

**Universidad Miguel Hernández de Elche**

**MÁSTER UNIVERSITARIO EN  
ROBÓTICA**



**“Detección de la intención de cambios de dirección  
durante la marcha a partir de señales EEG”**

**Trabajo de Fin de Máster**

**Curso 2019/2020**

**Autora: Paula Soriano Segura**

**Tutores: José María Azorín Poveda  
Eduardo Iáñez Martínez**



## Resumen

Hoy en día, los exoesqueletos y las interfaces cerebro máquina (BMI) se están convirtiendo en un instrumento muy importante en el proceso de rehabilitación de pacientes con problemas locomotores. Esto es gracias a su gran habilidad para recuperar la conexión entre el cerebro y las extremidades por medio de la plasticidad neuronal.

Este trabajo propone la detección de la intención de cambiar de dirección durante la marcha basada en potenciales de desincronización relacionados con eventos (ERD). Para ello, se caracteriza a las señales electroencefalográficas (EEG) adquiridas mediante la extracción de características frecuenciales y temporales. Además, se lleva a cabo un proceso de selección de aquellas características y electrodos que más influyen a la hora de diferenciar la intención de cambiar de dirección frente a caminar.

Tras aplicar clasificadores a las características extraídas siguiendo diferentes métodos de selección y acondicionamiento del modelo, los mejores resultados se obtienen cuando se combinan características frecuenciales y temporales con porcentaje medio de acierto del 95% y 3,7 falsos positivos. Los resultados son muy prometedores para, en un futuro, aplicar este sistema en el control de exoesqueletos.



## Abstract

Nowadays, the exoskeletons and the Brain-Computer Interfaces (BCI) are becoming an important instrument for the rehabilitation process of patients with locomotor problems, due to their ability to recover the connection between the brain and limbs by means of neural plasticity.

This project proposes the detection of the intention to change the direction during gait based on event-related desynchronization (ERD). Frequency and temporal features of the electroencephalographic (EEG) signals are characterized. Then, a selection of the most influential features and electrodes to differentiate the direction change intention from the walking is carried out.

After applying a classifier to the features extracted by means of different methods, best results are obtained when combining frequency and temporal features with an average accuracy of 95% and 3.7 false positives which are promising to be applied to the control of an exoskeleton.



## Agradecimientos

En primer lugar, me gustaría dar las gracias a mis tutores de proyecto José María Azorín y Eduardo Iáñez, por darme la oportunidad de formar parte de este proyecto y la confianza depositada en mí. Gracias por ayudarme y enseñarme tanto.

En segundo lugar, agradecer a mi compañero Vicente Quiles su implicación en el trabajo, resolviendo mis dudas, compartiendo impresiones acerca de posibles soluciones y también por aportar tanto optimismo en los días de mayor pesimismo. También, me gustaría hacer una mención especial a todos mis compañeros por hacer tan agradables las horas que hemos compartido en el laboratorio.

En tercer lugar, dar las gracias a los sujetos que, en su día, participaron en las pruebas ya que sin su colaboración hubiese sido imposible llevar a cabo este trabajo.

Finalmente, gracias a mis padres, a mis abuelos y a mi hermana, por motivarme cada día, por celebrar conmigo los cada uno de los avances que he ido consiguiendo en este trabajo, por soportarme en los momentos de frustración y por confiar siempre en que lograría sacar adelante el proyecto, incluso cuando yo dudaba de ello.





# Índice

Resumen .....	III
Abstract.....	V
Agradecimientos.....	VII
Índice .....	IX
Índice de Figuras .....	XI
Índice de Tablas.....	XIII
Capítulo 1. Introducción.....	1
1.1. Motivación .....	2
1.2. Objetivos.....	2
1.3. Estructura de la memoria .....	3
Capítulo 2. Estado del arte.....	5
2.1. Fundamentos del Sistema Nervioso.....	5
2.1.1. Lesiones motoras.....	6
2.2. Interfaces cerebro-máquina.....	8
2.2.1. Registro de señales cerebrales.....	9
2.2.2. Potenciales cerebrales .....	10
2.2.3. Tipos de BCI .....	12
2.3. Interfaces cerebro máquina en rehabilitación de la marcha.....	13
2.4. Exoesqueletos para la rehabilitación de la marcha .....	15
Capítulo 3. Material y Métodos.....	17
3.1. Equipo.....	17
3.1.1. IMU .....	17
3.1.2. Gorro de electrodos .....	19
3.2. Procedimiento experimental .....	20
3.3. Preprocesamiento.....	21
3.3.1. Cargar ficheros .....	23
3.3.2. Detección de cambios de dirección en las IMUs .....	23
3.3.3. Separar la señal de EEG en trozos entorno al cambio de dirección.....	27
3.3.4. Filtrado de las señales EEG.....	28
3.3.5. Cálculo de la potencia relativa .....	33

3.4. Extracción de características .....	38
3.4.1. Separar las señales en clases .....	38
3.4.2. Características frecuenciales .....	39
3.4.3. Características de potencia relativa .....	42
3.4.4. Características temporales .....	42
3.5. Selección de características y electrodos .....	45
3.5.1. Formación de la matriz de características .....	50
3.5.2. Tipos de vectores.....	54
3.6. Clasificación .....	57
3.6.1. Análisis Offline .....	59
3.6.2. Análisis Pseudo-Online .....	61
3.7. Usuarios .....	63
Capítulo 4. Resultados y discusión.....	65
4.1. Electrodo y características seleccionadas.....	65
4.1.1. Selección automática.....	65
4.1.2. Selección manual.....	69
4.2. Resultados del Análisis Offline .....	70
4.2.1. Análisis offline con selección automática de electrodos.....	70
4.2.2. Análisis offline con selección manual de electrodos .....	79
4.3. Resultados del Análisis Pseudo-Online .....	81
Capítulo 5. Conclusiones.....	85
5.1. Líneas futuras de investigación.....	85
Capítulo 6. Bibliografía .....	87

# Índice de Figuras

<b>Figura 1.</b> Representación de las lesiones medulares y sus consecuencias .....	6
<b>Figura 2.</b> Representación gráfica de los tipos de accidente cerebrovascular .....	7
<b>Figura 3.</b> Mecanismo de plasticidad neuronal.....	7
<b>Figura 4.</b> Esquema general de una interfaz cerebro-máquina .....	8
<b>Figura 5.</b> Representación de las ondas cerebrales según la banda de frecuencia en la que se está analizando la señal .....	9
<b>Figura 6.</b> Potenciales motores relacionados a eventos .....	11
<b>Figura 7.</b> Potencial de toma de decisiones P300 .....	11
<b>Figura 8.</b> Potencial de error .....	11
<b>Figura 9.</b> Posición de los electrodos en la cabeza para la adquisición de las señales EEG .....	12
<b>Figura 10.</b> Robot de rehabilitación de la marcha Lokomat .....	15
<b>Figura 11.</b> Tipos de exoesqueletos para la marcha.....	16
<b>Figura 12.</b> Distribución de las IMUs en las extremidades inferiores del sujeto.....	18
<b>Figura 13.</b> Casco de electrodos EEG con 32 electrodos distribuidos según el Sistema Internacional 10/10.....	19
<b>Figura 14.</b> Repetición de la tarea registrada con la IMU ubicada en el muslo derecho. ....	20
<b>Figura 15.</b> Estructura y contenido de las señales EEG adquiridas en un registro de sesión. ....	21
<b>Figura 16.</b> Esquema general del proceso offline .....	22
<b>Figura 17.</b> Orientación de los ejes de las IMUs.....	24
<b>Figura 18.</b> Señal XZ, normalizada y remuestreada, de la IMU del muslo derecho con 10 repeticiones de la tarea .....	25
<b>Figura 19.</b> Señales de la IMU para una repetición de la tarea.....	26
<b>Figura 20.</b> Señal de la IMU para una repetición de la tarea .....	27
<b>Figura 21.</b> Respuestas de una señal ante distintos filtros paso-banda .....	30
<b>Figura 22.</b> Señal EEG en la ventana creada alrededor del punto de cambio de dirección. ....	31
<b>Figura 23.</b> Señal EEG en banda Mu. ....	34
<b>Figura 24.</b> Energía de la señal EEG.....	34
<b>Figura 25.</b> Potencia relativa.....	35
<b>Figura 26.</b> Comparativa de potencia relativa de la señal.....	36
<b>Figura 27.</b> Potencia relativa de la señal en distintas bandas de potencia .....	36
<b>Figura 28.</b> Ventana de señal EEG alrededor del punto de cambio de dirección .....	38
<b>Figura 29.</b> PSD de la clase cambio en una repetición de la tarea.....	40
<b>Figura 30.</b> Diagramas de cajas de las características frecuenciales para cada clase. ....	46
<b>Figura 31.</b> Diagramas de cajas de las características temporales para cada clase.....	46
<b>Figura 32.</b> Matriz binaria con el resultado del análisis estadístico de la diferenciabilidad entre clases.....	47

<b>Figura 33.</b> Descarte de los electrodos con menos del 85% de características capaces de diferenciar entre clases .....	48
<b>Figura 34.</b> Descarte de las características con menos del 90% de electrodos capaces de diferenciar entre clases .....	49
<b>Figura 35.</b> Matriz con los electrodos y características frecuenciales y temporales definitivas. ....	50
<b>Figura 36.</b> Proceso de formación de la matriz de características a partir de los vectores de características de los registros.....	51
<b>Figura 37.</b> Tipos de vectores utilizados en el trabajo .....	55
<b>Figura 38.</b> Distribución de las clases en el espacio de características del clasificador KNN .....	59
<b>Figura 39.</b> Diagrama del proceso de validación cruzada de 8 iteraciones.....	60
<b>Figura 40.</b> Esquema del procedimiento seguido para llevar a cabo un análisis pseudo-online de las señales EEG.....	61
<b>Figura 41.</b> Electrodo seleccionados mediante el proceso de selección automática para las sesiones de los sujetos.....	67
<b>Figura 42.</b> Electrodo elegidos de forma manual .....	69
<b>Figura 43.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y electrodos .....	71
<b>Figura 44.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y electrodos reducido por potencial ERD .....	71
<b>Figura 45.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con selección de características y electrodos.....	72
<b>Figura 46.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con selección de características y electrodos reducido por outliers .....	72
<b>Figura 47.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector promedio con todas las características y electrodos .....	73
<b>Figura 48.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector promedio con todas las características y electrodos reducido por potencial ERD .....	73
<b>Figura 49.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector promedio con todas las características y electrodos reducido por outliers .....	74
<b>Figura 50.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y los electrodos seleccionados manualmente en la zona motora .....	80
<b>Figura 51.</b> Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y los electrodos seleccionados manualmente en la zona motora, premotora y occipital.....	80

# Índice de Tablas

<b>Tabla 1.</b> Tabla con la información contenida en cada una de las columnas de la estructura de Matlab llamada Trozos EEG.....	28
<b>Tabla 2.</b> Bandas de frecuencia en las que se filtra la señal mediante el filtro paso-banda. ....	31
<b>Tabla 3.</b> Tabla con la información ampliada contenida en cada una de las columnas de la estructura de Matlab llamada Trozos EEG.....	32
<b>Tabla 4.</b> Bandas de frecuencia en que se divide la PSD para extraer información en cada una de ellas. ....	40
<b>Tabla 5.</b> Tabla con las características frecuenciales extraídas.....	41
<b>Tabla 6.</b> Tabla con las características de potencia relativa extraídas. ....	42
<b>Tabla 7.</b> Tabla con las características temporales extraídas. ....	43
<b>Tabla 8.</b> Tabla con los conceptos de TP y FP de cada clase.....	58
<b>Tabla 9.</b> Tabla con los sujetos analizados y sus respectivas sesiones. ....	64
<b>Tabla 10.</b> Características seleccionadas automáticamente para las sesiones de cada sujeto. ....	68
<b>Tabla 11.</b> Porcentajes medios del análisis offline para el vector largo con todos los electrodos y características. ....	75
<b>Tabla 12.</b> Porcentajes medios del análisis offline para el vector largo con todos los electrodos y características reducido por potencial ERD. ....	76
<b>Tabla 13.</b> Porcentajes medios del análisis offline para el vector largo con selección de electrodos y características. ....	76
<b>Tabla 14.</b> Porcentajes medios del análisis offline para el vector largo con selección de electrodos y características reducido por outliers.....	77
<b>Tabla 15.</b> Porcentajes medios del análisis offline para el vector promedio con todos los electrodos y características. ....	77
<b>Tabla 16.</b> Porcentajes medios del análisis offline para el vector promedio con todos los electrodos y características reducido por potencial ERD. ....	78
<b>Tabla 17.</b> Porcentajes medios del análisis offline para el vector promedio con todos los electrodos y características reducido por outliers.....	78
<b>Tabla 18.</b> Resultados del análisis offline de las sesiones de los sujetos para el vector largo con todas las características y los electrodos en la zona motora y en la zona motora combinada con las regiones premotora y occipital.....	81
<b>Tabla 19.</b> Resultados del análisis pseudo-online para las sesiones de cada uno de los sujetos. ....	82



# Capítulo 1. Introducción

Anualmente, el número de personas afectadas por accidentes cerebrovasculares, lesiones en la espina dorsal (SCI: Spinal Cord Injury) y también neurodegeneración, aumenta en cifras cercanas al millón, a nivel mundial, según datos de la OMS. [53]

Este tipo de enfermedades, suelen tener una serie de consecuencias en el funcionamiento motor del organismo, entre las que se encuentra la dificultad para mover algunas extremidades y, en casos más graves, el paciente pierde la movilidad completa del cuerpo. Asimismo, muchos de estos pacientes tienen las extremidades sanas y el único problema es su conexión con el cerebro.

Por este motivo, la aplicación de los conocimientos de la ingeniería en el campo de la medicina y, más concretamente, en técnicas de rehabilitación, ha adquirido gran importancia con el objetivo de reestablecer la conexión entre el cerebro y las extremidades, mediante plasticidad cerebral, para recuperar el funcionamiento original del aparato locomotor de los pacientes.

Para ello, en las últimas décadas se han introducido tanto exoesqueletos [9], como interfaces cerebro-máquina (BMI: Brain-Machine Interface) basadas en señales electroencefalográficas (EEG) [35] [38] [42], en el proceso de rehabilitación, para que asistan al paciente durante la realización de ejercicios complementarios a la rehabilitación con los fisioterapeutas. Estos instrumentos, facilitan la repetición de las tareas de forma exacta y, también, producen efectos psicológicos en los pacientes, aumentando su participación en la rehabilitación a la vez que su motivación. [2] [5] [12] [52]

En este trabajo se propone una BMI que detecte la intención de cambiar de dirección durante la marcha basada en potenciales de desincronización relacionados con eventos (ERD: Event-Related Desynchronization) [39] [40]. Aunque es cierto que existen algunos estudios acerca de este tema, pero la mayoría están basados en Potenciales Evocados Visuales de Estado Estacionario (SSVEP) [21] [54] y muy pocos que usen los potenciales ERD. Por tanto, siguiendo esta línea se busca aumentar la implicación del sujeto, ya que es la tarea mental la que provoca el movimiento, que es mucho más realista. Así, se pueden eliminar mecanismos de movimiento basados en botones y otras tareas no mentales.

## **1.1. Motivación**

Esta investigación forma parte del proyecto Walk-Controlling Lower-Limb Exoskeletons By Means Of Brain-Machines Interfaces To Assist People With Walking Disabilities (RTI2018-096677-B-I00), financiado por el Ministerio de Ciencia, Innovación y Universidades; la Agencia Estatal de Investigación; y la Unión Europea a través del Fondo Europeo de Desarrollo Regional.

Dicho proyecto tiene como objetivo desarrollar dispositivos de asistencia de la marcha, basados en la combinación de exoesqueletos de extremidades inferiores con BMI. Estas BMI no sólo ayudan a sujetos que han sufrido ictus o SCI a llevar a cabo una acción tan básica como es la caminar, sino también aportan nuevas capacidades al sistema.

La BMI de detección de la intención de cambio de dirección desarrollada se combina en el proyecto con otras dos BMI. Una, consiste en aumentar y disminuir la velocidad al caminar. Otra, consiste en dejar de caminar en caso de que aparezcan obstáculos inesperados durante la marcha. Por tanto, la combinación de las tres permite a los sujetos mayor libertad de movimiento, similar a los que podría realizar una persona sana.

## **1.2. Objetivos**

El objetivo principal del trabajo es el diseño de una BMI basada en la detección de la intención de cambio de dirección durante la marcha mediante potenciales ERD. Para alcanzar el objetivo planteado, durante la realización del proyecto se llevan a cabo una serie de pasos:

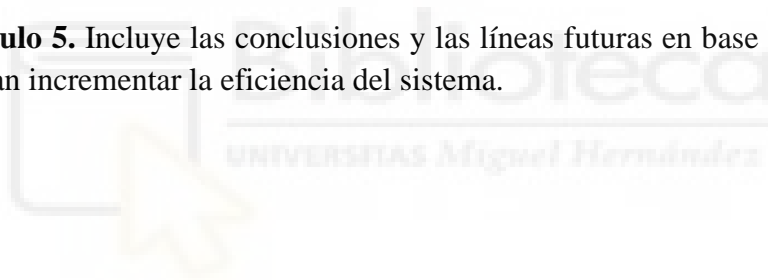
1. Detectar los cambios de dirección producidos mediante las señales de los sensores inerciales de movimiento (IMU) y etiquetar dichos cambios en las señales EEG.
2. Calcular la potencia relativa de las señales EEG con el fin de encontrar el potencial ERD previo al cambio de dirección.
3. Separar en clases y caracterizar las señales de EEG para formar los vectores de características.
4. Comprobar el funcionamiento de la BMI mediante un análisis offline y pseudo-online.



### 1.3. Estructura de la memoria

La memoria del proyecto está estructurada en una serie de capítulos:

- **Capítulo 1.** Contiene la introducción y motivación del trabajo, así como la estructura de la memoria redactada.
- **Capítulo 2.** Se desarrolla una explicación teórica acerca de las BMI y exoesqueletos utilizados en rehabilitación, y el estado actual en el que se encuentran.
- **Capítulo 3.** Se exponen los materiales utilizados en la realización de las pruebas y se desarrollan los pasos seguidos desde la adquisición de las diferentes señales hasta el análisis offline y pseudo-online del proceso, pasando por la búsqueda de los potenciales ERD y la selección de características y electrodos más relevantes de los diferentes sujetos.
- **Capítulo 4.** Se presentan y discuten los resultados obtenidos tanto en la selección de características, como en los análisis offline y pseudo-online.
- **Capítulo 5.** Incluye las conclusiones y las líneas futuras en base al trabajo, que podrían incrementar la eficiencia del sistema.





## Capítulo 2. Estado del arte

En las últimas décadas, la aplicación de interfaces cerebro-máquina (BMI) en el proceso de rehabilitación ha ido adquiriendo mayor importancia, hasta convertirla en casi un elemento indispensable. Esto es, principalmente, gracias a los efectos positivos que produce en los pacientes durante su rehabilitación, tanto físicos, como mentales, y que no son posibles con los métodos de rehabilitación convencional. [35] [38] [42]

A pesar de que se trata de una tecnología bastante reciente, avanza a pasos agigantados dado que cada vez más grupos ven a las BMI como un recurso de gran utilidad, no sólo en el campo de la medicina sino también en la vida cotidiana, y deciden seguir esta línea de investigación.

Por este motivo, este capítulo trata de introducir los fundamentos, biológicos y tecnológicos, que sustentan a las BMI y el estado en el que se encuentran actualmente las BMI aplicadas a la rehabilitación de la marcha. Además, se presentan una serie de exoesqueletos de extremidades inferiores, que se suelen utilizar junto con las BMI, para proporcionar mejores resultados en la recuperación de los pacientes con dificultades para caminar.

### 2.1. Fundamentos del Sistema Nervioso

El Sistema Nervioso (SN) es el encargado de la coordinación y control del cuerpo humano. Desde el punto de vista tecnológico, se podría decir que el SN son los cables que conectan un ordenador con otros complementos de hardware, como el ratón o los altavoces. Su papel principal es recibir órdenes, procesarlas y transmitir las a través de conexiones sinápticas entre neuronas que se excitan. En consecuencia, la potencia habitual de las células en estado de reposo varía, produciéndose potenciales de acción.

La información transmitida es distinta dependiendo de la parte del cuerpo de la que proviene, dividiendo anatómicamente el SN en dos: Sistema Nervioso Central (SNC) y Sistema Nervioso Periférico (SNP). Por un lado, el SNC consiste en que el cerebro envía órdenes a otras partes del cuerpo, como por ejemplo a los músculos de las extremidades inferiores para realizar los correspondientes movimientos y que la persona pueda caminar. Por otro lado, el SNP se basa en que el resto de los órganos y partes del cuerpo envían al cerebro tanto los estímulos captados del exterior, como los producidos en el interior.

La procedencia de los estímulos que llegan al cerebro permite diferenciar entre dos tipos de funcionamiento del SN. Cuando los estímulos son endógenos y se originan en otros órganos en el interior del organismo, es el SN Autónomo quien actúa, enviándoles las correspondientes respuestas biológicas ante el estímulo, como por ejemplo dilatar las pupilas. Por el contrario, cuando los estímulos son exógenos y su procedencia es del exterior, actúa el SN Somático que permite percibir el entorno y contribuye a que la persona se adapte a él. [13]

### 2.1.1. Lesiones motoras

El Sistema Nervioso comunica el cerebro con las zonas periféricas del cuerpo y coordina los movimientos, distribuyendo y procesando las señales enviadas. Sin embargo, cuando se produce una lesión en alguno de los elementos que componen este sistema, la conexión se pierde y, en consecuencia, deja de producirse el intercambio de órdenes y estímulos.

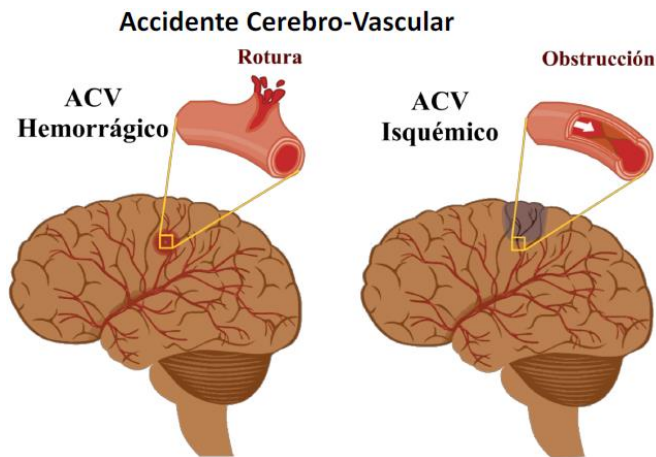
La lesión en la médula espinal (SCI: Spinal Cord Injury) es una de las lesiones más graves del SN, dado que la médula es el principal canal de comunicación entre el cerebro y el resto del cuerpo. La principal consecuencia de esta lesión es la pérdida de movilidad y sensibilidad en aquellas zonas que se encuentren por debajo del punto de la lesión, tal y como indica la Figura 1.



