



Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

Trabajo Fin de Máster

Decodificación de la actividad electroencefalográfica (EEG) para la detección de intención de movimiento en tiempo real

Autor

Eva Cortines Torre

Director

Armando Malanda Trigueros

Co-Director

Eduardo López Larraz

Máster Ingeniería Biomédica

Febrero 2022

Resumen

El ictus es la principal causa de discapacidad motora en el mundo y en más del 85% de los casos provoca déficits motores. La fisioterapia es el método de rehabilitación más ampliamente utilizado. Sin embargo, las personas post-ictus con parálisis más severa suelen presentar una recuperación limitada o nula en respuesta a estas terapias tradicionales, ya que requieren de un movimiento residual como premisa para su aplicación.

Las interfaces cerebro ordenador (BCI de sus siglas en inglés, Brain-Computer Interface) han surgido como único medio de terapia de rehabilitación motora en los pacientes con parálisis más severa, ya que no requieren movimiento residual activo. Las BCI decodifican las señales cerebrales, las analizan y finalmente las traducen en comandos que puedan controlar un dispositivo externo, como puede ser el caso de brazos robóticos o electroestimulación funcional (FES). A diferencia de las terapias clásicas, incorporan estrategias de retroalimentación al sistema nervioso, que restablecen los circuitos neuronales dañados mediante mecanismos de neuroplasticidad y hacen que se produzca un aprendizaje motor. Las señales cerebrales pueden ser adquiridas mediante técnicas invasivas o no invasivas como la electroencefalografía (EEG), método más ampliamente utilizado.

Este trabajo propone la implementación de una BCI basada en un clasificador lineal capaz de realizar la decodificación continua de la intención de movimiento y de generar comandos para el control de dispositivos, que puedan ser utilizados en terapias de rehabilitación motora. Para ello, se implementará un decodificador y se evaluará su comportamiento sobre dos conjuntos de datos de sujetos sanos grabados en Bitbrain (Zaragoza).

Lista de palabras clave

Electroencefalograma (EEG), interfaz cerebro-ordenador, electrodos secos, electrodos basados en agua, conjunto de datos BCI, clasificadores lineales, decodificación continua, motor imagery.

Contenido

1	Introducción	5
1.1	Motivación.....	5
1.2	Estado del arte	6
1.2.1	Interfaces Cerebro Ordenador (BCI)	6
1.2.2	EEG como método de evaluación en ictus.....	8
1.3	Objetivo	9
1.4	Organización de la memoria	10
2	Métodos.....	11
2.1	Datasets.....	11
2.1.1	Dataset 1	11
2.1.2	Dataset 2	13
2.2	Análisis datos EEG	16
2.2.1	Preprocesado de la señal	16
2.2.2	Extracción de características y entrenamiento.....	17
2.2.3	Clasificación	19
2.2.4	Métricas.....	21
2.3	Diseño BCI y análisis realizados.....	22
2.3.1	Análisis realizados sobre el dataset 1	22
2.3.2	Análisis realizados sobre el dataset 2	25
2.4	Integración en la plataforma en tiempo real	26
2.4.1	Descripción de la plataforma existente	26
2.4.2	Integración del sistema BCI en la plataforma en tiempo real.....	27
2.4.3	Clasificación pseudo-online.....	28
3	Resultados.....	29
3.1	Dataset 1	29
3.1.1	Análisis de la señal.....	29
3.1.2	Análisis intrasujeto	29
3.1.3	Análisis intersujeto	33
3.2	Dataset 2	35
3.2.1	Validaciones cruzadas K-Fold	35
3.2.2	Training con datos de “Imaginación de movimiento sin estimulación” y clasificación con “Imaginación de movimiento + FES”	38
3.2.3	Resultados de emulación de la clasificación en tiempo real	39
4	Conclusiones y futuras líneas de trabajo	41
4.1	Discusión	41
4.2	Conclusiones.....	42
4.3	Futuro trabajo	43
5	Bibliografía	44

Lista de figuras

Figura 1: Esquema general de una interfaz cerebro-máquina para la rehabilitación motora de los miembros superiores. Extraído de [1].	6
Figura 2: Clasificador LDA. Hiperplano que separa ambas clases. Extraído de [3].	7
Figura 3: Montaje experimental del dataset 1. Extraído de [6].	12
Figura 4: Configuración eléctrica utilizada en el dataset 1. A: Dispositivo Hero. B: Dispositivo Versatile.	13
Figura 5: ensayo en el dataset 2.	14
Figura 6: Configuración eléctrica utilizada en el dataset 2. A: Dispositivo Hero. B: Dispositivo Versatile.	15
Figura 7: Diagrama secuencial del tratamiento de la señal EEG.	16
Figura 8: Esquema del entrenamiento del clasificador en el dataset 1.	18
Figura 9: Esquema de entrenamiento del clasificador en el dataset 2.	19
Figura 10: Esquema del funcionamiento de la clasificación en el dataset 1.	20
Figura 11: Esquema del funcionamiento de la clasificación en el dataset 2.	20
Figura 12: Validación K-Fold propuesta.	23
Figura 13: Estructura plataforma en tiempo real de Bitbrain. Extraído de: www.bitbrain.com .	26
Figura 14: Ejemplo de PSD con (A) y sin (B) filtrado espacial CAR en uno de los sujetos y en el canal CP3.	29
Figura 15: A y B: Respuesta media temporal de los 4 clasificadores utilizados con validación cruzada 10-Fold (A: EEG seco. B: EEG húmedo). C y D: Precisión media en cada clasificador en todos los sujetos (C: EEG seco. D: EEG húmedo). E y F: Precisión media y STD obtenida en los 4 clasificadores por sujeto (E: EEG seco. F: EEG húmedo).	31
Figura 16: Respuesta media temporal del clasificador. A: 11 electrodos centro-parietales. B: 3 electrodos contralaterales. C: Sin promediar PSD en alfa y beta. Las zonas grises indican la desviación estándar con respecto a la media obtenida.	32
Figura 17: A y C: Respuesta media temporal del clasificador (A:EEG seco. C: EEG húmedo). B y D: Precisión media y STD del clasificador por sujeto (B: EEG seco. D: EEG húmedo).	34
Figura 18: Análisis con validación cruzada 10-Fold sobre el conjunto de datos: FES + MI. A y C: Respuesta media temporal del clasificador (A:EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujetos (B: EEG seco. D: EEG húmedo).	36
Figura 19: Análisis con validación cruzada 10-Fold sobre el conjunto de datos: Fes+ no Motor Imagery. A y C: Respuesta media temporal del clasificador (A:EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujetos (B: EEG seco. D: EEG húmedo).	37
Figura 20: Análisis con validación cruzada 10-Fold sobre el conjunto de datos: Fes+ Motor Imagery. A y C: Respuesta media temporal del clasificador (A:EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujetos (B: EEG seco. D: EEG húmedo).	38
Figura 21: Análisis sobre el conjunto de datos entrenamiento: sin Fes+ Motor Imagery y conjunto de datos de clasificación: Fes+ Motor Imagery. A y C: Respuesta media temporal del clasificador (A:EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujeto (B:EEG seco. D: EEG húmedo).	39
Figura 22: Precisión de decodificación media obtenida en simulación tiempo real con LDA. A: Sujetos con EEG seco B: Sujetos con EEG húmedo. Conjunto de datos entrenamiento: sin Fes+ Motor Imagery. Conjunto de datos clasificación: Fes+ Motor Imagery.	40
Figura 23: Ejemplo de las salidas del clasificación simulación on-line. Línea negra punteada, salidas del clasificador. Línea verde, etiquetas reales de EEG.	40

Lista de tablas

Tabla 1: Precisión media y STD en los 4 clasificadores	32
Tabla 2: Precisión media y STD variando el vector de características.....	33
Tabla 3: Precisión media y STD obtenida con LDA intrasujeto e intersujeto	35

1 Introducción

1.1 Motivación

El 85% de los supervivientes a un ictus, padecen déficits sobre el control motor, convirtiéndolo en la principal causa de discapacidad motora en el mundo. Estas limitaciones en el movimiento conllevan un cambio radical en la vida de estas personas, haciéndolas dependientes en su día a día, además del elevado coste económico que suponen los tratamientos post-ictus, tanto para la familia como para el sistema sanitario público. Es, por tanto, muy importante que estas personas realicen tratamientos de rehabilitación para recuperar su autonomía y mejorar su calidad de vida.

La tendencia natural de las personas post-ictus es utilizar la extremidad sana en lugar de utilizar la extremidad dañada para lograr sus objetivos funcionales, lo que conlleva al uso excesivo del hemisferio contralesional y al uso limitado del hemisferio lesionado. Esto hace que la reparación del sistema motor no se pueda desarrollar con normalidad. Los métodos actuales de rehabilitación consisten en terapia física y conductual, con el objetivo de restaurar la función motora original o compensatoria. En estas terapias se fuerza a los pacientes a utilizar tanto la extremidad sana como la lesionada y a reforzar la actividad neuronal excitatoria en el hemisferio lesionado. Ejemplos de ello son el entrenamiento bilateral de brazos, donde se utilizan ambos brazos simultáneamente en patrones simétricos o alternos, o la terapia de movimiento inducido por restricción, la cual restringe la extremidad sana para obligar al paciente a utilizar la lesionada [1]. Sin embargo, las personas con lesiones más graves en las que prácticamente no existe movimiento residual, suelen presentar una recuperación limitada o nula en respuesta a las terapias tradicionales [2], de modo que son necesarias nuevas formas de rehabilitación motora.

A raíz de esta necesidad, surgen las interfaces cerebro ordenador (BCI) como terapia eficaz para la rehabilitación motora en pacientes con ictus, ya que podrían ayudar a reactivar los mecanismos de plasticidad funcional del cerebro y promover la reparación y regeneración de las redes neuronales lesionadas, tanto en fase inicial como crónica [1]. Como neuroplasticidad se entiende la capacidad del sistema nervioso para reestructurarse a consecuencia del aprendizaje y la estimulación. Las neuronas tienen la capacidad de reorganizarse en respuesta a estímulos eléctricos que modifican la sinapsis entre ellas e incluso promueven la formación de nuevas conexiones. En pacientes pos-ictus, las zonas infartadas y las colindantes a ellas se encuentran inhibidas de actividad eléctrica y una manera de generar respuestas despolarizantes es someterlas a entradas sensoriales que aumentan la excitabilidad de esas neuronas y se induzca a que vuelvan a estar activas. Esto se puede conseguir artificialmente utilizando una BCI donde se decodifica la actividad cerebral y, posteriormente, se envía una respuesta al usuario en forma de estímulos, como electroestimulación funcional, de manera que la retroalimentación varía proporcionalmente con la actividad cerebral clasificada [2].

1.2 Estado del arte

1.2.1 Interfaces Cerebro Ordenador (BCI)

Una BCI es un sistema capaz de registrar, decodificar y elaborar comandos, de manera que estos sean utilizados como entrada para llevar a cabo un acción motora sin la intervención del sistema motor del sujeto [3]. La actividad cerebral realizada durante la intención de movimiento en el sujeto es grabada, amplificada, filtrada y decodificada mediante algoritmos, y finalmente utilizada para generar comandos que controlen dispositivos como brazos robóticos o estimulación eléctrica funcional (FES), lo que a su vez estimula la red neuronal dañada y favorece la neuroplasticidad.

Dependiendo de cómo se graben las señales cerebrales, las BCI se pueden clasificar en invasivas o no invasivas. Las BCI invasivas implican que se implanten quirúrgicamente electrodos para medir los patrones de actividad de las neuronas y obtener así la información relevante. Las BCI no invasivas no requieren implantación quirúrgica y la detección de señales cerebrales se puede realizar desde la superficie externa del cuero cabelludo mediante electroencefalografía (EEG), método más ampliamente utilizado.

Atendiendo a la clínica, también pueden clasificarse en asistenciales o de rehabilitación. El objetivo de las BCI asistenciales es sustituir funciones perdidas como la comunicación o el movimiento (por ejemplo, sistemas para escribir o sillas de ruedas controladas con la actividad cerebral), mientras que los sistemas de BCI de rehabilitación quieren facilitar la restauración de la función perdida a través de la neuro-retroalimentación, como comentamos en la sección anterior.

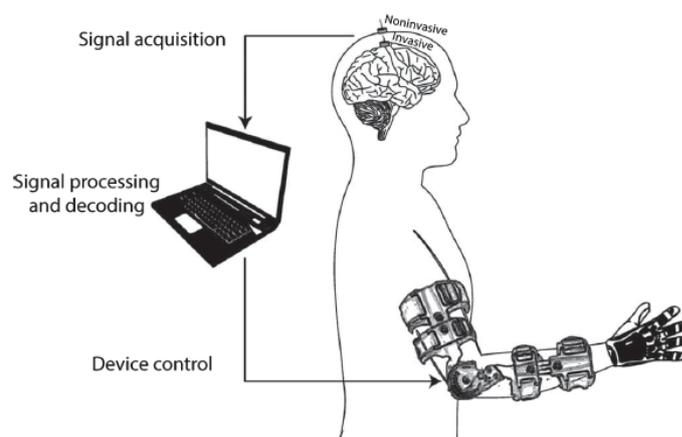


Figura 1: Esquema general de una interfaz cerebro-máquina para la rehabilitación motora de los miembros superiores. Extraído de [1].

Haciendo una revisión en la literatura, existe una amplia gama de algoritmos utilizados por BCI dependiendo de la finalidad para la que vayan a utilizarse: desde clasificadores lineales sencillos hasta complejas redes neuronales no lineales [2]. Los clasificadores lineales son los algoritmos más utilizados en BCI de rehabilitación, donde la predicción del clasificador responde a un problema binario: reposo o movimiento. Entre ellos, el análisis lineal discriminante (LDA) es uno de los más populares para las interfaces cerebro-ordenador por su sencillez, buenos resultados y rápida velocidad de respuesta, característica de suma importancia en entornos en tiempo real [4][2][5].

LDA utiliza hiperplanos para separar los datos que representan las dos clases del problema binario. La clase de un vector de características depende del lado del hiperplano en el que se encuentre el vector. LDA asume una distribución normal de los datos, con una matriz de covarianza igual para ambas clases. La manera de definir dónde se coloca el hiperplano es encontrando la proyección que maximice la distancia entre las medias de las dos clases y minimice la varianza entre las clases. Su principal inconveniente es su linealidad y su sensibilidad a los *outlayers*, lo que hace que sea un algoritmo poco robusto.

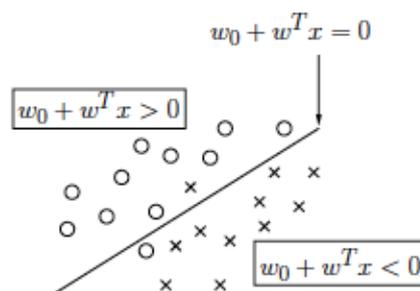


Figura 2: Clasificador LDA. Hiperplano que separa ambas clases. Extraído de [3].

Otros algoritmos solucionan el problema de la poca robustez de LDA, como la máquina de vectores de apoyo (SVM), que es capaz de encontrar un hiperplano de decisión con la máxima distancia (margen) a los puntos de datos más cercanos (vectores de soporte) de cada clase. Un clasificador SVM basado en un hiperplano clasificará todas las observaciones de entrenamiento perfectamente, lo cual conlleva a una sensibilidad a nuevas observaciones, que pueden cambiar por completo el hiperplano óptimo de separación. Por ello existen diferentes implementaciones de SVM que solucionan este problema, como es el caso del clasificador binario SVC (Support Vector Classification) que utiliza un parámetro de regularización C el cual permite que el hiperplano no separe perfectamente las dos clases, dejando que algunas observaciones se encuentren en el lado incorrecto del margen o incluso del hiperplano. Como resultado, SVC tiene un alto poder de generalización y no es tan sensible a los *outlayers* como LDA.

