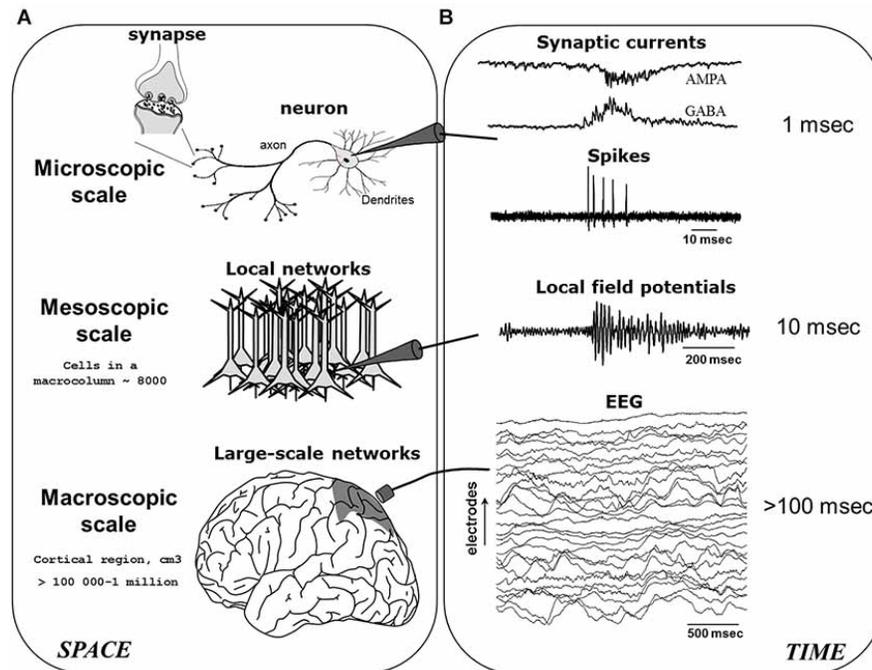


Figura A-1. Generación de EEG, tomada de [Ros et al., 2014]

A.1.1 Electroodos de copa para EEG

Se realiza el montaje 10-20, como se observa en la Figura ?? para la adquisición de señales de Electroencefalografía (EEG) de manera manual con electrodos de copa, de la siguiente manera:

- Se lava el cabello del sujeto con shampoo sin sal y jabon de coco, para realizar una limpieza profunda del mismo, se seca con una toalla y luego con el secador de cabello o de manera natural si no importa el tiempo que éste tarde.
- Con una cinta métrica se realiza la medición de la cabeza del sujeto desde el punto cefalométrico nasión, hasta la unión, esta medida se divide en dos y en ese punto se realiza la primera señalización que sirva como punto de

referencia para colocar los electrodos, se utiliza un plumón para realizar esta marcación, para la parte lateral se mide desde la punta de la oreja izquierda hasta la derecha y esta se divide en dos y debe coincidir con la marca anterior, teniendo así la mitad, de la mitad de la cabeza donde iría el electrodo de referencia Cz.

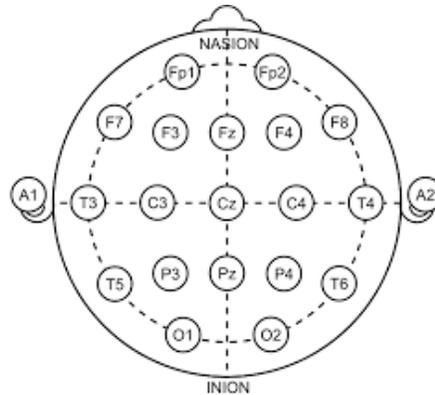


Figura A-2. Montaje 10-20 para adquisición de EEG, tomada de [Li et al., 2018]

- Partiendo del electrodo Cz como referencia, hacia la parte frontal de la cabeza, a esa medida se le saca el 20 % y allí se pondría el electrodo Fz, así mismo hacia la parte occipital desde Cz iría el electrodo Pz. Como se observa en la Fotografía A-2.
- Se realiza la medición desde el electrodo Pz se le saca el 20 % y se coloca el electrodo Oz. Desde el electrodo Fz hacia la parte frontoparietal se saca el 20 % de esa medida y se coloca el electrodo Fpz (Tierra), teniendo los electrodos ubicados en la parte vertical de la cabeza en una distribución de 20 % como se observa en la Fotografía A-4.
- Para Fz, Cz, Pz, y Oz serían canales hacia la derecha e izquierda F3 y F4, C3 y C4 P3 y P4, si es distribución de 10 % sería O1 y O2. En la parte temporal se colocan después de Cz con una distribución de 10 % observar Fotografía A-5.



Figura A-3. Fotografía electrodos de copa vista frontal

- Para colocar los electrodos, se realiza la limpieza del cuero cabelludo en lugar de la marca con un copito o algodón con alcohol o alguna sustancia desinfectante, al electrodo de copa se limpia con alcohol y se le aplica la pasta *Ten20 conductive* de manera que quedé llena la copa de éste material, se coloca en el cuero cabelludo y se pega con una cinta adhesiva en este caso micropore, y se procede a realizar las pruebas.
- Medir impedancias como se ha mencionado anteriormente, deben estar en la escala de $1\text{k}\Omega$ a $15\text{k}\Omega$, si por el contrario algún electrodo no se encuentra

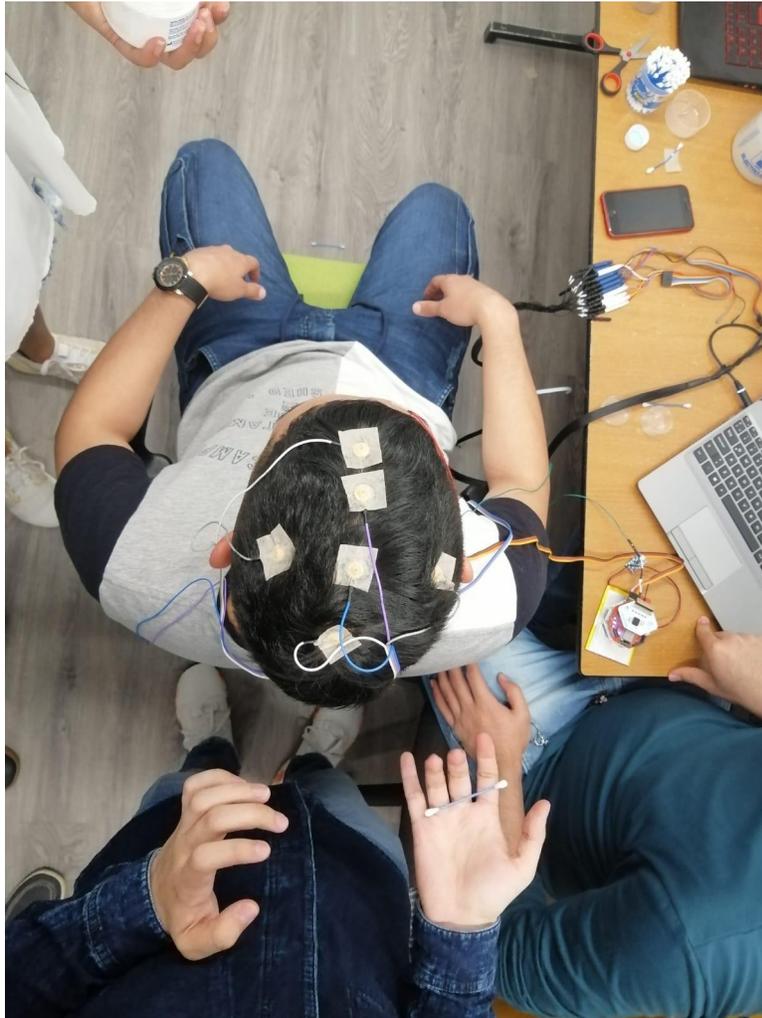


Figura A-4. Fotografía electrodos de copa vista superior

en este rango, se debe retirar y acomodar el cabello para que la medición este correcta.

- Para la limpieza de los electrodos de copa se colocan en un vaso con agua durante 3 horas para que se remueva el exceso y se limpian con un copito.

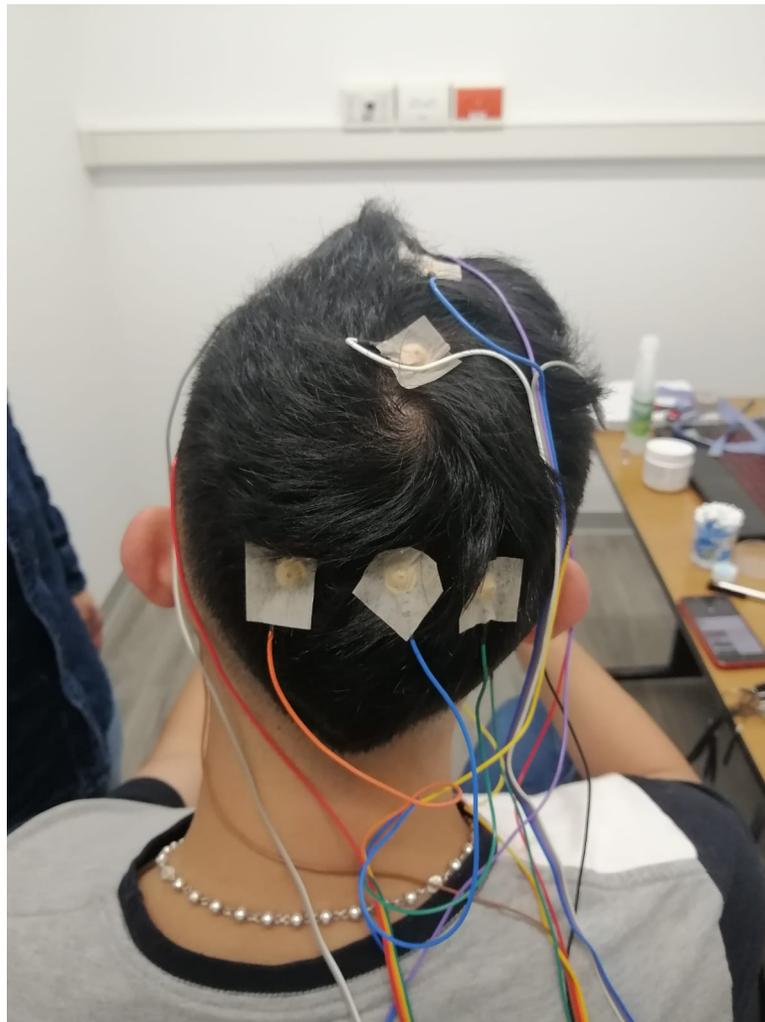


Figura A-5. Fotografía electrodos de copa vista posterior

ELECTROOCULOGRAFÍA

El ojo actúa como un dipolo entre la córnea (potencial positivo) y la retina (potencial negativo) que causa un campo eléctrico alrededor del globo ocular. Por lo tanto, cuando los humanos realizan movimientos sacádicos del ojo, generan señales relativas a este potencial llamado señales de electrooculografía (EOG). Estas señales se puede medir colocando electrodos cerca del ojo. Se pueden emplear configuraciones diferentes de electrodos para adquirir las señales de EOG. Las propiedades de estas señales cambian dependiendo del número y ubicación de los electrodos [López et al., 2016].