Figura 1. Representación de las lesiones medulares y sus consecuencias. [20]

En el caso de que la lesión se produzca en la zona cervical, la persona pierde la movilidad completa de cuello hacia abajo. Mientras que, si la lesión se produce en la zona lumbar de la espalda, sólo perdería la capacidad motora de las extremidades inferiores. En ambos casos, el usuario tiene dificultades para realizar acciones tan básicas como caminar.


Otra lesión que tiene severas consecuencias en la actividad motora del cuerpo humano son los accidentes cerebrovasculares (ACV), también conocidos como ictus. Un ACV se produce cuando deja de fluir la sangre por algún vaso sanguíneo o bien porque el vaso se rompe (ACV Hemorrágico), o bien porque el vaso se obstruye (ACV Isquémico). En consecuencia, los tejidos de esa zona cerebral dejan de recibir oxígeno y mueren, perdiéndose algunas de las funciones, incluyendo la movilidad en algunas regiones corporales.



**Figura 2.** Representación gráfica de los tipos de accidente cerebrovascular.

Además, existen otras afecciones como las enfermedades neurodegenerativas que causan lesiones motoras como consecuencia de la muerte de las neuronas que transmiten los potenciales y destrucción de zonas cerebrales. Algunas de estas enfermedades son el Parkinson o la Esclerosis Lateral Amiotrófica (ELA).

Por este motivo, la rehabilitación de los pacientes que sufren lesiones motoras cobra importancia para recuperar la movilidad o parte de esta. La finalidad de la rehabilitación es volver a establecer las conexiones neuronales entre el cerebro y las extremidades mediante la repetición de tareas básicas. Este mecanismo es conocido como plasticidad neuronal.



**Figura 3.** Mecanismo de plasticidad neuronal. Tras una lesión, las neuronas pueden volver a recuperar las funciones originas (sprouting) o aprender desde el principio, creando una nueva conexión (unmasking). [8]

Además, la inclusión de interfaces cerebro-máquina y exoesqueletos para la rehabilitación supone una gran mejora en el proceso. Esto es debido a que asisten de forma personalizada a los pacientes durante la repetición de las tareas y, en consecuencia, se obtienen resultados más satisfactorios.

## 2.2. Interfaces cerebro-máquina

Una interfaz cerebro-máquina es un sistema capaz de decodificar la actividad cerebral y traducirla en comandos de control que ejecuten acciones en el entorno. Se trata de una herramienta muy útil ya que permite realizar movimientos en otros dispositivos, como brazos robóticos, exoesqueletos o incluso manejar un ordenador, exclusivamente con señales mentales, sin necesidad de que la persona haga ningún movimiento. [35] [42] [52]

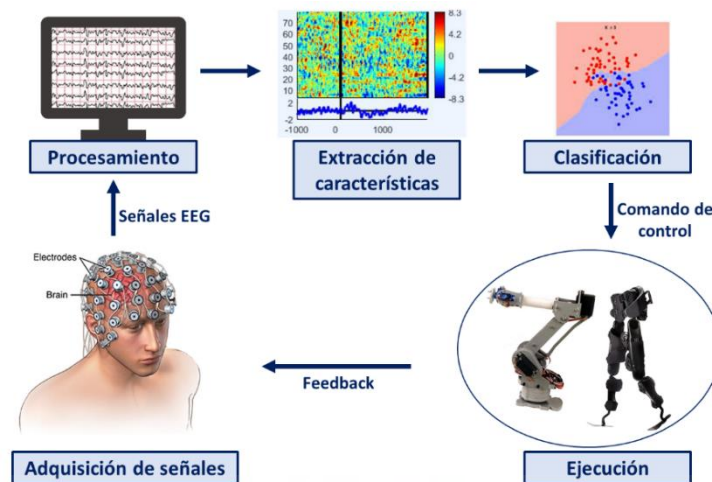


Figura 4. Esquema general de una interfaz cerebro-máquina.

El funcionamiento general de una BMI está representado en la Figura 4. El primer paso, es la adquisición de los datos, donde las señales cerebrales del sujeto son registradas mediante electrodos, invasivos o no invasivos, ubicados en su cabeza y transformadas a señales digitales a través de amplificadores.

El segundo paso, es el procesamiento de las señales registradas aplicándoles una serie de filtros para eliminar ruido y otros artefactos, como las interferencias de red. Una vez acondicionada la señal, el tercer paso es extraer características de los trozos de señal y se seleccionan aquellas que aportan información relevante para diferenciar la tarea en el clasificador.

El siguiente paso es clasificar los ritmos motores captados por los electrodos según los potenciales evocados o intenciones motoras que puedan contener. En función de la clasificación de la señal, se producen distintos comandos de control en otros dispositivos, como pueden ser ordenadores, robots domésticos o exoesqueletos, entre otros. Tras ejecutar el comando, el dispositivo que lo ha ejecutado produce una respuesta que es transmitida al sujeto.

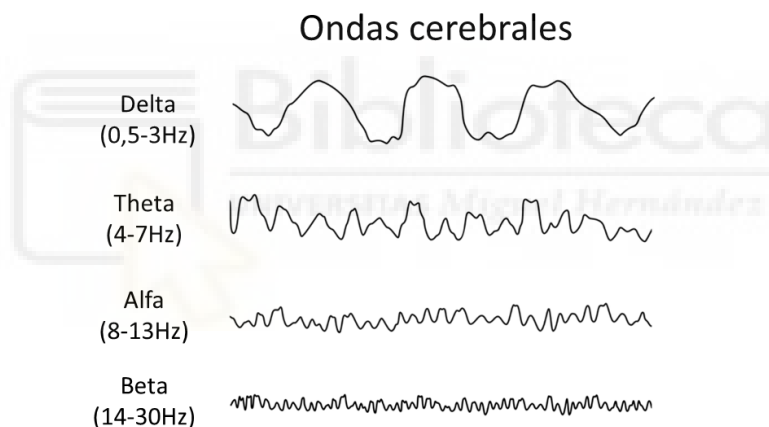
Generalmente, los BMI son sistemas de bucle cerrado donde el sujeto es realimentado con información acerca del resultado de las órdenes enviadas al dispositivo. La respuesta recibida varía dependiendo del dispositivo al que está vinculado la BMI. Cuando está conectada a un ordenador recibirá un feedback visual. En cambio, cuando se trate de un exoesqueleto, la respuesta será a través de un movimiento en la extremidad del sujeto.

### 2.2.1. Registro de señales cerebrales

El registro de señales cerebrales es una parte importante en el funcionamiento de una BMI, ya que son las encargadas de generar los comandos que controlan el sistema. La adquisición de estas señales se puede hacer mediante diferentes técnicas que aportan información muy variada dependiendo de la aplicación de la BMI.

La técnica de adquisición de señales cerebrales no invasiva más habitual es la electroencefalografía (EEG). La EEG consiste en el registro de las diferentes ondas y ritmos cerebrales en determinadas regiones del cerebro mediante un casco de electrodo. Las ondas que aparecen en las señales están codificadas dentro de bandas de frecuencia concretas.

Cada una de las bandas de frecuencia presenta una forma de onda característica. Por ejemplo, las señales de las bandas Delta (0.1-4 Hz), Theta (4-7 Hz), Alfa (8-15 Hz) o Mu (8-13 Hz) tienen ondas de frecuencia muy baja y muy pocos picos, mientras que las bandas Beta (16- 31 Hz) y Gamma (32-100 Hz), contendrán ondas con muchos picos. Además, existen potenciales asociados a ciertas bandas y sólo son visibles cuando la señal se filtra en las frecuencias de la banda correspondiente. [45]



*Figura 5. Representación de las ondas cerebrales según la banda de frecuencia en la que se está analizando la señal. [45]*

Otros métodos menos comunes en el registro no invasivo de señales cerebrales son la magnetoencefalografía (MEG) y la resonancia magnética funcional (fMRI). La MEG registra los campos magnéticos resultantes de las corrientes eléctricas que recorren el cerebro con gran resolución temporal pero baja resolución espacial [14]. Por el contrario, la fMRI sigue los principios de la resonancia magnética, pero registrando las variaciones de flujo de sangre cerebral, obteniendo una resolución espacial muy elevada y una resolución temporal muy baja. [25]

Asimismo, existe una técnica de registro de señal invasiva conocida como electrocorticografía (ECoG), cuyas señales adquiridas son muy similares a las obtenidas con EEG, pero con una mayor resolución espacial. Esto es debido a que los electrodos se encuentran sobre el cerebro y evitan el ruido causado por la impedancia de la piel y el hueso craneal. [15]

A pesar de que existen múltiples técnicas de registro de señales cerebrales y cada una de ellas aporta información muy variada sobre actividades cerebrales, el método de registro de EEG es el más utilizado. Este hecho se debe principalmente a la sencillez, portabilidad y adaptabilidad del equipo para desarrollar BMI en gran cantidad de aplicaciones muy diferentes.

### **2.2.2. Potenciales cerebrales**

Las señales de EEG registradas con el casco de electrodos están compuestas por ondas cerebrales que varían en función de la actividad que se está realizando. En ellas, se pueden encontrar variaciones en la potencia de las señales cerebrales que facilitan la decodificación de comandos de control en la BMI.


Las variaciones en la potencia producen diferentes potenciales y ritmos en las señales. En base a la naturaleza de los potenciales, se distinguen dos tipos muy utilizados en BMI: potenciales evocados y potenciales relacionados a eventos.

En primer lugar, los potenciales evocados (EPs) aparecen cuando el sujeto recibe un estímulo del exterior. Los estímulos recibidos pueden ser de distintas formas: visuales, auditivos, sensoriales y de propiocepción, etc. Por tanto, los EPs se clasifican en tres grupos en función del estímulo recibido: potenciales evocados visuales (VEPs), auditivos (AEPs) y somatosensoriales (SSEPs).

En segundo lugar, los potenciales relacionados a eventos (ERPs) son aquellos que surgen como respuesta a eventos motores, cognitivos y sensoriales. Este tipo de potenciales tiende a aparecer cuando se están realizando otras actividades y, por tanto, son más complicados de detectar. En muchos casos, su detección no es posible a tiempo real ya que es necesario promediar múltiples repeticiones del evento para que sean visibles. Estos potenciales se clasifican en tres tipos: potenciales motores, potenciales de toma de decisiones y potenciales de error.


Los potenciales motores son los que aparecen durante la realización de actividades motoras. Instantes previos a que se produzca el movimiento, se manifiesta la intención de realizar el movimiento como una caída de potencial en la banda Mu (8-13Hz) de la señal, conocida como potencial de desincronización relacionado a un evento (ERD) y, una vez comienza el movimiento, se produce un aumento en la potencia, llamado potencial de sincronización relacionado a un evento (ERS). [37]





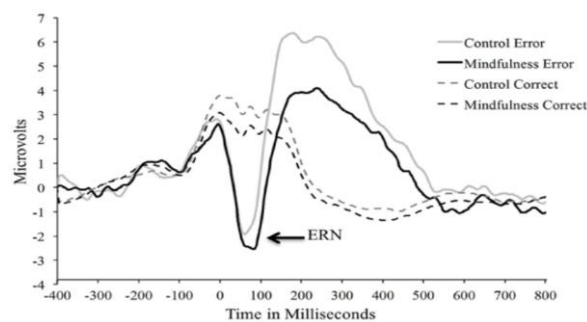
**Figura 6.** Potenciales motores relacionados a eventos. En azul, el potencial de desincronización (ERD) y, en rojo, el potencial de sincronización (ERS). [22]

Los potenciales motores y, más concretamente, los potenciales ERD son muy útiles para detectar movimientos antes de que se produzcan. Así, las BMI basadas en estos potenciales y que están conectadas a robots de rehabilitación, como exoesqueletos, son capaces de reproducir el movimiento que realizaría un paciente sano, fomentando la conexión entre el SN y los músculos.



**Figura 7.** Potencial de toma de decisiones P300. [48]

Por otro lado, el P300 es uno de los potenciales de toma de decisiones más conocidos. El nombre del potencial P300 se debe al hecho de que surge en la señal 300 ms después de que el sujeto perciba el estímulo. La forma y aparición de este potencial es muy similar en la mayoría de los sujetos, por lo que es muy sencillo detectarla. Este potencial es el más utilizado en BMI para el manejo de ordenadores. [48]



**Figura 8.** Potencial de error. [18]


El último tipo de ERPs son los potenciales de error (ErrP) que surgen cuando el sujeto detecta un estímulo exógeno en forma de error en la actividad que está realizando. Esto significa que cuando el funcionamiento de un sistema no es tal y como el sujeto espera que sea, genera una caída de potencial. [18]

### 2.2.3. Tipos de BCI

Existen varios tipos de BMI en función de distintos factores como las técnicas de captación de las señales, los tipos de actividad cerebral registrada, el origen y potenciales de la señal.

#### 2.2.3.1. Según las técnicas de captación de las señales cerebrales

Previamente, se comentaba que la adquisición de las señales se podía llevar a cabo mediante distintas técnicas que registran las señales cerebrales. Por tanto, según las técnicas de captación, se puede dividir en tres grandes grupos: BMI invasivos, BMI parcialmente invasivos y BMI no invasivos.



*Figura 9. Posición de los electrodos en la cabeza para la adquisición de las señales EEG. [4]*

En primer lugar, los BMI invasivos consisten en introducir los electrodos en la región intracortical de la cabeza. Este procedimiento implica una operación donde se retira un trozo de cráneo para implantar los electrodos en el cerebro y pinchar las neuronas. La principal ventaja de esta técnica es que la adquisición de la señal se hace directamente sobre las neuronas que producen las señales deseadas. Por tanto, la señal tiene una gran resolución espacial y temporal con escaso ruido. Sin embargo, esta técnica presenta una importante desventaja que es exponer al paciente a una intervención quirúrgica compleja y a electrodos en el interior de su cuerpo, que tarde o temprano deben ser o bien reemplazados, o bien retirados.

En segundo lugar, los BMI parcialmente invasivos colocan los electrodos sobre la superficie del cerebro. Esta técnica es muy similar a la anterior, pero en este caso la captación se realiza por electrocorticografía (ECoG) [15]. Este método presenta una resolución espacial y temporal medias, ya que eliminan parte de los artefactos causados por la piel y el hueso, pero las señales de las regiones más profundas del cerebro siguen presentando una pequeña cantidad de ruido espacial. Por el contrario, la principal

desventaja que presentan es exactamente la misma que en las BMI invasivas: la intervención quirúrgica y sus riesgos. Adicionalmente, ambas técnicas implican un elevado coste.

En tercer lugar, los BMI no invasivos ubican los electrodos en la superficie de la cabeza, sobre el cuero cabelludo. Por tanto, se elimina el problema de someter al paciente a la cirugía y se reduce el coste. Además, los electrodos son portables, normalmente están agrupados en un casco, y se puede colocar en distintos entornos, no sólo en un quirófano. Sin embargo, el tiempo de colocación de los electrodos es muy elevado. Asimismo, la desventaja de eliminar los electrodos no invasivos es que se pierde resolución espacial, especialmente al realizar la captación por EEG o MEG, donde algunos electrodos registran señales de múltiples regiones. No obstante, este método no pierde la resolución temporal.

### **2.2.3.2. Según la actividad cerebral registrada**

Otra clasificación que se puede hacer de las BMI es en función de la actividad cerebral registrada por los electrodos. Esta clasificación distingue entre BMI espontáneas y BMI evocadas.

Por un lado, las BMI espontáneas, o endógenas, son aquellas que se basan en la actividad cortical voluntaria de un sujeto, es decir, capturan los potenciales producidos cuando el sujeto realiza un movimiento como parpadear, tragar o levantar un brazo. Estas BMI se centran en imaginación motora visible en los ritmos sensorimotores y potenciales motores relacionados a eventos (ERD/ERS).

Por otro lado, las BMI evocadas, o exógenas, son los sistemas que funcionan a partir de potenciales evocados que aparecen como consecuencia de estímulos externos. Estos estímulos pueden ser visuales, auditivos o sensoriales. Por tanto, estas BMI recurren a los potenciales evocados visuales (VEPs), auditivos (AEPs) o somatosensoriales (SSEPs) y potenciales relacionados a eventos como el potencial de error (ErrP) y la P300.

## **2.3. Interfaces cerebro máquina en rehabilitación de la marcha**

A lo largo de los años, las interfaces BMI se han ido convirtiendo en un elemento de gran relevancia en la rehabilitación gracias a las ventajas que presentan. Además, cada vez es más habitual la aplicación de las BMI incluyendo exoesqueletos que asistan a los pacientes en sus movimientos.

Estos sistemas sirven de complemento a los ejercicios propuestos por los fisioterapeutas y permiten una rehabilitación más personalizada a cada sujeto. Las BMI se adaptan al nivel de afectación de la lesión, ya que algunos pacientes requieren de más ayuda que otros para realizar las repeticiones. [2][5][18]

A su vez, los exoesqueletos proporcionan un feedback como respuesta a los comandos generados por el paciente a través de la BMI. Así, se fomenta la reconexión entre las

neuronas, haciendo que el cerebro asocie esos potenciales con los respectivos movimientos. [9]

Por tanto, estos sistemas de acción y reacción entre el usuario y el exoesqueleto incluyen la participación del paciente de forma activa en el proceso de rehabilitación, cosa que no ocurre cuando el fisioterapeuta mueve sus extremidades. En consecuencia, aumenta su motivación y favorece a una reducción del tiempo de recuperación.

En este aspecto, se han desarrollado interfaces BMI entre el cerebro y exoesqueletos de extremidades superiores, inferiores y también exclusivos de algunas articulaciones como rodilla, tobillo o codo. Concretamente, la conexión, entre los exoesqueletos de extremidades inferiores y las interfaces BMI, basada en señales y potenciales motores y sensorimotrices ha supuesto un gran avance en la rehabilitación de la marcha. [54]

A pesar de que los pacientes que recurren a estas tecnologías tienen dificultades para caminar, la interfaz BMI detecta sus intenciones motoras y las convierte en movimientos a través del exoesqueleto, tratando de recrear unos movimientos lo más realistas posibles. Además, estos sistemas no sirven exclusivamente para la rehabilitación en centros hospitalarios, sino que también pueden ser usados en casa como robot de asistencia. Así, el paciente puede tener una mayor independencia en su día a día.

Las interfaces BMI para la marcha diseñadas no sólo tienen como objetivo caminar de forma realista, sino que también pretenden el control de otros movimientos implicados en la marcha como la intención de empezar a andar, pararse cuando aparecen obstáculos en el camino [10], cambiar de dirección y velocidad [41], entre otras.

Cuando las interfaces BMI son diseñadas para detectar la intención de realizar un movimiento determinado, uno de los paradigmas más utilizados está basado en los potenciales de desincronización relacionados a eventos (ERD). Los potenciales ERD son un tipo de potencial relacionado a un evento específico, que produce una caída de potencial en la banda Mu (8-13 Hz), unos instantes antes de que se produzca el evento. Así es posible detectar los eventos antes de que se produzcan y asistir a los sujetos, para que puedan realizar los movimientos correctamente. [39] [40] [49]

Hace un par de años, en el grupo de investigación de Brain-Machine Interface Systems Lab, donde se ha desarrollado el presente trabajo, se realizó un estudio donde se clasificaban los cambios de dirección a partir de señales EEG [1]. En esta línea, los Laboratorios de Neurociencia Computacional ATR (Tokio, Japón) proponen un modelo conocido como Markov Switching Model (MSM), capaz de diferenciar entre el estado de relax y los potenciales ERD, generados por medio de imaginación motora (MI), utilizando señales EEG [23]. J. Choi y H. Kim diseñan una interfaz BMI con un exoesqueleto para detectar la intención de comenzar a caminar mediante la detección de potenciales ERD en la banda Mu [7]. Además, algunos proyectos orientados a la detección de la intención en pacientes de ictus han obtenido resultados bastante satisfactorios. [36] [46]

En cuanto a interfaces BMI para la intención de cambio de dirección durante la marcha basados en potenciales ERD, el número de estudios es muy escaso. Si es cierto que existen

algunas investigaciones a cerca del cambio de dirección en la marcha, pero basadas en potenciales evocados visuales de estado estable (SSVEP: Steady State Visual Evoked Potentials). [21] [54]

Actualmente, no se tiene constancia de ninguna investigación, ni presente ni pasada, acerca de la propuesta de este trabajo, que pretende detectar la intención del cambio de dirección por medio de potenciales ERD. Por tanto, se podría decir que se trata de una línea de investigación muy novedosa que se encuentra todavía en sus fases iniciales.

## 2.4. Exoesqueletos para la rehabilitación de la marcha

Los exoesqueletos son un componente indispensable cuando se crean sistemas con interfaces BMI de bucle cerrado. Su principal labor es generar una respuesta al comando enviado por la interfaz en forma de movimiento, parada o giro. Por este motivo, cada vez son más los exoesqueletos de extremidades inferiores diseñados para la rehabilitación de la marcha basada en interfaces BMI. [9]

El exoesqueleto Lokomat de Hocoma [16] y Haptic Walker [47] del Instituto Fraunhofer de Berlín (Alemania) son dos esqueletos con una larga trayectoria en la rehabilitación de la marcha. Ambos dispositivos mantienen al usuario en suspensión, eliminando el peso del paciente mientras los actuadores le ayudan a caminar sobre una cinta y sobre pedales, respectivamente.