Otros algoritmos trabajan con la probabilidad de una observación de pertenecer a una de las dos clases de salida del clasificador. La regresión logística mide la relación entre la variable

dependiente (clase de salida) con una o más variables independientes (conjunto de características del modelo) y lo hace mediante una función logística que determina la probabilidad de la variable dependiente. Para ello se utiliza un umbral, de manera que los valores de probabilidad por encima del valor umbral (0.5 normalmente, aunque se puede modificar) la afirmación es cierta y por debajo es falsa. Las ventajas de la regresión logística es que no requiere mucho coste computacional, sin embargo, tiene la desventaja de que la variable objetivo ha de ser linealmente separable para que algoritmo funcione correctamente. Además, requiere una óptima selección de características previas al entrenamiento, que no muestren dependencia entre ellas y que tengan peso en la variable de salida, por lo que es necesario identificarlas previamente.

En aprendizaje automático hay otros métodos de clasificación capaces de trabajar con múltiples clases, como los Árboles de Decisión o Random Forest. Por ejemplo, en el algoritmo Random Forest se utilizan distintos árboles de decisión que trabajan con distintos subgrupos de los datos de entrenamiento para un mismo problema. De esta forma, al combinar sus resultados, unos errores se compensan con otros y se obtiene una predicción que generaliza mejor, una de sus principales ventajas. Por el contrario, el algoritmo es mucho más complejo y requiere mucho más tiempo de entrenamiento que los clasificadores lineales. Por ello y pese a que puede ofrecer un mejor rendimiento, quizá no sean los más aconsejables en una BCI en tiempo real.

1.2.2 EEG como método de evaluación en ictus

El método de adquisición de señales cerebrales más utilizado en BCI es EEG debido a su carácter no invasivo, al mínimo riesgo que conlleva y a la comodidad para realizar estudios y reclutar participantes. El objetivo de la BCI es realizar con la máxima precisión posible la decodificación de los intentos de movimiento en el sujeto y para ello se requiere un amplio estudio que establezca una correlación entre la intención del movimiento y la señal cerebral EEG medida.

Un evento motor genera cambios en la amplitud de la actividad oscilatoria cortical, predominantemente en los rangos de frecuencia alfa y beta, en forma de desincronizaciones relacionadas con el evento (ERD, del inglés Event Related Desincronization) o de sincronización relacionada con el evento (ERS, del inglés Event Related Sincronization). Numerosos estudios [6] han demostrado que en sujetos sanos, durante la ejecución/imaginación del movimiento, existe una ERD en los rangos de frecuencia alfa y beta del hemisferio contralateral. Sin embargo, en pacientes con daños motores, la ERD provocada por la intención de movimiento aparece en diferentes partes del cerebro según la fase de ictus en la que se encuentre y según el tipo de lesión existente. Por ejemplo, se ha comprobado que, en pacientes en fases crónicas de ictus al mover la mano lesionada, ERD se da tanto en el hemisferio ipsilateral como en el contralateral; la implicación del hemisferio ipsilateral es debida al intento del cerebro de compensar la enfermedad con el lado sano.

En 2017 se publicó un trabajo [7] que informó por primera vez sobre las diferencias en el rendimiento de una BCI que realizaba la decodificación de la intención de movimiento en función de la localización de la lesión en pacientes ictus crónico. En este trabajo se entrenó una BCI utilizando electrodos contralaterales y también electrodos en todo el córtex centro-parietal en pacientes con ictus y lesiones mixtas (con daño cortical) y sin daño cortical. Se demostró que en los pacientes sin lesiones corticales se obtenían mayores precisiones de decodificación en comparación con los pacientes que sí tenían daño cortical. Además, con y sin daño cortical, la precisión de decodificación era mayor colocando los electrodos en toda la zona centro parietal y no solo en el hemisferio contralateral a la lesión.

La precisión de decodificación en pacientes con lesiones mixtas y utilizando electrodos solo en el hemisferio ipsilesional, era muy baja al mover la mano lesionada. Sin embargo, se sabe que el aprendizaje asociativo del cerebro es mayor si las correlaciones neuronales entre la intención del movimiento y la retroalimentación del mismo se establece en este hemisferio, por lo que el estudio sugiere que puede ser interesante combinar ERD como características junto con otros sistemas que aporten información cortical, como pueden ser los potenciales corticales relacionados con el movimiento o la actividad electromiográfica residual de las extremidades paralizadas, para fomentar la neuroplasticidad en la rehabilitación motora.

1.3 Objetivo

Diversos estudios han decodificado la intención de movimiento mediante sistemas BCI, sin embargo, existe la necesidad de continuar investigando para poder trasladar estos sistemas del laboratorio al uso doméstico de las personas. Para ello, es necesario demostrar la efectividad de los sistemas BCI a largo plazo y bajo diversos supuestos que caractericen con la máxima precisión posible los ERD relacionados con la intención motora.

Bajo este marco, la empresa Bitbrain propone la utilización de una BCI no invasiva para el futuro control de dispositivos mediante la actividad cerebral en rehabilitación de trastornos motores, como los accidentes cerebrovasculares. El sistema propuesto es capaz de decodificar la intención de movimiento a partir del electroencefalograma (EEG) simulando un entorno en tiempo real, y de generar comandos que podrán ser utilizados para el control de estos dispositivos en terapias de rehabilitación motora que, en un futuro, podrían ser utilizadas en el domicilio de los pacientes. Con este fin, el proyecto (desarrollado en el lenguaje Python versión 1.8) se compuso de dos fases:

- Primera fase off-line: estudio de diferentes clasificadores y diferentes métodos de extracción de características, a partir de dos tipos de datasets diferentes, uno ya existente en la literatura y otro creado por Bitbrain para un proyecto realizado en paralelo al presente trabajo y que representaba mejor un entorno real debido a las características de grabación del dataset. Pese a que la implementación del sistema se realizó off-line, la estructura y ejecución se realizó simulando siempre una ejecución de decodificación continua de la intención del movimiento.

- Segunda fase pseudo-online: integración del sistema desarrollado en una plataforma en tiempo real ya existente, propiedad de Bitbrain, donde se evaluará el sistema BCI desarrollado emulando un entorno en tiempo real. Esta segunda fase fue evaluada sobre el dataset 2.

1.4 Organización de la memoria

La organización de la memoria está estructurada de la siguiente manera:

- El capítulo 1 presenta la motivación, estado del arte y objetivos del trabajo.
- En el capítulo 2 se detallan los dos conjuntos de datos utilizados para el estudio, la metodología utilizada para la adquisición y procesado de las señales EEG, así como los análisis realizados.
- En el capítulo 3 se muestran los resultados obtenidos en el trabajo.
- El capítulo 4 se presentan las conclusiones y las posibles líneas de trabajo futuras.
- Finalmente se referencia la bibliografía utilizada.

2 Métodos

En esta sección, se explicarán los conjuntos de datos (datasets) y métodos empleados en este estudio, como son el procesamiento de señal, la extracción de características, el entrenamiento y las pruebas en el clasificador, utilizados para la traducción de las señales cerebrales en comandos que puedan controlar dispositivos en terapias de rehabilitación motora.

2.1 Datasets

Dos fueron los datasets utilizados para el desarrollo del proyecto. En ambos se caracterizaba la señal EEG de los sujetos sanos y diestros al realizar un agarre (dataset 1), o bien imaginar que se realizaba el agarre (dataset 2), con la mano derecha.

- Dataset 1: existente en la literatura [8].
- Dataset 2: creado por Bitbrain en enero 2021 para otro proyecto que se desarrolló en paralelo al presente trabajo y más relevante en entornos reales que el dataset 1 por las características de las grabaciones. Éstas fueron realizadas en tres escenarios diferentes combinado dos condiciones: realizar estimulación funcional y/o imaginación del movimiento por parte del sujeto.

2.1.1 Dataset 1

2.1.1.1 Sujetos

Participaron 45 personas, todas ellas sanas y diestras. Se realizaron 3 tipos mediciones de EEG según el tipo de electrodos utilizados: 15 sujetos participaron en las grabaciones con electrodos de gel, 15 sujetos en la grabación con electrodos secos (tecnología Hero) y 15 con electrodos basados en agua (tecnología Versatile). Para este proyecto sólo se utilizaron las grabaciones hechas con los electrodos secos y basados en agua, de manera que se tuvieran en cuenta las mismas tecnologías en ambos datasets 1 y 2. Ambas las grabaciones se realizaron en las oficinas de Bitbrain, Zaragoza.

2.1.1.2 Montaje experimental

Los sujetos se encontraban sentados en una silla con la mano derecha apoyada en una mesa en una posición de base sensada. Encima de la mesa había un tarro vacío y un tarro con una cuchara dentro. Se pedía a los participantes que alcanzaran los dos objetos de manera que en el caso de la jarra se realizara un agarre con la palma de la mano y en el caso de la cuchara se hiciera un agarre lateral.

Los sujetos debían mirar el objeto fijamente 2 segundos antes de iniciar la acción y debían mantener el objeto en la mano durante al menos 1-2 s. Una vez hubieran regresado a la posición base, debían esperar 4 segundos para poder comenzar un nuevo ensayo. En total se registraron 80 ensayos por condición (agarre palmar y agarra lateral) repartidos en 4 series de 20 ensayos cada una. Se realizaron 3 minutos de descanso al principio, mitad y final del experimento y se cambió el orden de los objetos para tener igualdad de condiciones. Se realizó el registro de los movimientos oculares horizontales y verticales y de los parpadeos utilizando seis electrodos adicionales colocados en la órbita inferior y superior del ojo izquierdo y derecho y en el borde externo.

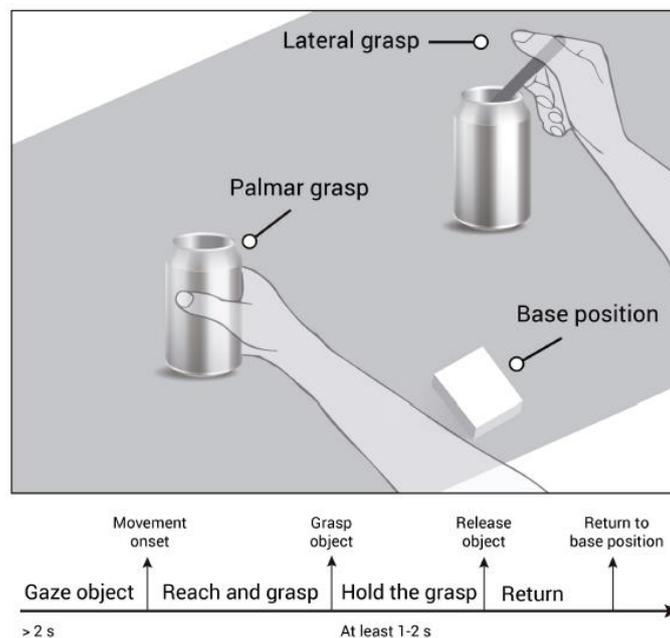


Figura 3: Montaje experimental del dataset 1. Extraído de [6].

2.1.1.3 Adquisición de datos

La adquisición de datos fue realizada con tres tecnologías diferentes de electrodos, aunque sólo se explicarán las utilizadas en este trabajo: EEG seco y EEG basado en agua. En ambos casos las señales se registraron con una frecuencia de muestreo de 256 Hz y se prefiltraron con un filtro Butterworth antialiasing de tercer orden con una frecuencia de banda de paso de CC a 100 Hz. Se utilizaron fotodiodos para registrar el inicio del movimiento y el punto de agarre de cada objeto. Los fotodiodos se digitalizaron utilizando un amplificador Biosensing™ (Bitbrain, España) a una frecuencia de muestreo de 256 Hz, que se colocó en la mesa. Todos los datos se transmitieron a través de Bluetooth a la unidad de cálculo utilizando el software propiedad de Bitbrain, y se hizo una copia de seguridad en una tarjeta SD interna para evitar la pérdida de datos debido a la conexión inalámbrica.

EEG seco (sistema comercial Hero): Desarrollado por Bitbrain. Tecnología EEG de electrodo seco. El sistema comercial Hero (ver figura 4A) cuenta con 11 electrodos secos colocados en las áreas sensoriomotoras según el sistema internacional 10/20: FC3, FCz, CP3, C3, C1, Cz, C2, C4, CP3, CPz, CP4. Para la referencia y tierra utiliza el lóbulo izquierdo. La transmisión de datos se lleva a cabo por Bluetooth. El dispositivo graba con una resolución de 24 bits a 256 Hz.

EEG basado en agua (sistema comercial Versatile): Desarrollado por Bitbrain. Sistema de EEG basado en agua para mejorar la conductividad (ver figura 4B) de 32 electrodos colocados en posiciones frontal, central y parietal según el sistema internacional 10/20: AFz, F3, F1, Fz, F2, F4, FC5, FC3, FC1, FCz, FC2, FC4, FC6, C5, C3, C1, Cz, C2, C4, C6, CP5, CP3, CP1, CPz, CP2, CP4, CP6, P3, P1, Pz, P2, P4. Para la referencia se utilizó el lóbulo de la oreja izquierda y para la tierra el canal AFz. La transmisión de datos se lleva a cabo por Bluetooth. El dispositivo graba con una resolución de 24 bits a 256 Hz.

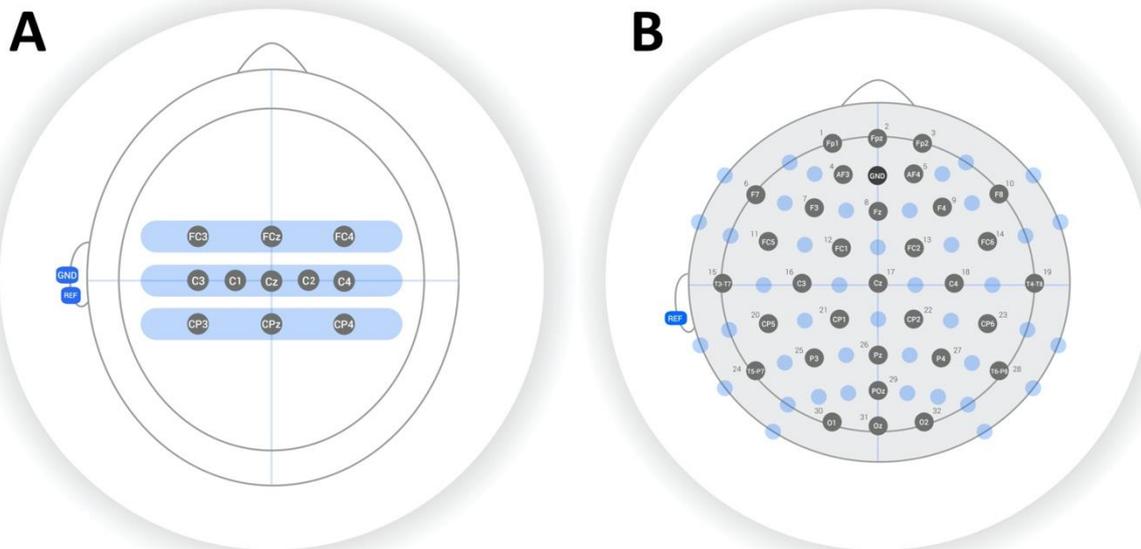


Figura 4: Configuración eléctrica utilizada en el dataset 1. A: Dispositivo Hero. B: Dispositivo Versatile.

2.1.2 Dataset 2

Se realizó la grabación del dataset en el marco de otro proyecto (TFM) desarrollado en Bitbrain en enero de 2021 denominado “Control de la estimulación eléctrica funcional (FES) mediante el uso del electroencefalograma (EEG) como método de rehabilitación motora”.

2.1.2.1 Sujetos

Participaron 18 personas, todas ellas sanas y diestras con edades comprendidas entre 18 y 65 años. Se realizaron 2 tipos mediciones de EEG según el tipo de electrodos utilizados: 10 sujetos en la grabación con electrodos secos (tecnología Hero) y 8 con electrodos basados en agua (tecnología Versatile). Todas ellas grabadas en las oficinas de Bitbrain, Zaragoza.