La EOG es una de los métodos utilizados para la estimación de la orientación del ojo. Las mediciones de EOG se basan en la modulación de amplitud de voltaje entre dos electrodos colocados alrededor de un ojo. Este voltaje depende directamente del ángulo del ojo, observar Fotografía **B-1**.

El movimiento del ojo es controlado por seis músculos extraoculares y un músculo que controla la elevación del párpado. Cuando el globo ocular se mueve al lado, el

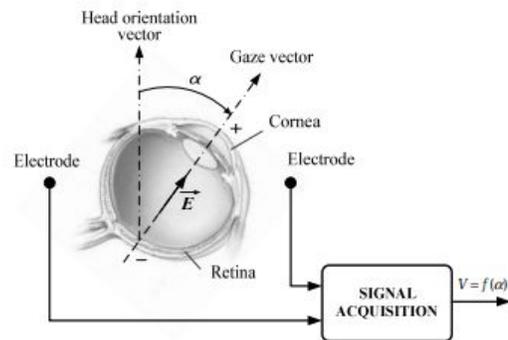


Figura B-1. Vista general de un sistema de medición EOG figura tomada de [López et al., 2016].

voltaje permanece positivo o negativo (dependiendo de colocación del electrodo) y vuelve a cero cuando se mira directamente [Malmivuo et al., 1995]. El voltaje para el movimiento horizontal del ojo es de hasta $16 \mu\text{V}$ para cada grado de movimiento ocular, mientras que es de $14 \mu\text{V}$ para movimiento. Este comportamiento es casi lineal para el ángulo de la mirada, que van desde $\pm 30^\circ$ verticalmente, y $\pm 50^\circ$ para movimiento horizontal. La polaridad registrada depende de la configuración del electrodo, ya que la señal es positiva cuando los ojos se mueven hacia el electrodo positivo. En humanos, la señal EOG varía de 0.05 a 3.5 mV , con un ancho de banda típico de CC a 50 Hz . sin embargo, el ancho de banda de la señal principal del movimiento ocular se encuentra en el rango de $0,1 \text{ Hz}$ a 40 Hz . En este rango de frecuencia, la señal EOG, como otras bioseñales, se corrompe por interferencias ambientales y otras señales bioeléctricas [García-Bermúdez et al., 2010].

En humanos, la señal de EOG oscila entre $0,05$ y $3,5 \text{ mV}$, con un ancho de banda típico de CC a 50 Hz [García-Bermúdez et al., 2010]. sin embargo, el ancho de banda principal de la señal del movimiento ocular se encuentra en el rango de $0,1 \text{ Hz}$ a 40 Hz , por lo que las señales por encima de 40 Hz deben ser remoto. En este rango de frecuencia la señal EOG, como otras bioseñales, está corrompido por interferencias ambientales y otras señales bioeléctricas. La lectura del electrooculograma depende de muchos otros factores: colocación de electrodos, contacto piel-electrodo, iluminación condiciones, movimientos de la cabeza,

parpadeo, etc. Los parpadeos intencionales son fáciles de distinguir de parpadeo involuntario porque mientras que el parpadeo involuntario típico está relacionado con ambos párpados juntos, el parpadeo voluntario es asimétrico y muestra un pico pronunciado con más amplitud.[Barea et al., 2002]

Por otro lado, el acondicionamiento de señales presenta un desafío de diseño en detectando pequeñas señales de AC con varias interferencias en el presencia de grandes diferenciales de potencial DC. Con el fin de eliminar o minimizar estos artefactos, se ha realizado un esfuerzo considerable hacerse en las etapas de acondicionamiento para asegurarse de que la señal EOG capturada tuvo las mínimas perturbaciones posibles y luego durante el procesamiento de los mismos para obtener la mejor posibles resultados [Barea et al., 2002].

B.0.1 Electrodo de copa para EOG

- Para adquirir datos de EOG se utiliza el siguiente montaje: En esta

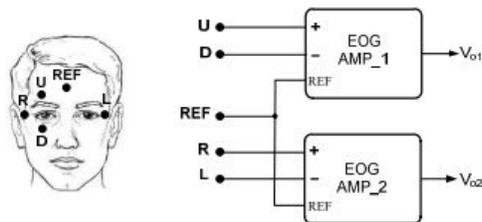


Figura B-2. Configuración de cinco electrodos para EOG figura tomada de [López et al., 2016].

configuración, la señal EOG se puede procesar por separado a través de canales horizontales y verticales, por lo que las posiciones se distribuyen comúnmente como se observa en la Figura B-2, los electrodos se colocan a ambos lados de los ojos (R - L) y por encima y por debajo de ellos (U - D) para lograr la derivación de la Señal EOG de cada canal. Para la adquisición de señales de EOG se coloca el montaje de 5 electrodos de la siguiente manera:



Figura B-3. Fotografía de los electrodos de copa de vista frontal.

- Se limpia la cara con algodón y alcohol en los puntos donde se van a colocar los electrodos, de la misma manera se limpian los electrodos.
- Se llena de pasta "*Ten20 conductive*" el electrodo de copa y se coloca sobre la piel en la parte frontal sobre el punto cefalométrico nasión, como se observa en la Fotografía B-3, (cable negro) que se referencia como la tierra (GND), en la parte frontal arriba y abajo del ojo (cable rojo y naranja) fotografía.B-4, en los esfenoides derecho (cable café) Fotografía B-3 e izquierdo (cable amarillo) fotografía.B-4 al lado de los ojos. Y por ultimo se

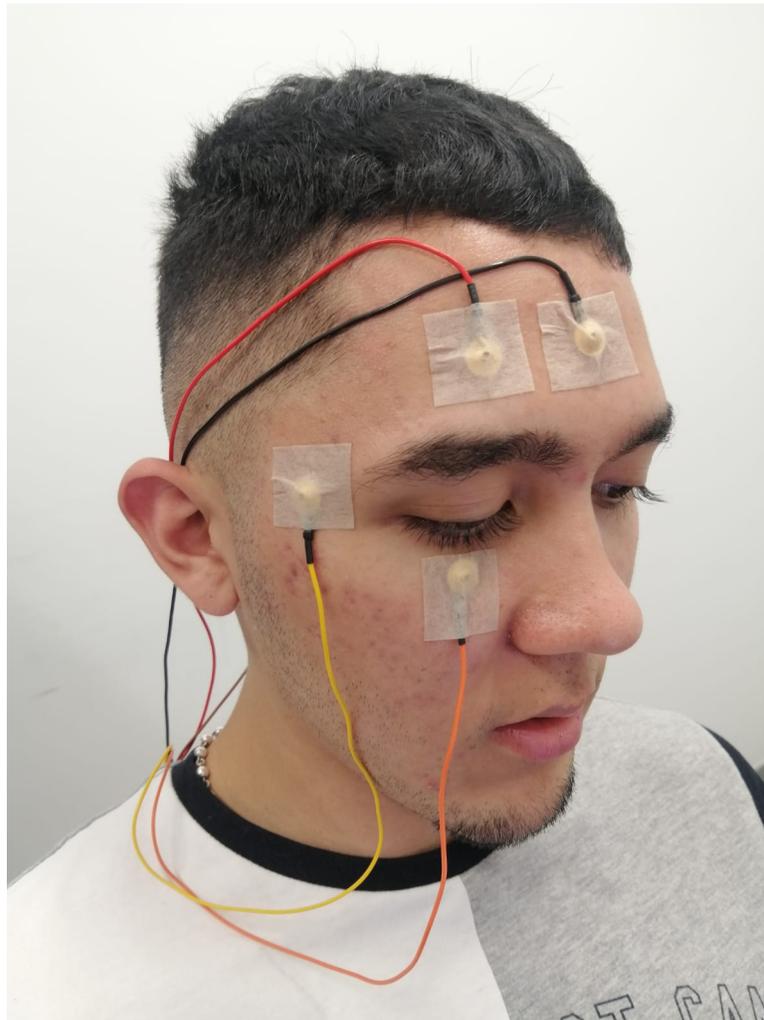


Figura B-4. Fotografía de los electrodos de copa de vista lateral.

coloca el electrodo de referencia bias en el mastoides izquierdo o derecho
Fotografía B-5.

B.0.2 Electrodo seco para EOG

- Se limpia la cara con algodón y alcohol en los puntos donde se van a colocar los electrodos, de la misma manera se limpian los electrodos.