*Figura 10. Robot de rehabilitación de la marcha Lokomat. [16]*

ALEX (Active Leg Exoskeleton), creado por la Universidad de Delaware (Estados Unidos), es otro exoesqueleto con un mecanismo diferente basado en fuerzas. Su funcionamiento consiste en ‘assist-as-needed’, o lo que es lo mismo, el exoesqueleto asiste de forma personalizada al paciente en sus movimientos, aplicando tanta fuerza como el paciente necesita. [3]

Otro de los exoesqueletos más utilizados en la rehabilitación de la marcha es el diseñado en la Universidad de Twente (Países Bajos), conocido como LOPES (Lower Extremity Powered Exoskeleton). Este robot de rehabilitación está formado por tres actuadores, dos en la cadera y uno en la rodilla, que permiten dos estados de funcionamiento: ‘robot-in-

charge', donde el robot mueve al paciente y, 'patient-in-charge', donde es el paciente quien realiza los movimientos. [51]



**Figura 11.** Tipos de exoesqueletos para la marcha. A la izquierda, el exoesqueleto LOPES de la Universidad de Twente. [51] A la derecha, el exoesqueleto Rex de Rex Bionics. [43]

Todos los robots citados previamente presentan un inconveniente de cara a un uso futuro en este trabajo: su mecanismo no está adaptado para realizar cambios de dirección. El exoesqueleto REX de Rex Bionics (Nueva Zelanda) es uno de los pocos exoesqueletos que hoy en día permite realizar cambios de dirección. [43]



## Capítulo 3. Material y Métodos

En este apartado, se especifican los distintos pasos seguidos a lo largo del trabajo hasta alcanzar los resultados que se manifiestan en el Capítulo 4. Primero, se describe el proceso experimental llevado a cabo para la adquisición de las señales, así como el equipo utilizado durante los experimentos. Seguidamente, se desarrolla todo el proceso de tratamiento de la señal desde su filtrado hasta la formación de la matriz de características, incluyendo el análisis de los potenciales ERD. Finalmente, se exponen los métodos de análisis seguidos para valorar el proceso.

### 3.1. Equipo

El proceso experimental consiste en una serie de pruebas realizadas a 4 sujetos en varias sesiones, es decir, en días distintos. Durante la realización de estas pruebas, son necesarios una serie de dispositivos electrónicos tales como un casco de electrodos y un conjunto de sensores de movimiento. Cada uno de ellos, capta diferentes tipos de señales de forma sincronizada, que quedan almacenadas en paquetes de datos y permiten caracterizar las pruebas realizadas.

#### 3.1.1. IMU

A la hora de detectar los movimientos llevados a cabo por el sujeto en todo momento, las Unidades de Medida Inerciales (IMU: *Inertial Measurement Unit*) son uno de los sistemas de captación de movimiento más adecuados gracias a su gran precisión.

El funcionamiento de una IMU está basado en los principios básicos de los giroscopios, magnetómetros y acelerómetros para obtener la posición, velocidad, aceleración de un cuerpo. Asimismo, es posible combinar las medidas de los sensores internos y obtener su orientación, calculando la Matriz de Rotación.

La Matriz de Rotación, también conocida como Matriz de Cosenos Directores (DCM), indica la orientación de la unidad inercial respecto a un sistema de coordenadas fijo. Las coordenadas del sistema fijo se orientan respecto a las fuerzas que actúan sobre la Tierra, es decir, el eje Z sigue la dirección de la gravedad, mientras que el eje X se orienta hacia el norte magnético. [50]

Por tanto, la Matriz de Rotación se expresa matemáticamente como:

$$Acc = \vec{W}_{(Z)} \approx [0 \quad 0 \quad 9.8] \quad (1)$$

$$Mag = \vec{M} = [M_X \quad M_Y \quad M_Z] \quad (2)$$

$$\vec{U}_{(Z)} = |\vec{W}_{(Z)} \times \vec{M}| \quad (3)$$

$$\vec{V}_{(z)} = |\vec{W}_{(z)} \times \vec{U}_{(x)}| \quad (4)$$

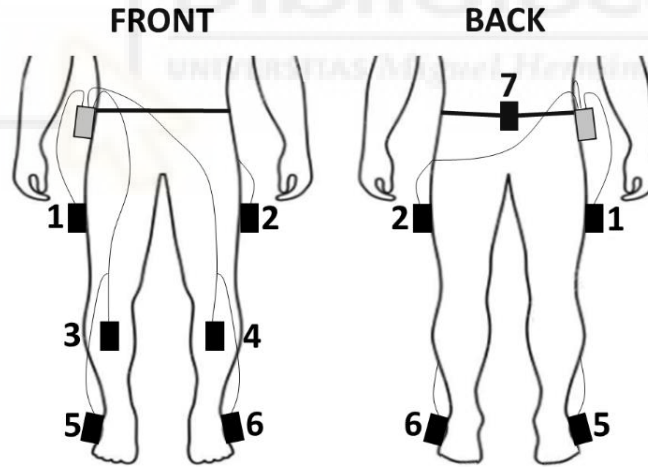
$$DCM = [\vec{U}_{(z)} \quad \vec{V}_{(z)} \quad \vec{W}_{(z)}] = \begin{bmatrix} \hat{u}_x & \hat{v}_x & \hat{w}_x \\ \hat{u}_y & \hat{v}_y & \hat{w}_y \\ \hat{u}_z & \hat{v}_z & \hat{w}_z \end{bmatrix} \quad (5)$$

Además, para que el cálculo de la DCM sea lo más preciso posible, su estimación se fundamenta en los principios del Filtro de Kalman Extendido (EKF), de manera que la matriz en el instante actual se obtiene teniendo en cuenta los valores de la matriz en el instante previo. Para ello, es necesario conocer los ángulos de rotación en cada eje, o lo que es lo mismo, la integral de las velocidades angulares del giroscopio.

$$Gyro = \vec{\omega} = [\omega_x \quad \omega_y \quad \omega_z] \quad (6)$$

$$DCM_{(t)} = DCM_{(t-1)} + \int \vec{\omega}_{(t)} \quad (7)$$

En estos experimentos, las IMU utilizadas son las *Tech-MCS V.3.0.* de Technaid [50], que son capaces de captar información en 3D y están especializadas para su uso en la captación del movimiento de personas. Por tanto, se distribuyen en las extremidades inferiores del sujeto 7 unidades inerciales: tres a lo largo de cada pierna, concretamente en el muslo, tibia y pie, y otra en la zona lumbar, tal y como se muestra en la Figura 12.



**Figura 12.** Distribución de las IMUs en las extremidades inferiores del sujeto.

Durante un experimento, cada IMU aporta 19 señales distintas con una frecuencia de muestreo de 30Hz: las medidas del giroscopio, magnetómetro y acelerómetro en los ejes X, Y, y Z, los nueve componentes de la DCM y, también, la temperatura del sujeto en cada momento.



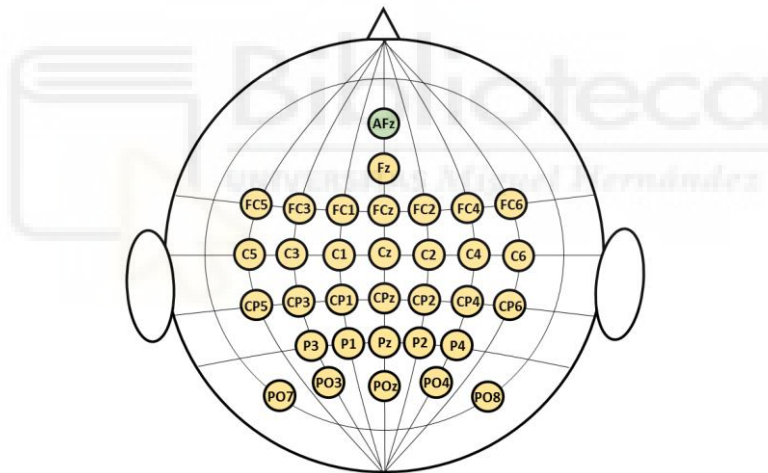
### 3.1.2. Gorro de electrodos

El gorro de electrodos es otro elemento indispensable en este tipo de experimentos, ya que es el encargado de registrar las señales EEG del sujeto. Para ello, el gorro está compuesto por una serie de electrodos distribuidos en la superficie de la cabeza, adquiriendo señales en distintas áreas del cerebro.

En este caso, se ha utilizado un gorro con dos amplificadores g.USBamp de la empresa g.Tec, donde cada uno de los amplificadores posee 16 canales de entrada, es decir, es capaz de adquirir la señal de 16 electrodos. Asimismo, los amplificadores incluyen en un interior un filtro Notch a 50Hz para eliminar las perturbaciones de la red. [11]

Toda la información recogida por los electrodos es procesada por el módulo g.INTERsync, que sincroniza las señales de los dos amplificadores. Seguidamente, es introducida en Matlab donde se lleva a cabo todo el procesamiento, estudio y caracterización de la señal.

Por tanto, este gorro contiene 32 electrodos que captan las señales de las distintas zonas cerebrales con una frecuencia de muestreo de 1200Hz y una buena resolución espacial. Así, por cada registro se obtienen 32 señales distintas, una de cada electrodo.



*Figura 13. Casco de electrodos EEG con 32 electrodos distribuidos según el Sistema Internacional 10/10. [6]*

En la Figura 13, se observa la disposición de todos los electrodos en la cabeza del sujeto siguiendo la norma del Sistema Internacional 10/10.[6] Los electrodos señalados en amarillo son utilizados para registrar las señales, mientras que el electrodo señalado en verde sirve como referencia a tierra.

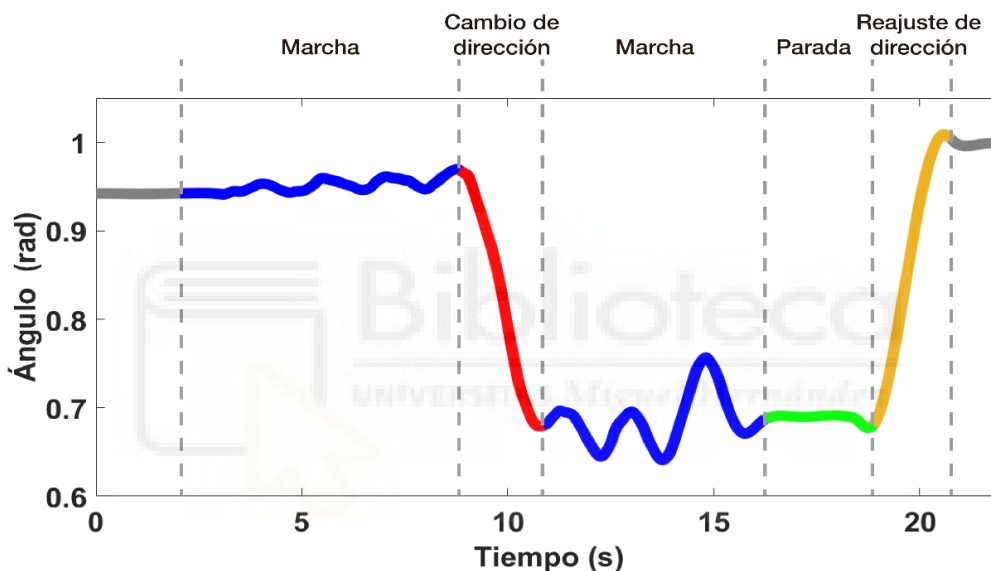
La disposición de los electrodos en este casco permite cubrir las diferentes áreas funcionales del cerebro, de forma que cada electrodo aporta un tipo de información distinta. Por ejemplo, los electrodos de la zona frontal contendrán potenciales originados por tareas mentales, mientras que la zona occipital generará los potenciales visuales y la zona central informará de funciones motoras.

## 3.2. Procedimiento experimental

El experimento que se explica a continuación, cuyas señales han sido procesadas y analizadas a lo largo de este trabajo, fue llevado a cabo por otro compañero del laboratorio hace un par de años durante otro proyecto.

El protocolo experimental seguido con los sujetos se basa en que cada uno realiza, al menos, 2 sesiones en diferentes días. En cada sesión, se toman 8 registros de señal donde el sujeto debe realizar 10 repeticiones de una tarea.

La tarea se compone de una serie de acciones y se inicia cuando el sujeto empieza la marcha. En la Figura 14, se representa una repetición de la tarea vista desde la señal adquirida por la IMU del muslo derecho, conocida como IMU 1 en Figura 12. En ella, se marcan por colores los diferentes movimientos realizados durante la tarea.



**Figura 14.** Repetición de la tarea registrada con la IMU ubicada en el muslo derecho. En azul, la marcha; en rojo, el cambio de dirección; en verde, la parada; en amarillo, el reajuste de la dirección de la marcha.

A partir de la Figura 14, se observa un tramo inicial azul donde el sujeto inicia el movimiento y camina durante unos segundos. Seguidamente, la pendiente en rojo representa el cambio de dirección y, nuevamente un tramo oscilatorio azul que indica cómo, después del cambio, el sujeto continúa caminando un par de segundos más. Después, un tramo verde llano indica la parada que realiza antes de reorientarse completamente, que es la pendiente en naranja. Así, en la siguiente repetición caminará en la misma dirección, pero en sentido contrario.

Cada tarea está descrita por múltiples señales obtenidas por los diferentes componentes electrónicos colocados en el sujeto. Por un lado, una tarea está formada por 32 señales de EEG, una por cada uno de los electrodos que componen el casco que lleva el sujeto colocado en la cabeza. Por otro lado, está formada por 134 señales del sensor IMU, es decir, 19 señales por cada una de las 7 IMU más un índice de valores para representar las señales.



*Figura 15. Estructura y contenido de las señales EEG adquiridas en un registro de sesión.*

Al finalizar una sesión, se obtiene un paquete de datos por cada registro, en cuyas señales habrán registrados 10 repeticiones de la tarea. Esto quiere decir que cada sesión tendrá 8 paquetes de datos con 10 cambios de dirección cada una, haciendo un total de 80 cambios de dirección por sesión.

### 3.3. Preprocesamiento

En esta sección, se expone todo el proceso de análisis y estudio de los paquetes de señales procedentes de los experimentos explicados en el apartado anterior. Al tratarse de un desarrollo largo y complejo, en la Figura 16 se plantea un esquema que resume a grandes rasgos los pasos seguidos, o rutas a seguir, para llevar a cabo los objetivos planteados en el trabajo.

En primer lugar, el diagrama está formado por unos primeros bloques amarillos de procesamiento de la señal. En estas secciones se detectan los cambios de dirección y se acondicionan las ventanas de señales EEG entorno a los cambios de dirección, mediante múltiples filtros.

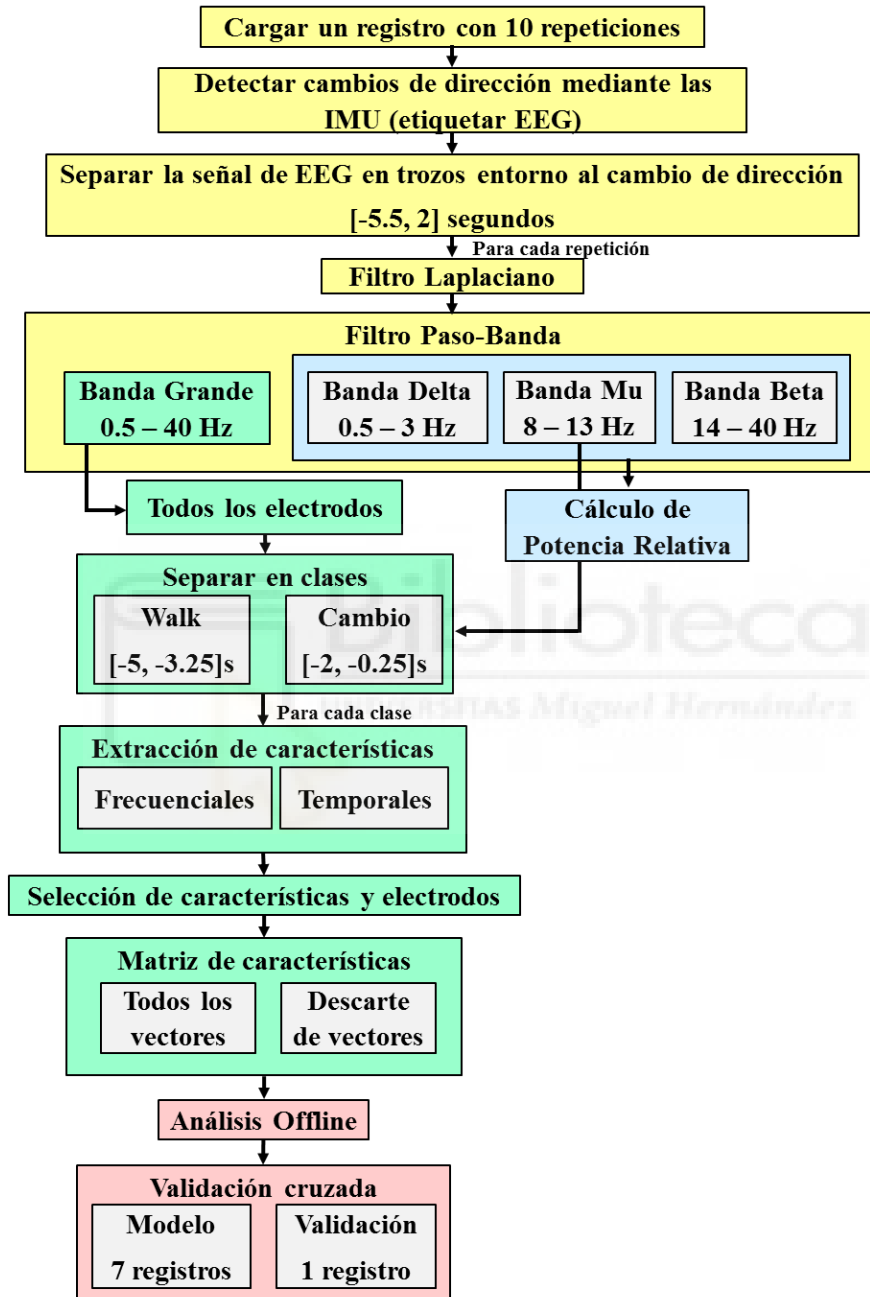
En segundo lugar, se plantean dos caminos que más adelante se vuelven a unir. Por un lado, en el camino marcado de color azul en el esquema, se plantea la forma de extraer los potenciales ERD que indican la intención de cambio de dirección. Por otro lado, en el camino marcado de color verde en el esquema, se procede a la caracterización de las señales.

Para ello, las señales procesadas de todos los electrodos se separan en dos ventanas que determinan las dos clases que se quieren diferenciar: clase walk y clase cambio. Estas clases hacen referencia a los tramos donde el sujeto está caminando y cambiando de dirección, respectivamente.

Entonces, se extraen las características frecuenciales, temporales y de potencia relativa, tanto en las señales de la clase walk, como en las de la clase cambio. Además, se aplica un algoritmo para elegir las características más relevantes, es decir, las que tengan mayor

diferencia entre clases y se forma la matriz de características o bien con las características seleccionadas, o bien con todas las características.

Finalmente, se llevan a cabo los distintos métodos de clasificación, offline y pseudo-online, para comprobar si se detectan correctamente los cambios de dirección y, también, para establecer cuáles son los caminos que mejores resultados proporcionan.



*Figura 16.* Esquema general del proceso offline. En amarillo, el preprocesamiento de las señales; en azul, el cálculo de la potencia relativa y potencial ERD; en verde, la caracterización de las señales de marcha y cambio de dirección; en rojo, la clasificación y análisis offline de la información extraída.

### 3.3.1. Cargar ficheros

El primer paso del procedimiento seguido en este trabajo es cargar todos los ficheros de los registros captados en una misma prueba, para realizar su correspondiente procesamiento y tratamiento de los datos adquiridos durante el experimento.

Cada registro está formado por una estructura, llamada *session*, con toda la información perteneciente al registro, incluyendo referencias al equipo y electrodos empleados, tareas realizadas, frecuencias de muestreo, señales electroencefalográficas y de las unidades inerciales, entre otros.

Por tanto, los datos deseados de los registros se deben ir extrayendo fichero a fichero. Sin embargo, para facilitar este proceso se cuenta con una función de Matlab, que almacena los nombres de todos los archivos de datos que se quieren procesar.

Así, mediante un bucle, es posible cargar un fichero, coger los datos necesarios, realizar el tratamiento de estos datos, almacenarlos en otra estructura y pasar a cargar el siguiente registro. De forma que al final del bucle, toda la información procesada de los archivos está almacenada en conjunto, pero con una serie de índices que permiten diferenciar qué elementos pertenecen a cada registro.

### 3.3.2. Detección de cambios de dirección en las IMUs


El siguiente paso tras cargar el fichero de un registro es detectar los instantes donde se han producido los cambios de dirección a partir de las señales de los sensores de tipo IMU. Anteriormente, en el Apartado 3.1.1., ya se indicaba la disposición de las unidades inerciales a lo largo de las piernas durante la prueba.

En este caso, para la detección de los cambios de dirección, se ha decidido utilizar las señales de las IMU de los muslos (1 y 2 en la Figura 12), ya que tienen menor cantidad de ruido por la zona en la que están situadas. Considerando que cada unidad inercial se encuentra en una pierna, el punto exacto del cambio de dirección se verá afectado en pocos milisegundos por el lado hacia el que se realice el giro, pero sin afectar al proceso.

Por este motivo, se decide utilizar también la IMU de la zona lumbar (7 en la Figura 12) que, al situarse en una zona central, se encuentra menos influenciada por la dirección a la que decida cambiar el sujeto. No obstante, al analizar esta unidad se descubre que, por algún motivo desconocido, la representación de sus picos aparece desfasada de las IMU de los muslos y, finalmente, se descarta del trabajo.

Tal y como se ha comentado en el Apartado 3.2., cada IMU contiene 20 señales distintas y, por tanto, no sólo basta con elegir la posición de la unidad inercial, sino que también se debe seleccionar la señal donde mejor se aprecien los cambios de dirección.

En el Apartado 3.1.1., se expone el cálculo de la matriz de rotación (Ecuación 5) que indica las rotaciones producidas en cada eje respecto a una posición base. Dicha posición viene representada en la Figura 17 y, en ella, se aprecia como el eje Z se encuentra en la dirección de la gravedad.



*Figura 17. Orientación de los ejes de las IMUs. [24]*

Por tanto, los cambios de dirección producen rotaciones entorno al eje Z y mueven los ejes X e Y. En consecuencia, las señales que serán de utilidad para detectar los cambios de dirección será las pertenecientes a los parámetros XZ e YZ de la matriz de rotación. En este caso, se eligen tan sólo las señales del parámetro XZ para simplificar el proceso de detección de los instantes donde el sujeto cambia de dirección.

Entonces, para detectar el punto donde se produce el cambio de dirección, independientemente de cuál sea la IMU con la que se está tratando, se ha creado un algoritmo capaz de detectar de forma automática dicho punto en la señal.

En primer lugar, se normaliza la señal para estandarizar los datos, dividiendo entre el máximo valor de la señal, tal que la señal queda contenida en un intervalo de  $[-1, 1]$ . El motivo de la presencia de valores negativos se debe a que el sujeto, tras realizar un cambio de dirección durante la prueba, se reorienta completamente en el sentido opuesto al que se estaba moviendo.