2.1.2.2 Montaje experimental

Los sujetos se encontraban sentados en una silla con la mano derecha apoyada en una mesa. Se pedía a los participantes que realizaran 3 tareas diferentes:

- A. Estimulación FES pasiva: Se realizó estimulación eléctrica en el brazo del sujeto que produjo el cierre de su mano.
- B. Estimulación FES durante imaginación de movimiento (IM): El sujeto debía realizar IM al mismo tiempo que se aplicaba FES.
- C. Imaginación de movimiento (IM) sin estimulación (control): El sujeto debía de realizar IM y no se aplicó FES.

Cada participante realizó las 3 tareas (A, B, C) con dos tecnologías diferentes: EEG seco Hero y EEG basado en agua Versatile. En una pantalla frente al sujeto aparecían las palabras “rest” y “move” de manera alterna. Durante el período “rest” el sujeto debía de permanecer relajado sin realizar ninguna acción. Durante el período “move” el sujeto debía realizar una de las tres acciones propuestas. El orden de ejecución de las 3 tareas fue aleatorio entre participantes. Para cada una de las 3 tareas grabadas con cada tecnología se grabaron 3 bloques de 20 ensayos cada uno, dando lugar a 60 ensayos por condición experimental. Cada ensayo consistió en un periodo de reposo (~10 s) seguido de un período de estimulación/IM (~5 s). Los participantes descansaron ~2 min entre bloques.



Figura 5: ensayo en el dataset 2.

2.1.2.3 Adquisición de datos

Para la grabación se utilizaron 2 tecnologías diferentes de electrodos: EEG seco y EEG húmedo, ambos sistemas desarrollados por Bitbrain. Todas las grabaciones fueron realizadas a una frecuencia de muestreo de 256 Hz.

EEG seco (sistema comercial Hero): El sistema comercial Hero evolucionado de su versión anterior (ver figura 4A) y desarrollado por Bitbrain, presenta 10 electrodos secos, colocados sobre la corteza motora: FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4 y A2 (ver figura 6A). Para la referencia y tierra utiliza el lóbulo izquierdo. La transmisión de datos se lleva a cabo por Bluetooth. El dispositivo graba con una resolución de 24 bits a 256 Hz.

Electrodos húmedos (sistema comercial Versatile): El sistema comercial Versatile fue el mismo utilizado en la grabación del dataset 1 cuyo detalle se explicó en 2.1.1.3. Se recuerda su configuración eléctrica en la figura 6B.

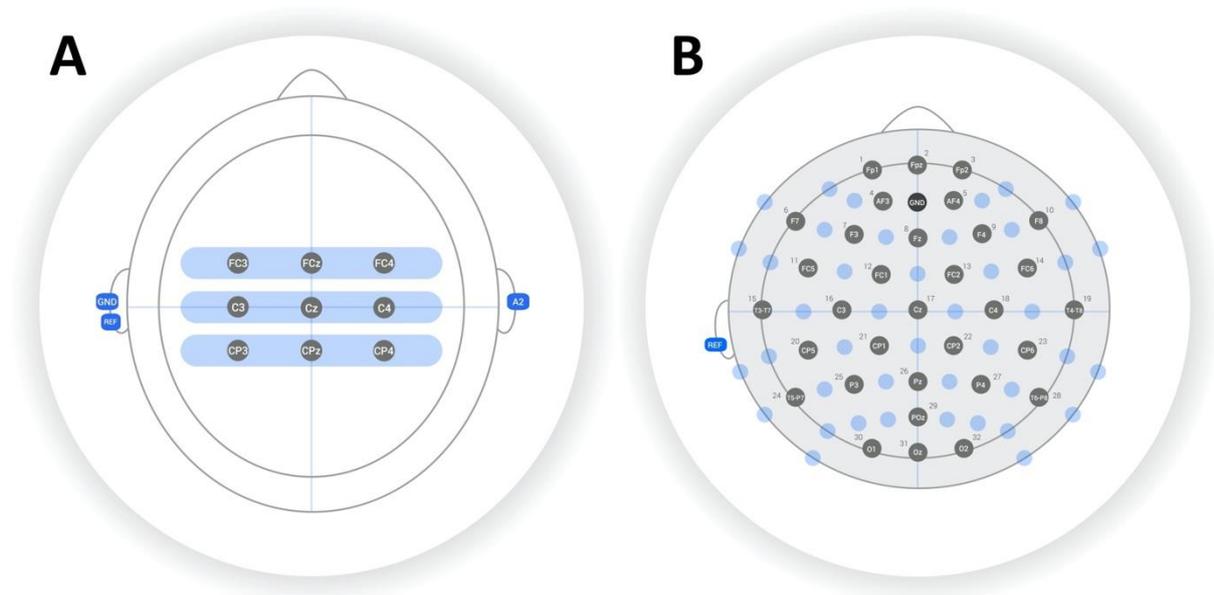


Figura 6: Configuración eléctrica utilizada en el dataset 2. A: Dispositivo Hero. B: Dispositivo Versatile.

En el caso de EEG seco en el dataset 2 se desestimó el canal A2, por no ser de interés al encontrarse en la oreja, de manera que para los análisis se utilizaron 9 canales del área sensoriomotora: FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4 en el sistema Hero y los 32 canales en el sistema Versatile.

2.2 Análisis datos EEG

2.2.1 Preprocesado de la señal

Las señales EEG son de baja amplitud y susceptibles al ruido eléctrico, tanto del ambiente como de la propia actividad ocular o muscular, por lo que es de vital importancia implementar técnicas que permitan eliminar el ruido y otros artefactos de la EEG registrada, así como resaltar la información conveniente contenida en las señales. Para ello, se aplican técnicas como filtros espaciales y frecuenciales cuyo fin es transformar señales EEG crudas en un nuevo conjunto de señales con menos ruido, de manera que se aumente la relación SNR.

Para cada sujeto se procesaron sus grabaciones EEG con un filtro CAR (Common average reference) y con un filtro paso banda Butterworth de orden 4 entre las frecuencias 0.1 - 48 Hz. En el filtro CAR, a cada canal se le resta el valor medio del resto de los electrodos. Esto hace que funcione como un filtro paso alto donde se realza la actividad local del electrodo y se reduce la actividad común de los demás electrodos de sensado [9]. Entre la actividad común reducida se encuentran las fuentes distantes como EMG, movimientos oculares, parpadeos o el rimo alfa visual. Por tanto, es aconsejable este tipo de filtros para subir la relación señal/ruido y poder discernir mejor entre los estados de reposo y movimiento. Cuanto más se diferencien los dos estados, mejor funcionará el clasificador y, por ende, la BCI.

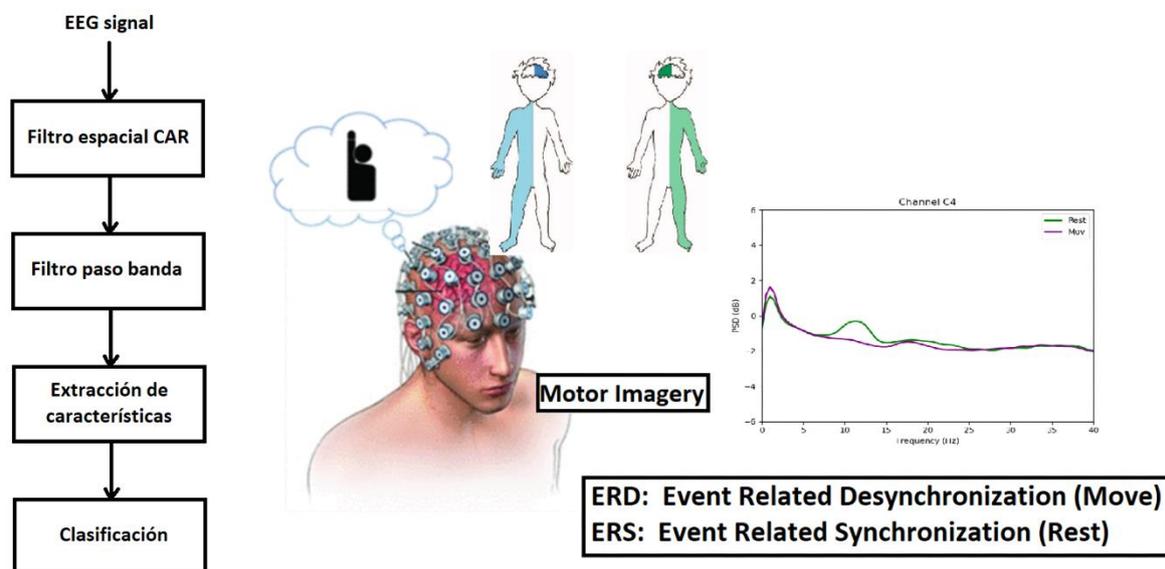


Figura 7: Diagrama secuencial del tratamiento de la señal EEG.

2.2.2 Extracción de características y entrenamiento

Como se describió en la sección 1.2.2, las ERD son desincronizaciones relacionadas con eventos que se producen en las bandas de frecuencia alfa y beta justo antes del movimiento y dan lugar a una disminución de la potencia en el estado previo al movimiento con respecto al estado de reposo (ver figura 7). Por ello, se realizó un análisis de potencia espectral (PSD) para evaluar las diferencias espectrales entre reposo y de movimiento y así poder realizar una óptima selección de las características a utilizar por el clasificador. Se calculó PSD para cada canal de interés de la señal EEG utilizando el método Welch sin solapamiento utilizando una ventana de 1 segundo [10].

Se comprobó que cuando los sujetos realizaban el movimiento con la extremidad superior derecha, la potencia media en ambos rangos de frecuencias era inferior a cuando estaban en reposo, por lo que se seleccionó el promedio de PSD en alfa y beta (7-13 Hz y 14-25 Hz respectivamente) de cada canal como características de entrada al clasificador, para que este pudiera discernir entre las dos clases a clasificar: reposo o movimiento.

Para llevar a cabo el entrenamiento y clasificación de las señales, se dividieron ambos conjuntos de datos provenientes de los datasets 1 y 2 en: conjunto de datos de entrenamiento y conjunto de datos de pruebas, ya que, en una clasificación con un modelo previamente entrenado, no está permitido mezclar ambos grupos para garantizar la validez de los resultados. A continuación, se detallan los conjuntos de datos de entrenamiento y pruebas (clasificación) utilizados en cada uno de los datasets.

2.2.2.1 Dataset 1

Para el análisis, se dividió la señal continua de EEG en diferentes ensayos o tareas repetitivas. Se consideró ensayo al espacio temporal contenido entre los 3 segundos antes de darse el inicio del movimiento (en $t=0$ s) y los dos segundos posteriores a éste. De esta manera, se obtuvieron ensayos de cinco segundos en total, donde los tres primeros segundos eran descanso y los dos siguientes eran considerados movimiento. Los ejemplos de la clase de reposo se calcularon en el intervalo $[-2,0]$ s y los ejemplos de movimiento en el intervalo $[0, 2]$ s con una ventana deslizante de 1 segundo y con un paso deslizante de 0,25s. De esta manera, para cada ensayo del conjunto de datos de entrenamiento, se obtuvieron 5 ventanas de un segundo como ejemplo de reposo y cinco como ejemplo de movimiento (figura 8). No se consideraron ventanas intermedias para el entrenamiento (ventanas que contenían el segundo $t=0$ s).

Los vectores de características obtenidos para cada ventana de un segundo fueron las potencias medias en alfa y beta para cada canal de la señal EEG medida. De esta manera, el vector de características de cada ventana era de tamaño 22 ($2*11$ canales) en el caso de los electrodos secos y 64 ($2*32$ canales) en el caso de los electrodos basados en agua. Sus valores se normalizaron para tener una media cero y una varianza unitaria antes de entrenar el clasificador mediante el método Z-Score ampliamente utilizado en aprendizaje automático, ya que mejora

las precisiones de clasificación [11]. Z-Score estandariza los valores del vector de características de manera que permite comparar dos puntuaciones que proceden de muestras diferentes (que pueden tener medias y desviaciones estándar diferentes):

$$Z = \frac{x - \mu}{\sigma}$$

donde x es la observación individual, μ es la media del conjunto de datos y σ es la desviación estándar del conjunto de datos.

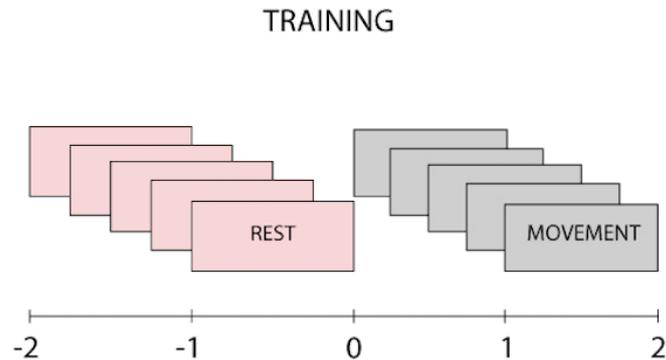


Figura 8: Esquema del entrenamiento del clasificador en el dataset 1.

2.2.2.2 Dataset 2

Debido a que la estimulación funcional eléctrica (FES)/imaginación del movimiento (IM) era de 5 segundos en la sesión de grabación del dataset 2, los ensayos calculados en este experimento se consideraron de 11 segundos: 6 segundos de reposo y 5 segundos de movimiento. Los ejemplos de la clase de reposo se calcularon en el intervalo $[-5,0]$ s y los ejemplos de movimiento en el intervalo $[0, 5]$ s con una ventana deslizante de 1 segundo y con un paso deslizante de 0,25s. De esta manera, para cada ensayo del conjunto de datos de entrenamiento, se obtuvieron 1024 ventanas de un segundo como ejemplo de reposo y 1024 como ejemplo de movimiento (ver figura 9). No se consideraron ventanas intermedias para el entrenamiento (ventanas que contenían el instante $t=0$ s).

Los vectores de características obtenidos para cada ventana fueron las potencias medias en alfa y beta para cada canal de la señal EEG medida. De esta manera, para cada ventana el vector de características utilizado era de tamaño 18 ($2*9$ canales) en el caso de electrodos secos y de 64 ($2*32$ canales) en el caso de electrodos basados en agua. Sus valores se normalizaron para tener una media cero y una varianza unitaria antes de entrenar el clasificador de la misma manera que en dataset 1.

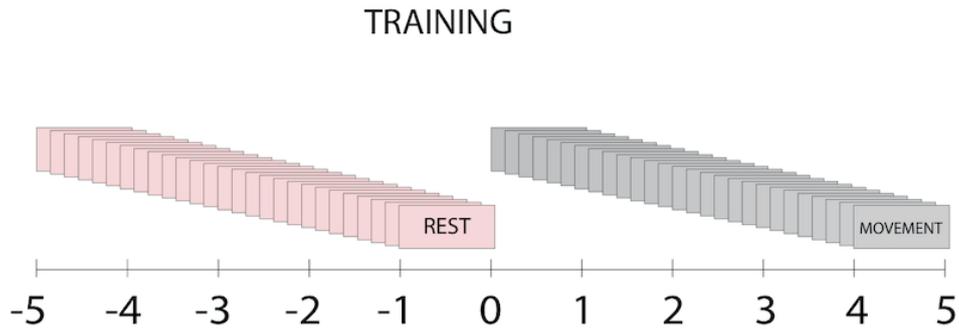


Figura 9: Esquema de entrenamiento del clasificador en el dataset 2.

2.2.3 Clasificación

A pesar de que los conjuntos de datos estudiados en este trabajo se analizaron en primer lugar off-line, todos los procedimientos se realizaron simulando un escenario on-line con el uso de ventanas deslizantes y buffer circular para la clasificación.