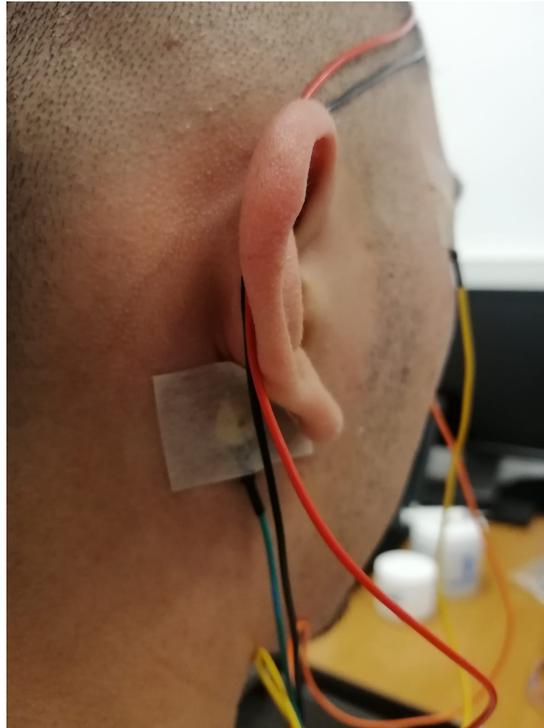


Figura B-5. Fotografía de electrodo en el mastoides derecho.

- Se coloca el electrodo seco con la misma configuración de 5 electrodos mencionada anteriormente o alguna de su preferencia, el electrodo seco trae su tela adherente, se pone en el rostro y se coloca la tela sobre el electrodo. En esta prueba se utilizó la configuración de 5 electrodos como se observa en la Fotografía B-2.
- También se pueden utilizar otros tipos de electrodos, como en las Fotografías B-6, B-7, se utilizó el mismo montaje pero con electrodos secos, que solo necesitan que la piel este limpia y se colocan sin necesidad de ningún tipo de gel o crema conductiva.
- Después de tener puestos los electrodos con la configuración necesaria, se procede a adquirir las señales de EOG.



Figura B-6. Fotografía de los electrodos secos vista lateral izquierda.



Figura B-7. Fotografía de los electrodos secos vista lateral derecha.

MEMORIA DE TRABAJO VISUOESPACIAL: TAREA DE DETECCIÓN DE CAMBIOS

La tarea consiste en recordar los colores de un conjunto de cuadrados que se muestran en la pantalla de una computadora, denominado matriz de memoria, y luego compararlos con los colores de un segundo conjunto de cuadrados ubicados en las mismas posiciones, denominado matriz de prueba [Vogel and Machizawa, 2004]. Una prueba de la tarea comienza con una flecha que indica el lado izquierdo o derecho de la pantalla durante 0,2 s. Luego, aparece una matriz de memoria en la pantalla durante 0,1 s. Para cada prueba, las matrices de memoria se muestran en ambos hemisferios, pero el sujeto debe recordar solo las que aparecen en el lado indicado por la señal de flecha. A continuación, después de un intervalo de retención que dura 0,9 s, aparece una matriz de prueba durante un período de 2 s, como se observa en la figura C-1. Durante este período, el sujeto informa si los colores de todos los elementos en la memoria y las matrices de

prueba coinciden. La tarea tiene tres niveles según la cantidad de elementos en la matriz de memoria: carga de memoria baja (un cuadrado), carga de memoria media (dos cuadrados) y carga de memoria alta (cuatro cuadrados), ver Figura C-2. El sujeto debe realizar un total de 300 intentos, con 100 intentos por cada nivel de carga de memoria (50 intentos por hemisferio). Los ensayos de diferentes niveles se presentan al azar. El color de uno de los cuadrados en la matriz de prueba difiere de su contraparte en la matriz de memoria en el 50 % de las pruebas.

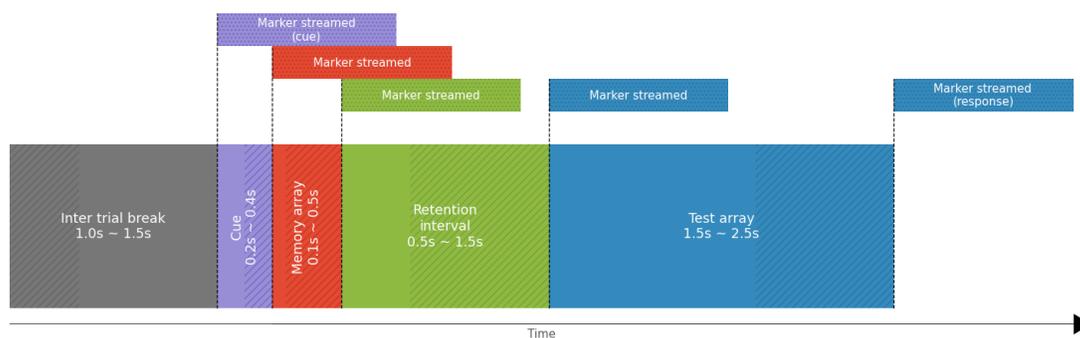


Figura C-1. Línea de tiempo para la ejecución del paradigma memoria de trabajo visuoespacial.

Presentación de estímulos:

Todos los estímulos se presentan en una pantalla de computadora situada a 120 cm del sujeto. Las matrices de estímulo aparecen dentro de dos regiones rectangulares que están centradas a la izquierda y a la derecha de una cruz de fijación central sobre un fondo gris (el símbolo representa los grados del ángulo visual 2). Cada cuadrado de color (×) se selecciona aleatoriamente de un conjunto de siete colores (rojo, azul, violeta, verde, amarillo, negro y blanco). Un color dado no puede aparecer más de dos veces dentro de una matriz. Las posiciones de los estímulos se aleatorizaron en cada prueba, con la restricción de que la distancia entre cuadrados dentro de un hemisferio fuera al menos (de centro a centro).

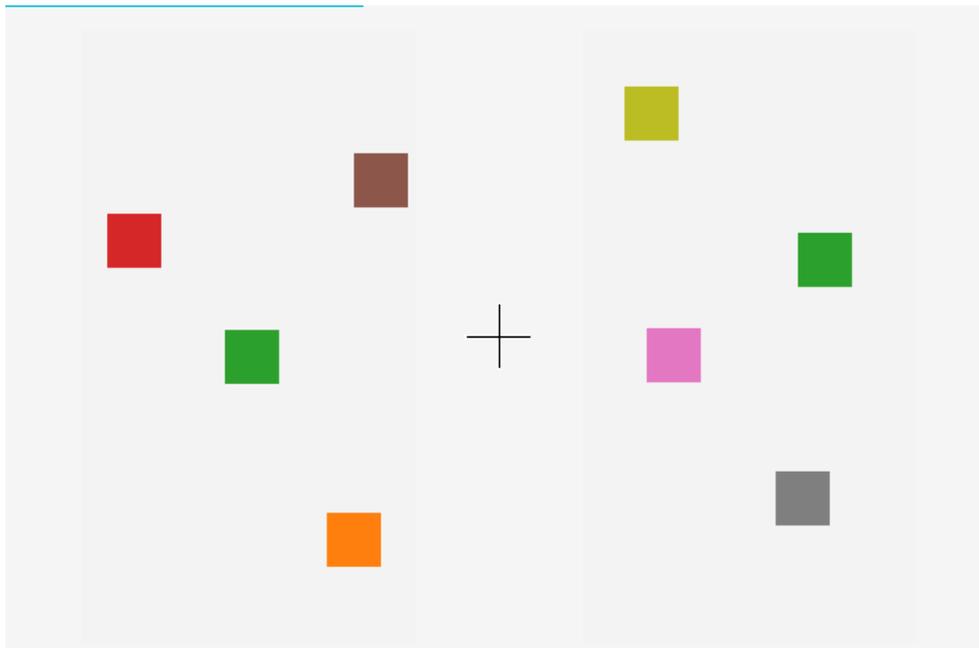


Figura C-2. Presentación de estímulos para el paradigma memoria de trabajo visoespacial.

Intervalos

Descanso entre pruebas:

- Descanso en milisegundos entre intentos, 2000 ms por defecto.

Señal de flecha:

- Tiempo en pantalla para la señal en milisegundos, 200 ms por defecto.

Matriz de memoria:

- Tiempo utilizado para visualizar la matriz, 100 ms por defecto.

Intervalo de retención:

- Tiempo utilizado para memorizar la matriz, 900 ms por defecto.

Matriz de prueba:

- Tiempo empleado por el sujeto en la respuesta, 2000 ms por defecto.

C.1 Adquisición

Se realizó la adquisición de datos con el paradigma de memoria visual de trabajo, se tomaron datos de 7 sujetos, en la Figura C-3 se observa la adquisición de señales mientras el sujeto realizaba la tarea, también se realizó la respectiva medición de impedancias, se usó el montaje estándar 10-20, 16 canales y una frecuencia de muestro de 1000 Hz.



Figura C-3. Adquisición de datos de EEG para memoria visual de trabajo.

ESTADO DE REPOSO Y ADQUISICIÓN DE RUIDO

Este experimento realiza la misma tarea implementada en [Cho et al., 2017]: Descansar con los ojos abiertos, descansar con los ojos cerrados, parpadeo de los ojos, movimiento del globo ocular arriba/abajo, movimiento del globo ocular izquierda/derecha, movimiento de la cabeza izquierda/derecha y apretar la mandíbula. El tiempo de adquisición de tiempo para cada tarea se puede configurar de forma independiente. El sujeto puede decidir explícitamente cuándo continuar con la siguiente tarea con un evento de teclado.

Todas las tareas tienen la misma opción de configuración, el tiempo de adquisición, desde 0 (tarea deshabilitada) hasta 5 minutos, 1 minuto por defecto, ver Figura **D-1**.