La IMU es capaz de detectar estos cambios de sentido porque, al igual que el eje Z de las coordenadas base se orienta con la gravedad, el eje X está orientado con el norte magnético. De manera que cada vez que el sujeto se reorienta, se está produciendo una diferencia respecto a dicho eje magnético que se ve reflejada en cambio positivos o negativos, en función del sentido que esté siguiendo, tal y como se refleja en la Figura 17.

En segundo lugar, la señal inercial tiene una frecuencia de muestreo de 30Hz, mientras que las señales EEG proporcionadas por los electrodos poseen una frecuencia de muestreo de 1200Hz. Por tanto, los cambios de dirección detectados en las IMU no están situados en el mismo instante que las señales cerebrales del sujeto.


Por este motivo, el siguiente paso es remuestrear la señal de la IMU y transformarla en una señal con una frecuencia de muestreo de 1200Hz. Así, los puntos detectados se podrán extrapolar de forma más sencilla a las señales electroencefalográficas.

El remuestreo de una señal consiste en obtener la relación entre la frecuencia deseada y la original, que se ve reflejada en unos factores integrales. Al aplicar dichos factores en la señal original, se remodela y adquiere la frecuencia de muestreo deseada.

Seguidamente, se multiplica la señal normalizada por un vector cuyos valores son ceros y unos. Por un lado, los trozos de unos representan los valores de la señal durante los que

el sujeto está realizando la tarea. Por otro lado, a cero se encuentran los instantes en los que el sujeto está parado o no está realizando la tarea.

Por tanto, el producto entre el vector binario y el vector de la señal de la IMU tendrá como resultado un vector con la señal de las IMU normalizada, pero los instantes que no son de interés están puestos a cero, tal y como se observa en la Figura 18.



*Figura 18.* Señal XZ, normalizada y remuestreada, de la IMU del muslo derecho con 10 repeticiones de la tarea.


Esta señal presenta muchos picos en mitad de la pendiente que indica el cambio, complicando la distinción del instante del cambio mediante el algoritmo. Por esta razón, se decide aplicar el Filtro de S-Golay repetición a repetición, es decir, se van cogiendo los trozos de la señal que no son nulos y se van filtrando trozo a trozo.

El Filtro de Savitzky-Golay, más conocido como Filtro de S-Golay, es un filtro suavizador de tipo FIR, es decir, que se aplica en trozos finitos de señal y reduce los picos que hay en ella. Para hacer esto posible, se debe tener en cuenta el tamaño de ventana que se va a filtrar y decidir el orden del polinomio que va a recorrer la señal.

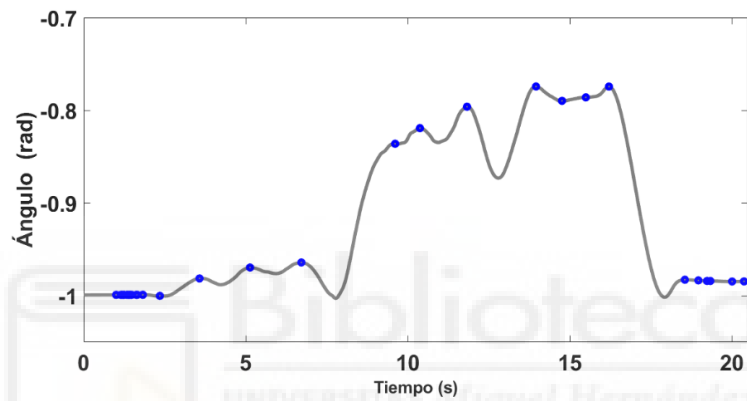
El orden de polinomio indica cuánto se va a suavizar la señal. Por ejemplo, para polinomios de grados pequeño, el suavizado de los picos es muy grande y, si son pequeños, los convierte en un tramo plano, mientras que los polinomios de grado elevado respetan en gran medida la señal original. [27]

En este caso, se han probado diferentes opciones y, finalmente, el polinomio seleccionado es de orden 3, ya que permite eliminar los picos en mitad de la pendiente de cambio, sin destruir la pendiente. En la Figura 19, se puede apreciar cómo, al suavizar la señal, se detectan menos picos.

### Señal IMU sin suavizar



### Señal IMU suavizada



**Figura 19.** Señales de la IMU para una repetición de la tarea. Arriba, los picos detectados cuando la señal está sin suavizar. Abajo, los picos detectados cuando la señal está suavizada.

La aplicación de este filtro de suavizado puede suponer, en algunos casos, un problema porque existe la posibilidad de que se suavice el punto exacto donde comienza el cambio de dirección, siendo detectado el cambio antes de que realmente ocurra. Sin embargo, en general el resultado es tal y como se espera.

Una vez la señal está suavizada y lista para detectar el punto de cambio de dirección, se aplica un algoritmo que, en base a los picos que se encuentran en la señal, tal y como se indica en la Figura 19, detecte el punto exacto del cambio.

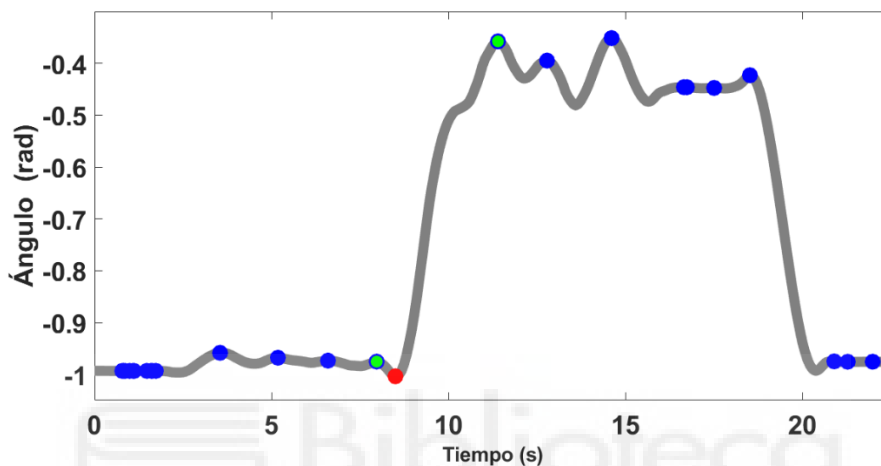
El primer paso de este algoritmo consiste en buscar los picos en los trozos de cada repetición de la tarea y su posición en dicho trozo de señal. Seguidamente, se calcula la diferencia de amplitud de cada pico con el pico anterior de manera que, al producirse el giro, la diferencia entre picos es mucho mayor que cuando el sujeto sólo está andando.

Por tanto, la señal de cada repetición contiene dos diferencias entre puntos elevadas, que hacen referencia a dos grandes pendientes: una cuando se produce el giro y, otra, cuando trata de reorientarse. Puesto que se sabe que la primera pendiente es la correspondiente al cambio, se buscan las dos diferencias más elevadas entre puntos y se elige la que se encuentra en una posición más cercana al inicio de la tarea.



Por consiguiente, el primer punto de la pendiente es el punto donde comienza el cambio de dirección, mientras que el segundo punto, situado al final de la pendiente, representa el final del giro. Asimismo, se coge el tramo de la señal y se calcula un punto en mitad de la pendiente, o lo que es lo mismo, un punto durante el cambio de dirección.

El diseño del código permite que, en función de la información que se quiera obtener, se pueda elegir si se quiere tratar las señales entorno al punto donde comienza el cambio, durante el cambio o al finalizar el cambio. En este caso, el punto elegido es el punto donde se inicia el cambio dado que el potencial ERD que se está buscando en las señales de EEG del sujeto se produce antes de producirse el giro.



*Figura 20.* Señal de la IMU para una repetición de la tarea. En azul, todos los picos detectados; en verde, los puntos con mayor diferencia de amplitud que aparecen primero en el tiempo y, que indican, el cambio de dirección; en rojo, el punto que es establecido como instante donde se produce el cambio de dirección.

En la Figura 20, se muestran en azul todos los picos detectados entre los que se calculan las diferencias de amplitud y en verde se indican los puntos de la pendiente del cambio de dirección. Además, en rojo se puede observar el punto elegido para procesar la información. Dicho punto se obtiene reajustando el inicio del cambio mediante el cálculo del valor máximo entre los puntos verdes, en caso de que la pendiente sea descendente, y del valor mínimo, en caso de que sea ascendente. Así, se asegura que el punto está situado en el instante exacto.

### **3.3.3. Separar la señal de EEG en trozos entorno al cambio de dirección**

Seguidamente, tras detectar los puntos donde se producen los cambios de dirección en el registro, se extrapolan a la señal de EEG de todos los electrodos del sujeto con el objetivo de crear ventanas entorno a dicho punto y obtener información referente a los potenciales ocurridos durante ese período de tiempo de la prueba.

Para ello, se establece un tamaño de ventana estándar para que todos los trozos de señal sean del mismo tamaño. El tamaño de ventana es de 10 segundos previos al punto de cambio de dirección y 2 segundos posteriores al cambio de dirección.

Este proceso se aplica a las repeticiones de la tarea de todos los registros y, tal y como se explica en el Apartado 3.3.1., cada registro se debe procesar por separado. Por este motivo, cada vez que se crean los trozos de cada registro se van almacenando en una estructura de datos. Así, al finalizar, la información de todos los registros está en un mismo conjunto y resulta más sencilla de procesar.

Para poder diferenciar entre registros, repeticiones de tareas y señales de cada electrodo, se crea una estructura donde al mismo tiempo que se almacena el trozo de señal de EEG, se añade información acerca de dicha señal. La estructura se llama *trozos EEG* y tiene la siguiente disposición:

**Tabla 1.** Tabla con la información contenida en cada una de las columnas de la estructura de Matlab llamada Trozos EEG.

Estructura Trozos EEG							
Columna	1	2	3	4	5	6	7
Fila	Trozo de señal EEG del electrodo	Punto de cambio de dirección	Registro	Tarea realizada	Electrodo	IMU	Nº de tarea

En la Tabla 1, se muestra la disposición de la información de cada señal almacenada en la estructura de datos. En la primera columna, se almacena el trozo de señal correspondiente a la ventana entorno al punto de cambio de dirección.

En la segunda columna, está el punto donde se produce el cambio de dirección dentro de dicha ventana. Este punto es el mismo en todas las ventanas, ya que, tras separar los trozos, se alinean todos entorno a dicho punto para que la sucesiva extracción de información esté situada en los mismos instantes.

Asimismo, en la cuarta y sexta columna, se almacena la tarea realizada y la IMU utilizada para detectar los cambios. Se trata de información general para todas las filas, dado que en todos los registros se realiza la tarea número 14 y la IMU del muslo derecho (1 en Figura 12) se elige previamente.

En el resto de las columnas, se almacenan datos que permiten calificar de qué señal se trata, es decir, el registro, la tarea y el electrodo al que pertenece el trozo de la señal almacenada en la primera columna de la fila.

La creación de esta estructura es de gran utilidad para el procesado que se lleva a cabo de ahora en adelante y sus filas están directamente relacionadas con una gran matriz en cuyas filas se encuentran cada uno de los trozos de las señales de EEG. Esta matriz está creada para simplificar los filtrados desarrollados en el siguiente apartado.

### 3.3.4. Filtrado de las señales EEG

Sucesivamente, a partir de la información aportada por la estructura de datos generada en el apartado anterior, se procede al filtrado de todas las señales para eliminar el ruido y, también, para generar señales que contengan sólo las bandas de frecuencia de interés.

### 3.3.4.1. Filtro Laplaciano

En primer lugar, se lleva a cabo un filtrado espacial Laplaciano. Este tipo de filtrado consiste en eliminar el ruido que el resto de los electrodos del casco puedan haber originado en la señal de un electrodo.

Para ello, se generan bucles que recorran todos los registros y sus tareas, así como los electrodos de cada una de ellas. Para filtrar la señal de un electrodo de una repetición de tarea, se seleccionan las 32 señales de EEG que describen la tarea en cada uno de los electrodos.

El proceso del filtrado Laplaciano comienza con el cálculo de las distancias de todos los electrodos al electrodo que se quiere filtrar, dado que en función de la distancia a la que se encuentren los electrodos, aportarán mayor o menor cantidad de ruido. La información acerca de las posiciones de los electrodos en el gorro de electrodos también se encuentra almacenada dentro de la estructura de datos *session* comentada en el Apartado 3.1.2.

A continuación, se calculan los pesos de los electrodos teniendo en cuenta la distancia, en los ejes X e Y, al electrodo y el sumatorio de las distancias de todos los electrodos, mediante las fórmulas:

$$d_{ij} = \sqrt{(d_x)^2 + (d_y)^2} \quad (8)$$

$$g_{ij} = \frac{1/d_{ij}}{\sum_{j \in S_i} 1/d_{ij}} \quad (9)$$

Donde  $g_{ij}$  son los pesos de cada electrodo y  $d_{ij}$  es el módulo de la distancia en X e Y.

A partir de los pesos  $g_{ij}$ , se estima la cantidad de ruido que aporta cada electrodo ponderando la señal de cada electrodo ( $V_j$ ) con sus pesos.

$$ruido_{ij} = g_{ij} * V_j \quad (10)$$

Finalmente, se resta, muestra a muestra, el sumatorio de los ruidos de cada electrodo a la señal del electrodo que se quiere filtrar.

$$V_i^{LAP} = V_i - \sum_{j \in S_i} ruido_{ij} \quad (11)$$


Donde  $V_i^{LAP}$  es el elemento  $i$  filtrado de la señal del electrodo que se está procesando,  $V_i$  es el elemento  $i$  de la señal original del electrodo y  $\sum_{j \in S_i} ruido_{ij}$  es el sumatorio de los ruidos del resto de electrodos en la muestra  $i$  de sus señales. [26]

### 3.3.4.2. Filtro Butterworth Paso-banda

Tras aplicar el Filtro Laplaciano y eliminar los artefactos provocados por los electrodos adyacentes, se realiza un filtrado paso-banda para eliminar otros ruidos que afectan a la

señal y, también, extraer las señales en diferentes bandas de frecuencia, como delta, mu, beta.

El filtro paso-banda elegido es el Filtro Butterworth, que es un tipo de filtro IIR fundamentado en los filtros analógicos que tiene unas respuestas en frecuencia planas, a diferencia de otros filtros cuyas respuestas son rizadas y modifican en gran medida la señal, tal y como se muestra en la Figura 21.



*Figura 21. Respuestas de una señal ante distintos filtros paso-banda. [28]*

A la hora de diseñar el filtro, es necesario especificar las frecuencias de corte, inferior y superior, así como el orden del filtro que determina la forma de la función de transferencia que, posteriormente, se aplica a la señal para filtrarla.

La elección del orden del filtro se ha llevado a cabo siguiendo el procedimiento de prueba y error, es decir, probando las múltiples opciones y eligiendo la que mejores resultados genera en la señal. En este caso, el orden del filtro escogido es 4, ya que filtros de orden mayor provocan oscilaciones excesivamente grandes que afectan a toda la ventana de la señal y la deforman.

Asimismo, se quiere obtener la señal en múltiples bandas de frecuencias, por lo que las frecuencias de corte superior e inferior varían en función de la banda que se quiera estudiar. Para ello, los trozos de señal filtrados con el Filtro Laplaciano pasan por cuatro filtros paso-banda.

En la Tabla 2, se indican las cuatro bandas de frecuencia en las que se filtra la señal, previamente filtrada con el filtro Laplaciano. Las señales de las tres primeras bandas (Delta, Mu y Beta) aportan información concreta sobre los movimientos y el área motora. Por este motivo, se utilizan para extraer la potencia relativa en cada banda, que se explica más adelante en este documento, y poder conocer si aparecen potenciales de desincronización ERD, antes de producirse el cambio de dirección.

Tabla 2. Bandas de frecuencia en las que se filtra la señal mediante el filtro paso-banda.

Bandas de frecuencia		
Banda	Frec. Inferior	Frec. Superior
Delta	0,5	3
Mu	8	13
Beta	14	35
Banda amplia	0,5	40

La cuarta banda de la Tabla 2 es una banda amplia donde se eliminan los artefactos del equipo con la frecuencia de corte inferior y los artefactos de red, situados alrededor de los 50 Hz, con la frecuencia de corte superior. Además, esta cuarta banda contiene las tres bandas anteriores y se utiliza más adelante para extraer las características que formarán parte de la matriz de características introducida en el clasificador.

El filtrado paso-banda de las señales en cada banda se logra en dos pasos. Primero, se aplica un filtro paso-bajo para eliminar las frecuencias inferiores a la frecuencia de corte inferior. Después, se aplica un filtro paso-alto para eliminar las frecuencias superiores a la frecuencia de corte superior.

Al principio del apartado, se explicaba que este filtro busca una respuesta lo más plana posible a la función de transferencia. Sin embargo, la señal filtrada resultante presenta una oscilación en el tramo inicial de la señal hasta que se estabiliza. Por este motivo, se habían elegido ventanas de gran tamaño entorno al punto de cambio de dirección en el Apartado 3.3.3.




Figura 22. Señal EEG en la ventana creada alrededor del punto de cambio de dirección. En azul, el segmento oscilatorio de la señal, que es eliminado; en verde, la ventana de señal definitiva; en rojo, el instante donde comienza el cambio de dirección.

En consecuencia, tras aplicar los filtrados paso-banda, se recorta el tramo inicial de la señal que contiene la oscilación y se reduce la ventana, a 5.5 segundos antes de cambio de dirección y 2 después, tal y como se puede apreciar en la Figura 22. En ella, se muestra la señal filtrada donde el tramo en azul representa el trozo de señal descartado y, el tramo en verde, el trozo de señal filtrada definitiva.

Una vez se han filtrado todas las señales en las diferentes bandas, es importante almacenarlas indicando a qué registro, tarea y electrodo pertenece cada una. Para ello, se recurre al mismo procedimiento que el seguido en la Tabla 1 del Apartado 3.3.3.

Dado que el bucle implementado en el código de Matlab recorre cada una de las señales de la estructura *Trozos\_EEG*, al mismo tiempo que se filtra la señal, se van guardando las señales de las bandas en nuevas columnas de la fila donde se encuentra la señal. Así, las nuevas señales también quedan etiquetadas con los parámetros de información necesarios para distinguirlas entre ellas. Por tanto, la nueva estructura de *Trozos EEG* se indica en la Tabla 3.

**Tabla 3.** Tabla con la información ampliada contenida en cada una de las columnas de la estructura de Matlab llamada Trozos EEG.

Estructura Trozos EEG	
Columna	Fila
1	EEG (0,5 - 40 Hz)
2	Punto de cambio de dirección
3	Registro
4	Tarea realizada
5	Electrodo
6	IMU
7	Número de Tarea
8	Potencia relativa (Banda Mu)
9	EEG Banda Delta
10	-
11	EEG Banda Mu
12	EEG Banda Beta
13	-

En la Tabla 3 se visualiza la nueva disposición de la estructura de *Trozos EEG*, donde cada fila contiene la información indicada. La primera columna donde se encontraba la señal original de EEG del electrodo, queda reemplazada por la señal filtrada en la banda amplia (0,5 – 40Hz), mientras que las siguientes columnas, de la 2 a la 7, continúan exactamente como estaban al principio.

En las nuevas columnas añadidas, se almacenan las señales filtradas por bandas, concretamente en las columnas 9, 11 y 12. Además, también se incluye una columna, la columna 8, donde se sitúa la potencia relativa de la señal en la banda mu, que se calcula más adelante y adquiere gran importancia en algunos pasos a seguir a lo largo del trabajo.

El hecho de que las columnas 10 y 13 se encuentren vacías se debe a que estaban destinadas a ser la posición de almacenamiento de las señales filtradas en las bandas Theta (4-7 Hz) y Gamma (32-100 Hz), respectivamente. Sin embargo, tras procesar varias pruebas de sujetos, se concluye que no aportan ninguna información relevante en el trabajo, por lo que se decide eliminarlas para reducir espacio en el disco y, sobre todo, tiempo de computación, que en sí ya es muy elevado.

### 3.3.5. Cálculo de la potencia relativa

Este apartado, se corresponde con la continuación del camino azul en el esquema de la Figura 16. Esto quiere decir que a partir de las señales filtradas en las bandas Delta, Mu y Beta en el apartado anterior, se realiza el cálculo de la potencia relativa para cada una de ellas.

El objetivo del estudio de la potencia relativa es encontrar potenciales de desincronización relativos a un evento, también conocidos como potenciales ERD, que son un tipo de potencial motor y se producen en los instantes previos al cambio de dirección del sujeto.

La obtención de los potenciales ERD es compleja, ya que son potenciales que no cumplen una forma exacta, ni aparecen siempre en el mismo instante. A veces no se pueden apreciar a simple vista, incluso es posible que en las señales de algunos electrodos no aparezcan porque según la zona del cerebro, también aparecen otros tipos de potenciales que los eclipsan.

En los experimentos que se están estudiando en este trabajo, adquiere mayor dificultad, si cabe, encontrarlos. Esto es debido a que el sujeto está andando antes del cambio de dirección y, en consecuencia, no sólo estará el potencial ERD del cambio, sino que también se encuentran los potenciales que está generando el sujeto mientras camina.


Por esta razón, se decide buscar los potenciales en tres bandas distintas, de manera que se encuentre también aquella banda en la que la marcha afecta en menor medida a la aparición del potencial ERD deseado.

A pesar de que se trata de una tarea ardua y computacionalmente pesada, la visualización del potencial ERD en la señal EEG del sujeto supone un gran paso a la hora de detectar la intención espontánea en la mente del sujeto de cambiar de dirección. Además, en este trabajo, son utilizados para seleccionar las ventanas de las clases que se quieren clasificar.

Los pasos a seguir para el cálculo de la potencia relativa se basan en encontrar el potencial de desincronización relativo al cambio de dirección. Este proceso se lleva a cabo tres veces por cada repetición de la tarea, es decir, para extraer la potencia de las señales en las bandas Delta, Mu y Beta.

El primer paso es calcular la envolvente de la señal que es gran utilidad ya que alcanzar algún resultado concluyente con la señal, tal y como sale del filtro paso-banda, sería casi imposible, debido a su disposición llena de picos muy juntos. A pesar de seleccionar la envolvente, ésta todavía presenta muchos picos que perturban los cálculos sucesivos, especialmente en la obtención de una ventana de referencia. Por ello, se decide suavizar un poco estos picos.

En la Figura 23, se representa en azul la señal original salida del filtro paso-banda; en rojo, la envolvente de dicha señal, con la que se va a trabajar de ahora en adelante y, en verde, la envolvente suavizada con la que se trabaja de ahora en adelante. Asimismo, se ha añadido una línea vertical en negro que representa el instante donde la IMU ha detectado el cambio de dirección.