2.2.3.1 Dataset 1

La clasificación de los datos de prueba se realizó simulando un escenario on-line. Se evaluó una ventana deslizante de un segundo cada 31.20 ms (de -3 a 2 s), extrayendo las características y obteniendo una salida del clasificador (ver figura 10). Se creó un buffer circular donde se guardaba el último segundo de señal EEG leída, de manera que, cada vez que se llamaba al clasificador, se analizaba y clasificaba la señal EEG contenida en el buffer circular de un segundo de duración. Nótese que la primera salida del clasificador con datos consistentes es en $t = -2$ s (buffer circular lleno).

Las características de los datos de clasificación se calcularon con el mismo procedimiento que el explicado para el entrenamiento (sección 2.2.2.1). La normalización de las características de las ventanas de clasificación se realizó aplicando los parámetros calculados previamente a partir de los datos de entrenamiento con la normalización Z-Score, explicada en la misma sección.

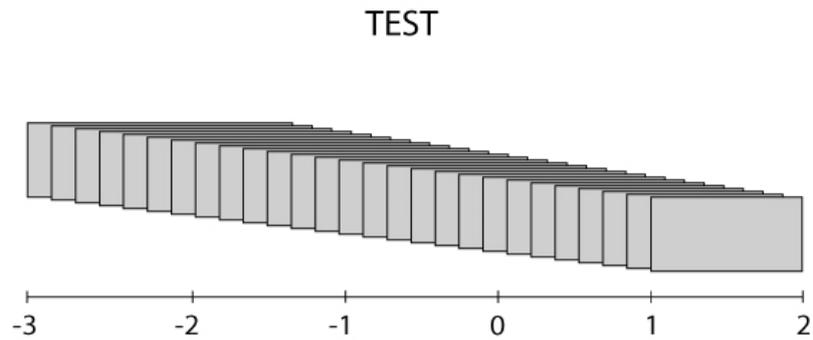


Figura 10: Esquema del funcionamiento de la clasificación en el dataset 1.

2.2.3.2 Dataset 2

La clasificación de los datos de prueba se realizó simulando un escenario on-line. Se evaluó una ventana deslizante de un segundo cada 31.20 ms (de -6 a 5 s), extrayendo las características y obteniendo una salida del clasificador (ver figura 11). Para ello, se creó un buffer circular donde se guardaba el último segundo de señal EEG leída, de manera que, cada vez que se llamaba al clasificador se hacía con el buffer circular como entrada. Nótese que la primera salida del clasificador con datos consistentes es en $t = -5$ s (buffer circular lleno).

Las características de los datos de clasificación se calcularon con el mismo procedimiento que el explicado para el entrenamiento (sección 2.2.2.2). La normalización de las características de las ventanas de clasificación se realizó aplicando los parámetros calculados previamente a partir de los datos de entrenamiento con la normalización Z-Score, explicada en la misma sección.

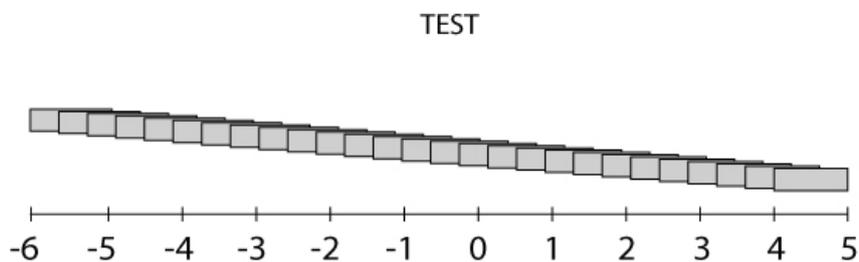


Figura 11: Esquema del funcionamiento de la clasificación en el dataset 2.

2.2.4 Métricas

La métrica de evaluación de resultados fue la misma en todos los análisis del proyecto. Trazamos las salidas medias del decodificador cuando la predicción era “movimiento” durante todo el ensayo, de manera que las dos métricas principales para cuantificar el rendimiento del clasificador fueron: verdaderos positivos (TP) durante el período de movimiento ([0,2]s en el dataset 1 y [0,5]s en el dataset 2 y falsos positivos (FP) durante el período de reposo ([-2,0]s en el dataset 1 y [-5,0]s en el dataset 2. La precisión media se calculó como la media entre los verdaderos positivos o TP y los verdaderos negativos o TN (es decir, 1-FP) en ambos datasets.

Para calcular la precisión media obtenida en ambos grupos de datos, se tuvieron en cuenta los períodos del ensayo donde la salida del clasificador proporcionaba datos más estables. En el caso del dataset 1, los sujetos recibían la orden de iniciar el alcance del objeto en $t=0$ s, es decir, en ese instante la mano derecha se levantaba de la posición base sensada pero, antes de que esto ocurra, es necesario mover hombro, brazo...etc. por lo que en el intervalo [-1,1] s la salida del clasificador no era estable. Por ello, en el dataset 1 la precisión media del clasificador se calculó entre los intervalos [-2,-1]s y [1,2]s.

En el dataset 2, en el instante $t=0$ s los sujetos recibían la señal visual de imaginación del movimiento, de manera que existía un pequeño retardo en las salidas del clasificador de reposo a movimiento en el intervalo [0,1]s, debida a que los sujetos pueden no realizar la acción exactamente en ese instante y tardar un poco más en reaccionar. En este caso, no se dio inestabilidad en el intervalo [-1,0], pero para ser consistentes en las métricas de ambos conjuntos de datos, en el dataset 2 la precisión media del clasificador se calculó entre los intervalos [-5,-1]s y [1,5]s.

Se calcularon los intervalos de confianza de las gráficas conforme a [12]. La probabilidad de que un ensayo X_i sea clasificado correctamente en un problema de dos clases (reposo o movimiento) consistente en n ensayos, sigue una distribución binomial, en caso de que el clasificador funcione a nivel aleatorio, donde cada clase (reposo o movimiento) tiene la misma probabilidad de ocurrir (50%), con un intervalo de confianza en un determinado nivel α que depende del número de ensayos (n). De tal manera se establecen, con el uso de una fórmula, los intervalos de confianza en torno al valor esperado de probabilidad fija de cada una de las dos clases ($p=0.5$), para evaluar si los resultados de un clasificador dado difieren significativamente de uno aleatorio:

$$p \pm \sqrt{\left(\frac{p * (1 - p)}{(n + 4)}\right)} Z_{1-(\alpha/2)}$$

donde p es la probabilidad de ser clasificado como reposo o movimiento ($p=0.5$), n es el número total de ensayos a clasificar, $Z_{1-(\alpha/2)}$ es el cuantil de la distribución normal estándar $N(0,1)$ y α el nivel de significación, en este caso 0,01.

2.3 Diseño BCI y análisis realizados

Se realizó un estudio sobre diferentes clasificadores y diferentes métodos de extracción de características de manera off-line sobre los datasets 1 y 2. El objetivo de todos los experimentos en ambos datasets fue detectar el movimiento de agarre con la mano derecha (sin distinguir entre tipos de agarre) sobre sujetos sanos y diestros, de manera que, ante una señal de EEG, el clasificador generaba un comando: reposo (0) o movimiento (1).

Para ello, diferentes casuísticas en la evaluación de la BCI fueron analizadas: se realizaron validaciones cruzadas K-Fold, pruebas intrasujeto e intersujeto, variación en el vector de características del clasificador, entrenamiento y clasificación con 4 modelos diferentes y posterior análisis estadístico en las precisiones obtenidas.

2.3.1 Análisis realizados sobre el dataset 1

2.3.1.1 Clasificación intrasujeto

A. Clasificación

Se realizaron dos análisis 10-Fold intrasujeto sobre los 15 sujetos que utilizaban electrodos secos Hero y los 15 sujetos con electrodos basados en agua Versatile por separado. En cada una de las 10 iteraciones de la validación cruzada, se subdividió el conjunto de datos de cada sujeto de manera que, un subgrupo se reservaba para la clasificación y el resto de los subgrupos se utilizaba para entrenar. Para ello, se utilizaron 4 clasificadores diferentes: Regresión Logística, SVC, Random Forest y LDA.

En cada iteración de la validación cruzada se normalizaban los datos obtenidos sobre el subconjunto de datos entrenamiento para obtener media 0 y varianza 1, y se aplican la media y desviación típica obtenidas, sobre el conjunto de datos de prueba para cada K- iteración, como se explicó en la sección 2.2.2.1. Nótese que en cada iteración de la validación cruzada K-Fold se utilizaba un nuevo modelo de clasificador de cada tipo y una nueva normalización (ver figura 12).

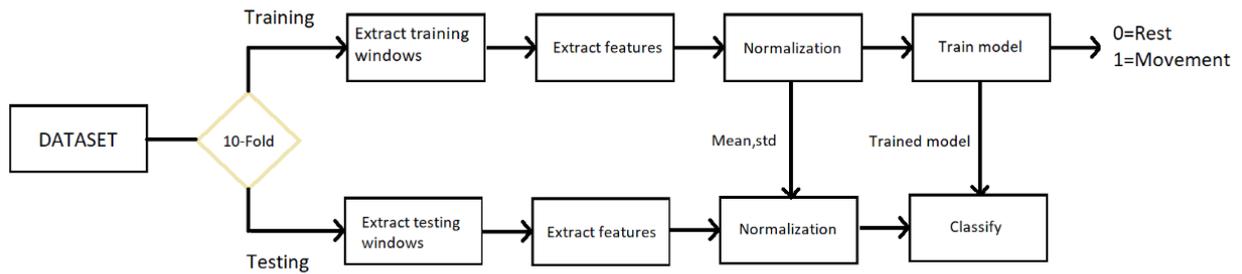


Figura 12: Validación K-Fold propuesta.

B. Análisis estadístico

Se realizaron comparaciones estadísticas para analizar la influencia en la precisión de la decodificación del factor “tipo de clasificador”. Se obtuvieron las precisiones medias con cuatro clasificadores sobre los grupos de sujetos de electrodos secos y electrodos basados en agua. Los clasificadores utilizados fueron Regresión Logística, SVC, Random Forest y LDA.

Se utilizó un análisis ANOVA de un factor para las comparaciones lo que permitió comparar los cuatro grupos en la variable cuantitativa, la precisión media del clasificador. El análisis ANOVA se aplica para contrastar la igualdad de medias de tres o más poblaciones independientes y con distribución normal. Supuestas k poblaciones independientes, las hipótesis del contraste son siguientes:

- $H_0: \mu_1 = \mu_2 = \dots = \mu_k$ Las medias poblacionales son iguales
- H_1 : Al menos dos medias poblacionales son distintas

Se consideró que la diferencia era estadísticamente significativa cuando los valores p eran inferiores a 0,05.

2.3.1.2 Clasificación intrasujeto variando el vector de características

A. Clasificación

Se realizaron 2 análisis variando el número de características del vector para evaluar las diferencias en cuanto a salidas del clasificador:

- (1) Utilizando únicamente los electrodos contralaterales a la extremidad implicada, es decir, los electrodos FC3, C3, CP3 situados en el hemisferio izquierdo, ya que son los que controlan el movimiento de la parte derecha del cuerpo.
- (2) En lugar de promediar las potencias alfa y beta en los 11 canales, se obtuvieron todas las potencias recogidas en los rangos de frecuencias entre 7-13 Hz y 14-25 Hz.

En ambos casos se realizó una validación cruzada K-Fold siguiendo el mismo procedimiento que en el punto anterior y se utilizó un clasificador lineal LDA.

B. Análisis estadístico

Se realizaron comparaciones estadísticas para analizar la influencia en la precisión de la decodificación de los factores: (no)promediar la potencia PSD en alfa y beta y la configuración eléctrica utilizada para la extracción de características (contralateral a la extremidad implicada *versus* todos los electrodos sobre el córtex centroparietal).

En primer lugar, evaluamos, la precisión media obtenida sobre los 15 sujetos que utilizaron los 11 electrodos secos Hero sobre el córtex centroparietal para tener una referencia con la que comparar las otras dos casuísticas. En segundo lugar, se analizó el efecto de utilizar sólo electrodos contralaterales FC3, C3 y CP3. Por último, se analizó la influencia de utilizar como característica las potencias PSD obtenidas en los rangos de frecuencias alfa y beta, en lugar de promediar los valores en dichos rangos de frecuencia.

Se utilizó un análisis ANOVA de un factor para las comparaciones lo que permitió comparar los tres grupos en la variable cuantitativa, la precisión media obtenida con el clasificador LDA. Posteriormente, se utilizó la prueba de Scheffé para realizar los contrastes de igualdad de medias dos a dos ya que el p-valor obtenido en ANOVA fue significativo. En ambos casos se consideró que la diferencia era estadísticamente significativa cuando los p valores eran inferiores a 0,05.

2.3.1.3 Clasificación intersujeto

A. Clasificación

Se realizaron dos análisis intersujeto, uno para los 15 sujetos de electrodos secos y otro para los 15 sujetos de electrodos húmedos. En ambos casos se utilizó un clasificador lineal LDA. En cada iteración del análisis, el conjunto de datos de entrenamiento fueron los ensayos de todos los sujetos, menos los correspondientes a esa iteración, que se utilizaban para clasificar. Así hasta completar las 15 iteraciones correspondientes a los 15 sujetos. De esta manera, en cada ciclo del algoritmo, se testeaba con un sujeto y se entrenaba con todos los demás, de manera que el clasificador no tenía datos del entrenamiento del sujeto que estaba clasificando.

En cada iteración se normalizaban los datos obtenidos sobre el conjunto de entrenamiento de los 14 sujetos para obtener media 0 y varianza 1, y se aplicó la media y desviación típica obtenidas, sobre el conjunto de datos de test de esa iteración. Nótese que en cada una de las 15 iteraciones se utilizaba un nuevo modelo de clasificador LDA y una nueva normalización.

B. Análisis estadístico

Se realizaron comparaciones estadísticas para analizar la influencia en la precisión de la decodificación del factor “tipo de análisis”: intrasujeto o intersujeto. Se compararon las precisiones medias obtenidas con el clasificador lineal LDA sobre los grupos de sujetos de electrodos secos y electrodos basados en agua tanto en el análisis intrasujeto (sección 2.3.1.2) como intersujeto (sección 2.3.1.3).

Se utilizó un análisis ANOVA de un factor para las comparaciones lo que permitió comparar los cuatro grupos en la variable cuantitativa, la precisión media del clasificador LDA. Posteriormente, se utilizó la prueba de Scheffé para realizar los contrastes de igualdad de medias dos a dos ya que el p-valor obtenido en ANOVA fue significativo. En ambos casos se consideró que la diferencia era estadísticamente significativa cuando los p valores eran inferiores a 0,05.

2.3.2 Análisis realizados sobre el dataset 2

2.3.2.1 Validación 10-Fold en tres escenarios diferentes

Se analizaron por separado las tres series diferentes grabadas en el dataset 2:

- (1) Sujetos que recibieron estimulación FES durante la imaginación de movimiento
- (2) Sujetos que recibieron estimulación FES durante el período considerado movimiento pero que no realizaban la imaginación de este.
- (3) Sujetos que no recibieron estimulación FES durante la imaginación del movimiento.

En cada uno de los tres análisis se estudiaron por separado los sujetos que habían utilizado electrodos secos y por otro, los que utilizaron electrodos húmedos. En todos los casos se utilizó un clasificador lineal LDA, se realizó una validación cruzada 10-Fold intrasujeto y se normalizaron los datos del conjunto de datos de entrenamiento y de clasificación siguiendo el algoritmo Z-Score ya explicado (ver figura 12).

2.3.2.2 Training con datos de “Imaginación de movimiento sin estimulación” y clasificación con “Imaginación de movimiento + FES”

El supuesto más fiel a la realidad en una terapia de rehabilitación motora (en este caso con FES) en tiempo real, es el caso en el que se entrena el clasificador con el conjunto de datos proveniente de imaginación del movimiento (IM) sin estimulación funcional (FES) (por tanto, sin artefactos de estimulación), y se clasifica con los datos de IM junto con FES. El objetivo de la BCI es clasificar la señal cerebral en tiempo real, en este caso, en una supuesta utilización con un dispositivo FES, por lo tanto, la EEG del sujeto grabada en tiempo real estará influenciada por los artefactos de la estimulación.