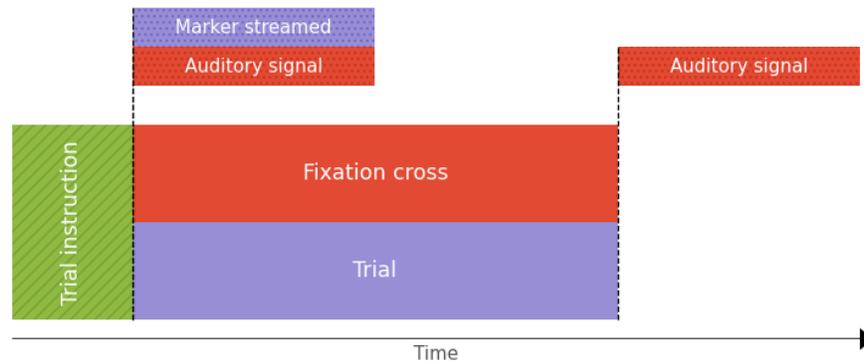


Figura D-1. Línea de tiempo para la ejecución del paradigma estado de reposo y adquisición de ruido.

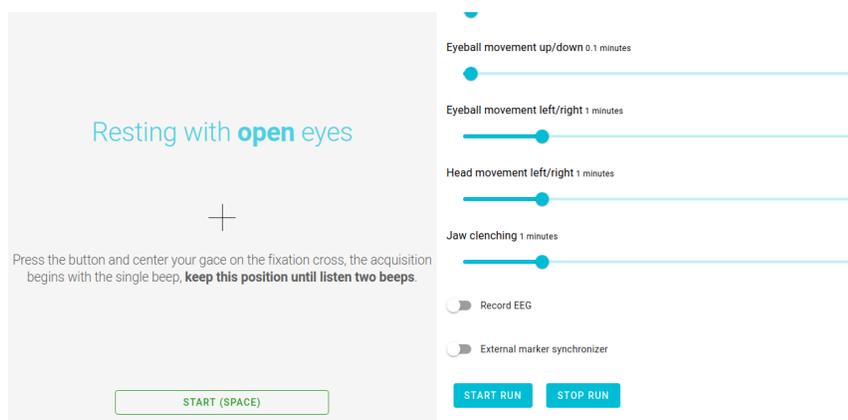


Figura D-2. presentación de estímulos para el paradigma estado de reposo y adquisición de ruido.

D.1 Adquisición

Se realizó la adquisición de datos con el paradigma estado de reposo y adquisición de ruido, ver Figura D-3, se tomaron datos de 5 sujetos, con la respectiva medición de impedancias, se utilizó el montaje estándar 10-20, 16 canales y una frecuencia de muestro de 1000 Hz.



Figura D-3. Adquisición de datos, con los ojos cerrados.

BIBLIOGRAFÍA

- [Abhang et al., 2016] Abhang, P. A., Gawali, B. W., and Mehrotra, S. C. (2016). *Introduction to EEG-and speech-based emotion recognition*. Academic Press. (páginas 98 and 99)
- [Abiri et al., 2019] Abiri, R., Borhani, S., Sellers, E. W., Jiang, Y., and Zhao, X. (2019). A comprehensive review of eeg-based brain-computer interface paradigms. *Journal of neural engineering*, 16(1):011001. (página 3)
- [Aghaei et al., 2015] Aghaei, A. S., Mahanta, M. S., and Plataniotis, K. N. (2015). Separable common spatio-spectral patterns for motor imagery bci systems. *IEEE Transactions on Biomedical Engineering*, 63(1):15-29. (página 30)
- [Ahmadi et al., 2012] Ahmadi, A., Dehzangi, O., and Jafari, R. (2012). Brain-computer interface signal processing algorithms: A computational cost vs. accuracy analysis for wearable computers. In *2012 Ninth International Conference on Wearable and Implantable Body Sensor Networks*, pages 40-45. IEEE. (página 26)

- [Ai et al., 2019] Ai, Q., Chen, A., Chen, K., Liu, Q., Zhou, T., Xin, S., and Ji, Z. (2019). Feature extraction of four-class motor imagery eeg signals based on functional brain network. *Journal of neural engineering*, 16(2):026032. (páginas 30 and 110)
- [Allouch et al., 2023] Allouch, S., Kabbara, A., Duprez, J., Khalil, M., Modolo, J., and Hassan, M. (2023). Effect of channel density, inverse solutions and connectivity measures on eeg resting-state networks reconstruction: A simulation study. *NeuroImage*, 271:120006. (página 117)
- [Alotaiby et al., 2015] Alotaiby, T., El-Samie, F. E. A., Alshebeili, S. A., and Ahmad, I. (2015). A review of channel selection algorithms for eeg signal processing. *EURASIP Journal on Advances in Signal Processing*, 2015:1-21. (páginas 10 and 15)
- [Altaheri et al., 2023] Altaheri, H., Muhammad, G., Alsulaiman, M., Amin, S. U., Altuwaijri, G. A., Abdul, W., Bencherif, M. A., and Faisal, M. (2023). Deep learning techniques for classification of electroencephalogram (eeg) motor imagery (mi) signals: A review. *Neural Computing and Applications*, 35(20):14681-14722. (páginas 21, 23y24)
- [Alvarez and Rossetti, 2015] Alvarez, V. and Rossetti, A. O. (2015). Clinical use of eeg in the icu: technical setting. *Journal of clinical neurophysiology*, 32(6):481-485. (páginas 5 and 14)
- [An et al., 2014] An, X., Kuang, D., Guo, X., Zhao, Y., and He, L. (2014). A deep learning method for classification of eeg data based on motor imagery. In *Intelligent Computing in Bioinformatics: 10th International Conference, ICIC 2014, Taiyuan, China, August 3-6, 2014. Proceedings 10*, pages 203-210. Springer. (página 27)
- [Anderson, 2004] Anderson, K. D. (2004). Targeting recovery: priorities of the spinal cord-injured population. *Journal of neurotrauma*, 21(10):1371-1383. (página 2)

- [Arns et al., 2013] Arns, M., Conners, C. K., and Kraemer, H. C. (2013). A decade of eeg theta/beta ratio research in adhd: a meta-analysis. *Journal of attention disorders*, 17(5):374–383. (página 2)
- [Ashenaee et al., 2022] Ashenaee, R., Beheshti, A. A., and Rezaii, T. Y. (2022). Stable eeg-based biometric system using functional connectivity based on time-frequency features with optimal channels. *Biomedical Signal Processing and Control*, 77:103790. (página 24)
- [Assran et al., 2020] Assran, M., Aytekin, A., Feyzmahdavian, H. R., Johansson, M., and Rabbat, M. G. (2020). Advances in asynchronous parallel and distributed optimization. *Proceedings of the IEEE*, 108(11):2013–2031. (páginas 9 and 14)
- [Barea et al., 2002] Barea, R., Boquete, L., Mazo, M., and López, E. (2002). System for assisted mobility using eye movements based on electrooculography. *IEEE transactions on neural systems and rehabilitation engineering*, 10(4):209–218. (página 129)
- [Bashivan et al., 2015] Bashivan, P., Rish, I., Yeasin, M., and Codella, N. (2015). Learning representations from eeg with deep recurrent-convolutional neural networks. *arXiv preprint arXiv:1511.06448*. (página 27)
- [Becker et al., 2022] Becker, S., Dhindsa, K., Mousapour, L., and Al Dabagh, Y. (2022). Bci illiteracy: it’s us, not them. optimizing bcis for individual brains. In *2022 10th International Winter Conference on Brain-Computer Interface (BCI)*, pages 1–3. IEEE. (página 3)
- [Beniczky et al., 2017] Beniczky, S., Aurlien, H., Brøgger, J. C., Hirsch, L. J., Schomer, D. L., Trinka, E., Pressler, R. M., Wennberg, R., Visser, G. H., Eisermann, M., et al. (2017). Standardized computer-based organized reporting of eeg: Score-second version. *Clinical Neurophysiology*, 128(11):2334–2346. (página 14)
- [Boere et al., 2023] Boere, K., Parsons, E., Binsted, G., and Krigolson, O. E. (2023). How low can you go? measuring human event-related brain potentials from a two-channel eeg system. *International Journal of Psychophysiology*, 187:20–26. (páginas 10 and 15)

- [Bonnet et al., 2022] Bonnet, C., Bayram, M., El Bouzaïdi Tiali, S., Lebon, F., Harquel, S., Palluel-Germain, R., and Perrone-Bertolotti, M. (2022). Kinesthetic motor-imagery training improves performance on lexical-semantic access. *PLoS one*, 17(6):e0270352. (página 2)
- [Bozhokin and Suslova, 2021] Bozhokin, S. V. and Suslova, I. B. (2021). Wavelet correlation of non-stationary bursts of eeg. In *BIOSIGNALS*, pages 142–149. (páginas 8, 10y12)
- [Cárdenas-Peña et al., 2017] Cárdenas-Peña, D., Collazos-Huertas, D., and Castellanos-Dominguez, G. (2017). Enhanced data representation by kernel metric learning for dementia diagnosis. *Frontiers in neuroscience*, 11:413. (página 6)
- [Cardona-Álvarez et al., 2023] Cardona-Álvarez, Y. N., Álvarez-Meza, A. M., Cárdenas-Peña, D. A., Castaño-Duque, G. A., and Castellanos-Dominguez, G. (2023). A novel openbci framework for eeg-based neurophysiological experiments. *Sensors*, 23(7):3763. (páginas 2, 3, 9, 29y71)
- [Carvalhaes and De Barros, 2015] Carvalhaes, C. and De Barros, J. (2015). The surface laplacian technique in EEG: Theory and methods. *International Journal of Psychophysiology*, 97(3):174–188. (página 44)
- [Changoluisa et al., 2020] Changoluisa, V., Varona, P., and Rodríguez, F. D. B. (2020). A low-cost computational method for characterizing event-related potentials for bci applications and beyond. *IEEE Access*, 8:111089–111101. (página 26)
- [Chattopadhyay et al., 2018] Chattopadhyay, A., Sarkar, A., Howlader, P., and Balasubramanian, V. N. (2018). Grad-cam++: Generalized gradient-based visual explanations for deep convolutional networks. In *2018 IEEE winter conference on applications of computer vision (WACV)*, pages 839–847. IEEE. (páginas 51 and 52)
- [Chavan and Kolte, 2015] Chavan, A. and Kolte, M. (2015). Improved eeg signal processing with wavelet based multiscale pca algorithm. In *2015 International Conference on Industrial Instrumentation and Control (ICIC)*, pages 1056–1059. IEEE. (página 23)