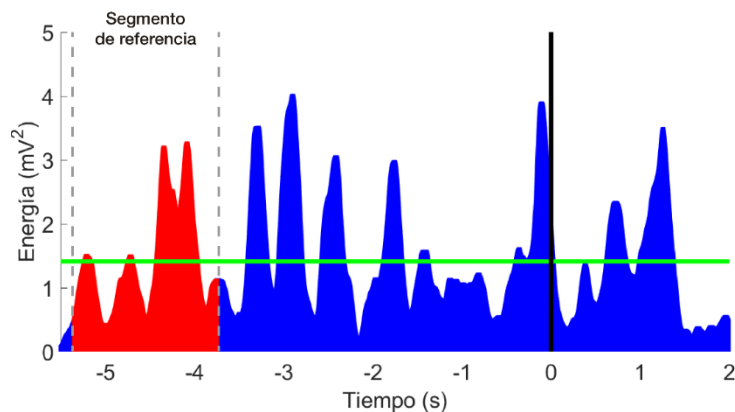
**Figura 23.** Señal EEG en banda Mu. En azul, ventana de la señal EEG original en la banda Mu; en rojo, la envolvente de la señal; en verde, la envolvente suavizada.

El siguiente paso, es el cálculo de la energía de la señal, es decir, elevar al cuadrado cada una de las muestras de la señal. A partir de esta señal, se elige una ventana de referencia que representa un período de tiempo donde el sujeto se encuentra sólo caminando y, respecto a la cual, se calcula la potencia relativa.

El tamaño de la ventana seleccionado pertenece a un trozo de la señal que va desde -5.35 segundos hasta -3.75 segundos, antes del cambio de dirección. Debido a que el sujeto se encuentra caminando en este tramo, la señal presenta algunas oscilaciones. Por ello, se calcula la media de los valores de la señal y se establece como referencia el punto medio.

Durante la selección de la ventana, se han probado múltiples tamaños de ventana y, también, el uso de la mediana en lugar de la media para extraer el punto de referencia. Sin embargo, tamaños de ventana mayores presentaban la posibilidad de que el potencial ERD se encontrase en el trozo de referencia y el uso de la mediana, en general, no mejoró los resultados obtenidos con la media.

A continuación, en la Figura 24, está representada en azul la energía de la señal y, el tramo marcado en rojo representa el trozo de señal elegido como referencia. Además, la línea verde horizontal es el punto medio que sirve como valor de referencia para el cálculo de la potencia.




**Figura 24.** Energía de la señal EEG. En azul, la energía de la señal EEG en la banda Mu. En rojo, el segmento de referencia; en verde, el punto medio que sirve como referencia.



Seguidamente, se procede a extraer la potencia relativa de la señal. Esta operación se basa en el cálculo del porcentaje de la señal respecto al punto de referencia obtenido previamente, con el objetivo de que los tramos donde camina queden oscilando entorno al 0%, mientras que los potenciales ERD de desincronización se van reflejados como un descenso del porcentaje del potencial. Para ello, se aplica una sencilla fórmula a cada uno de los elementos del vector correspondiente con la señal de energía. [39] [40] [49]

$$ERD_i(\%) = \frac{Referencia - Energía_i}{Referencia} * 100 \quad (12)$$

La señal resultante es la potencia relativa, que es un porcentaje respecto a una referencia. Teóricamente, los valores del vector deberían encontrarse entre -100% y 100%, pero la presencia de grandes picos y de algunos puntos tan lejanos del punto de referencia, provoca que, en ocasiones, muchos valores se salgan del rango.




**Figura 25.** Potencia relativa. En azul, la potencia relativa de la señal; en rojo, la potencia relativa suavizada. El potencial ERD es visible entre los instantes -1,75 y 0.

Al principio de la señal de potencia relativa, la forma es oscilatoria con valores cercanos a cero, representando la marcha del sujeto. Unos segundos antes del cambio, se produce una caída de potencial, creándose una forma cóncava que es el potencial ERD, es decir, la intención del sujeto de cambiar de dirección. Seguidamente, se produce nuevamente un crecimiento del potencial, representando el instante del cambio de dirección.

Esto se ve reflejado en la Figura 25, donde el sujeto está caminando y 1.5 segundos antes del cambio aparece el potencial ERD hasta que en el instante 0 segundos, cambia de dirección, aumentando la potencia. En esta gráfica, se observa en azul la potencia relativa obtenida y, en rojo, la potencia relativa suavizada, que mantiene la forma básica de la potencia, pero la reducción de los picos pequeños facilitará futuras extracciones de información de la señal.

A la hora de extraer los potenciales ERD de las señales, se puede aplicar un paso intermedio entre el cálculo de la energía y la selección del punto de referencia. Ese paso consiste en promediar las energías de varias repeticiones de la tarea en un mismo electrodo. La energía media resultante del promedio se usaría para coger la ventana de referencia y calcular el punto medio del mismo modo que se ha explicado previamente.


Sin embargo, tras estudiar este procedimiento se comprueba como no es necesario aplicar la media de las energías, sino que es posible calcular las potencias relativas de cada una de las señales de un mismo electrodo en diferentes tareas y, posteriormente, promediarlas. El resultado es muy similar al obtenido con aplicando el promedio de las energías, tal y como se observa en la Figura 26.



**Figura 26.** Comparativa de potencia relativa de la señal. En azul, potencia relativa como resultado del promedio de las potencias relativas de varias repeticiones en un mismo electrodo. En rojo, potencia relativa obtenida a partir del promedio de las energías de varias repeticiones en el mismo electrodo.

El método preferido es aplicar el promedio posteriormente, con las potencias relativas, ya que así es posible extraer los potenciales ERD de cada una de las tareas y estudiar en qué repetición se ven mejor los potenciales.

Tal y como se comentaba previamente, el proceso de extracción de la potencia relativa se repite en las tres bandas de potencia. En la Figura 27, se representa la potencia relativa en cada una de las bandas: en amarillo, la potencia relativa de la banda Delta (0,5-3Hz); en magenta, la potencia relativa de la banda Mu (8-13Hz) y, en azul, la potencia relativa de la banda Beta (14-40Hz).



**Figura 27.** Potencia relativa de la señal en distintas bandas de potencia. En amarillo, la potencia relativa en la banda Delta (0,5-3Hz); en magenta, la potencia relativa en la banda Mu (8-13Hz); en azul, la potencia relativa en la banda Beta (14-40Hz).

En la gráfica se observa que la potencia relativa de la banda Delta no aporta ningún tipo de información relevante acerca de los movimientos realizados. En cambio, en las bandas

Mu y Beta se puede identificar claramente la marcha del sujeto, donde en algunos tramos las oscilaciones de ambas señales se encuentran en fase.

Concretamente, en la banda Mu se distingue el potencial ERD entre el segundo -1,5 y -1. Sin embargo, este potencial es no visible en la banda Beta, donde exclusivamente se manifiesta la marcha. Por este motivo, se decide continuar con el desarrollo a partir de la información proporcionada exclusivamente por la potencia relativa de la banda Mu en lo referente al potencial ERD.

No obstante, la gráfica también demuestra que otras bandas como la banda Beta, situada a mayores frecuencias, es la aporta información relacionada con la marcha del sujeto. Esto implica que, a la hora de extraer características, es interesante caracterizar una señal filtrada en una amplia banda de potencia que informe sobre ambos estados.

En otro orden de cosas, en la Figura 26, se percibe claramente el tramo de marcha y el potencial ERD del sujeto durante la repetición de la tarea en la banda Mu. No obstante, esto no siempre es así y, generalmente, es complejo que aparezcan los potenciales de forma tan clara. Existen muchos factores que condicionan este potencial: electrodos, tramo de referencia, IMU, señales, incluso del sujeto.

Concretamente, en función del electrodo con el que se ha adquirido la señal, el potencial será más o menos visible. Ya que dependiendo de la zona donde esté situado, captará mejor el potencial generado y, también, es posible que la señal se vea influenciada por otros potenciales no motores. Asimismo, esta señal capturada también influye dependiendo de la banda de frecuencia en la que se filtra y, también, de si presenta o no artefactos muy ruidosos.

Otro de los factores que influyen de manera importante es la detección del instante del cambio de dirección con la IMU. Esto quiere decir que si el punto no está exactamente donde se ha producido el cambio, como consecuencia del ruido de la señal de movimiento, el potencial puede aparecer en otros instantes más lejanos del segundo 0.

Además, la selección de la ventana de referencia puede modificar completamente la forma del potencial. Cuando el sujeto se encuentra andando, la señal de energía es oscilatoria, por tanto, el punto medio se calcula de una señal con picos. En algunos casos, los picos del tramo son muy elevados y pueden suponer un valor medio de referencia algo desviado. También puede causar que las oscilaciones de marcha se hagan más presentes y desaparezca el potencial.

Al estudiar estos potenciales ERD, también se debe tener en cuenta que pueden variar dependiendo del sujeto que ha realizado la prueba. El cerebro de una persona no funciona exactamente igual que el de otra y durante los registros se pueden captar señales influenciadas por distracciones, cansancio u otros potenciales provocados por el entorno en el instante de la prueba, que pueden modificar estos potenciales.

### 3.4. Extracción de características

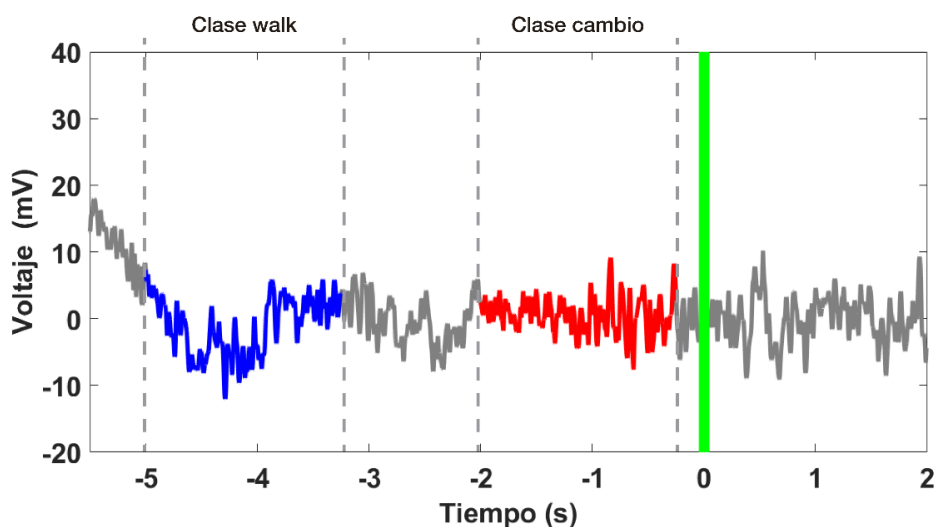
En este apartado, se explica la separación de la señal en dos clases para extraer sus correspondientes características que las diferencien en un clasificador. Asimismo, se profundiza en el cálculo de las características de los distintos grupos: frecuenciales, temporales y de potencia relativa.

#### 3.4.1. Separar las señales en clases

El principal objetivo del trabajo es detectar la intención del cambio de dirección, a partir de las señales EEG generadas por el sujeto durante las pruebas. En el apartado anterior, queda demostrado que existe un potencial motor directamente relacionado con la intención de cambio de dirección, que aparece en un intervalo de 2 segundos previos a que se produzca dicho cambio. Por tanto, es posible buscar diferencias entre las señales generadas cuando está caminando y cuando decide girar.

Por este motivo, la ventana creada previamente entorno al cambio de dirección, que va desde 5.5 segundos previos al cambio hasta 2 segundos después, se separa nuevamente en dos trozos: walk y cambio. Cada uno de los tramos representa una clase, es decir, la clase walk representa los trozos de señal donde el sujeto está caminando, mientras que la clase cambio es el trozo que contiene la señal donde se encuentra situado el potencial ERD.

En base a la información obtenida con la potencia relativa, se establece un tamaño de ventana estándar para las dos clases de 1.75 segundos. A partir de dicha información, también se establece una ubicación estándar de las ventanas en las señales. Por un lado, la ventana de la clase walk se ubica desde -5 segundos hasta -3.25 segundos antes del cambio de dirección, de color azul en la Figura 28. Por otro lado, la posición de la ventana de la clase cambio se establece desde -2 segundos hasta -0.25 segundos previos al cambio, de color rojo en la Figura 28.



*Figura 28.* Ventana de señal EEG alrededor del punto de cambio de dirección. En azul, el segmento de la clase walk; en rojo, el segmento de la clase cambio.

En la figura anterior, se representa la señal en la ventana entorno al cambio de dirección. En ella, se marcan en color azul el trozo de la clase walk y, en color rojo, el trozo de señal de la clase cambio. También, la línea en verde representa el instante donde se produce el cambio de dirección.

Dado que el cambio de dirección debe ser detectado antes de que se produzca para que, al utilizar el exoesqueleto, el movimiento sea lo más realista posible, el tramo de señal posterior al cambio no es relevante en la separación por clases. Por ello, en la posición de la ventana de cambio de dirección se deja un pequeño margen de unos segundos respecto al instante del cambio.

El hecho de generalizar tanto los tamaños como las ubicaciones de las ventanas puede tener consecuencias negativas en el proceso de estudio. La variabilidad del potencial ERD puede dificultar su localización dentro de la clase cambio. Para corregirlo, se han estudiado las posiciones de los potenciales ERD de todos los sujetos y se ha seleccionado un tamaño de ventana y posición que sea capaz de albergar a la gran mayoría de los potenciales de todos los sujetos.

Una vez seleccionadas las ventanas de las dos clases, se debe caracterizar cada una de las señales para, posteriormente, poder distinguirlas. Para ello, se extraen una serie de características que parametrizan las propiedades de las señales y forman un vector. Por tanto, cada señal queda descrita por un vector, de manera que el vector de la señal de una clase debe ser similar al resto de vectores de señales de dicha clase.

En este trabajo, se extraen tres tipos de características que están relacionadas entre sí y, para que sea más sencillo diferenciarlas, se las ha agrupado en tres grupos: características frecuenciales, temporales y de potencia relativa.

### 3.4.2. Características frecuenciales


El primer grupo de características extraídas son las características frecuenciales. Este grupo se denomina así porque se obtienen las características a partir de la transformación de la señal temporal a señal en el dominio de la frecuencia.

En primer lugar, tal y como se había comentado, se transforma la señal EEG en tiempo a señal en frecuencia mediante la Transformada Rápida de Fourier (FFT: Fast Fourier Transform). A partir de esta señal, se calcula la densidad espectral de potencia, más conocida como PSD.

La PSD consiste en estimar la distribución de la potencia en cada banda de frecuencia de una señal discreta, siguiendo siguiente fórmula:

$$S_{xx}(\Omega) = FFT\{R_{xx}[m]\} = \sum_{m=-\infty}^{\infty} R_{xx}[m] \cdot e^{-j\Omega m} \quad (13)$$

En este trabajo, se ha utilizado la función *psburg* [34] de Matlab que obtiene el espectro de las frecuencias de forma rápida y sencilla. En la Figura 29. En ella, se puede observar en la PSD de la clase cambio.



**Figura 29.** PSD de la clase cambio en una repetición de la tarea. En rojo, los valores máximos en las bandas Delta, Theta-Mu y Beta; el punto negro entorno al punto rojo de la banda Theta-Mu, es el valor máximo del espectro; en gris, las líneas verticales representan el sumatorio de los valores en cada banda.

En la Figura 29, se puede apreciar como las bajas frecuencias poseen una mayor cantidad de potencia. Asimismo, en la figura anterior también están representadas una serie de líneas verticales, que muestran las diferentes bandas en las que se va a extraer la información de las densidades de potencia. En esta división en bandas, se ha aplicado un pequeño solape para no perder información en el trozo del espectro entre una frecuencia y otra.

Por tanto, las tres bandas en que queda dividido el espectro y, cómo van a ser nombradas de ahora en adelante en este apartado, son:

**Tabla 4.** Bandas de frecuencia en que se divide la PSD para extraer información en cada una de ellas.

Banda de frecuencia PSD		
Banda	Inicio (Hz)	Fin (Hz)
Delta ( $\delta$ )	0.5	3
Theta + Mu ( $\theta+\mu$ )	3	14
Beta ( $\beta$ )	14	40

Ahora, para cada una de las bandas se extraen una serie de parámetros a partir de la señal de PSD. Los parámetros extraídos son: el máximo por banda y el sumatorio de todos los valores de la banda. Por tanto, se obtienen 8 parámetros a partir de cada PSD: máximos en cada banda, sumatorios en cada banda. Además, también se extrae el máximo total y el sumatorio total del espectro.

Sin embargo, tras formar las matrices de características con todas las señales en varios sujetos se observa un gran inconveniente: la variabilidad dentro de las clases. Debido a que cada vez que el sujeto comienza a caminar, los potenciales generados no son exactamente los mismos y, además, pueden verse afectados por factores externos.

A este problema, hay que sumarle la similitud encontrada entre los valores de las dos clases, donde en algunas señales el máximo en una banda es mayor para una clase, mientras que, en otras señales, lo es en la otra clase. En consecuencia, la clasificación con estas características resulta casi imposible.

Por este motivo, se decide extraer nuevas características en base a estos parámetros: relación entre bandas en forma de porcentajes y normalización de los parámetros. Esta solución permite reducir la variabilidad dentro de una misma clase y, a su vez, aumentar la diferenciabilidad entre clases.

La explicación a este hecho es que los potenciales ERD aparecen como consecuencia de una diferencia de potencial entre las bandas de frecuencia en la potencia original [40]. Entonces, al centrarse en buscar las diferencias dentro de una misma señal y normalizar los valores respecto al máximo de la señal, la variabilidad entre las señales desaparece y se obtienen valores mucho más estandarizados.

Las nuevas características calculadas a partir de los anteriores valores extraídos del espectro de potencia son: diferencia entre bandas normalizada, máximos de cada banda normalizados y sumatorios de cada banda normalizados. En la Tabla 5, se muestran las fórmulas empleadas para el cálculo de cada una de ellas.

Tabla 5. Tabla con las características frecuenciales extraídas.

<b>Características Temporales</b>		
<b>Relación entre bandas</b>		
<b>Bandas <math>\delta/\mu</math></b>	<b>Bandas <math>\beta/\mu</math></b>	<b>Bandas <math>\beta/\delta</math></b>
$\frac{\text{Sumatorio } \mu}{\text{Sumatorio } \delta} \cdot 100$	$\frac{\text{Sumatorio } \beta}{\text{Sumatorio } \mu} \cdot 100$	$\frac{\text{Sumatorio } \beta}{\text{Sumatorio } \delta} \cdot 100$
<b>Porcentaje máximo bandas</b>		
<b>Banda <math>\delta</math></b>	<b>Banda <math>\mu</math></b>	<b>Banda <math>\beta</math></b>
$\frac{\text{Sumatorio } \delta}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Sumatorio } \mu}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Sumatorio } \beta}{\text{Sumatorio Total}} \cdot 100$
<b>Porcentaje sumatorio bandas</b>		
<b>Banda <math>\delta</math></b>	<b>Banda <math>\mu</math></b>	<b>Banda <math>\beta</math></b>
$\frac{\text{Máximo } \delta}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Máximo } \mu}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Máximo } \beta}{\text{Sumatorio Total}} \cdot 100$

Como resultado de las nuevas características en frecuencia, ahora el vector de características contendrá 9 características de tipo frecuencial, en lugar de 8 como en un primer momento se había pensado. Estas características están dispuestas en el vector siguiendo el orden de la tabla de izquierda a derecha.

### 3.4.3. Características de potencia relativa

El segundo tipo de características extraídas de las señales son las de potencia relativa. Este tipo de características no se obtienen de la señal de EEG filtrada, sino de la potencia relativa en la banda Mu (8 – 13Hz) calculada en el Apartado 3.3.5.

La potencia relativa, tal y como se puede observar en el apartado mencionado anteriormente, es una señal que presenta, a simple vista, diferencias entre la ventana de la clase walk y la ventana de la clase cambio. Esto se debe a la presencia del potencial ERD en la ventana cambio y, por tanto, de un descenso en los valores respecto al trozo de señal donde el sujeto sólo está caminando.

Las características que se obtienen son: máximo, mínimo, valor medio y amplitud desde el punto mínimo hasta cero. Teóricamente, el máximo en la ventana walk debería ser mayor, mientras que el mínimo de la clase cambio debería ser más pequeño.

*Tabla 6. Tabla con las características de potencia relativa extraídas.*

Características de Potencia Relativa			
Máximo	Mínimo	Media	Amplitud

En ocasiones, los valores obtenidos para ambas ventanas pueden ser muy similares debido a la amplitud de las oscilaciones que representan la marcha del sujeto o, también, porque el potencial no se encuentra muy marcado y su mínimo presenta valores cercanos a números positivos. A pesar de ello, cuando los potenciales ERD aparecen correctamente, las características suelen ser muy discriminatorias entre clases.

Sin embargo, este tipo de características presentan un gran inconveniente: elevado coste computacional en el cálculo de la potencia relativa. En consecuencia, estas características no pueden ser utilizadas en los métodos de clasificación pseudo-online ni online, ya que presentarían una latencia muy elevada.

Por este motivo, se busca otro tipo de características que requieran de un menor coste computacional para su obtención y que, a la vez, sean capaces de diferenciar entre clases. Las características que cumplen estos requisitos se las ha denominado, en el trabajo, características temporales y se explican en mayor profundidad en el siguiente apartado.

### 3.4.4. Características temporales

Finalmente, tercer y último tipo de características extraídas son las características temporales. Reciben este nombre por el simple hecho de que se extraen a la señal de EEG en el dominio del tiempo, es decir, tal y como se encuentra la señal tras su filtrado Laplaciano y paso-banda entre 0.5 y 40Hz.

Las características que se han obtenido a partir de la señal de EEG en el dominio del tiempo son muy variadas. Algunas están basadas en la forma de la señal, mientras que



otras son parámetros estadísticos. En total, se obtienen 20 características de este tipo y, más tarde, se seleccionan las que mejor diferenciación entre clases presenten. A continuación, en la Tabla 7, se muestra una tabla resumen con las características temporales calculadas.

**Tabla 7.** Tabla con las características temporales extraídas.

Características Temporales					
Energía	Entropía de Wavelet	Valor Absoluto Medio	Parámetros de Weibull	Máximo de Yule-Walker	
Desviación Típica			Parámetros de Hjörth		
EEG	EEG Frecuencia	EEG Hilbert	Actividad	Movilidad	Complejidad

La primera característica obtenida es la desviación típica ( $S$ ), que se extrae de tres tipos de señales: a la señal EEG filtrada, a la señal de EEG transformada en frecuencia mediante la FFT y, también, a la señal de EEG aplicándole la transformada de Hilbert. A pesar de que esta característica si se extrae de otras señales que no son están en dominio del tiempo, se incluyen en esta característica para facilitar los agrupamientos.