Se hicieron dos análisis, uno para los 10 sujetos con electrodos secos Hero y otro para los 8 sujetos con electrodos basados en agua Versatile. Para cada sujeto se entrenó un clasificador LDA con los datos de ese participante en su serie “Imaginación de movimiento (IM) sin estimulación”, se normalizaron los datos para obtener media cero y varianza unitaria con el método Z-Score y se utilizó ese modelo/datos de normalización para clasificar los datos de la serie “Imaginación de movimiento + FES” del mismo sujeto. Nótese que, para la clasificación de cada sujeto, se utilizaba un nuevo modelo LDA y una nueva normalización.

2.4 Integración en la plataforma en tiempo real

2.4.1 Descripción de la plataforma existente

Se integró el sistema implementado en una plataforma de decodificación de EEG en tiempo real (desarrollada en C++) propiedad de Bitbrain, para evaluar los resultados del sistema BCI en un escenario on-line. Para esta fase se tuvieron en cuenta las grabaciones del dataset 2 ya resultan más relevantes en entornos reales.

La plataforma utilizada (ver figura 13) es un sistema multiproceso que implementa un patrón de comunicación publicación-suscripción con distintos módulos comunicados entre sí mediante sockets TCP/IP. Los módulos que la componen son ejecutados de manera sincronizada y son controlados por dos procesos especiales que implementan el control de alto nivel de todo el sistema: el controlador, que es el responsable de la configuración del sistema; y el gestor, que secuencia todos los módulos. Este bucle de control se repite con una frecuencia configurable (en este caso, cada 32 ms).

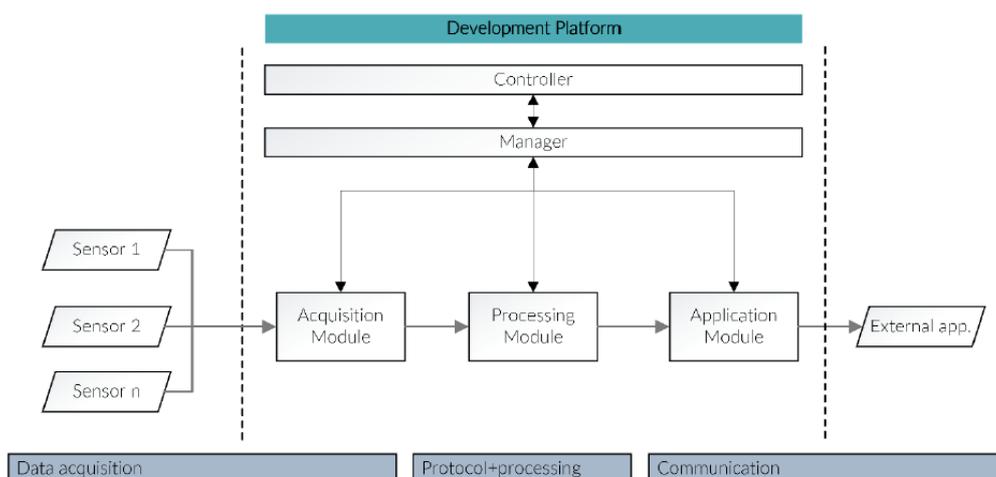


Figura 13: Estructura plataforma en tiempo real de Bitbrain. Extraído de: www.bitbrain.com.

En primer lugar, el módulo de adquisición introduce las señales de los sensores en la arquitectura. A continuación, el/los módulo/s de procesamiento realiza/n el procesamiento de la señal de entrada, generando señales y eventos. Por último, un "módulo de aplicación" cierra el bucle de control, proporcionando retroalimentación al usuario o comunicándose con una aplicación externa, como por ejemplo un brazo robótico o un sistema FES.

Dentro de cada módulo hay unidades de procesamiento. Las unidades de procesamiento son componentes de software que contienen las funcionalidades del sistema (por ejemplo, algoritmos de procesamiento). Las unidades se ejecutan secuencialmente, y presentan una interfaz común (inicializar, procesar, reiniciar).

2.4.2 Integración del sistema BCI en la plataforma en tiempo real

La integración del sistema desarrollado en este proyecto en la plataforma en tiempo real consistió en el desarrollo de una nueva unidad suscrita al módulo de procesamiento de esta arquitectura. Esta nueva unidad, recibía en tiempo real una señal cerebral proveniente de un gorro EEG seco de 10 electrodos, la procesaba, clasificaba y enviaba la predicción generada por el clasificador a un módulo de estimulación FES, el cuál realizaba estimulación sobre un sujeto sano cuando éste realizaba imaginación del movimiento.

Para ello, se creó un script en Python que implementaba la interfaz requerida por la plataforma: inicializar(), procesar(), reiniciar(), y que contenía el código relativo tanto del procesado de la señal EEG como de la clasificación continua de la misma. El código fue replicado tal y como se había desarrollado en el sistema off-line, ya que se hizo una implementación emulando en todo momento el objetivo final del proyecto, por lo que el uso de ventanas deslizantes, buffer circular y resto de detalles del diseño permitió una integración directa y sencilla.

El bucle de control del sistema se repetía a una frecuencia configurable, en este caso cada 32 ms. Es decir, cada 32 ms la unidad de procesado creada, era llamada por el control del sistema con un nuevo bloque de datos EEG a clasificar.

La configuración del sistema se realizó en un fichero JSON donde se definió la nueva unidad creada que procesaba/clasificaba la señal, y las entradas/salidas de esta. A modo esquemático, el fichero de configuración contenía:

- Módulo Adquisición de la señal:
 - Configuración de los parámetros del gorro EEG seco en tiempo real utilizado (1).
- Módulo Procesado:
 - Definición de la nueva unidad del sistema BCI desarrollado:
 - Entrada: Señal EEG proveniente del gorro de EEG seco Hero (1).
 - Salida: Predicción del clasificador del bloque de señal recibida (2).

- Módulo Comunicación:
 - Definición módulo de comunicación que recibe el comando, por ejemplo, FES:
 - Entrada: Predicción del clasificador (2).
 - Salida: activar/desactivar FES.

Se evaluó el sistema integrado sobre un sujeto particular sano y diestro. Para ello, se realizó una grabación EEG en la que se pidió al sujeto que realizara imaginación de movimiento (sin FES) durante 3 series de datos, replicando el escenario de grabación del dataset 2. Se obtuvieron un total de 60 ensayos de los cuáles se extrajeron las ventanas de entrenamiento. Se procesaron y normalizaron los datos de la misma manera que se hizo con el dataset 2 (sección 2.1.2). Finalmente, se entrenó un clasificador LDA con el sistema desarrollado en este trabajo.

Para el experimento en tiempo real, el sujeto debía mantener la atención en una pantalla donde aparecían secuencias de 5 segundos con las palabras “rest” y “move”. Cuando aparecía la palabra “move”, el sujeto debía realizar la imaginación de movimiento. El control de la plataforma en tiempo real llamaba al nuevo módulo desarrollado e integrado en el sistema, el cuál procesaba y clasificaba con una frecuencia de 32 Hz nuevos bloques de señal EEG, de manera que la estimulación FES se activaba en el antebrazo derecho del sujeto cuando el clasificador entrenado así lo predecía.

2.4.3 Clasificación pseudo-online

Se recreó un escenario de pruebas intrasujeto con los datos del dataset 2. Para ello, se creó un script en Python que generaba un clasificador LDA entrenado para cada sujeto del conjunto de pruebas, normalizaba el conjunto de datos de entrenamiento con media cero y varianza unitaria y guardaba el modelo entrenado y los datos de la normalización en disco. Como conjunto de datos de entrenamiento se utilizó la serie de grabaciones donde los sujetos realizaban imaginación de movimiento (IM) y no recibían estimulación. La razón de elegir esta serie para entrenar fue que no existieran artefactos de estimulación FES, para que el clasificador detectara la ERD con el menor ruido y siendo lo más fiel a la señal EEG del sujeto posible.

Una vez que los clasificadores fueron entrenados (uno para cada sujeto) se lanzó un segundo script que contenía la integración del sistema BCI emulando el entorno en tiempo real explicado en la sección anterior. Para cada sujeto, se leía de disco el clasificador entrenado y los datos de normalización y se aplicaban al conjunto de datos de prueba, correspondiente a las grabaciones de IM + FES de ese sujeto, de modo que se replicaba el escenario en tiempo real.

3 Resultados

3.1 Dataset 1

3.1.1 Análisis de la señal

La figura 14 muestra la PSD obtenida en el canal CP3 sin (figura 14A) y con filtrado espacial CAR (figura 14B). El filtro CAR realza la actividad local del electrodo y reduce la actividad común de los demás electrodos, incluyendo artefactos, ruido y parpadeos, por tanto, se eleva la relación señal/ruido. Los vectores de características del clasificador para los ensayos de “reposo” y “movimiento” se obtienen del promedio de la potencia PSD en alfa y beta para cada canal, por tanto, cuanto más distantes sean estos vectores entre sí, mejor podrá discernir el clasificador entre los estados de reposo y movimiento.

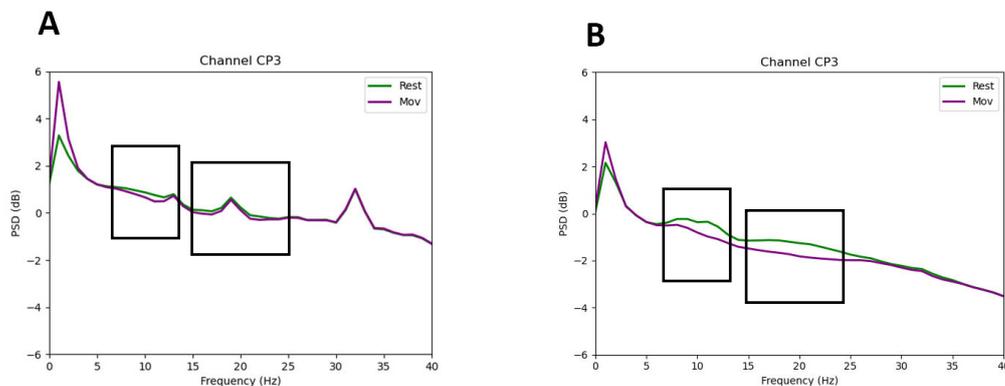


Figura 14: Ejemplo de PSD sin (A) y con (B) filtrado espacial CAR en uno de los sujetos y en el canal CP3.

3.1.2 Análisis intrasujeto

En todos los análisis mostrados a continuación del dataset 1, las zonas celestes indican los intervalos tenidos en cuenta para calcular la precisión media de clasificación y la zona rosa indica el intervalo de confianza del nivel de azar ($\alpha = 0,01$) calculado según [12].

3.1.2.1 Clasificación intrasujeto

La figura 15 muestra la respuesta media de los 4 clasificadores utilizados a lo largo del ensayo, mostrando los FP (falsos positivos) en el intervalo $[-2,0]$ y los TP (verdaderos positivos) en el intervalo $[0,2]$ en los análisis con EEG seco (fig.15A) y EEG húmedo (figura 15B). En ambos análisis, los 4 clasificadores (lineales o no lineales) tienen un comportamiento muy similar. Vimos anteriormente que los clasificadores lineales son los más utilizados en decodificación

EEG para rehabilitación motora, sin embargo, en ocasiones puede que los no lineales obtengan un mejor rendimiento.

En los 4 casos, se obtienen en torno a un 20% de salidas de FP (falsos positivos) durante el período de descanso, es decir, en torno al 20% de las veces los clasificadores se equivocan en su predicción. Durante el período de movimiento [0,2] s, en torno al 80% de las veces se obtienen TP (verdaderos positivos), es decir, el clasificador predice que la salida es movimiento, y efectivamente lo es.

En el caso de los sujetos con electrodos Versatile (figura 15B) las precisiones obtenidas en los cuatro clasificadores son muy similares a las obtenidas con EEG seco (figura 15A), aunque ligeramente inferiores. Es decir, con la tecnología Versatile el clasificador se equivoca de media más veces que con la tecnología Hero, al menos en los sujetos analizados.

Se observa el hecho de que el movimiento es detectado un segundo antes del inicio del mismo. Ello se debe a que los sujetos recibían la señal de comienzo del movimiento en $t=0$ s y, en ese preciso instante, la mano era levantada de la base sensada en el experimento. Aunque el movimiento de la mano comience en $t=0$ s, para realizar esa acción son necesarios movimientos previos de toda la extremidad, como son hombro y brazo, antes de que la mano comience realmente a moverse. Este hecho se repetirá en todos los análisis sobre el dataset 1.

La siguiente figura 15C-D muestra el detalle de las medias y desviaciones típicas obtenidas con cada modelo, tanto en Hero (fig. 15C) como en Versatile (fig. 15D). La figura 15E-F, muestra el resultado de las precisiones medias de los cuatro modelos, por sujeto, en los grupos de EEG seco Hero (fig.15E) y EEG húmedo (fig. 15F). En todos los casos, la precisión media obtenida estuvo entre 57% y 99% para los sujetos que utilizaban Hero y entre 62% y 85% para los que utilizaban Versatile, lo que hace que todos los clasificadores obtengan un rendimiento en torno al 80% en ambas tecnologías y en ambos grupos de sujetos.

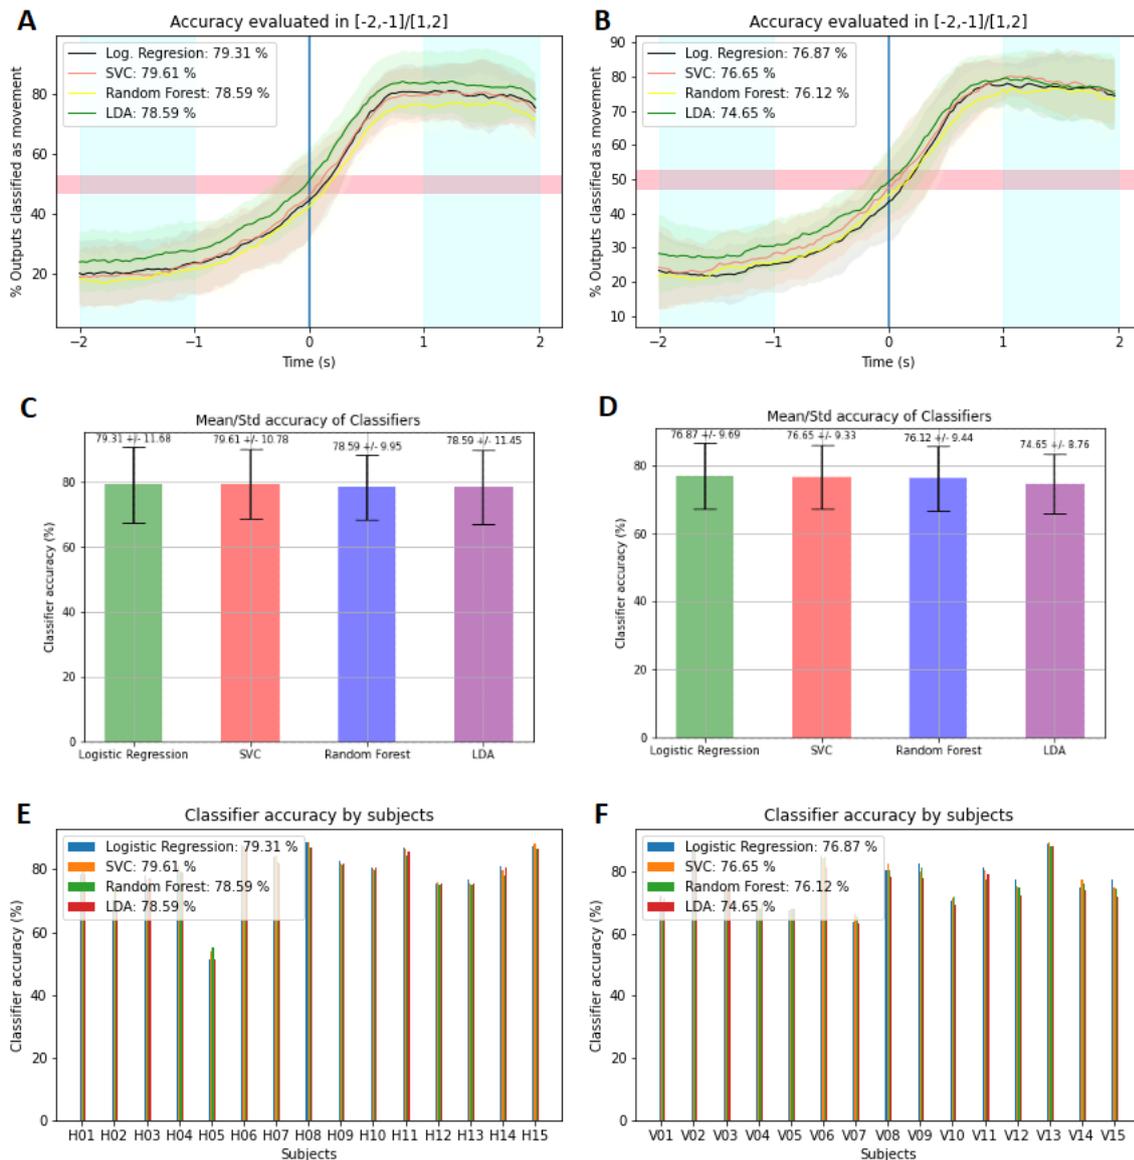


Figura 15: A y B: Respuesta media temporal de los 4 clasificadores utilizados con validación cruzada 10-Fold (A: EEG seco. B: EEG húmedo). C y D: Precisión media en cada clasificador en todos los sujetos (C: EEG seco. D: EEG húmedo). E y F: Precisión media y STD obtenida en los 4 clasificadores por sujeto (E: EEG seco. F: EEG húmedo).