- [Chen and Stouffs, 2021] Chen, J. and Stouffs, R. (2021). From exploration to interpretation: Adopting deep representation learning models to latent space Interpretation of architectural design alternatives. (página 12)
- [Cheng et al., 2020] Cheng, L., Li, D., Yu, G., Zhang, Z., Li, X., and Yu, S. (2020). A motor imagery eeg feature extraction method based on energy principal component analysis and deep belief networks. *IEEE Access*, 8:21453–21472. (página 19)
- [Cho et al., 2017] Cho, H., Ahn, M., Ahn, S., Kwon, M., and Jun, S. C. (2017). Eeg datasets for motor imagery brain-computer interface. *GigaScience*, 6(7):gix034. (páginas 38, 40, 59, 64, 91, 92, 100, 104y139)
- [Cho et al., 2021] Cho, J.-H., Jeong, J.-H., and Lee, S.-W. (2021). Neurograsp: Real-time eeg classification of high-level motor imagery tasks using a dual-stage deep learning framework. *IEEE Transactions on Cybernetics*, 52(12):13279–13292. (páginas 5, 31y110)
- [Choi et al., 2020a] Choi, I., Kwon, G. H., Lee, S., and Nam, C. S. (2020a). Functional electrical stimulation controlled by motor imagery brain-computer interface for rehabilitation. *Brain Sciences*, 10(8):512. (página 1)
- [Choi et al., 2020b] Choi, J., Kim, K. T., Jeong, J. H., Kim, L., Lee, S. J., and Kim, H. (2020b). Developing a motor imagery-based real-time asynchronous hybrid bci controller for a lower-limb exoskeleton. *Sensors*, 20(24):7309. (páginas 5, 30, 31y110)
- [Choi, 2013] Choi, K. (2013). Electroencephalography (eeg)-based neurofeedback training for brain-computer interface (bci). *Experimental brain research*, 231:351–365. (página 74)
- [Chu et al., 2018] Chu, Y., Zhao, X., Zou, Y., Xu, W., Han, J., and Zhao, Y. (2018). A decoding scheme for incomplete motor imagery eeg with deep belief network. *Frontiers in neuroscience*, 12:680. (página 17)

- [Citron, 2012] Citron, F. M. (2012). Neural correlates of written emotion word processing: A review of recent electrophysiological and hemodynamic neuroimaging studies. *Brain and language*, 122(3):211-226. (página 120)
- [Collazos-Huertas et al., 2020] Collazos-Huertas, D., Caicedo-Acosta, J., Castaño-Duque, G. A., and Acosta-Medina, C. D. (2020). Enhanced multiple instance representation using time-frequency atoms in motor imagery classification. *Frontiers in Neuroscience*, 14:155. (páginas 3 and 4)
- [Collazos-Huertas et al., 2019] Collazos-Huertas, D., Cárdenas-Peña, D., and Castellanos-Dominguez, G. (2019). Instance-based representation using multiple kernel learning for predicting conversion to alzheimer disease. *International journal of neural systems*, 29(02):1850042. (página 6)
- [Collazos-Huertas et al., 2023] Collazos-Huertas, D. F., Álvarez-Meza, A. M., Cárdenas-Peña, D. A., Castaño-Duque, G. A., and Castellanos-Domínguez, C. G. (2023). Posthoc interpretability of neural responses by grouping subject motor imagery skills using cnn-based connectivity. *Sensors*, 23(5):2750. (páginas 86 and 102)
- [Collazos-Huertas et al., 2021a] Collazos-Huertas, D. F., Álvarez-Meza, A. M., and Castellanos-Dominguez, G. (2021a). Spatial interpretability of time-frequency relevance optimized in motor imagery discrimination using deep&wide networks. *Biomedical Signal Processing and Control*, 68:102626. (páginas 13, 49y53)
- [Collazos-Huertas et al., 2021b] Collazos-Huertas, D. F., Velasquez-Martinez, L. F., Perez-Nastar, H. D., Alvarez-Meza, A. M., and Castellanos-Dominguez, G. (2021b). Deep and wide transfer learning with kernel matching for pooling data from electroencephalography and psychological questionnaires. *Sensors*, 21(15):5105. (página 23)
- [Cona et al., 2009] Cona, F., Zavaglia, M., Astolfi, L., Babiloni, F., Ursino, M., et al. (2009). Changes in eeg power spectral density and cortical connectivity in healthy and tetraplegic patients during a motor imagery task. *Computational intelligence and neuroscience*, 2009. (página 25)

- [de Bogotá et al., 2018] de Bogotá, C. d. C. et al. (2018). La agenda 2030 y los objetivos de desarrollo sostenible una oportunidad para américa latina y el caribe. (página 2)
- [Deriche et al., 2019] Deriche, M., Arafat, S., Al-Insaif, S., and Siddiqui, M. (2019). Eigenspace time frequency based features for accurate seizure detection from eeg data. *IRBM*, 40(2):122-132. (página 23)
- [Deshmukh et al., 2021] Deshmukh, S., Thirupathi Rao, K., and Shabaz, M. (2021). Collaborative learning based straggler prevention in large-scale distributed computing framework. *Security and communication networks*, 2021:1-9. (páginas 9 and 14)
- [Djamal and Putra, 2020] Djamal, E. C. and Putra, R. D. (2020). Brain-computer interface of focus and motor imagery using wavelet and recurrent neural networks. *Telkomnika (Telecommunication Computing Electronics and Control)*, 18(5):2748-2756. (página 2)
- [Duan et al., 2021] Duan, X., Xie, S., Xie, X., Obermayer, K., Cui, Y., and Wang, Z. (2021). An online data visualization feedback protocol for motor imagery-based bci training. *Frontiers in human neuroscience*, 15:266. (páginas 11 and 16)
- [Duan et al., 2023] Duan, Y., Wang, Z., Li, Y., Tang, J., Wang, Y.-K., and Lin, C.-T. (2023). Cross task neural architecture search for eeg signal recognition. *Neurocomputing*, 545:126260. (página 117)
- [Echtioui et al., 2021] Echtioui, A., Zouch, W., Ghorbel, M., Mhiri, C., and Hamam, H. (2021). A novel ensemble learning approach for classification of eeg motor imagery signals. In *2021 International Wireless Communications and Mobile Computing (IWCMC)*, pages 1648-1653. IEEE. (página 27)
- [Farahani and Karwowski, 2019] Farahani, F. V. and Karwowski, W. (2019). Computational methods for analyzing functional and effective brain network connectivity using fmri. In *Advances in Neuroergonomics and Cognitive Engineering: Proceedings of the AHFE 2018 International Conference on Neuroergonomics and Cognitive Engineering, July 21-25, 2018, Loews Sapphire Falls Resort at Universal Studios, Orlando, Florida USA 9*, pages 101-112. Springer. (páginas 4 and 19)

- [Farahani et al., 2019] Farahani, F. V., Karwowski, W., and Lighthall, N. R. (2019). Application of graph theory for identifying connectivity patterns in human brain networks: a systematic review. *frontiers in Neuroscience*, 13:585. (páginas 4 and 19)
- [Feng et al., 2020] Feng, Z., Qian, L., Hu, H., and Sun, Y. (2020). Functional connectivity for motor imaginary recognition in brain-computer interface. In *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 3678–3682. IEEE. (página 24)
- [Feradov et al., 2020] Feradov, F., Mporas, I., and Ganchev, T. (2020). Evaluation of features in detection of dislike responses to audio–visual stimuli from eeg signals. *Computers*, 9(2):33. (página 23)
- [Fraiwan et al., 2021] Fraiwan, M., Alafeef, M., and Almomani, F. (2021). Gauging human visual interest using multiscale entropy analysis of eeg signals. *Journal of Ambient Intelligence and Humanized Computing*, 12(2):2435–2447. (página 1)
- [Friston,] Friston, K. Feb 2009a. causal modelling and brain connectivity in functional magnetic resonance imaging. *PLoS Biol*, 7(2):e33. (páginas 5 and 19)
- [Friston et al., 1991] Friston, K. J., Frith, C., Liddle, P., and Frackowiak, R. (1991). Comparing functional (pet) images: the assessment of significant change. *Journal of Cerebral Blood Flow & Metabolism*, 11(4):690–699. (páginas 4 and 19)
- [Fu et al., 2019] Fu, Z., Tu, Y., Di, X., Du, Y., Sui, J., Biswal, B. B., Zhang, Z., de Lacy, N., and Calhoun, V. D. (2019). Transient increased thalamic-sensory connectivity and decreased whole-brain dynamism in autism. *Neuroimage*, 190:191–204. (página 12)
- [García-Bermúdez et al., 2010] García-Bermúdez, R., Ruiz, F. R., Peñalver, J. G., Cansino, O. V., Pérez, L. V., Torres, C., and Becerra-García, R. (2010). Evaluation of electro-oculography data for ataxia sca-2 classification: A blind source separation approach. In *2010 10th International Conference on Intelligent Systems Design and Applications*, pages 237–241. IEEE. (página 128)