La fórmula seguida para la obtención de la desviación típica por la función *std* [33] de Matlab es:

$$S = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2} \quad (14)$$

Donde  $S$  es el valor de la desviación típica,  $N$  es el número de elementos del vector de la señal,  $A_i$  es el valor del vector en la muestra  $i$ , y  $\mu$  es el valor medio del vector de la señal, que se calcula con la siguiente fórmula:

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \quad (15)$$

La siguiente característica es el Valor Medio Absoluto (MAV), que consiste en calcular el valor absoluto de cada uno de los componentes del vector de la señal y, después, obtener la media del nuevo vector de valores absolutos.

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_j| \quad (16)$$

También se calcula una característica basada en la forma de la señal, como es la energía (SSI) del trozo de señal. La obtención de esta característica es muy similar al cálculo de la energía para el cálculo de la potencia relativa en las bandas llevado a cabo en el Apartado 3.3.5. Sin embargo, ahora presenta una pequeña diferencia: tras elevar al cuadrado todos los elementos del vector, se aplica un sumatorio de todos ellos.

$$SSI = \sum_{i=0}^N (|x_i|^2) \quad (17)$$

Otra característica basada en la forma de la señal es la Entropía de Wavelet (WE). Este método basa en los fundamentos de Wavelet de descomponer la señal poco a poco en forma de árbol para ir caracterizando el desorden encontrado en la señal y las grandes variaciones producidas en ella.

La función de Matlab empleada para el cálculo de este valor es *wentropy* [32], a la cual hay que especificarle el tipo de entropía que se quiere calcular. En este caso, se ha optado por la Entropía de Wavelet de tipo ‘*log energy*’, es decir, basada en el logaritmo de la energía. Por tanto, las fórmulas matemáticas que sigue la función para alcanzar el resultado son:

$$WE = \sum_{i=1}^N E(s_i) \quad (18)$$

Y según el método de energía logarítmica,  $E(s_i)$  se calcula como:

$$E(s_i) = \log (s_i^2) \quad (19)$$

Donde  $E$  es la entropía del logaritmo de la energía de la señal  $s$  en la muestra  $i$ .

El cálculo del siguiente elemento consiste en aplicar la transformada de Yule-Walker a la señal de EEG en el dominio del tiempo y obtener el máximo valor de dicha transformación. Esta transformada sirve para calcular la PSD que se calculaba en el Apartado 3.4.2., pero siguiendo un método autorregresivo.

Un método autorregresivo es aquel que no sólo utiliza la señal actual, sino que también considera la señal en instantes anteriores. Así, es capaz de establecer una relación entre ambos para extraer los cambios producidos.

La función de Matlab utilizada es *pyulear* [31] que, además del vector con la señal, requiere que se especifique el orden del modelo autorregresivo. En este caso, se recurre a un modelo de orden 3.

Otras características del vector de características son los Parámetros de Weibull, obtenidos a partir de la distribución estadística de Weibull. Se trata de dos parámetros calculados con la función de Matlab *wblfit* [30], que representan las estimaciones de máxima probabilidad de la distribución estadística generada a partir de la señal.

La distribución estadística de Weibull se representa como:

$$y = f(x|a, b) = ba^{-b}x^{b-1}e^{-\left(\frac{x}{a}\right)^b} \quad (20)$$

Siendo  $a, b$  los parámetros calculados y, que componen el vector de características.

Finalmente, se calculan otros tres parámetros, más conocidos como Parámetros de Hjörth. Se trata nuevamente de parámetros estadísticos referidos a la señal en el dominio del tiempo. Los tres parámetros son: Actividad ( $Ax$ ), Movilidad ( $Mx$ ) y Complejidad ( $Cx$ ). Las fórmulas de cada uno de ellos son las siguientes:

$$Ax = \frac{\sum_{t=1}^T (x(t) - \mu)^2}{T} \quad (21)$$

$$M_x = \sqrt{\frac{\text{var}(\dot{x}(t))}{\text{var}(x(t))}} \quad (22)$$

$$C_x = \frac{\dot{M}(x(t))}{M(x(t))} \quad (23)$$

Estos parámetros no se obtienen con una función de Matlab, sino que simplemente se implementan las fórmulas en el código y se realizan los cálculos correspondientes.

Los 12 parámetros expuestos anteriormente son considerados como características temporales de las señales y formarán parte del vector de características que caracteriza a cada señal. Además de estas características, se probaron otras como la Kurtosis y la Amplitud de Wilson, pero daban valores muy similares entre las dos clases y no eran capaces de producir una discriminación lo suficientemente buena para que el clasificador pudiese clasificarlas. [17] [19] [44]

### 3.5. Selección de características y electrodos

En este apartado, con el objetivo de reducir la longitud de los vectores de características largos y escoger tanto aquellas características, como electrodos, que más faciliten la diferenciación entre clases, se lleva a cabo un proceso de selección.

Para ello, se realiza un análisis estadístico de las características en cada uno de los electrodos de forma individual. Este análisis se implementa de manera sencilla con una función de Matlab llamada *ranksum*, que se fundamenta en la Prueba de Suma de Rango de Wilcoxon. [29]

Dicha prueba parte de una hipótesis que plantea que las dos clases son independientes entre ellas. Para comprobar si es cierta o no, se realiza el análisis estadístico y se calcula el p-valor. Si el p-valor obtenido es menor del 5%, se demuestra que la hipótesis es cierta. Sin embargo, si el p-valor es mayor del 5%, se descarta la hipótesis y, por tanto, significa que las clases no son independientes.

Un aspecto importante a tener en cuenta es que la intención de cambio de dirección que se busca y que debe estar diferenciada de los tramos de caminar, se encuentra influenciada por los potenciales de la marcha, ya que se produce a la vez que el sujeto está andando. Esto significa que existen características de la clase cambio en algunos electrodos perturbadas por potenciales de la marcha y, por tanto, dificultan la diferencia entre clases.

Al mismo tiempo, se calculan y representan los diagramas de caja, también conocidos como *box-plot*, que permiten visualizar la diferencia o similitud entre cada una de las características analizadas de manera gráfica. En las Figuras 30 y 31, se pueden observar los diagramas de caja para las características tanto frecuenciales, como temporales de un electrodo, respectivamente.

### Análisis de Características Frecuenciales

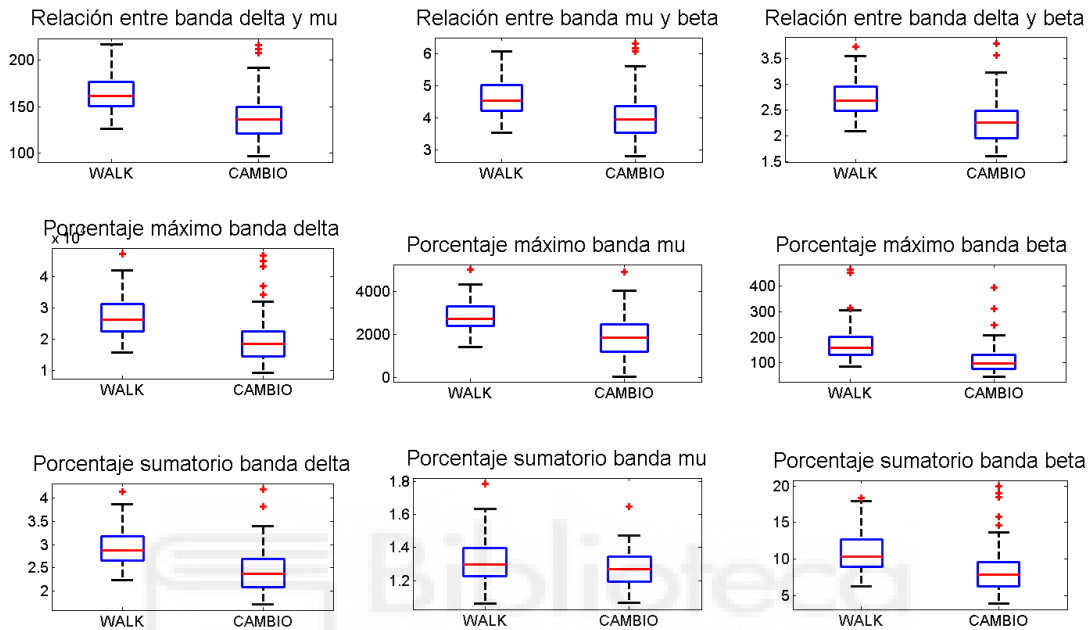


Figura 30. Diagramas de cajas de las características frecuenciales para cada clase.

### Análisis de Características Temporales

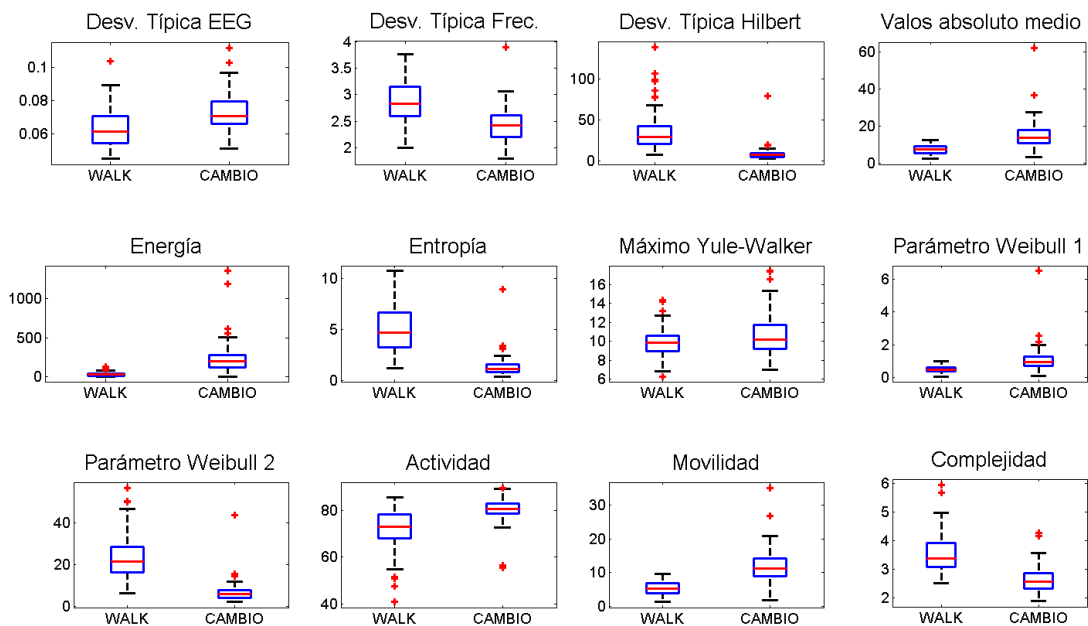


Figura 31. Diagramas de cajas de las características temporales para cada clase.

En las gráficas se puede comprobar como algunas características, como la energía o la entropía, son claramente diferenciables entre clases. En cambio, otras características, como por ejemplo el porcentaje del sumatorio en la banda Mu, son tan similares que sería muy complicado que el clasificador pudiese distinguir entre una clase u otra.

El resultado de este análisis estadístico es una matriz de valores lógicos, o lo que es lo mismo, de ceros y unos. Por un lado, los ceros indican que no se cumple la hipótesis nula y que las características no son diferenciables entre clases. Por otro lado, los unos indican que la hipótesis nula si se cumple y que las características son independientes entre clases.

En la Figura 32, se representa el resultado del análisis de una de las matrices de características. En ella, las filas indican las características y las columnas son los electrodos. Por tanto, al analizar la matriz larga de todos los electrodos con características frecuenciales y temporales, la matriz está compuesta por 22 filas (22 características) y 32 columnas (32 electrodos).

		Electrodos																																
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	
Características Frecuenciales	1	1	1	1	0	1	0	1	0	1	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	0	1	1	0	1	1	1	1	
	2	1	1	1	0	0	0	1	0	1	1	0	1	1	1	1	0	1	1	1	1	0	0	0	0	0	0	1	1	1	1	1	1	
	3	1	1	1	0	1	0	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0	0	1	1	0	0	1	1	1	1	
	4	1	1	1	0	1	0	1	0	1	1	1	1	1	1	1	0	1	1	0	1	0	0	0	1	1	1	1	0	1	1	1	1	
	5	1	1	0	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	0	0	0	0	1	1	1	1	0	0	1	1	1	
	6	0	1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0	1	1	1	1	1	1	1	1	1	
	7	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	0	0	0	0	0	1	1	1	1	1	0	1	0	1	
	8	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	1	0	0	0	1	0	0	0	1	1	1	0	0	1	1	0	
	9	1	1	0	0	1	1	0	1	1	1	0	1	1	1	1	0	1	0	0	0	0	0	0	0	0	0	1	1	0	1	1	0	1
Características Temporales	10	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	0	1	0	0	0	0	0	0	1	1	0	1	0	1	0	0	1	
	11	1	1	1	1	0	0	1	1	1	1	1	1	1	1	0	1	0	0	0	0	0	0	0	1	1	1	0	0	1	0	1	1	
	12	1	1	0	1	1	1	0	1	1	1	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	0	0	1	0	1	1		
	13	1	1	0	1	0	1	0	0	1	1	1	1	1	1	1	0	1	1	0	0	0	0	0	0	1	1	1	0	0	0	1	1	
	14	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	0	0	0	1	0	0	1	1	1	0	1	0	1	1	
	15	1	1	0	1	0	1	0	1	1	1	1	1	1	1	1	0	1	0	0	0	0	1	0	0	1	1	1	0	1	1	0	1	
	16	1	1	1	1	0	1	0	1	1	0	1	1	1	1	0	0	1	0	0	0	0	1	0	0	1	1	0	0	1	0	1	0	
	17	1	1	1	1	0	1	0	1	1	1	1	0	1	1	0	1	1	1	0	0	0	0	0	0	0	1	1	0	1	1	0	1	0
	18	1	1	1	1	0	1	0	1	1	1	1	1	1	1	1	0	1	1	1	0	0	1	1	0	1	1	1	0	1	1	0	1	1
	19	0	1	1	1	0	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0	0	1	1	1	0	1	1	1	1	1	
	20	1	0	1	1	0	1	0	1	1	0	1	1	1	1	0	1	1	0	1	1	0	0	0	0	1	1	0	1	1	1	1	1	
	21	1	1	0	1	0	1	0	1	1	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	0	1	1	0	1	1	1	1	1

Figura 32. Matriz binaria con el resultado del análisis estadístico de la diferenciableidad entre clases. Los ceros indican que las clases no son lo suficientemente independientes en la característica del electrodo concreto; los unos, indican que si son diferenciables.

En base a los resultados obtenidos, se hace una selección de las características y electrodos que mayor independencia presentan entre clases. Para ello, se divide el proceso en dos pasos: primero se eliminan los electrodos de bajo porcentaje y con los resultantes se eligen las características con porcentajes más altos.

En primer lugar, para elegir los mejores electrodos se calcula el porcentaje de características independientes entre clases que posee cada uno, es decir, se calcula el porcentaje de unos que hay en cada columna. Los electrodos con porcentajes inferiores al 85% se descartan.

Los porcentajes de los electrodos se calculan por separado para las características de tipo frecuenciales y temporales. Este hecho se debe porque algunos electrodos aportan información muy buena en un dominio y, en cambio, en otro dominio aportan información irrelevante. De esta forma, se seleccionan los mejores electrodos de cada tipo de características. Por tanto, habrá electrodos en los que se elijan características frecuenciales y temporales, en otros sólo de un tipo y en algunos electrodos puede que no se elijan características de ningún tipo.

En la Figura 33, se encuentran marcados en rojo los electrodos que se descartan para cada tipo de características.

		Electrodos																																			
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32				
Características Frecuencia	1	1	1	1	0	1	0	1	0	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	0	0	1	1	0	1	1	1	1	1			
	2	1	1	1	0	0	0	1	0	1	1	0	1	1	1	1	0	1	1	1	1	0	0	0	0	0	0	1	1	1	1	1	1	1			
	3	1	1	1	0	1	0	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0	0	1	1	0	0	1	1	1	1	1			
	4	1	1	1	0	1	0	1	0	1	1	1	1	1	1	1	0	1	1	0	1	0	0	0	0	1	1	1	1	1	0	1	1	1	1		
	5	1	1	0	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	1	1	1	1	1	0	0	1	1	1		
	6	0	1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0	0	1	1	1	1	1	1	1	1	1	1		
	7	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	0	0	0	0	0	0	1	1	1	1	1	0	1	0	1	0	1	
	8	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	0	1	0	0	0	1	0	0	0	1	1	1	1	0	0	1	1	0	1	0	
	9	1	1	0	0	1	1	0	1	1	1	0	1	1	1	1	0	1	0	0	0	0	0	0	0	0	0	1	1	0	1	1	0	1	0	1	
Características Temporales	10	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	0	1	0	0	0	0	0	0	0	1	1	0	1	0	1	0	0	1	0		
	11	1	1	1	1	0	0	1	1	1	1	1	1	1	1	1	0	1	0	0	0	0	0	0	0	1	1	1	0	0	1	0	1	0	1	1	
	12	1	1	0	1	1	1	0	1	1	1	1	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	1	0	0	1	0	1	0	1	1	
	13	1	1	0	1	0	1	0	0	1	1	1	1	1	1	1	0	1	1	0	0	0	0	0	0	0	1	1	1	0	0	0	0	1	1	1	
	14	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	0	0	0	1	0	0	1	1	1	1	0	1	0	1	0	1	1	
	15	1	1	0	1	0	1	0	1	1	1	1	1	1	1	1	0	1	0	0	0	0	1	0	0	1	1	1	1	0	1	1	0	1	1	0	1
	16	1	1	1	1	0	1	0	1	1	0	1	1	1	1	1	0	0	1	0	0	0	0	1	0	0	1	1	0	0	1	0	1	0	1	0	1
	17	1	1	1	1	0	1	0	1	1	1	1	0	1	1	0	1	1	1	0	0	0	0	0	0	0	1	1	0	1	1	0	1	1	0	1	0
	18	1	1	1	1	0	1	0	1	1	1	1	1	1	1	1	0	1	1	1	0	0	1	1	0	1	1	1	0	1	1	0	1	1	0	1	1
	19	0	1	1	1	0	1	0	1	1	1	1	1	1	1	1	0	1	1	1	1	0	0	0	0	1	1	1	0	1	1	1	1	1	1	1	1
	20	1	0	1	1	0	1	0	1	1	0	1	1	1	1	1	0	1	1	0	1	1	0	0	0	0	1	1	0	1	1	1	1	1	1	1	1
	21	1	1	0	1	0	1	0	1	1	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	0	0	1	1	0	1	1	1	1	1	1	1

Figura 33. Descarte de los electrodos con menos del 85% de características capaces de diferenciar entre clases. En rojo, los electrodos descartados.

En segundo lugar, tras eliminar las columnas de los electrodos que no son los suficientemente buenos para la diferenciación de características, se sigue un proceso similar al anterior, pero con cada una de las características. Para ello, se calcula el porcentaje de electrodos en los que la característica es diferenciable entre clases, es decir, el número de unos por filas. Entonces, se eligen las características con un porcentaje mayor o igual al 90%.

		Electrodos															
		1	2	5	7	9	10	12	13	14	15	17	26	27	30	32	
Características Frecuencia	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	2	1	1	0	1	1	1	1	1	1	1	1	1	0	1	1	1
	3	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1
	4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	6	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	7	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0
	9	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1

		Electrodos													
		1	2	4	6	8	9	11	12	13	14	17	25	26	29
Características Temporales	10	1	1	1	1	1	1	1	1	0	1	1	1	0	1
	11	1	1	1	0	1	1	1	1	1	1	1	1	1	1
	12	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	13	1	1	1	1	0	1	1	1	1	1	1	1	1	0
	14	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	15	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	16	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	17	1	1	1	1	1	1	1	0	1	1	1	1	1	1
	18	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	19	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	20	1	0	1	1	1	1	1	1	1	1	1	1	1	1
	21	1	1	1	1	1	1	1	1	1	1	1	1	1	1

*Figura 34. Descarte de las características con menos del 90% de electrodos capaces de diferenciar entre clases. En la matriz rosa, se marcan en rojo las características frecuenciales descartadas; en la matriz azul, se marcan en rojo las características temporales descartadas.*

Finalmente, tras las correspondientes eliminaciones de filas y columnas de la matriz de valores lógicos, queda como resultado una matriz mucho más reducida con los electrodos y características definitivas que compondrán los vectores de características que describen a las clases en cada repetición de la tarea y, por tanto, que compondrán la matriz de características. Los electrodos y características definitivas de cada tipo se muestran en las siguientes tablas.

		Electrodos															
		1	2	5	7	9	10	12	13	14	15	17	26	27	30	32	
Caract. Frecuencia	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	3	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1
	4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	6	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	7	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0
	9	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1

		Electrodos														
		1	2	4	6	8	9	11	12	13	14	17	25	26	29	
Características Temporales	11	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1
	12	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	14	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	15	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	16	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	17	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1
	18	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	19	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	20	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	21	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1

*Figura 35. Matriz con los electrodos y características frecuenciales (rosa) y temporales (azul) definitivas.*

En las tablas anteriores no todos los valores lógicos son positivos, sino que todavía hay características de algunos electrodos que no cumplen la hipótesis nula de independencia entre clases del test de Wilcoxon. A pesar de ello, el modelo de características resultante presenta una mayor precisión en lo referente a la diferenciabilidad entre clases.