3.1.2.2 Análisis estadístico intrasujeto de los cuatro clasificadores

El análisis ANOVA de un factor permitió comparar los cuatro modelos en la variable cuantitativa, la precisión media del clasificador. Considerando que la diferencia era estadísticamente significativa cuando los valores p eran inferiores a 0,05, no se obtuvieron diferencias significativas en las precisiones obtenidas con los cuatro modelos, ni en el caso de EEG seco (p-valor=0,983) ni en el caso de EEG húmedo (p-valor=0,793).

Basándonos en este resultado y en las ventajas anteriormente descritas de los clasificadores lineales (sencillos, fáciles de utilizar y apropiados para rehabilitación motora), se utilizó el clasificador lineal LDA para el resto de los análisis del trabajo. En la figura 15A-B y en la tabla 1 se muestran los detalles de las precisiones medias y STD utilizadas para el análisis estadístico.

Tabla 1: Precisión media y STD en los 4 clasificadores

	Log.Regression	SVC	Random Forest	LDA
Hero electrodes	79,31 ± 11,68%	79,61 ± 10,78%	78,59 ± 9,95%	78,59 ± 11,45%
Versatile electrodes	76,87 ± 9,69%	76,65 ± 9,33%	76,12 ± 9,44%	74,65 ± 8,76%

3.1.2.3 Clasificación intrasujeto variando el vector de características

En la figura 16 se observa el resultado de los análisis intrasujeto variando el vector de características y utilizando LDA. La precisión media en los sujetos que utilizaron EEG seco con los 11 electrodos centro-parietales fue de 78,59% (figura 16A) frente al 66,05% obtenido utilizando solo los canales contralaterales a la mano que se movía (figura 16B) de manera que se perdía información de codificación al reducir el número de electrodos. Ampliar el número de características no promediando la potencia en alfa y beta, sino utilizando todas las potencias en dichos rangos de frecuencias, supuso un descenso del 3% en la precisión media obtenida (figura 16C) con respecto a sí promediarlas (figura 16A).

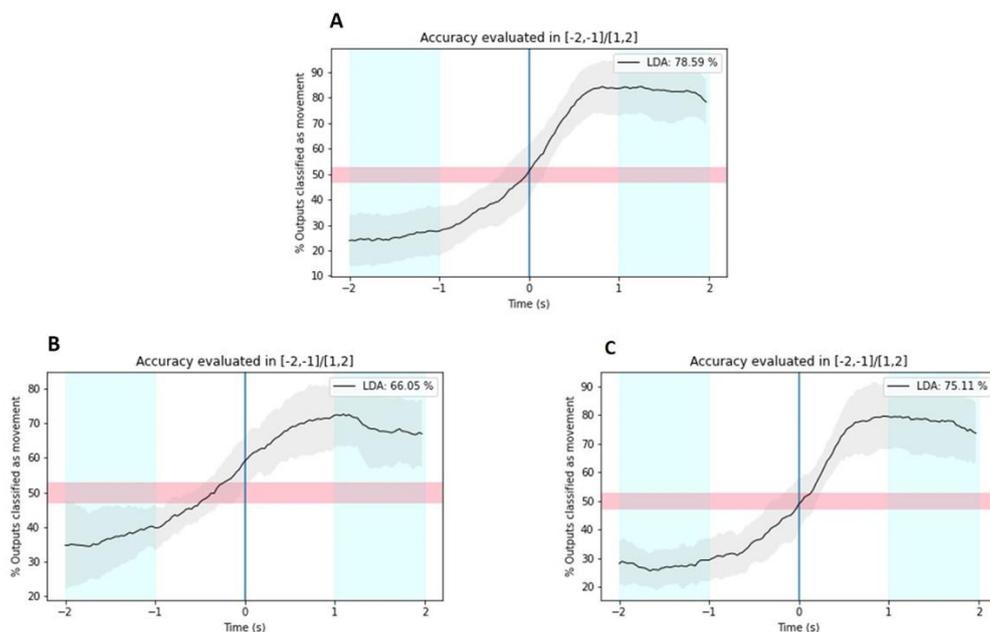


Figura 16: Respuesta media temporal del clasificador. A: 11 electrodos centro-parietales. B: 3 electrodos contralaterales. C: Sin promediar PSD en alfa y beta. Las zonas grises indican la desviación estándar con respecto a la media obtenida.

3.1.2.4 Análisis estadístico intrasujeto de variar el vector de características

El análisis ANOVA de un factor permitió comparar los tres grupos en la variable cuantitativa, la precisión media obtenida con el clasificador LDA (ver tabla 2). Los supuestos fueron:

- (1) EEG seco en el córtex centroparietal
- (2) EEG seco contralateral a la extremidad implicada
- (3) No promediar la potencia PSD en alfa y beta con EEG seco en el córtex centroparietal

Considerando que la diferencia era estadísticamente significativa cuando los valores p eran inferiores a 0,05, las diferencias entre los tres grupos fueron significativamente diferentes con p -valor=0,01. El análisis posterior con la prueba de Scheffé para realizar los contrastes de igualdad de medias dos a dos, concluyó que las diferencias fueron significativas entre los grupos (1) y (2), de manera que la utilización de todos los electrodos -respecto a la utilización de sólo los contralaterales- suponía una mejora significativa en la precisión de decodificación. El no realizar el promedio de PSD en alfa y beta sino utilizar todas las potencias obtenidas en dichos rangos, no obtuvo diferencias significativas en la precisión media obtenida (p -valor=0,554).

Tabla 2: Precisión media y STD variando el vector de características

	Mean/STD
Electrodos centro-parietales	78,59 ± 11,45%
Electrodos contralesionales	66,05 ± 11,93%
PSD sin promediar en α y β	75,11 ± 11,19%

3.1.3 Análisis intersujeto

3.1.3.1 Clasificación intersujeto

La figura 17 muestra los resultados de las pruebas intersujeto realizadas en ambos grupos. Las zonas grises indican la desviación estándar con respecto a la media obtenida. En ambos casos, la precisión media obtenida intersujeto es inferior a la obtenida en intrasujeto (ver Figura 15) lo que pone de manifiesto la dificultad añadida del problema de clasificación. Nótese que este caso, la clasificación de cada sujeto, era realizada por un modelo que había sido entrenado previamente con los datos de los demás sujetos.

En el caso de las pruebas con EEG seco (fig.17A), la precisión media obtenida con LDA fue de 67,09% frente al 78,59% en la clasificación LDA intrasujeto (figura 15A). En caso de EEG húmedo (fig. 17C), la precisión media obtenida con LDA fue de 64,52% frente al 74,65% en la clasificación LDA intrasujeto (figura 15B).

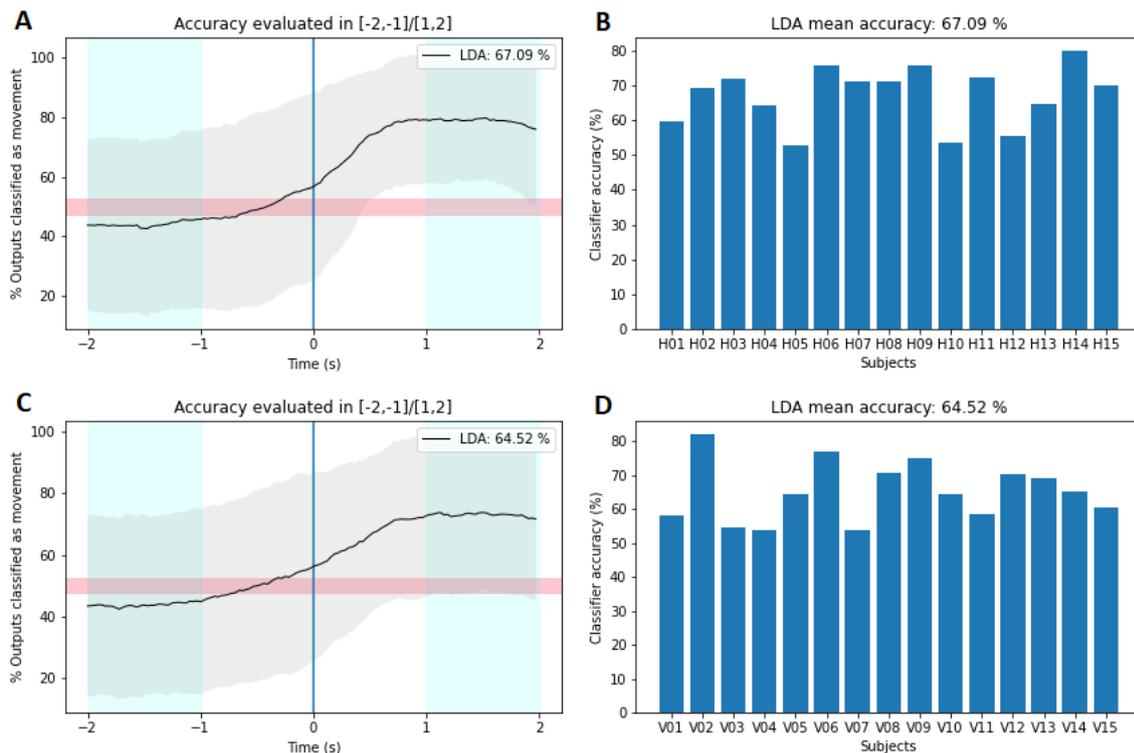


Figura 17: A y C: Respuesta media temporal del clasificador (A: EEG seco. C: EEG húmedo). B y D: Precisión media y STD del clasificador por sujeto (B: EEG seco. D: EEG húmedo).

3.1.3.2 Análisis estadístico comparativo intrasujeto-intersujeto

El análisis ANOVA de un factor permitió comparar los cuatro grupos en la variable cuantitativa, la precisión media obtenida con el clasificador LDA (ver tabla 3). Los cuatro grupos comparados fueron:

- (1) EEG seco en análisis intrasujeto
- (2) EEG húmedo en análisis intrasujeto
- (3) EEG seco en análisis intersujeto
- (4) EEG húmedo en análisis intersujeto

Considerando que la diferencia era estadísticamente significativa cuando los valores p eran inferiores a 0,05, las diferencias entre los cuatro grupos fueron significativamente diferentes con p-valor=0,01. El análisis posterior con la prueba de Scheffé para realizar los contrastes de igualdad de medias dos a dos, concluyeron que las diferencias fueron significativas entre los grupos (1) y (3), y (2) y (4) con p-valor de 0,007 y 0,021 respectivamente. Es decir, realizar un análisis intersujeto en cada una de las tecnologías suponía un descenso significativo en la precisión de decodificación, con respecto a realizar el análisis con la misma tecnología, intrasujeto.

Las comparaciones dentro de los análisis intrasujeto, con Hero y Versatile, no supusieron resultados significativamente diferentes con un p-valor de 0,663. De la misma manera, dentro

de los análisis intersujeto, utilizar una tecnología de EEG seco o húmedo, no supuso cambios significativos en cuanto a resultados de precisión, con un p-valor de 0,878.

Tabla 3: Precisión media y STD obtenida con LDA intrasujeto e intersujeto

		Mean/STD
Intrasujeto	Hero	78,59 ± 11,45%
	Versatile	74,65 ± 8,76%
Intersujeto	Hero	67,09 ± 8,41%
	Versatile	64,52 ± 10%

3.2 Dataset 2

En todos los análisis del dataset 2, las zonas celestes indican los intervalos tenidos en cuenta para calcular la precisión media del clasificador. Las zonas rosas indican intervalo de confianza del nivel de azar ($\alpha = 0,01$) calculado según [12]. Las zonas verdes claro son la desviación típica de la media.

3.2.1 Validaciones cruzadas K-Fold

3.2.1.1 Estimulación FES durante imaginación de movimiento.

La figura 18 muestra la precisión media de clasificación obtenida con validación 10-Fold en los sujetos recibían estimulación funcional mientras realizaban la imaginación del movimiento. La media de FP (falsos positivos) en Hero se encuentra en un 40% (figura 18A) mientras que en Versatile es del 30% aproximadamente (figura 18C). Es decir, el clasificador se equivocó en su predicción en un 40% y 30% de las veces respectivamente, en el periodo de reposo. En los periodos de movimiento, en ambos casos Hero y Versatile, el clasificador ofrece TP (verdaderos positivos) en un 75% de las veces aproximadamente (es decir, predice que es movimiento, y efectivamente, lo es).

Si comparamos estos resultados con los obtenidos en el dataset 1, donde se obtenían unas medias en el caso del análisis intrasujeto con LDA de 78,59% (Hero) y 74,65% (Versatile) (figura 15A y B), con los obtenidos en dataset 2: 66,47% (Hero) y 72,45 % (Versatile) (figura 18 A y C), observamos que son ligeramente inferiores.

La estimulación FES introduce artefactos a 35 Hz en la señal EEG, es decir, aumenta la potencia en el rango de frecuencias beta. Esto tiene consecuencias en el rendimiento del clasificador, el cuál toma como vector de características de entrada, las potencias promedio en alfa y beta para cada canal. Por lo tanto, si FES genera ERS en beta, el clasificador interpretará reposo

(reposo=ERS, movimiento=ERD), cuando realmente es movimiento (FES solo se aplica en los intervalos de los ensayos $t > 0s$, es decir, en movimiento). Un ejemplo de ello se puede observar en la figura 18 A, donde en el intervalo $[0,1]s$ la desviación típica (zona marcada en verde claro) muestra cómo, en muchos casos, se ha detectado reposo en lugar de movimiento (la pendiente que marca las salidas del clasificador como movimiento, se mantiene más o menos constante hasta el segundo 1 donde se hace más acusada al haber más salidas clasificadas como “1” o movimiento).

Se observa el hecho de que el movimiento es detectado, a diferencia de lo que ocurre en el dataset 1, unos 0,5 segundos después del comienzo de este. Ello se debe a que los sujetos recibían la señal visual de comienzo del movimiento en $t=0s$, pero puede que los sujetos no estuvieran entrenados en el ejercicio de realizar “imaginación de movimiento” y que tarden unas décimas de segundo en comenzar la acción. Esto hecho se observa en todos los análisis del dataset 2.