- [García-Murillo et al., 2021] García-Murillo, D. G., Alvarez-Meza, A., and Castellanos-Dominguez, G. (2021). Single-trial kernel-based functional connectivity for enhanced feature extraction in motor-related tasks. *Sensors*, 21(8):2750. (páginas 11 and 47)
- [García-Murillo et al., 2023] García-Murillo, D. G., Álvarez-Meza, A. M., and Castellanos-Dominguez, C. G. (2023). Kcs-fcnet: Kernel cross-spectral functional connectivity network for eeg-based motor imagery classification. *Diagnostics*, 13(6):1122. (páginas 3, 4, 46, 57, 59y83)
- [Géron, 2022] Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. .o'Reilly Media, Inc.". (páginas 46, 47, 59y104)
- [Han et al., 2019] Han, C.-H., Kim, Y.-W., Kim, D. Y., Kim, S. H., Nenadic, Z., and Im, C.-H. (2019). Electroencephalography-based endogenous brain-computer interface for online communication with a completely locked-in patient. *Journal of neuroengineering and rehabilitation*, 16:1-13. (páginas 8 and 11)
- [Hasan et al., 2020] Hasan, M. A., Khan, M. U., and Mishra, D. (2020). A computationally efficient method for hybrid eeg-fnirs bci based on the pearson correlation. *BioMed Research International*, 2020:1-13. (página 26)
- [Hassanpour et al., 2019] Hassanpour, A., Moradikia, M., Adeli, H., Khayami, S. R., and Shamsinejadbabaki, P. (2019). A novel end-to-end deep learning scheme for classifying multi-class motor imagery electroencephalography signals. *Expert Systems*, 36(6):e12494. (página 17)
- [He and Wu, 2019] He, H. and Wu, D. (2019). Transfer learning for brain-computer interfaces: A euclidean space data alignment approach. *IEEE Transactions on Biomedical Engineering*, 67(2):399-410. (página 2)
- [He et al., 2022] He, Y., Lu, Z., Wang, J., and Shi, J. (2022). A channel attention based mlp-mixer network for motor imagery decoding with eeg. In *ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1291-1295. IEEE. (página 20)

- [Hoffmann et al., 2021] Hoffmann, A., Fanconi, C., Rade, R., and Kohler, J. (2021). This looks like that... does it? shortcomings of latent space prototype interpretability in deep networks. *arXiv preprint arXiv:2105.02968*. (página 12)
- [Hsu, 2014] Hsu, W.-Y. (2014). Improving classification accuracy of motor imagery eeg using genetic feature selection. *Clinical EEG and neuroscience*, 45(3):163–168. (página 19)
- [Huang et al., 2020] Huang, W., Xue, Y., Hu, L., and Liuli, H. (2020). S-eegnet: Electroencephalogram signal classification based on a separable convolution neural network with bilinear interpolation. *IEEE Access*, 8:131636–131646. (página 18)
- [Huang et al., 2019] Huang, Y.-C., Chang, J.-R., Chen, L.-F., and Chen, Y.-S. (2019). Deep neural network with attention mechanism for classification of motor imagery eeg. In *2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)*, pages 1130–1133. IEEE. (página 21)
- [Hurtado-Rincón et al., 2016] Hurtado-Rincón, J. V., Martínez-Vargas, J. D., Rojas-Jaramillo, S., Giraldo, E., and Castellanos-Dominguez, G. (2016). Identification of relevant inter-channel eeg connectivity patterns: a kernel-based supervised approach. In *Brain Informatics and Health: International Conference, BIH 2016, Omaha, NE, USA, October 13-16, 2016 Proceedings*, pages 14–23. Springer. (página 6)
- [Ince et al., 2007] Ince, N. F., Tewfik, A. H., and Arica, S. (2007). Extraction subject-specific motor imagery time–frequency patterns for single trial eeg classification. *Computers in biology and medicine*, 37(4):499–508. (página 16)
- [Jiang et al., 2021] Jiang, P.-T., Zhang, C.-B., Hou, Q., Cheng, M.-M., and Wei, Y. (2021). Layercam: Exploring hierarchical class activation maps for localization. *IEEE Transactions on Image Processing*, 30:5875–5888. (página 51)
- [Kim and Im, 2021] Kim, H. and Im, C.-H. (2021). Influence of the number of channels and classification algorithm on the performance robustness to electrode shift in steady-state visual evoked potential-based brain-computer interfaces. *Frontiers in Neuroinformatics*, 15:750839. (páginas 10 and 15)

- [Kisakye, 2013] Kisakye, H. S. (2013). *Brain computer interfaces: OpenViBE as a platform for a p300 speller*. PhD thesis, Hochschule Heilbronn. (páginas 29 and 30)
- [Klein et al., 2022] Klein, F., Debener, S., Witt, K., and Kranczioch, C. (2022). fmri-based validation of continuous-wave fnirs of supplementary motor area activation during motor execution and motor imagery. *Scientific reports*, 12(1):3570. (página 10)
- [Ko et al., 2021] Ko, W., Jeon, E., Jeong, S., and Suk, H.-I. (2021). Multi-scale neural network for eeg representation learning in bci. *IEEE Computational Intelligence Magazine*, 16(2):31–45. (página 91)
- [Kong et al., 2021] Kong, Q., Wu, Y., Yuan, C., and Wang, Y. (2021). Ct-cad: Context-aware transformers for end-to-end chest abnormality detection on x-rays. In *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pages 1385–1388. IEEE. (páginas 21 and 91)
- [Kumar et al., 2016] Kumar, S., Sharma, A., Mamun, K., and Tsunoda, T. (2016). A deep learning approach for motor imagery eeg signal classification. In *2016 3rd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE)*, pages 34–39. IEEE. (página 27)
- [Kumar et al., 2021] Kumar, S., Sharma, R., and Sharma, A. (2021). Optical+: a frequency-based deep learning scheme for recognizing brain wave signals. *Peerj Computer Science*, 7:e375. (página 91)
- [Kundu and Ari, 2022] Kundu, S. and Ari, S. (2022). Brain-computer interface speller system for alternative communication: a review. *IRBM*, 43(4):317–324. (página 2)
- [Lawhern et al., 2018] Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., and Lance, B. J. (2018). Eegnet: a compact convolutional neural network for eeg-based brain-computer interfaces. *Journal of neural engineering*, 15(5):056013. (páginas 20, 52, 53, 59, 64, 91, 98y101)

- [Lee and Schachter, 1980] Lee, D.-T. and Schachter, B. J. (1980). Two algorithms for constructing a delaunay triangulation. *International Journal of Computer & Information Sciences*, 9(3):219–242. (página 49)
- [Li and Song, 2023] Li, C. and Song, L. (2023). Gcn-lstm for eeg classification based on unspoken speech of bilinguals. In *2023 24th International Conference on Digital Signal Processing (DSP)*, pages 1–4. IEEE. (páginas 20 and 52)
- [Li and Ruan, 2021] Li, M.-a. and Ruan, Z.-w. (2021). A novel decoding method for motor imagery tasks with 4d data representation and 3d convolutional neural networks. *Journal of Neural Engineering*, 18(4):046029. (página 26)
- [Li et al., 2018] Li, Z., Song, Y., Xiao, G., Gao, F., Xu, S., Wang, M., Zhang, Y., Guo, F., Liu, J., Xia, Y., et al. (2018). Bio-electrochemical microelectrode arrays for glutamate and electrophysiology detection in hippocampus of temporal lobe epileptic rats. *Analytical biochemistry*, 550:123–131. (páginas 120 and 122)
- [Liang et al., 2021] Liang, Y., Li, S., Yan, C., Li, M., and Jiang, C. (2021). Explaining the black-box model: A survey of local interpretation methods for deep neural networks. *Neurocomputing*, 419:168–182. (página 13)
- [Liu et al., 2022] Liu, G., Tian, L., and Zhou, W. (2022). Multiscale time-frequency method for multiclass motor imagery brain computer interface. *Computers in Biology and Medicine*, 143:105299. (página 11)
- [Llanos et al., 2013] Llanos, C., Rodriguez, M., Rodriguez-Sabate, C., Morales, I., and Sabate, M. (2013). Mu-rhythm changes during the planning of motor and motor imagery actions. *Neuropsychologia*, 51(6):1019–1026. (página 74)
- [López et al., 2016] López, A., Ferrero, F., Valledor, M., Campo, J. C., and Postolache, O. (2016). A study on electrode placement in eeg systems for medical applications. In *2016 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, pages 1–5. IEEE. (páginas 127, 128y129)

- [Luo et al., 2018] Luo, T.-j., Zhou, C.-l., and Chao, F. (2018). Exploring spatial-frequency-sequential relationships for motor imagery classification with recurrent neural network. *BMC bioinformatics*, 19(1):1–18. (páginas 4 and 18)
- [Ma et al., 2020] Ma, X., Wang, D., Liu, D., and Yang, J. (2020). Dwt and cnn based multi-class motor imagery electroencephalographic signal recognition. *Journal of neural engineering*, 17(1):016073. (página 18)
- [Malmivuo et al., 1995] Malmivuo, J., Plonsey, R., et al. (1995). *Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields*. Oxford University Press, USA. (página 128)
- [Marcos-Martínez et al., 2021] Marcos-Martínez, D., Martínez-Cagigal, V., Santamaría-Vázquez, E., Pérez-Velasco, S., and Hornero, R. (2021). Neurofeedback training based on motor imagery strategies increases eeg complexity in elderly population. *Entropy*, 23(12):1574. (página 2)
- [Marks and Isaac, 1995] Marks, D. F. and Isaac, A. R. (1995). Topographical distribution of eeg activity accompanying visual and motor imagery in vivid and non-vivid imagers. *British Journal of Psychology*, 86(2):271–282. (página 23)
- [Martini et al., 2020] Martini, M. L., Oermann, E. K., Opie, N. L., Panov, F., Oxley, T., and Yaeger, K. (2020). Sensor modalities for brain-computer interface technology: a comprehensive literature review. *Neurosurgery*, 86(2):E108–E117. (página 4)
- [Meng et al., 2022] Meng, C., Trinh, L., Xu, N., Enouen, J., and Liu, Y. (2022). Interpretability and fairness evaluation of deep learning models on mimic-iv dataset. *Scientific Reports*, 12(1):7166. (páginas 13, 22y116)
- [Miao et al., 2020] Miao, M., Hu, W., Yin, H., and Zhang, K. (2020). Spatial-frequency feature learning and classification of motor imagery eeg based on deep convolution neural network. *Computational and mathematical methods in medicine*, 2020. (páginas 1, 3y8)