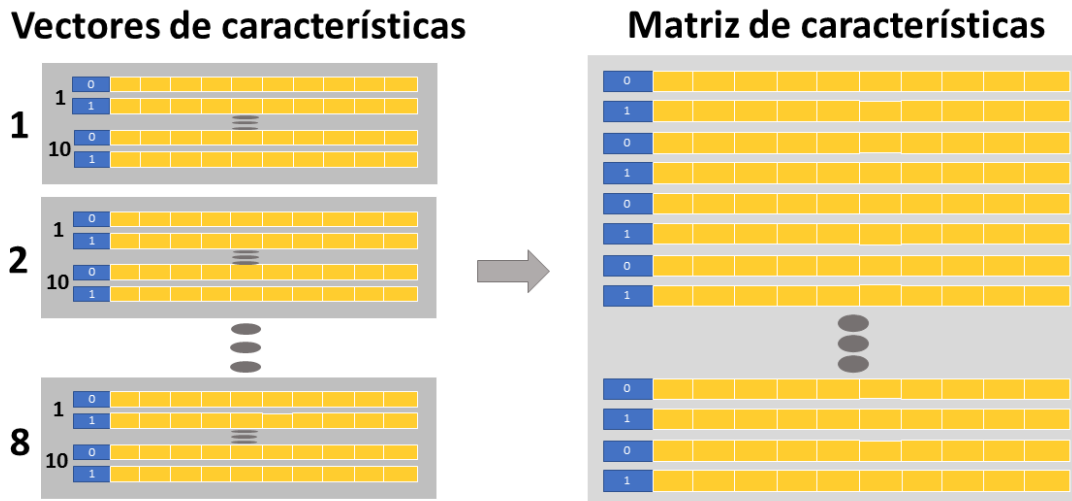
Después de seleccionar las características y electrodos definitivos, se deben extrapolar sus posiciones al vector de características largo original, para poder seleccionar las buenas y reducirlo. Para ello, se establecen una serie de bucles en el código que recorren el vector de características original por características en cada electrodo y van almacenando las posiciones definitivas.

### 3.5.1. Formación de la matriz de características

El paso previo al proceso de clasificación es la formación de la matriz de características, que es un conjunto de vectores de características de las dos clases, walk y cambio. La



matriz contiene los vectores de varios registros, en cada uno se realizan 10 repeticiones de la tarea. Además, de cada repetición se extraen dos vectores: uno de la clase walk y otro de la clase cambio. Por tanto, cada registro aporta a la matriz 20 vectores de características, 10 de la clase walk y 10 de la clase cambio.



**Figura 36.** Proceso de formación de la matriz de características a partir de los vectores de características de los registros. A la izquierda: en gris, los 8 registros procesados; en amarillo los 20 vectores de características de cada registro; en azul, las etiquetas de cada clase en el vector, ya que hay 10 vectores de cada clase. A la derecha, la matriz de características formada.

La Figura 36 es un ejemplo de la formación de la matriz de características para la clasificación offline. Los rectángulos grises del lado izquierdo son cada uno de los registros analizados y caracterizados. En su interior, se encuentran los 20 vectores de características correspondientes a las 10 repeticiones de la tarea. Las características están representadas en amarillo y, en azul, se indica la clase a la que pertenece cada vector.

Entonces, todos los vectores de los registros procesados se agrupan y combinan en la matriz de características, cuya primera columna indica la clase de cada vector y, el resto de las columnas, son las diferentes características extraídas.

Sin embargo, en ocasiones no todos los vectores contienen información precisa sobre la clase a la que representan, especialmente cuando se trata del vector de la clase cambio. Esto se debe a que, en algunas repeticiones, el punto de cambio detectado en las IMU no es el punto exacto, como consecuencia de señales alteradas por movimiento. Por este motivo, el punto de cambio que puede variar unos instantes afectando a la ventana establecida para la clase cambio.

Además, en algunas tareas los potenciales ERD de intención del cambio, e incluso los potenciales referentes a la marcha, están muy afectados por otros factores que corrompen las características, aumentando la variabilidad dentro de las clases.

Por esta razón, se lleva a cabo una selección de tareas para eliminar de la matriz aquellos vectores que no aportan información relevante y dificultan la diferenciación entre clases.

Así, se busca generar un modelo lo más preciso posible como instrumento para alcanzar el objetivo de distinguir las intenciones de cambio de dirección de la marcha.

Esta reducción de la matriz, como la mayoría de las decisiones, tiene su lado positivo, pero también su lado negativo. Por un lado, el aspecto positivo de la eliminación de vectores que no son válidas es el aumento de la precisión del modelo. Por otro lado, el aspecto negativo que presenta esta eliminación de vectores es que también supone una pérdida el número de muestras de entrenamiento, que en algunos casos puede provocar problemas en el clasificador.

A la hora de generar el modelo del clasificador se prueba con ambas matrices, tanto la completa con todos los vectores, como con la matriz de características reducida. Por tanto, es posible valorar si realmente la eliminación de vectores ha sido adecuada o si, por el contrario, ha empeorado el modelo.

En este trabajo, se llevan a cabo dos tipos de eliminación de vectores: el método de eliminación por potencial ERD y el método de eliminación por outliers. Más adelante, en los resultados, se valora cuál de los dos métodos es más preciso para la reducción del modelo.

### **3.5.1.1. Método de eliminación de vectores por potencial ERD**

Uno de los métodos empleados para la eliminación de vectores, que aumentan la variabilidad dentro del modelo, es el método de eliminación por potencial ERD. Este método se basa en el estudio de la señal media de las potencias relativas de todos los electrodos en una repetición de la tarea, calculadas en la banda Mu, y de los potenciales que aparecen en ella.

Para este proceso de selección de vectores se debe tener en cuenta que la potencia relativa es muy variable en cada repetición y puede que en algunos casos no la selección o eliminación del vector no sea del todo correcta. Sin embargo, el algoritmo diseñado es lo suficientemente efectivo para descartar algunos vectores irrelevantes para el modelo y que afectan de manera negativa a la varianza de la clase.

Por un lado, la eliminación de vectores de la clase cambio de dirección se fundamenta en el análisis del potencial ERD en la ventana de la clase cambio. Para ello, se implementan dos modos de descarte de vectores basados en los valores mínimos y las amplitudes de los potenciales.

El primer paso de descarte es estudiar el mínimo del potencial ERD. Si el valor mínimo de la ventana de la clase cambio es mayor de cero, la tarea se descarta directamente. Esto se impone así porque el potencial de desincronización debe indicar un descenso de la potencia relativa respecto a una referencia situada en 0% en la señal, es decir, el potencial debe tener valores negativos y, en este caso, no se está produciendo de manera suficiente. Además, este valor podría indicar que la señal está influenciada por otros potenciales que nada tienen que ver con el potencial ERD que se está buscando.

En algunos casos, a pesar de que se visualiza la forma del potencial, se descarta porque el hecho de presentar valores positivos podría afectar a las características, especialmente a las frecuenciales que se basan en la potencia de la señal, aumentando la variabilidad dentro de la clase cambio y añadiendo mayor dificultad a la hora de clasificar.

El siguiente paso de descarte es estudiar la amplitud del potencial ERD. Este potencial no sólo debe suponer una caída de potencial, sino que también debe ser lo suficientemente amplio para ser diferenciado de las señales ondulatorias producidas durante la marcha. Por ello, las tareas cuyo valor mínimo es negativo son analizadas con el algoritmo de amplitud.

El algoritmo consiste en obtener también el valor máximo de la señal que determinará el siguiente paso. Si el valor máximo es positivo, se buscan los picos de la señal mayores de cero y si, por el contrario, es negativo, se buscan los picos de la señal en un umbral entorno al valor del máximo. A partir de dichos picos, se calcula la distancia entre ellos, es decir, la amplitud de la onda que hay entre ellos.

Para que el potencial sea aceptado como tal se establece una amplitud de al menos 0.85 segundos que debe cumplir, sino la tarea es descartada. Esto se debe a que la forma de la potencia relativa representada se asemeja más a un potencial de marcha del sujeto que del propio potencial de desincronización. Por tanto, las características de este tipo también suponen un problema cuando se intenta diferenciar entre las dos clases.

Por otro lado, dado que se elimina un grupo de vectores de la clase cambio de la matriz de características, también se lleva a cabo un descarte de vectores de repeticiones de la clase walk. Así, las clases quedan equilibradas dentro del modelo y el número de vectores y características de cada clase es el mismo. En algunos casos, los números de descartes no son balanceados entre clases, por lo que se selecciona a mano los vectores que se van a eliminar a partir de los descartados con este método.

El proceso de eliminación de repeticiones de esta clase consiste, en primer lugar, en calcular el máximo, mínimo y amplitud de la señal desde el mínimo hasta cero. En base a dichos parámetros, se crea una señal senoidal cuyos máximos y mínimos sean los mismos que los de la señal original. Entonces, se establece una correlación entre ambas señales y se descartan aquellas repeticiones con baja correlación, ya que tal y como se ha comentado anteriormente, la persona general un potencial oscilatorio cuando está caminando.

En general, la selección de repeticiones de la tarea válidas con este método tiene como resultado un porcentaje de eliminación medio de entre el 15% y el 20% de los vectores incluidos en la matriz de características original.

### **3.5.1.2. Método de eliminación de vectores por outliers**

Otro de los métodos utilizados para reducir la variabilidad dentro de las clases y generar un modelo de entrenamiento del clasificador mejor es el método de reducción por outliers. Este método consiste en eliminar aquellas repeticiones cuyos valores del vector de

características se encuentren fuera del rango de valores normales y que aumentan la variabilidad dentro de la clase, es decir, aquellos que presenten un mayor número de outliers.

Se trata de un procedimiento que surge a partir de la selección de características y electrodos explicada en el Apartado 3.5. En él, se expone la utilización de diagramas de cajas para observar cómo de diferentes son las clases entre ellas en cada característica y electrodo.

En base a dichos diagramas, se extraen información de los outliers de cada clase en las diferentes características y electrodos seleccionados en el Apartado 3.5. Estos outliers se pueden observar cómo puntos rojos en las Figuras 30 y 31. Toda esta información se almacena en dos grandes matrices, donde una contiene la información de los outliers de la clase walk y, otra, la de los outliers de la clase cambio en cada característica y electrodo.

Por tanto, las filas de la matriz representan la característica y las columnas el electrodo al que pertenecen los outliers. Esto quiere decir que la matriz es muy similar a la matriz de valores lógicos obtenida en el Apartado 3.5., pero cada casilla, en lugar de contener un 0 o un 1, contiene un vector con los valores fuera de rango en los diagramas de cajas.

Sin embargo, los elementos de las matrices de outliers por clase tan sólo son el valor de la característica y no indican a qué repetición de tarea pertenece. Por este motivo, se debe recorrer cada casilla de las dos matrices, relacionando en valor de outlier con la repetición a la que pertenecen dentro de la clase. Así, se van formando otras dos matrices que si contienen los outliers por cada repetición.

A partir de la información contenida en las nuevas matrices creadas, se hace un recuento del número de veces que se repite cada repetición a lo largo de la matriz y se calcula su porcentaje respecto al número total de características en los electrodos seleccionados. Tras analizar los resultados del proceso en varios sujetos, se decide establecer un umbral del 15%, descartándose aquellos vectores que presentan un porcentaje de outliers entre sus características superior al umbral.

Generalmente, este proceso descarta alrededor del 20% de los vectores de la matriz original. Sin embargo, los descartes se basan en reducir la variabilidad directamente con datos y no con señales, por lo que el modelo generado con este método debería ser mucho más preciso que el modelo que se origina a partir del método de reducción por potencial ERD.

### **3.5.2. Tipos de vectores**

La extracción de los distintos tipos de características da lugar a la formación de los vectores de características que califican a cada una de las clases en las diferentes repeticiones de la tarea y registros. Todos estos vectores se agrupan posteriormente para dar lugar a la matriz de características utilizada en el entrenamiento del clasificador.

El primer paso para la formación de cualquier vector es etiquetarlo, es decir, indicar si el vector pertenece a la clase walk o a la clase cambio. Por tanto, el primer componente del

vector es un índice, que será 0 cuando el vector pertenece a la clase walk y 1 cuando pertenece a la clase cambio.

El siguiente paso, es decidir el tipo de vector que se va a conformar. Se distinguen dos tipos de vectores: el vector largo y el vector promedio. Por un lado, el vector largo contiene las características de las señales de cada uno de los electrodos por separado, es decir, se extraen las características para la señal de cada uno de los electrodos y se colocan en el vector.

Por otro lado, el vector promedio consiste en promediar las señales de todos los electrodos, generando una señal de EEG promedio a la cual se le extraen las características. El resultado es un vector mucho más corto y reducido.



**Figura 37.** Tipos de vectores utilizados en el trabajo. Arriba, el vector largo compuesto por las características extraídas a las señales de cada electrodo individualmente. Abajo, el vector promedio compuesto por las características extraídas a una señal promedio de las señales de todos los electrodos.

Ambos tipos tienen sus ventajas e inconvenientes, que se deben tener en cuenta a la hora de enviar la matriz con los vectores al clasificador, ya que tendrán influencia en los resultados. La ventaja del vector largo respecto al vector promedio es que se tiene las características de todos los electrodos y se pueden eliminar los electrodos menos relevantes, mientras que, en el vector promedio, al hacer la media de las señales se pueden perder características relevantes de algunos electrodos y potenciar electrodos menos relevantes.

La desventaja del vector largo es que, al incluir información por separado de todos los electrodos, se produce un vector de gran tamaño que provoque grandes dificultades en el clasificador para distinguir clases. En contraposición, el pequeño tamaño del vector promedio, lo hace mucho más simple para la clasificación.

En el Apartado 3.4. se especifican tres tipos de características: frecuenciales, temporales y de potencia relativa. Además, también se explica que las características de potencia relativa presentan un elevado coste computacional, por lo que se descartan. Entonces, se decide crear tres vectores según el contenido: vectores con características frecuenciales exclusivamente (9 características por señal), vectores con sólo características temporales (12 características por señal) y vectores con una combinación de las características frecuenciales y temporales (21 características por señal).

Algunos de los vectores resultantes son muy largos y no todas las características son igual de relevantes en el clasificador, en función de las señales que genera cada sujeto. Por este motivo, en el Apartado 3.4. se explica el método de selección de características y electrodos más relevantes, mientras que en los Apartados 3.5.1.1. y 3.5.1.2. se exponen los métodos de eliminación de repeticiones de tareas que perturban el modelo, potenciando una mayor diferencia entre los vectores de características la clase.

Dado que se han implementado distintos métodos de selección de características y reducción de la eliminación de vectores, se generan distintos tipos de vectores creados a partir de los diferentes procedimientos. Estos vectores forman distintas matrices de características y, a partir de cada tipo, se realiza un análisis offline que servirá para determinar cómo de bueno es cada método.

1. **Vector largo con todas las características y electrodos.** Se trata de un vector que contiene todas las características extraídas de cada una de las señales de todos los electrodos.
2. **Vector largo con todas las características y electrodos reducido por el método de potencial ERD.** Es un vector igual que el Vector 1, pero a la hora de formar la matriz, se eliminan una serie de vectores en cuya señal no aparece el potencial ERD y perturban el modelo.
3. **Vector largo con selección de características y electrodos.** Es un vector muy similar al Vector 1, pero seleccionando sólo ciertas características de los electrodos seleccionados automáticamente por el método explicado en el Apartado 3.4.
4. **Vector largo con selección de características y electrodos reducido por el método de outliers.** Es un vector igual que el Vector 3, pero en la formación de la matriz de características se eliminan los vectores cuyas características se encuentran fuera de los valores típicos.

5. **Vector promedio con todas las características y electrodos.** Se trata de un vector más corto que contiene todas las características extraídas de una señal resultante del promedio de las señales de todos los electrodos.
6. **Vector promedio con todas las características y electrodos reducido por el método de potencial ERD.** Es un vector igual al Vector 5, pero excluyendo aquellos vectores descartados por el método de potencial ERD y, por tanto, que no poseen el potencial.
7. **Vector promedio con todas las características y electrodos reducido por el método de outliers.** Es un vector exactamente igual que el Vector 5, pero descartando los vectores cuyas características presenten mayor número de outliers.

Todos estos tipos de vectores se generan para las características frecuenciales, temporales y una combinación de ambas. En consecuencia, habrá 7 tipos de vectores por cada grupo de características, haciendo un total de 21 tipos de vectores que son analizados a través del análisis offline. Así, es posible valorar todos los métodos y decidir cuál de todos será el más adecuado para un análisis pseudo-online y, en un futuro, en una aplicación online.

### 3.6. Clasificación

El último paso del desarrollo de este trabajo es comprobar cómo de bueno es el proceso implementado y conocer con qué caminos, o tipos de vectores y características, se obtienen mejores resultados.

El concepto básico de clasificador es entrenar un sistema para que sea capaz de diferenciar entre clases, de manera que cuando reciba nuevo elemento, sepa indicar a qué clase pertenece de la forma más precisa posible. Este proceso se desarrolla en dos pasos: modelo y clasificación.

El primer paso es la creación de un modelo a partir de características extraídas en los trozos de señal de cada clase. Los valores de estas características deben ser muy diferentes entre clases para que el clasificador pueda distinguirlas de la mejor forma posible.

El segundo paso es la verificación del clasificador para comprobar cómo de bien diferencia entre clases. En este paso, se van introduciendo datos nuevos, con sus correspondientes características, y clasificándolos en sus respectivas clases.

Dado que los clasificadores utilizados son de tipo supervisado, donde se conoce la clase a la que pertenece cada dato clasificado, es posible valorar la precisión del clasificador con una serie de parámetros de evaluación.

**Tabla 8.** Tabla con los conceptos de TP y FP de cada clase.

Evento \ Detección	Walk	Cambio
Walk	TPwalk	FPcambio
Cambio	FPwalk	TPcambio

El primer parámetro calculado es la precisión total del clasificador, también conocida como *accuracy*, que es el porcentaje de aciertos totales del clasificador.

$$Accuracy = \frac{Total\ de\ aciertos}{Total\ de\ eventos} \quad (24)$$

Los siguientes parámetros que se calculan son los verdaderos positivos (TP) por cada clase, que son los porcentajes de acierto para cada clase.

$$TP_{walk} = \frac{Aciertos\ de\ clase\ walk}{Total\ de\ eventos\ de\ clase\ walk} \quad (25)$$

$$TP_{cambio} = \frac{Aciertos\ de\ clase\ cambio}{Total\ de\ eventos\ de\ clase\ cambio} \quad (26)$$

Además, se evalúa también las veces que se clasifica el elemento de una clase como elemento de la otra clase, más conocido como falsos positivos (FP).

$$FP_{walk} = \frac{(Total\ detecciones\ clase\ walk - Aciertos\ clase\ walk)}{Total\ detecciones\ clase\ walk} \quad (27)$$


$$FP_{cambio} = \frac{(Total\ detecciones\ clase\ cambio - Aciertos\ clase\ cambio)}{Total\ detecciones\ clase\ cambio} \quad (28)$$

A la hora de calcular estos parámetros, es importantes saber diferenciar entre detecciones y eventos. Cuando se habla de eventos, se hace referencia a las veces que entran en el clasificador nuevos datos de una clase, independientemente de la salida que da después el clasificador. Mientras que las detecciones, indican las veces que la salida del clasificador indica que los datos pertenecen a una clase, independientemente de la clase a la que pertenecen los datos al entrar en el clasificador.

En este trabajo, se ha optado por utilizar el clasificador Vecino Más Cercano (KNN), entre los múltiples tipos de clasificadores. El clasificador KNN consiste un espacio donde se distribuyen los vectores de características de entrenamiento que conforman el modelo.

Al introducir un nuevo vector de características, que se desea clasificar, se crea un área a su alrededor cuyo diámetro queda determinado por una constante  $k$ , más conocida como tamaño del kernel. Entonces, se hace recuento del número de vectores de cada clase contenidos en dicha circunferencia y se le asigna la clase que presente más vectores de características dentro del área.





**Figura 38.** Distribución de las clases en el espacio de características del clasificador KNN. En azul y rojo, las dos clases; en negro el nuevo valor que debe ser clasificado; la circunferencia negra es el kernel.

La clase seleccionada puede variar en función del tamaño de circunferencia establecido, es decir, del valor de  $k$ . Por este motivo, se realiza una prueba de clasificación con mismo grupo de características en distintos sujetos, pero variando el valor de la distancia  $k$ . En base a los resultados obtenidos, se establece una  $k$  con valor 5.

Durante el proceso de análisis, también se probó con el clasificador SVM. Se trata de un clasificador que genera hiperplanos para separar las clases de forma lineal. Sin embargo, presenta un gran inconveniente. Cuando la matriz de características contiene vectores de características, con una longitud cercana o mayor al número de muestras de entrenamiento, tal y como ocurre en este caso, no es capaz de separar las clases de manera lineal ya que hay más características que muestras. En consecuencia, no clasifica correctamente y produce resultados erróneos.

En este trabajo, se aplican dos tipos de análisis con el clasificador: el análisis offline y el análisis pseudo-online. La principal diferencia entre ambos es que el análisis offline realiza la clasificación en ventanas concretas a posteriori de la prueba, mientras que el pseudo-online clasifica por ventanas en todos los instantes de la señal.

### 3.6.1. Análisis Offline

El análisis offline del clasificador se fundamenta en adquirir la señal y, después de la prueba, se realiza el acondicionamiento y clasificación de las múltiples señales en ventanas concretas. Este método está basado en el aprendizaje supervisado, donde los vectores de características que componen el modelo están etiquetados con la clase a la que pertenecen.

La valoración de los resultados de este clasificador consiste en un proceso de validación cruzada. En este procedimiento se divide el conjunto de datos en dos grupos donde las clases están balanceadas, teniendo cada grupo el mismo número de datos de cada clase.

Por un lado, un 80% de los datos forman el grupo de entrenamiento, que sirve para formar el modelo del clasificador. Por otro lado, el 20% restante forman el grupo de test, que se utiliza para validar el modelo.

En este trabajo, para la validación cruzada se utiliza información de 8 registros que componen una prueba, donde cada uno aporta 20 vectores de características, 10 de cada

clase. Por tanto, se realizan 8 iteraciones, donde cada vez se eligen 7 registros para crear el modelo y, los vectores del registro restante se utilizan como test.




Figura 39. Diagrama del proceso de validación cruzada de 8 iteraciones.

Una vez realizada la separación en dos conjuntos, el clasificador solicita dos tipos de parámetros: las etiquetas de clase y los datos. Las etiquetas de clase son la primera columna de los vectores de datos, que contienen la clase a la que pertenece el vector. Por tanto, el vector de etiquetas será un vector de ceros y unos, donde los ceros indican la clase walk y, los unos, la clase cambio.

Los datos son el resto de los elementos del vector de características, desde la segunda columna hasta el final. Así, se forma una matriz de datos donde cada columna pertenece a una característica concreta. Además, el conjunto de las características de cada fila corresponde con la clase de la misma fila en el vector de etiquetas, que sirve para etiquetar los datos.

A la hora de realizar la clasificación de cada iteración, el clasificador recibe como entrada el vector de etiquetas de entrenamiento y las matrices de datos de entrenamiento y test. La salida es un vector con el resultado de la clasificación realizada. Este vector se compara con el vector de etiquetas de test y se calcula tanto el porcentaje de acierto, como el resto de los parámetros de valoración comentados anteriormente (Ecuaciones 24-28). Al final todas las iteraciones, se calcula la media y la desviación típica de los parámetros de las iteraciones para valorar en rasgos generales el clasificador.