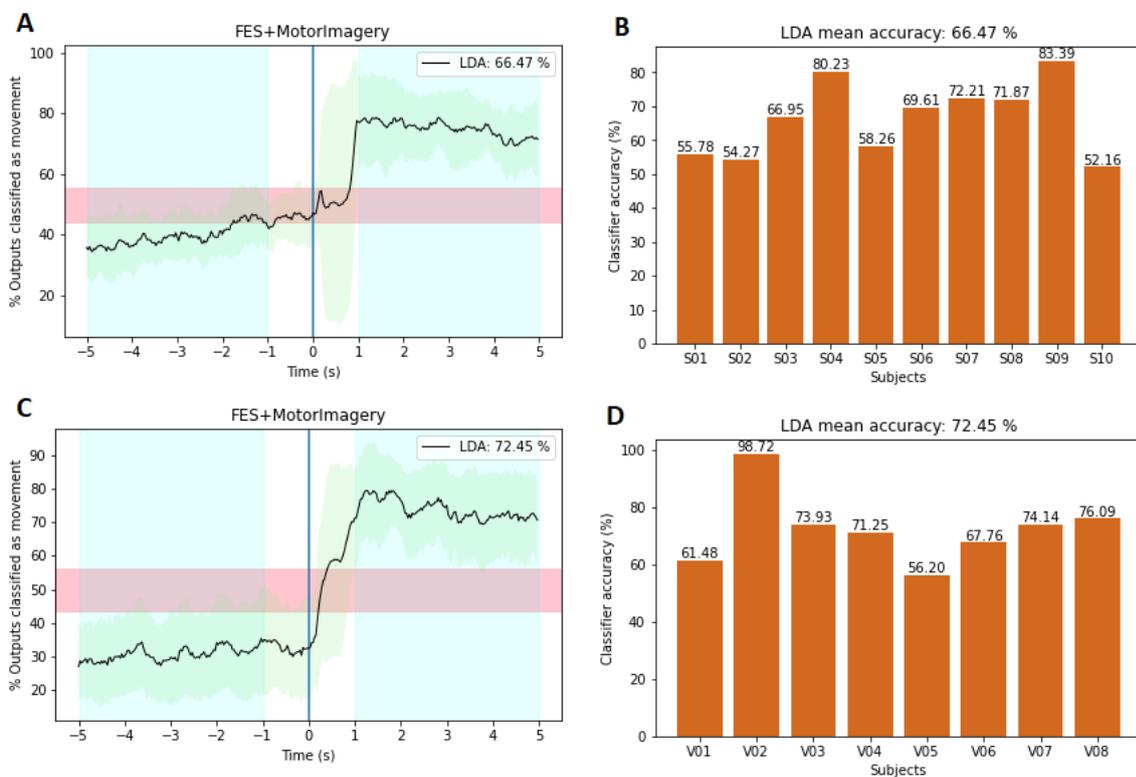


Figura 18: Análisis con validación cruzada 10-Fold sobre el conjunto de datos: FES + MI. A y C: Respuesta media temporal del clasificador (A: EEG seco. C: EEG húmedo). B y D: Precisión media del clasificador por sujetos (B: EEG seco. D: EEG húmedo).

3.2.1.2 Estimación FES pasiva (sin imaginación del movimiento durante la estimulación)

La figura 19 muestra la precisión media de clasificación obtenida con validación 10-Fold en los sujetos que recibían estimulación funcional sin realizar la imaginación del movimiento. Las precisiones medias obtenidas en los sujetos que utilizaron EEG seco y en los sujetos que usaron

EEG húmedo fueron de 70,95 % y 68,68% (fig. 19 A y C) respectivamente, es decir, muy similares entre ellas y también similares a los obtenidos en la serie FES+ Imaginación motora (figura 18). Se observa el hecho de que realizar imaginación del movimiento *versus* no realizarla, no varía apenas los resultados, existiendo en ambos casos estimulación FES. Nótese de nuevo la variabilidad de resultados en el intervalo [0,1]s debida a la estimulación (zona verde claro), y ya comentada en el punto anterior 3.2.1.1.

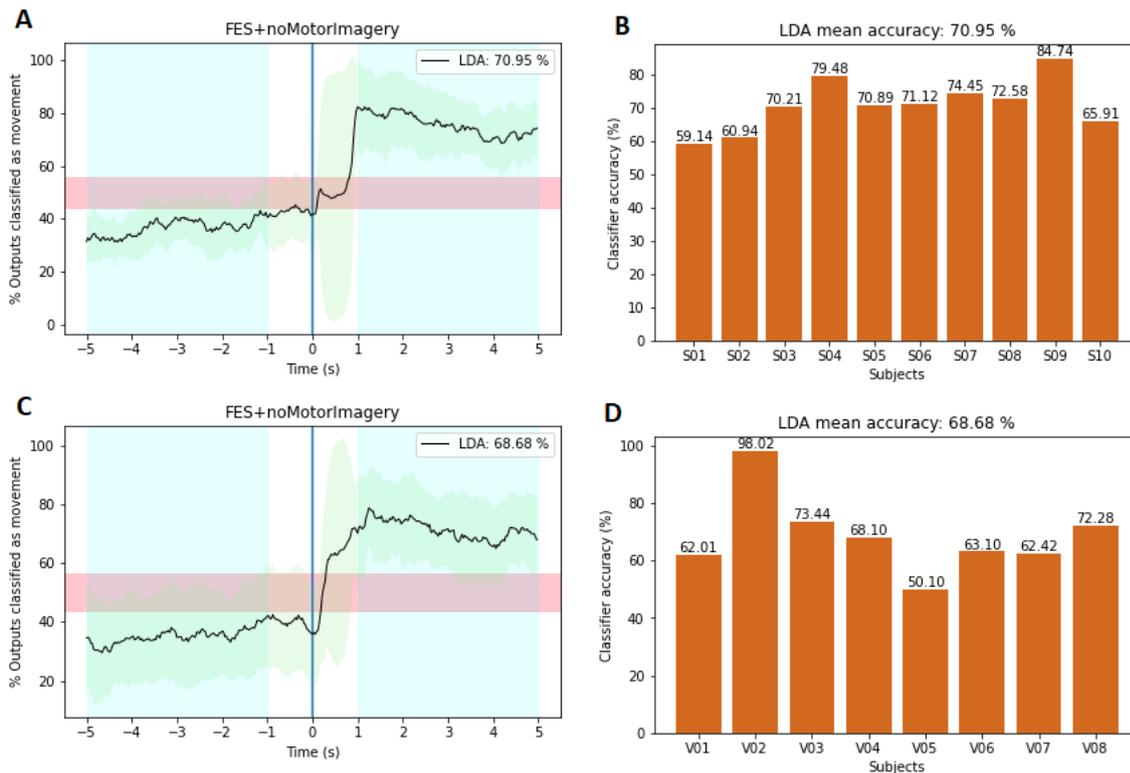


Figura 19: Análisis con validación cruzada 10-Fold sobre el conjunto de datos: Fes+ no Motor Imagery. A y C: Respuesta media temporal del clasificador (A: EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujetos (B: EEG seco. D: EEG húmedo).

3.2.1.3 Imaginación de movimiento sin estimulación

La figura 20 muestra la precisión media de clasificación obtenida con validación 10-Fold en los sujetos que no recibían estimulación funcional mientras realizaban la imaginación del movimiento. Las precisiones medias obtenidas fueron de 56,30% y 64,69% en EEG seco y EEG húmedo respectivamente (figura 20 A y C), inferiores a los dos supuestos recientemente estudiados donde, en ambos casos, se utilizaba estimulación FES.

La estimulación introduce artefactos en la señal EEG de manera que se genera artificialmente una ERD asociada al movimiento. Por esta razón, cuando se realiza FES, el clasificador obtiene

mejores resultados de clasificación con respecto a cuando el sujeto solo realiza la imaginación del movimiento.

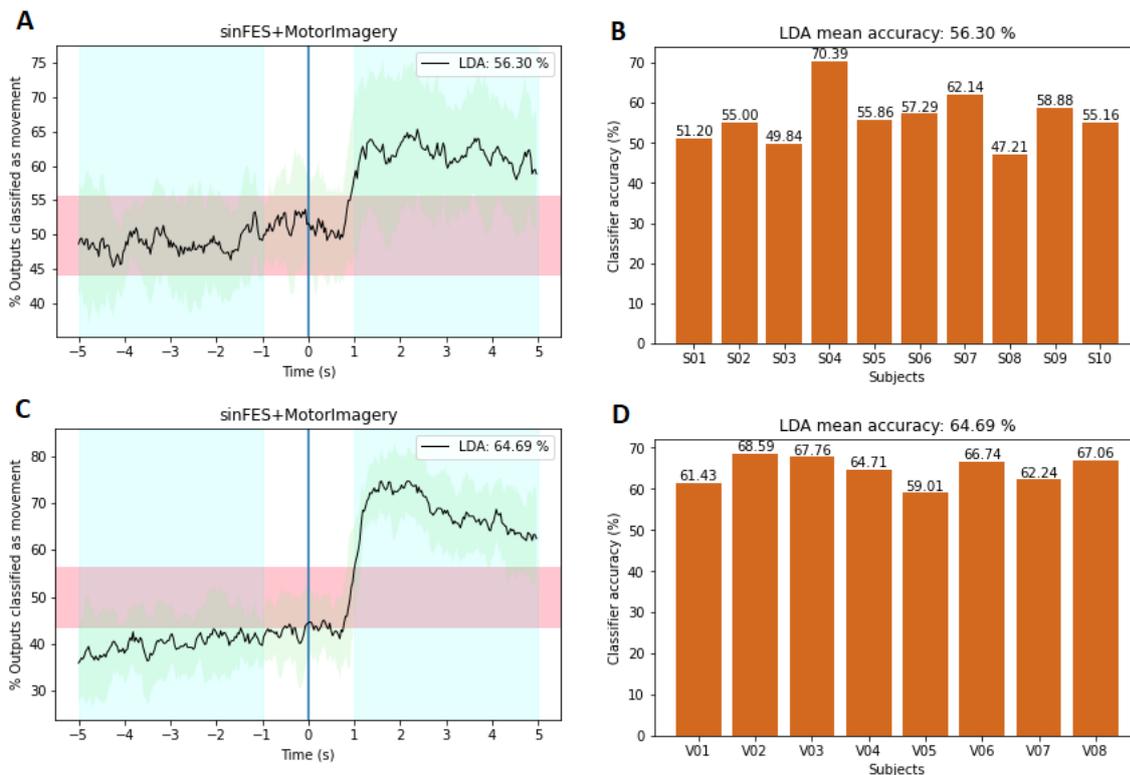


Figura 20: Análisis con validación cruzada 10-Fold sobre el conjunto de datos: Fes+ Motor Imagery. A y C: Respuesta media temporal del clasificador (A: EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujetos (B: EEG seco. D: EEG húmedo).

3.2.2 Training con datos de “Imaginación de movimiento sin estimulación” y clasificación con “Imaginación de movimiento + FES”

La figura 21 muestra la precisión media obtenida con el clasificador LDA en los sujetos que utilizaron la EEG seco (fig. 21 A) y EEG húmedo (fig. 21 C) en una simulación de caso de uso real, donde el entrenamiento de los datos se realiza con IM sin FES y la clasificación se realiza sobre IM+FES. Las precisiones medias obtenidas fueron muy parecidas en ambas tecnologías, de 64,67% y 67,59% respectivamente, y similares a las obtenidas en la validación 10-Fold del apartado anterior.

Nótese como en el EEG seco (figura 21 A) se aprecia muy bien el artefacto de estimulación durante el primer segundo de movimiento y como en el caso de EEG húmedo (figura 21 B) no es tan acusado. No se puede garantizar que este hecho sea debido a la tecnología, ya que hay muchos factores que pueden influir en los resultados, como la propia capacidad de los sujetos en realizar el ejercicio de imaginación de movimiento.

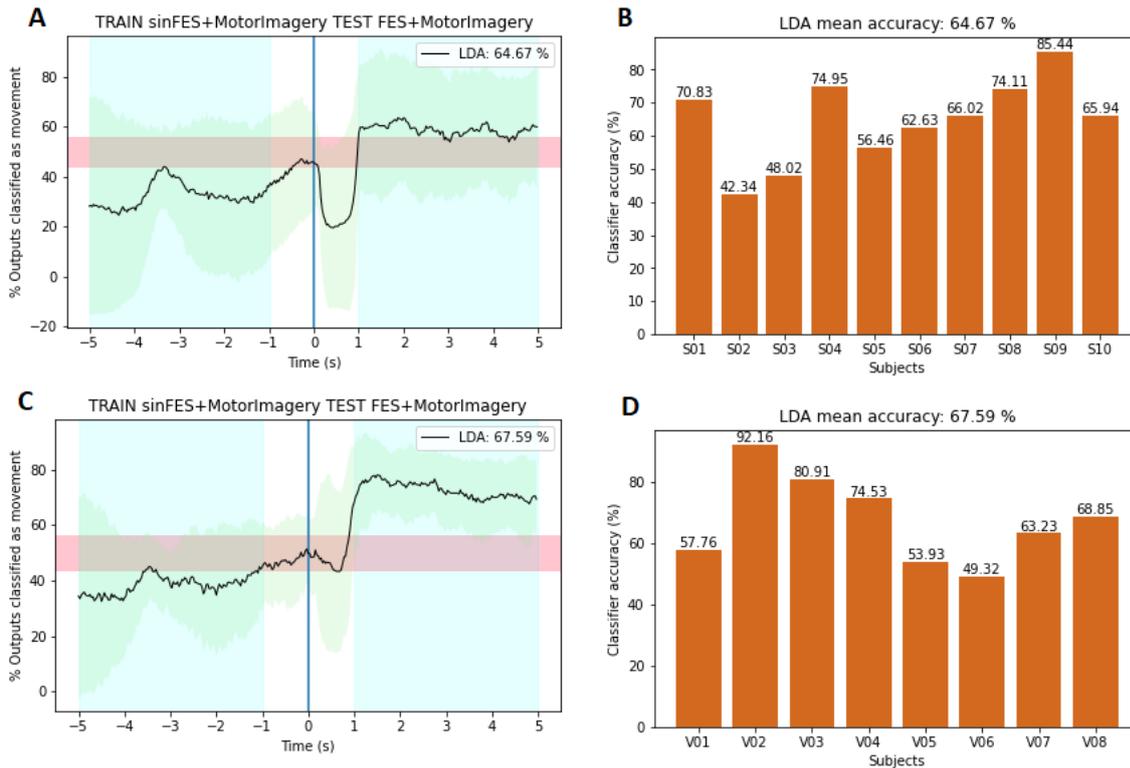


Figura 21: Análisis sobre el conjunto de datos entrenamiento: sin Fes+ Motor Imagery y conjunto de datos de clasificación: Fes+ Motor Imagery. A y C: Respuesta media temporal del clasificador (A: EEG seco. B: EEG húmedo). B y D: Precisión media del clasificador por sujeto (B: EEG seco. D: EEG húmedo).

3.2.3 Resultados de emulación de la clasificación en tiempo real

En la figura 22 se observan las precisiones medias obtenidas en la clasificación de cada uno de los sujetos del dataset 2 donde se hizo una emulación de decodificación del movimiento en tiempo real. La precisión media obtenida con LDA en el caso de los sujetos que utilizaron electrodos secos fue de 55,84% (fig. 22A) y 61,83% en el caso de electrodos húmedos (fig. 22B).

La figura 23 muestra un ejemplo de la salida del clasificador en una de las emulaciones de clasificación en tiempo real y en uno de los sujetos donde se obtuvo una precisión media de 72,94%. Se comparaba la predicción del clasificador pseudo-online (línea negra) *versus* la etiqueta real de la señal en ese instante de tiempo (línea verde). El clasificador generaba una respuesta (“reposo” o “movimiento”) con una frecuencia de 32 Hz, es decir, cada 8 muestras de señal EEG (eje X de la figura 23) o cada 31,25 ms.