- [Miraglia et al., 2022] Miraglia, F., Vecchio, F., Pappalettera, C., Nucci, L., Cotelli, M., Judica, E., Ferreri, F., and Rossini, P. M. (2022). Brain connectivity and graph theory analysis in alzheimer’s and parkinson’s disease: the contribution of electrophysiological techniques. *Brain Sciences*, 12(3):402. (página 19)
- [Mridha et al., 2021] Mridha, M. F., Das, S. C., Kabir, M. M., Lima, A. A., Islam, M. R., and Watanobe, Y. (2021). Brain-computer interface: Advancement and challenges. *Sensors*, 21(17):5746. (página 17)
- [Muñiz et al., 2009] Muñiz, C., Rodríguez, F. d. B., and Varona, P. (2009). Rtbio manager: a software platform to expand the applications of real-time technology in neuroscience. *BMC Neuroscience*, 10(Suppl 1):P49. (página 5)
- [Nahmias et al.,] Nahmias, D. O., Civillico, E. F., and Kontson, K. L. Deep learning and feature based medication classifications from eeg in a large clinical data set. *Scientific Reports*. (página 117)
- [Nasihatkon et al., 2009] Nasihatkon, B., Boostani, R., and Jahromi, M. Z. (2009). An efficient hybrid linear and kernel csp approach for eeg feature extraction. *Neurocomputing*, 73(1-3):432–437. (página 23)
- [Netzer et al., 2020] Netzer, E., Frid, A., and Feldman, D. (2020). Real-time eeg classification via coresets for bci applications. *Engineering applications of artificial intelligence*, 89:103455. (páginas 26 and 30)
- [Nicolas-Alonso and Gomez-Gil, 2012] Nicolas-Alonso, L. F. and Gomez-Gil, J. (2012). Brain computer interfaces, a review. *sensors*, 12(2):1211–1279. (página 3)
- [Padfield et al., 2019] Padfield, N., Zabalza, J., Zhao, H., Masero, V., and Ren, J. (2019). Eeg-based brain-computer interfaces using motor-imagery: Techniques and challenges. *Sensors*, 19(6):1423. (páginas 1, 3, 8, 11y15)
- [Phunruangsakao et al., 2022] Phunruangsakao, C., Achanccaray, D., and Hayashibe, M. (2022). Deep adversarial domain adaptation with few-shot learning for motor-imagery brain-computer interface. *IEEE Access*, 10:57255–57265. (página 20)

- [Pires et al., 2022] Pires, G., Cruz, A., Jesus, D., Yasemin, M., Nunes, U. J., Sousa, T., and Castelo-Branco, M. (2022). A new error-monitoring brain–computer interface based on reinforcement learning for people with autism spectrum disorders. *Journal of Neural Engineering*, 19(6):066032. (páginas 5, 31y110)
- [Polat et al., 2021] Polat, K., Aygun, A. B., and Kavsaoglu, A. R. (2021). Eeg based brain-computer interface control applications: A comprehensive review. *Journal of Bionic Memory*, 1(1):20–33. (páginas 1 and 10)
- [Pulgarin-Giraldo et al., 2017] Pulgarin-Giraldo, J. D., Ruales-Torres, A., Álvarez-Meza, A. M., and Castellanos-Dominguez, G. (2017). Relevant kinematic feature selection to support human action recognition in mocap data. In *Biomedical Applications Based on Natural and Artificial Computing: International Work-Conference on the Interplay Between Natural and Artificial Computation, IWINAC 2017, Corunna, Spain, June 19-23, 2017, Proceedings, Part II*, pages 501–509. Springer. (página 6)
- [Qayyum et al., 2022] Qayyum, A., Razzak, I., Moustafa, N., and Mazher, M. (2022). Progressive shallownet for large scale dynamic and spontaneous facial behaviour analysis in children. *Image and Vision Computing*, 119:104375. (páginas 20 and 52)
- [Rashid et al., 2020] Rashid, M., Sulaiman, N., PP Abdul Majeed, A., Musa, R. M., Ab Nasir, A. F., Bari, B. S., and Khatun, S. (2020). Current status, challenges, and possible solutions of eeg-based brain-computer interface: a comprehensive review. *Frontiers in neurorobotics*, page 25. (página 17)
- [Rodrigues et al., 2019] Rodrigues, P. G., Attux, R., Castellano, G., Soriano, D. C., et al. (2019). Space-time recurrences for functional connectivity evaluation and feature extraction in motor imagery brain-computer interfaces. *Medical & biological engineering & computing*, 57(8):1709–1725. (página 91)
- [Rolls et al., 2022] Rolls, E. T., Deco, G., Huang, C.-C., and Feng, J. (2022). The effective connectivity of the human hippocampal memory system. *Cerebral Cortex*, 32(17):3706–3725. (página 5)

- [Ros et al., 2014] Ros, T., J. Baars, B., Lanius, R. A., and Vuilleumier, P. (2014). Tuning pathological brain oscillations with neurofeedback: a systems neuroscience framework. *Frontiers in human neuroscience*, 8:1008. (páginas 120 and 121)
- [Rossini et al., 2019] Rossini, P. M., Di Iorio, R., Bentivoglio, M., Bertini, G., Ferreri, F., Gerloff, C., Ilmoniemi, R. J., Miraglia, F., Nitsche, M. A., Pestilli, F., et al. (2019). Methods for analysis of brain connectivity: An ifcn-sponsored review. *Clinical Neurophysiology*, 130(10):1833–1858. (página 12)
- [Roy et al., 2020] Roy, S., Chowdhury, A., McCreddie, K., and Prasad, G. (2020). Deep learning based inter-subject continuous decoding of motor imagery for practical brain-computer interfaces. *Frontiers in Neuroscience*, 14:918. (página 20)
- [Ruiz-Gómez et al., 2019] Ruiz-Gómez, S. J., Hornero, R., Poza, J., Maturana-Candelas, A., Pinto, N., and Gómez, C. (2019). Computational modeling of the effects of eeg volume conduction on functional connectivity metrics. application to alzheimer’s disease continuum. *Journal of neural engineering*, 16(6):066019. (página 25)
- [Saha and Baumert, 2020] Saha, S. and Baumert, M. (2020). Intra-and inter-subject variability in eeg-based sensorimotor brain computer interface: a review. *Frontiers in computational neuroscience*, 13:87. (página 8)
- [Schalk et al., 2004] Schalk, G., McFarland, D. J., Hinterberger, T., Birbaumer, N., and Wolpaw, J. R. (2004). Bci2000: a general-purpose brain-computer interface (bci) system. *IEEE Transactions on biomedical engineering*, 51(6):1034–1043. (páginas 28 and 29)
- [Selvaraju et al., 2016] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. (2016). Grad-cam: Visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision*, 128:336–359. (página 25)

- [Selvaraju et al., 2017] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision*, pages 618–626. (página 51)
- [Sharma et al., 2023a] Sharma, K., Dash, A., and Kumar, D. (2023a). Investigating the effect of eeg channel selection on inter-subject emotion classification. In *2023 13th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, pages 312–316. IEEE. (página 10)
- [Sharma et al., 2023b] Sharma, N., Sharma, M., Singhal, A., Vyas, R., Malik, H., Afthanorhan, A., and Hossaini, M. A. (2023b). Recent trends in eeg based motor imagery signal analysis and recognition: A comprehensive review. *IEEE Access*. (página 117)
- [Shen et al., 2017] Shen, Y., Lu, H., and Jia, J. (2017). Classification of motor imagery eeg signals with deep learning models. In *Intelligence Science and Big Data Engineering: 7th International Conference, IScIDE 2017, Dalian, China, September 22-23, 2017, Proceedings 6*, pages 181–190. Springer. (página 27)
- [Shin et al., 2022] Shin, H., Suma, D., and He, B. (2022). Closed-loop motor imagery eeg simulation for brain-computer interfaces. *Frontiers in Human Neuroscience*, 16:951591. (página 2)
- [Shoka et al., 2019] Shoka, A., Dessouky, M., El-Sherbeny, A., and El-Sayed, A. (2019). Literature review on eeg preprocessing, feature extraction, and classifications techniques. *Menoufia J. Electron. Eng. Res*, 28(1):292–299. (páginas 4, 11y15)
- [Singh et al., 2021] Singh, A., Hussain, A. A., Lal, S., and Guesgen, H. W. (2021). A comprehensive review on critical issues and possible solutions of motor imagery based electroencephalography brain-computer interface. *Sensors*, 21(6):2173. (página 17)

- [Song et al., 2021] Song, Y., Jia, X., Yang, L., and Xie, L. (2021). Transformer-based spatial-temporal feature learning for eeg decoding. *arXiv preprint arXiv:2106.11170*. (página 20)
- [Stergiadis et al., 2022] Stergiadis, C., Kostaridou, V.-D., and Klados, M. A. (2022). Which bss method separates better the eeg signals? a comparison of five different algorithms. *Biomedical Signal Processing and Control*, 72:103292. (página 17)
- [Sturm et al., 2016] Sturm, I., Lopuschkin, S., Samek, W., and Müller, K.-R. (2016). Interpretable deep neural networks for single-trial eeg classification. *Journal of neuroscience methods*, 274:141–145. (página 26)
- [Sugiarto and Putro, 2009] Sugiarto, I. and Putro, I. H. (2009). Application of distributed system in neuroscience, a case study of bci framework. In *The 1st international seminar on science and technology*. (páginas 9, 13, 14y96)
- [Sun et al., 2022] Sun, B., Liu, Z., Wu, Z., Mu, C., and Li, T. (2022). Graph convolution neural network based end-to-end channel selection and classification for motor imagery brain-computer interfaces. *IEEE transactions on industrial informatics*. (página 20)
- [Šverko et al., 2022] Šverko, Z., Vrankić, M., Vlahinić, S., and Rogelj, P. (2022). Complex pearson correlation coefficient for eeg connectivity analysis. *Sensors*, 22(4):1477. (página 24)
- [Taheri et al., 2020] Taheri, S., Ezoji, M., and Sakhaei, S. M. (2020). Convolutional neural network based features for motor imagery eeg signals classification in brain-computer interface system. *SN Applied Sciences*, 2:1–12. (página 18)
- [Taherian and Davies, 2018] Taherian, S. and Davies, T. C. (2018). Caregiver and special education staff perspectives of a commercial brain-computer interface as access technology: a qualitative study. *Brain-Computer Interfaces*, 5(2-3):73–87. (páginas 1 and 2)