Nótese que en la clasificación pseudo-online no se realizó la segmentación de la señal EEG continua, sino que se llamó al clasificador con una frecuencia de 32 Hz durante toda la señal EEG. Los ensayos de la grabación del dataset 2 consistieron en 10 segundos de reposo, donde

en los 5 primeros, se permitió a los participantes parpadear/moverse/relajarse y, en los 5 segundos siguientes, debían concentrarse en la tarea de reposo y no hacer nada más. A continuación, comenzaban los 5 segundos de movimiento. Al clasificar la señal completa, se incluían los 5 primeros segundos en el análisis donde el sujeto se relajaba, lo que introdujo ruido debido a este tipo de artefactos y lo dejaba en desventaja con respecto al análisis off-line realizado con la misma serie de datos para el entrenamiento (IM sin FES) y la clasificación (IM+FES), donde solo se evaluaban los ensayos y no las secuencias entre uno y otro (figura 21).

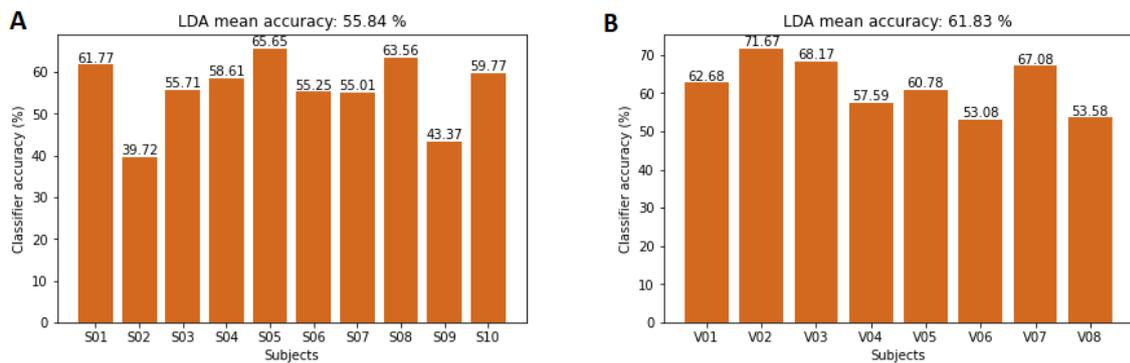


Figura 22: Precisión de decodificación media obtenida en simulación tiempo real con LDA. A: Sujetos con EEG seco. B: Sujetos con EEG húmedo. Conjunto de datos entrenamiento: sin Fes+ Motor Imagery. Conjunto de datos clasificación: Fes+ Motor Imagery.

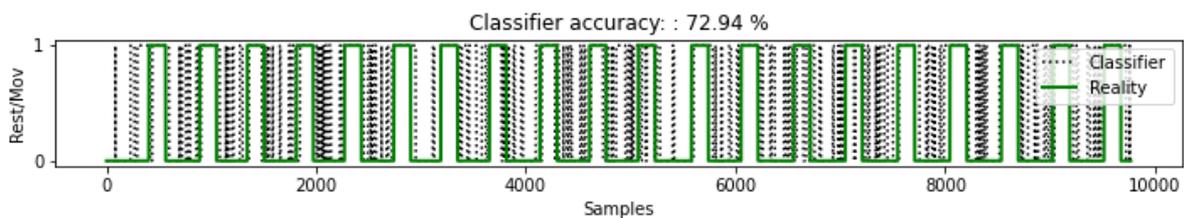


Figura 23: Ejemplo de las salidas de la clasificación/simulación on-line. Línea negra punteada, salidas del clasificador. Línea verde, etiquetas reales de EEG.

4 Conclusiones y futuras líneas de trabajo

4.1 Discusión

El presente trabajo demuestra aplicabilidad de las interfaces cerebro ordenador (BCI) para la decodificación continua de la intención de movimiento mediante EEG utilizando como características las ERD asociadas a la intención de movimiento. Se utilizó un clasificador lineal LDA y el sistema fue evaluado en escenarios off-line y pseudo-online, así como sobre grabaciones de EEG con/sin artefactos producidos por estimulación FES.

En los experimentos realizados sobre el dataset 1, donde no había artefactos de estimulación, se obtuvieron buenos rendimientos en la ejecución del clasificador lineal LDA, entorno al 80% en los análisis intrasujeto. Estos resultados concuerdan con los obtenidos en otros estudios similares intrasujeto como [7], [13], [14].

Los análisis intersujeto demostraron peores resultados, lo cual era de esperar ya que el clasificador es capaz de predecir mejor la intención de movimiento si es entrenado con los datos EEG del sujeto al que va a clasificar. Este hecho es debido a la alta variabilidad en los patrones cerebrales del EEG, concretamente en la actividad alfa, entre sujetos [15]. La actividad alfa tiene también una alta variabilidad intrasujeto, ya que puede cambiar entre sesiones de entrenamiento debido a cambios en el estado cognitivo y/o emocional [16]. Este hecho sugiere dos enfoques distintos en cuanto al diseño de una BCI: los enfoques clásicos donde el rango alfa es fijo [17] y los enfoques modernos donde antes de realizar la decodificación en tiempo real, se realiza una calibración del rango de frecuencias óptimo para el sujeto [16]. En este proyecto se utilizó un rango fijo para la actividad alfa, ya que la decodificación en tiempo real se realizó sobre un solo sujeto en una sola sesión, pero una calibración variable que adapte los patrones cerebrales a un sujeto específico en el momento de utilizar la tecnología sería lo aconsejable en una posible utilización del sistema desarrollado en un entorno real.

En los experimentos realizados con el dataset 2, se observó que la estimulación FES introducía artefactos en la señal EEG de manera que, durante el primer segundo del movimiento, la BCI detectaba reposo, pese a que era movimiento. Este hecho es debido a que la estimulación hace que suba la potencia en las frecuencias en el rango beta, de manera que se produce ERS en lugar de ERD, y el clasificador interpreta equivocadamente reposo. En los análisis off-line no se realizó tratamiento alguno para el artefacto introducido por el FES y las precisiones de decodificación obtenidas fueron inferiores a las obtenidas en el dataset 1, donde no existían artefactos FES. Las precisiones de decodificación obtenidas en el dataset 2 fueron de 72%, en el mejor de los casos, cuando se realizaba FES tanto en el entrenamiento como en la clasificación y del 67% cuando no se realizaba FES durante el entrenamiento, pero se clasificaba en las series de datos que sí la contenían. Es decir, se obtuvieron mejores resultados cuando se realizaba FES y, por tanto, cuando la señal EEG incluía artefactos. Que el rendimiento obtenido con las señales EEG contaminadas por el FES sea mayor, podría reflejar la capacidad del sistema para decodificar los artefactos presentes en la EEG, y no la

decodificación de la activación cortical debida a la intención de movimiento, lo que conllevaría a que el BCI fomente los patrones anormales de actividad [13]. Es decir, el hecho de que el entrenamiento/clasificación de las señales EEG sin artefactos proporcionen valores de precisión más bajos para la decodificación de las intenciones de movimiento, no significa necesariamente que la eficacia de la BCI sea menor.

En la emulación on-line de la decodificación de movimiento sobre el dataset 2, la precisión media obtenida fue del 61% en el mejor de los casos, ligeramente inferior al resto de análisis off-line sobre el mismo dataset. Esto es debido a que la señal no fue segmentada en ensayos y el clasificador analizaba toda la señal EEG de manera continua, con artefactos como parpadeos, movimientos no permitidos, respiraciones, lo que baja el *accuracy* con respecto a los demás experimentos off-line donde los ensayos estaban diseñados para que esto no ocurriera.

4.2 Conclusiones

En este estudio hemos conseguido caracterizar la intención de movimiento a partir de la ERD relacionada con la intención de movimiento de la extremidad superior derecha obtenida mediante el electroencefalograma (EEG) y utilizarla en una BCI en tiempo real para terapias de rehabilitación motora. Para ello se utilizaron dos tipos de tecnologías de medida de EEG desarrolladas por la empresa Bitbrain como son EEG seco y EEG basado en agua. Se implementó un pipeline de procesamiento de señal para tratar la señal cerebral, entrenar un clasificador lineal y realizar la clasificación de esta en dos clases diferentes: reposo o movimiento, que podrán ser utilizadas como comandos que controlen dispositivos en las terapias de neurorrehabilitación en pacientes con parálisis motoras.

La BCI propuesta demostró su validez en los análisis intrasujeto off-line, acordes a los existentes en la literatura. Se demostró que las clasificaciones intrasujeto obtienen mejor rendimiento que las intersujeto y que, con el uso todos los electrodos del córtex motor se obtienen unos resultados significativamente mejores a solo el uso de los electrodos del hemisferio contralateral a la mano implicada, al menos en el conjunto de datos 1 analizado, lo que sugiere un estudio más amplio que determine si este hecho es extensible a otras poblaciones.

Se demostró la validez de la BCI desarrollada en combinación con estimulación eléctrica funcional en tiempo real sobre un sujeto dado y se puso de manifiesto la necesidad de realizar el tratamiento del artefacto producido por el FES en terapias en tiempo real, debido a su influencia sobre los resultados en la precisión de este. FES genera subidas de potencia en la banda beta de la EEG, característica utilizada como entrada al clasificador debido a su relación directa con las ERD generadas en el ejercicio de imaginación de movimiento.

4.3 Futuro trabajo

Los análisis aquí presentados fueron realizados sobre sujetos sanos, por tanto, el siguiente paso esperado sería evaluar la BCI desarrollada sobre pacientes con parálisis motora en la extremidad superior en terapias de neurorrehabilitación. En una posible combinación de este sistema BCI en tiempo real junto con estimulación FES, se introduce una dificultad añadida que sería necesario investigar. Aunque el decodificador sea entrenado utilizando la señal sin artefactos de FES, durante la terapia con FES, las señales de EEG suelen estar alteradas por los artefactos de la estimulación, por lo tanto, otra línea de experimentos adicionales sería comprobar la presencia de estos durante el período de movimiento y eliminarlos antes de clasificar la EEG.

Otra línea de investigación sería estudiar la óptima obtención de características EEG para caracterizar los diferentes sujetos post-ictus, dependientes del tipo y grado de lesión sufrida y la posible combinación con otros sistemas que aporten información cortical, como pueden ser los potenciales corticales relacionados con el movimiento o la actividad electromiográfica (EMG) residual de las extremidades paralizadas. Por ejemplo, en caso de daños corticales, puede que la EEG no sea capaz de detectar la intención de movimiento por sí misma y, en ese caso, sería conveniente utilizar una estrategia de detección de intención de movimiento híbrida. [18].

5 Bibliografía

- [1] E. López-Larraz, A. Sarasola-Sanz, N. Irastorza-Landa, N. Birbaumer, and A. Ramos-Murguialday, “Brain-machine interfaces for rehabilitation in stroke: A review,” *NeuroRehabilitation*, vol. 43, no. 1, pp. 77–97, 2018, doi: 10.3233/NRE-172394.
- [2] N. Birbaumer, A. R. Murguialday, and L. Cohen, “Brain-computer interface in paralysis,” *Curr. Opin. Neurol.*, vol. 21, no. 6, pp. 634–638, 2008, doi: 10.1097/WCO.0b013e328315ee2d.
- [3] U. Chaudhary, N. Birbaumer, and A. Ramos-Murguialday, “Brain-computer interfaces for communication and rehabilitation,” *Nat. Rev. Neurol.*, vol. 12, no. 9, pp. 513–525, 2016, doi: 10.1038/nrneurol.2016.113.
- [4] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, “A review of classification algorithms for EEG-based brain-computer interfaces,” *J. Neural Eng.*, vol. 4, no. 2, 2007, doi: 10.1088/1741-2560/4/2/R01.
- [5] A. Ayatollahi, “Classification of two motor imagery based on EEG signals in brain computer interface systems using LDA, SVM and GMM methods,” *1st Int. Conf. Appl. Res. Sci. Eng.*, no. October, pp. 1–12, 2016, [Online]. Available: http://www.civilica.com/paper-iseconf01-iseconf01_095=classification-of-two-motor-imagery-based-on-ee-g-signals-in-brain-computer-interface-systems-using-lda-svm-and-gmm-methods.html.
- [6] E. Monge-Pereira *et al.*, “Electroencefalografía como método de evaluación tras un ictus. Una revisión actualizada,” *Neurología*, vol. 32, no. 1, pp. 40–49, 2017, doi: 10.1016/j.nrl.2014.07.002.
- [7] E. Lopez-Larraz, A. M. Ray, T. C. Figueiredo, C. Bibian, N. Birbaumer, and A. Ramos-Murguialday, “Stroke lesion location influences the decoding of movement intention from EEG,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 3065–3068, 2017, doi: 10.1109/EMBC.2017.8037504.
- [8] A. Schwarz, C. Escolano, L. Montesano, and G. R. Müller-Putz, “Analyzing and Decoding Natural Reach-and-Grasp Actions Using Gel, Water and Dry EEG Systems,” *Front. Neurosci.*, vol. 14, no. August, pp. 1–17, 2020, doi: 10.3389/fnins.2020.00849.
- [9] D. J. McFarland, L. M. McCane, S. V. David, and J. R. Wolpaw, “Spatial filter selection for EEG-based communication,” *Electroencephalogr. Clin. Neurophysiol.*, vol. 103, no. 3, pp. 386–394, 1997, doi: 10.1016/S0013-4694(97)00022-2.
- [10] P. Welch, “Welch_1967.pdf.” 1967.
- [11] R. Zhang, P. Xu, L. Guo, Y. Zhang, P. Li, and D. Yao, “Z-Score Linear Discriminant Analysis for EEG Based Brain-Computer Interfaces,” *PLoS One*, vol. 8, no. 9, 2013, doi: 10.1371/journal.pone.0074433.
- [12] G. Mueller-Putz, R. Scherer, C. Brunner, R. Leeb, and G. Pfurtscheller, “Better than random: A closer look on BCI results,” *Int. J. Bioelectromagn.*, vol. 10, no. 1, pp. 52–55, 2008.
- [13] E. López-Larraz, C. Bibián, N. Birbaumer, and A. Ramos-Murguialday, “Influence of artifacts on movement intention decoding from EEG activity in severely paralyzed stroke patients,” *IEEE Int. Conf. Rehabil. Robot.*, pp. 901–906, 2017, doi: 10.1109/ICORR.2017.8009363.
- [14] E. López-Larraz, L. Montesano, Á. Gil-Agudo, and J. Minguez, “Continuous decoding

- of movement intention of upper limb self-initiated analytic movements from pre-movement EEG correlates,” *J. Neuroeng. Rehabil.*, vol. 11, no. 1, pp. 1–15, 2014, doi: 10.1186/1743-0003-11-153.
- [15] S. Haegens, H. Cousijn, G. Wallis, P. J. Harrison, and A. C. Nobre, “Inter- and intra-individual variability in alpha peak frequency,” *Neuroimage*, vol. 92, pp. 46–55, 2014, doi: 10.1016/j.neuroimage.2014.01.049.
- [16] W. Klimesch, “EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. Brain Research Reviews, 29(2-3), 169–195. doi:10.1016/S0165-0173(98)00056-3,” *Brain Res. Rev.*, vol. 29, no. 2–3, pp. 169–195, 1999, doi: 10.1016/S0165-0173(98)00056-3.
- [17] D. J. Vernon, “Can neurofeedback training enhance performance? An evaluation of the evidence with implications for future research,” *Appl. Psychophysiol. Biofeedback*, vol. 30, no. 4, pp. 347–364, 2005, doi: 10.1007/s10484-005-8421-4.
- [18] E. Loopez-Larraz, N. Birbaumer, and A. Ramos-Murguialday, “A hybrid EEG-EMG BMI improves the detection of movement intention in cortical stroke patients with complete hand paralysis,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2018-July, pp. 2000–2003, 2018, doi: 10.1109/EMBC.2018.8512711.