- [Tang et al., 2019] Tang, X., Zhao, J., Fu, W., Pan, J., and Zhou, H. (2019). A novel classification algorithm for mi-*eeg* based on deep learning. In *2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*, pages 606–611. IEEE. (página 26)
- [Teng et al., 2022] Teng, Q., Liu, Z., Song, Y., Han, K., and Lu, Y. (2022). A survey on the interpretability of deep learning in medical diagnosis. *Multimedia Systems*, pages 1–21. (página 25)
- [Thiebaut de Schotten and Forkel, 2022] Thiebaut de Schotten, M. and Forkel, S. J. (2022). The emergent properties of the connected brain. *Science*, 378(6619):505–510. (páginas 12 and 19)
- [Tibor Schirrneister et al., 2017] Tibor Schirrneister, R., Gemein, L., Eggenesperger, K., Hutter, F., and Ball, T. (2017). Deep learning with convolutional neural networks for decoding and visualization of *eeg* pathology. *arXiv e-prints*, pages arXiv-1708. (página 27)
- [Tobón-Henao et al., 2022] Tobón-Henao, M., Álvarez-Meza, A., and Castellanos-Domínguez, G. (2022). Subject-dependent artifact removal for enhancing motor imagery classifier performance under poor skills. *Sensors*, 22(15):5771. (páginas 8, 11, 17, 44, 59, 64, 77, 107y112)
- [Tobon-Henao et al., 2023] Tobon-Henao, M., Álvarez-Meza, A., and Castellanos-Dominguez, G. (2023). Kernel-based regularized *eegnet* using centered alignment and gaussian connectivity for motor imagery discrimination. (páginas 20 and 112)
- [Torralba et al., 2015] Torralba, A., Zhou, B., and Khosla, A. (2015). Learning deep features for discriminative localization. *CoRR abs/1512.04150*. (página 50)
- [Tremmel et al., 2019] Tremmel, C., Herff, C., Sato, T., Rechowicz, K., Yamani, Y., and Krusienski, D. J. (2019). Estimating cognitive workload in an interactive virtual reality environment using *eeg*. *Frontiers in human neuroscience*, 13:401. (páginas 1 and 10)

- [Uribe et al., 2019] Uribe, L. F. S., Stefano Filho, C. A., de Oliveira, V. A., da Silva Costa, T. B., Rodrigues, P. G., Soriano, D. C., Boccato, L., Castellano, G., and Attux, R. (2019). A correntropy-based classifier for motor imagery brain-computer interfaces. *Biomedical Physics & Engineering Express*, 5(6):065026. (página 17)
- [Velasquez-Martinez et al., 2020a] Velasquez-Martinez, L., Caicedo-Acosta, J., and Castellanos-Dominguez, G. (2020a). Entropy-based estimation of event-related de/synchronization in motor imagery using vector-quantized patterns. *Entropy*, 22(6):703. (página 59)
- [Velasquez-Martinez et al., 2020b] Velasquez-Martinez, L. F., Zapata-Castano, F., and Castellanos-Dominguez, G. (2020b). Dynamic modeling of common brain neural activity in motor imagery tasks. *Frontiers in Neuroscience*, 14:714. (página 22)
- [Vidaurre and Blankertz, 2010] Vidaurre, C. and Blankertz, B. (2010). Towards a cure for bci illiteracy. *Brain topography*, 23:194–198. (página 11)
- [Vinogradova et al., 2020] Vinogradova, K., Dibrov, A., and Myers, G. (2020). Towards interpretable semantic segmentation via gradient-weighted class activation mapping (student abstract). In *Proceedings of the AAAI conference on artificial intelligence*, volume 34, pages 13943–13944. (página 52)
- [Vogel and Machizawa, 2004] Vogel, E. K. and Machizawa, M. G. (2004). Neural activity predicts individual differences in visual working memory capacity. *Nature*, 428(6984):748–751. (página 135)
- [Wang et al., 2020] Wang, H., Wang, Z., Du, M., Yang, F., Zhang, Z., Ding, S., Mardziel, P., and Hu, X. (2020). Score-cam: Score-weighted visual explanations for convolutional neural networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*, pages 24–25. (página 51)
- [Wang et al., 2018] Wang, P., Jiang, A., Liu, X., Shang, J., and Zhang, L. (2018). Lstm-based eeg classification in motor imagery tasks. *IEEE transactions on neural systems and rehabilitation engineering*, 26(11):2086–2095. (página 17)

- [Wang et al., 2023] Wang, W., Li, B., Wang, H., Wang, X., Qin, Y., Shi, X., and Liu, S. (2023). Eeg-fmcnn: A fusion multi-branch 1d convolutional neural network for eeg-based motor imagery classification. *Medical & Biological Engineering & Computing*, pages 1-14. (página 117)
- [Wilson et al., 2010] Wilson, J. A., Mellinger, J., Schalk, G., and Williams, J. (2010). A procedure for measuring latencies in brain-computer interfaces. *IEEE transactions on biomedical engineering*, 57(7):1785-1797. (páginas 28, 29y30)
- [Wolpaw and McFarland, 1994] Wolpaw, J. R. and McFarland, D. J. (1994). Multichannel eeg-based brain-computer communication. *Electroencephalography and clinical Neurophysiology*, 90(6):444-449. (página 2)
- [Wriessnegger et al., 2020] Wriessnegger, S. C., Müller-Putz, G. R., Brunner, C., and Sburlea, A. I. (2020). Inter-and intra-individual variability in brain oscillations during sports motor imagery. *Frontiers in human neuroscience*, 14:576241. (página 11)
- [Xie et al., 2022] Xie, J., Zhang, J., Sun, J., Ma, Z., Qin, L., Li, G., Zhou, H., and Zhan, Y. (2022). A transformer-based approach combining deep learning network and spatial-temporal information for raw eeg classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30:2126-2136. (páginas 20 and 26)
- [Xu et al., 2018] Xu, B., Zhang, L., Song, A., Wu, C., Li, W., Zhang, D., Xu, G., Li, H., and Zeng, H. (2018). Wavelet transform time-frequency image and convolutional network-based motor imagery eeg classification. *Ieee Access*, 7:6084-6093. (página 17)
- [Xygonakis et al., 2018] Xygonakis, I., Athanasiou, A., Pandria, N., Kugiumtzis, D., Bamidis, P. D., et al. (2018). Decoding motor imagery through common spatial pattern filters at the eeg source space. *Computational intelligence and neuroscience*, 2018. (páginas 8, 10y15)

- [Yang et al., 2015] Yang, H., Sakhavi, S., Ang, K. K., and Guan, C. (2015). On the use of convolutional neural networks and augmented csp features for multi-class motor imagery of eeg signals classification. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 2620–2623. IEEE. (página 27)
- [Yang et al., 2021] Yang, H., Xiong, W., Zhang, X., Wang, K., and Tian, M. (2021). Penalized homophily latent space models for directed scale-free networks. *Plos one*, 16(8):e0253873. (página 13)
- [Yang et al., 2020] Yang, J., Ma, Z., Wang, J., and Fu, Y. (2020). A novel deep learning scheme for motor imagery eeg decoding based on spatial representation fusion. *IEEE Access*, 8:202100–202110. (página 16)
- [Yap et al., 2017] Yap, H.-y., Choo, Y.-h., and Khoh, W.-h. (2017). Overview of acquisition protocol in eeg based recognition system. In *Brain Informatics: International Conference, BI 2017, Beijing, China, November 16-18, 2017, Proceedings*, pages 129–138. Springer. (página 119)
- [Yuan and He, 2014] Yuan, H. and He, B. (2014). Brain-computer interfaces using sensorimotor rhythms: current state and future perspectives. *IEEE Transactions on Biomedical Engineering*, 61(5):1425–1435. (página 2)
- [Zhang et al., 2015] Zhang, L., Guindani, M., and Vannucci, M. (2015). Bayesian models for functional magnetic resonance imaging data analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, 7(1):21–41. (páginas 5 and 19)
- [Zhang et al., 2019] Zhang, Z., Duan, F., Sole-Casals, J., Dinares-Ferran, J., Cichocki, A., Yang, Z., and Sun, Z. (2019). A novel deep learning approach with data augmentation to classify motor imagery signals. *IEEE Access*, 7:15945–15954. (página 20)
- [Zhao et al., 2019] Zhao, X., Zhang, H., Zhu, G., You, F., Kuang, S., and Sun, L. (2019). A multi-branch 3d convolutional neural network for eeg-based motor imagery classification. *IEEE transactions on neural systems and rehabilitation engineering*, 27(10):2164–2177. (página 16)

-
- [Zheng et al., 2013] Zheng, J., Cheng, J., and Yang, Y. (2013). A rolling bearing fault diagnosis approach based on lcd and fuzzy entropy. *Mechanism and Machine Theory*, 70:441–453. (página 30)
- [Zhou et al., 2015] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., and Torralba, A. (2015). Learning deep features for discriminative localization. (página 25)
- [Zhou et al., 2016] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., and Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2921–2929. (página 51)