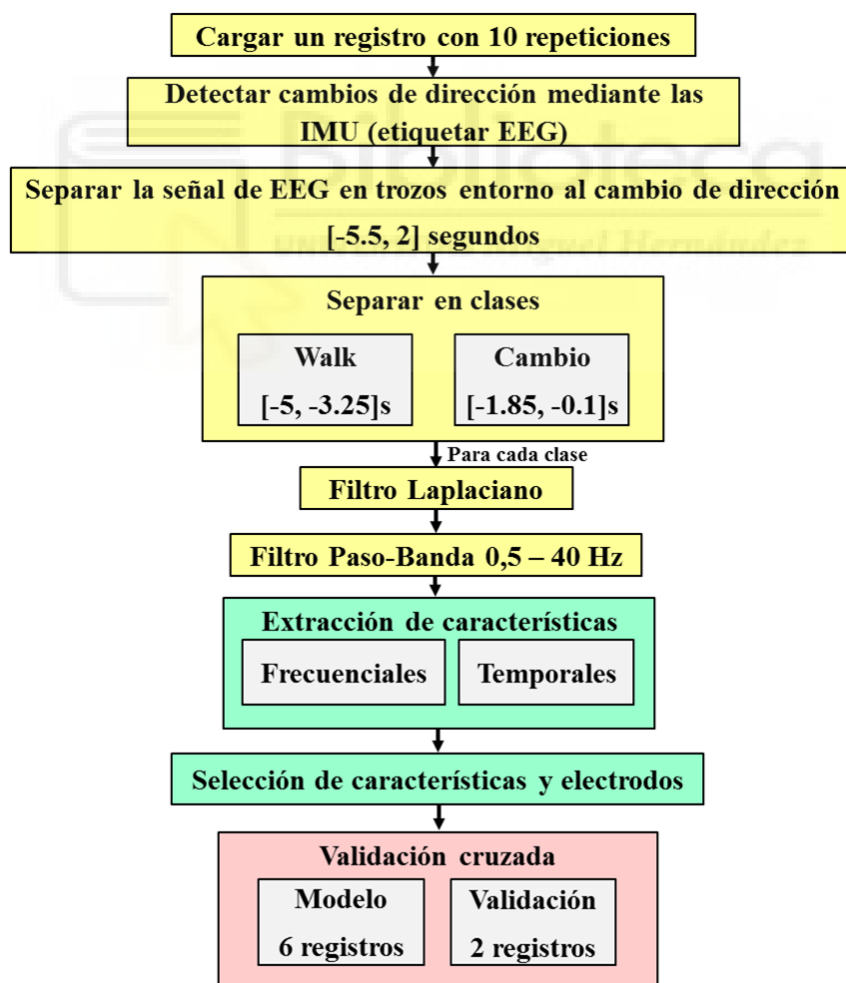
Generalmente, este tipo de clasificación permite obtener mejores resultados porque las características se extraen en zonas donde se sabe que se está produciendo la tarea de la clase a la que pertenecen.

### 3.6.2. Análisis Pseudo-Online

El análisis pseudo-online es un método que se acerca más a la realidad, ya que simula el funcionamiento del sistema a tiempo real, a pesar de que se lleva a cabo después de la prueba. Para ello, utiliza un conjunto de datos para crear el modelo y un registro completo para testear, donde una ventana deslizante va recorriendo la señal, procesándola, caracterizándola y clasificando en cada trozo.

La principal diferencia que presenta el análisis pseudo-online respecto al online es que la información ya está toda registrada previamente. Además, en pseudo-online se puede obtener los parámetros de valoración del clasificador, del mismo modo que ocurría en el clasificador offline.

En este tipo de análisis pseudo-online, se realiza un procesamiento diferente de la información que forma parte del conjunto de entrenamiento para que sea similar al procesado que sufren las señales de test en cada ventana. Esto es principalmente porque los filtros no afectan igual a ventanas pequeñas que a ventanas de mayor tamaño y, a tiempo real, no se puede coger información que todavía no se ha obtenido.



*Figura 40. Esquema del procedimiento seguido para llevar a cabo un análisis pseudo-online de las señales EEG.*

Por tanto, se ha creado un esquema del procedimiento seguido para tratar y caracterizar las señales que componen la matriz de características del modelo. Se trata de un proceso muy similar al utilizado en el análisis offline, que se basa en los mismos conceptos, pero más reducido y en un orden distinto.

Tal y como se observa en el esquema de la Figura 40, los tres primeros pasos del proceso son exactamente iguales que los pasos seguidos para procesar la información offline. Esto quiere decir que se cargan los 6 registros utilizados para generar el modelo, se detectan los cambios de dirección mediante las señales de las IMU y se forman trozos de señal en ventanas de -5.5 y 2 segundos entorno al cambio detectado.

El siguiente paso es diferente al offline, dado que en este caso se opta por separar en ventanas de clases antes, para aplicar los filtros a las ventanas por separado. La elección de esta opción se debe a que, a la hora de filtrar las señales a tiempo real, las ventanas que se filtran son de ese tamaño y se quiere evitar que los filtros tengan consecuencias posteriores en la variabilidad de las características.

Por tanto, la ventana de señal entorno al cambio de dirección se subdivide nuevamente en dos ventanas de 1.75 segundos: la ventana de la clase walk ([-5, -3.25]s) y la ventana de la clase cambio ([-1.85, -0.1]s), diferente que en offline. Esta modificación respecto al análisis offline se debe a que se intenta ajustar la ventana más cerca del cambio.

Seguidamente, se aplican los filtros Laplaciano y paso-banda, de 0.5Hz a 40Hz, a las señales de cada ventana. En el Apartado 3.3.4.2., se comenta que el filtro paso-banda Butterworth produce una oscilación en el tramo inicial de la señal. Por este motivo, la señal de la ventana filtrada con el filtro Laplaciano se alarga añadiendo al principio de la señal un vector de unos multiplicado por el primer valor de la señal original, creando una señal de 9.25 segundos. Una vez se ha aplicado el filtro paso-banda, se corta el trozo inicial y se selecciona únicamente el trozo de la ventana original, sin oscilaciones y correctamente filtrado.

Tras el proceso de filtrado, se extraen las características tanto frecuenciales, como temporales de las señales de todos los electrodos filtradas pertenecientes a las dos clases, formando un vector largo para cada repetición de la tarea. Como el número de características es muy elevado para el proceso y no todas son efectivas para diferenciar entre clases, se seleccionan las características más destacadas.

En el Apartado 3.4. se habían elegido una serie de características y electrodos específicamente para cada sujeto, a partir de los 8 registros. Sin embargo, para que el análisis sea lo más realista posible, se hace vuelve a hacer una nueva selección de características y electrodos, pero sólo con la información de los 6 registros del modelo.

Una vez conformado el modelo del clasificador con las características elegidas, se debe testear con los 2 registros restantes. Para ello, se establece una ventana deslizante con un ancho de 1.75 segundos y un avance de 0.5 segundos. Cada vez que la ventana avanza por la señal de uno de los registros de test, realiza todo el proceso explicado previamente a dicho trozo hasta obtener el vector con las características seleccionadas en la formación

del modelo. Entonces, se clasifica el vector en una clase u otra y, al finalizar el análisis, se obtiene un vector de predicciones.

A partir del vector de predicciones, se valora el análisis mediante el cálculo del porcentaje de cambios detectados correctamente y del porcentaje de cambios detectados erróneamente durante la marcha. Para ello, se recurre a la información de las IMUs pertenecientes al registro de test y siguiendo el procedimiento explicado en el Apartado 3.3.2., se detectan los cambios de dirección en las IMUs localizadas en los muslos.

Para evitar falsas detecciones debido a señales ruidosas de las IMUs y que el punto detectado sea muy preciso, se realiza una comparación entre los instantes detectados por la IMUs del muslo derecho e izquierdo. En caso de que la diferencia entre un instante y otro sea similar, se elige la que se produce después, para asegurar que el potencial se encuentre en la señal. Por el contrario, si la diferencia es mayor de 2 segundos, se elige aquel punto que se encuentre cerca de los 8 segundos de la repetición de la tarea, instante a partir del cual se realiza generalmente el cambio en todas las repeticiones.

Cuando el punto de cambio está establecido, se seleccionan los valores del vector de predicción correspondientes a las ventanas que contienen 1.75 segundos previos al instante de cambio, tiempo en el cual debería detectarse el cambio de dirección. Si se encuentra una detección de cambio en dicho período, se cuenta como acierto. Dado que el registro cuenta con 10 repeticiones, deberían detectarse 10 cambios de dirección. Por tanto, tras analizar las 10 repeticiones se realiza un promedio y obteniéndose así el porcentaje de acierto.

Asimismo, se calcula el porcentaje de FP por minuto de cambio detectados durante la marcha del sujeto.

$$FP/min = \frac{n^{\circ} \text{detecciones clase cambio} \cdot 60 \text{ segundos}}{\text{tiempo marcha}} \quad (29)$$

Para ello, se seleccionan las predicciones obtenidas desde el inicio de la tarea hasta 1.75 segundos antes del instante de cambio y se cuenta el número de veces que se detectan cambios. Además, se almacena el tiempo de duración de los tramos de marcha en cada repetición y se calculan los FP por minuto de cada repetición. Al final de las 10 repeticiones, también se calcula el promedio.

### **3.7. Usuarios**

En el proceso experimental participaron cuatro sujetos con edades comprendidas entre 23 y 30 años ( $27 \pm 3,6$ ). Cada sujeto realizó al menos 2 días de sesiones, con 8 registros de señales cada día. Excepcionalmente, el sujeto S2 participó en 3 sesiones.

Todos los sujetos dieron su consentimiento de acuerdo a la declaración de Helsinki y el Comité de Ética de la Oficina de Investigación Responsable (OIR) de la Universidad Miguel Hernández de Elche aprobaron el estudio.

A continuación, se muestra una tabla con los nombres de los sujetos con los que se han almacenado los datos procesados y con los que se les va a nombrar de ahora en adelante a lo largo de este trabajo.

*Tabla 9. Tabla con los sujetos analizados y sus respectivas sesiones.*

Sujetos									
Sujeto	S1		S2			S3		S4	
Sesión	S1.1	S1.2	S2.1	S2.2	S2.3	S3.1	S3.2	S4.1	S4.2

Durante el desarrollo del procesamiento de las señales, se han tenido que descartar algunos registros y sesiones de sujetos debido a la baja calidad de la señal y la gran cantidad de ruido que poseían, ya que hacían imposible la obtención de parámetros lógicos y buenos resultados.

La sesión descartada es S3.1 y también se ha descartado el primer registro de la sesión S4.2, dado que parece tratarse de una prueba para comprobar el funcionamiento del sistema, que sólo contiene 2 cambios de dirección, y no un registro completo.



## Capítulo 4. Resultados y discusión

En este apartado, se exponen los resultados obtenidos a lo largo de todo el proceso implementado en el trabajo. Durante el desarrollo, no sólo se ha realizado un análisis con los clasificadores de los distintos métodos, sino que también se han llevado a cabo una serie de selecciones de electrodos, características y también descartes de vectores correspondientes a ciertas repeticiones de la tarea.

Primero, se expone de forma gráfica cuáles son los electrodos seleccionados para cada una de las sesiones de los 4 sujetos, así como las características más relevantes en la diferenciación de clases en cada caso. No sólo se exponen los electrodos seleccionados de forma automática, también se eligen algunas configuraciones de electrodos de forma manual para poder realizar una comparación de los resultados entre las diferentes sesiones de pruebas y sujetos.

Seguidamente, se manifiestan los resultados obtenidos del análisis offline con el clasificador KKN para cada uno de los vectores explicados en el Apartado 3.5.3. Además, se presentan los resultados obtenidos con el clasificador para la selección manual de electrodos. Después de este primer análisis, se muestran los resultados del análisis pseudo-online con los vectores que mejores resultados proporcionan en el análisis offline.

### 4.1. Electrodos y características seleccionadas

En este apartado, se presentan los resultados de la selección de electrodos y características, tanto automáticamente según el método del Apartado 3.5., como manualmente, para todos los usuarios.

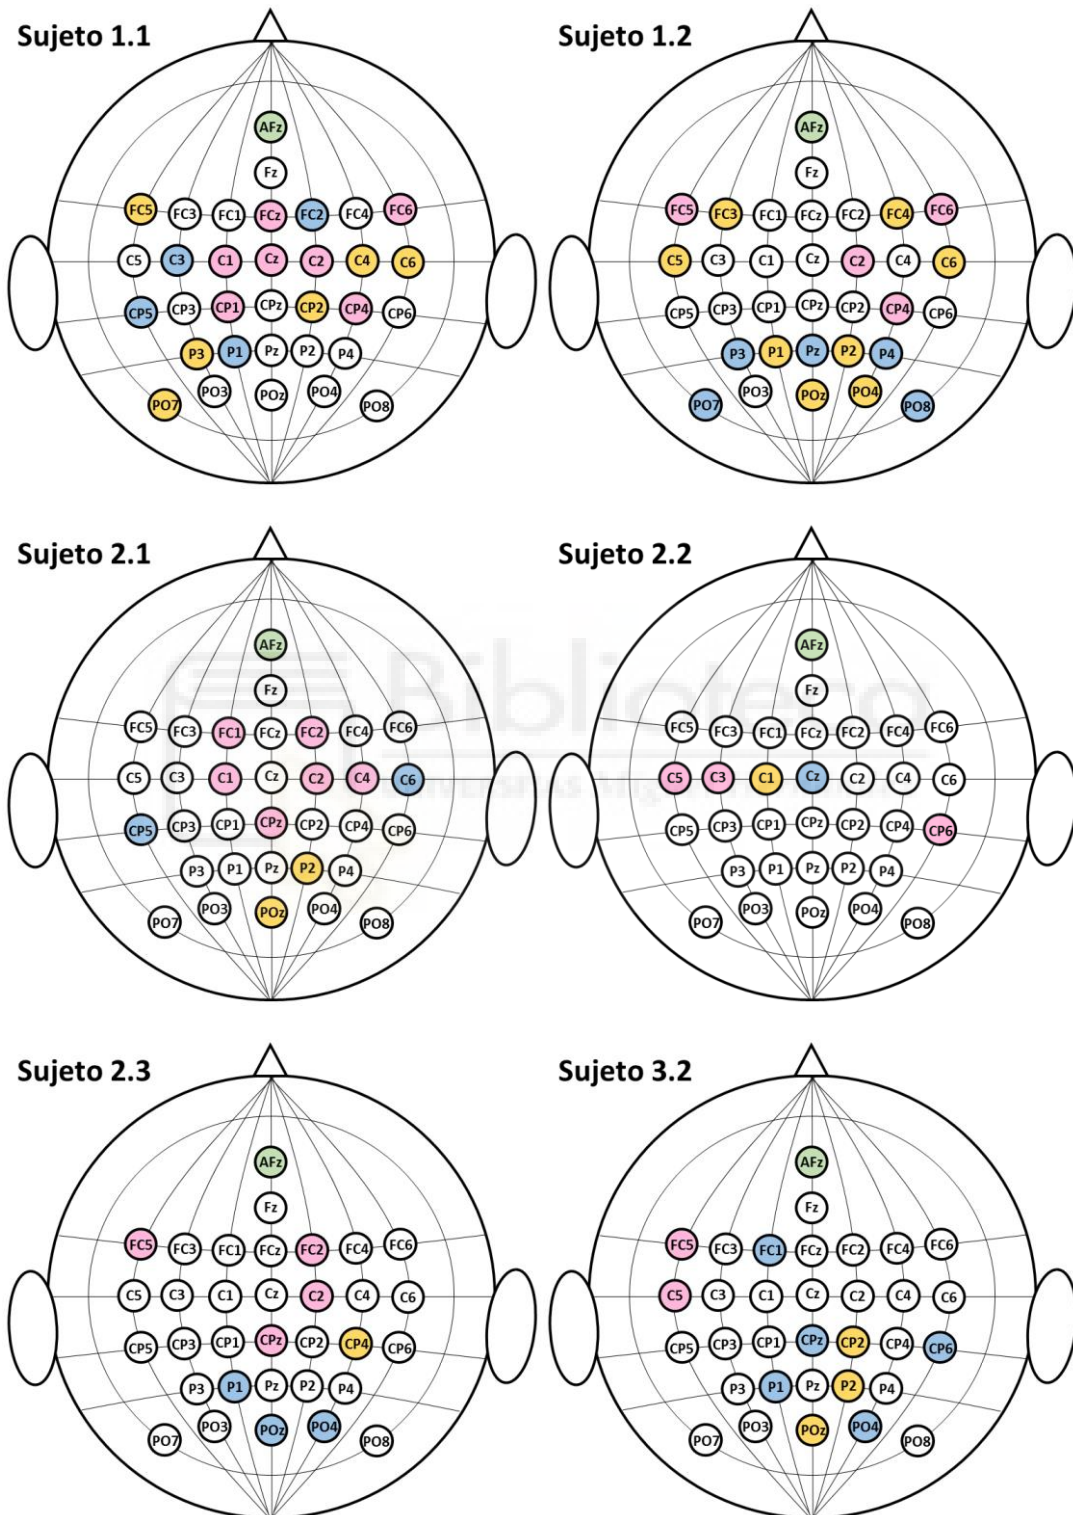
#### 4.1.1. Selección automática

En el Apartado 3.5. se explica el procedimiento seguido para seleccionar de forma automática los electrodos y características con información más relevante para la creación del modelo a partir de un análisis estadístico de los valores de las diferentes características. A continuación, se muestra gráficamente la distribución de los electrodos elegidos en el casco para las distintas sesiones de los usuarios.

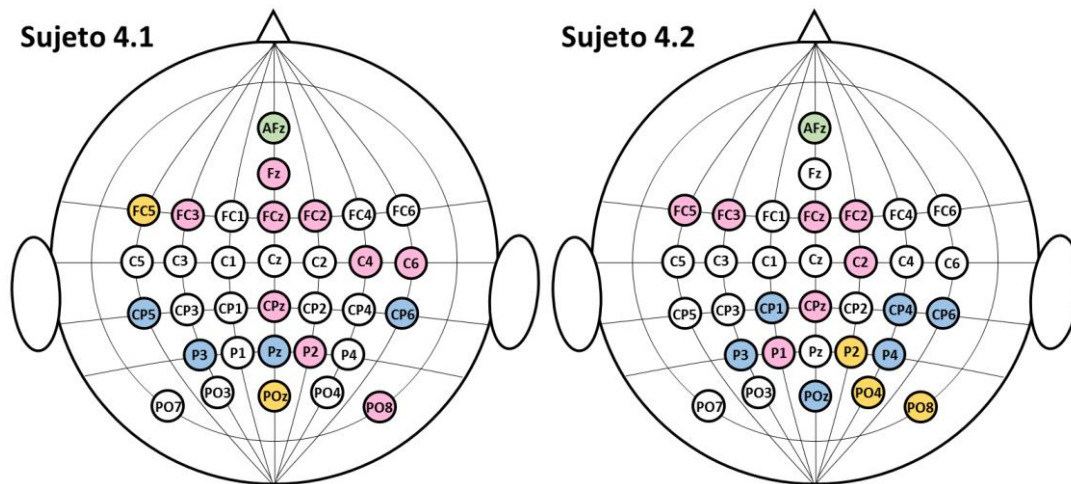
Tal y como se explica en el apartado correspondiente a la selección de características y electrodos, algunos de los electrodos sólo aportan información válida en un tipo de dominio, es decir, exclusivamente mediante un tipo de características elegidas automáticamente, o bien frecuenciales, o bien temporales. Mientras que otros aportan información relevante en ambos tipos de características.

Por este motivo, en los cascos de la Figura 41 los electrodos seleccionados están marcados con tres colores diferentes. En azul, los electrodos seleccionados con características frecuenciales elegidas; en rosa, los electrodos seleccionados con las características

temporales elegidas y, en amarillo, los electrodos seleccionados para aportar información con las características frecuenciales y temporales elegidas por el método estadístico.







**Figura 41.** Electrodo seleccionados mediante el proceso de selección automática para las sesiones de los sujetos. En azul, los electrodo seleccionados para características frecuenciales; en rosa, los electrodo seleccionados para características temporales; en amarillo, los electrodo seleccionados para características frecuenciales y temporales.

En la figura anterior, se puede observar cómo los electrodo seleccionados no son los mismos entre sujetos, e incluso entre diferentes sesiones de un mismo usuario son diferentes. Sin embargo, si se puede apreciar como existen algunos patrones comunes en todos ellos.

Los electrodo seleccionados para características frecuenciales tienden a distribuirse en el lóbulo occipital de cerebro, donde se llevan a cabo las funciones de control de movimiento y los pensamientos. Además, algunos electrodo elegidos para este tipo de características están localizados en la zona motora.

Por otro lado, los electrodo temporales seleccionados son mucho más numerosos que los electrodo de características frecuenciales. En este caso, la mayoría de ellos están distribuidos alrededor al área motora, especialmente en FC5 y C2, que han sido seleccionados en la mayoría de los casos. Asimismo, algunos electrodo de este tipo de características están situados en el lóbulo occipital como, por ejemplo, P2 que también es elegido en la mayoría de las sesiones. Igualmente, se escogen ciertos electrodo de la zona central de la cabeza, siendo CPz y POz electrodo elegidos en diversas ocasiones.

Adicionalmente, existen electrodo que no sólo han sido seleccionados para aportar un tipo de características, sino ambos. Esta selección también es muy diversa entre usuarios, pero al igual que ocurría en los electrodo anteriores, aparecen algunos que se repiten en gran cantidad de casos, como son los electrodo POz y P2.

En esta sección, además de seleccionar los electrodo más importantes en la detección de la intención del cambio de dirección durante la marcha, se seleccionan aquellas características cuyos valores tengan mayor capacidad discriminativa entre las clases walk y cambio dentro del modelo. En la Tabla 10, se presentan las características de ambos tipos, seleccionadas para cada sujeto, en cada una de sus sesiones.

Tabla 10. Características seleccionadas automáticamente para las sesiones de cada sujeto.

Tipo	Característica	Sujeto							
		S1.1	S1.2	S2.1	S2.2	S2.3	S3.2	S4.1	S4.2
<b>Frecuenciales</b>	Relación Delta-Mu	o	o	o	o	o	o	o	
	Relación Mu-Beta		o		o	o	o	o	o
	Relación Delta-Beta	o	o	o	o		o	o	
	Máximo normalizado banda Delta	o	o	o	o	o	o		o
	Máximo normalizado banda Mu	o		o	o		o	o	o
	Máximo normalizado banda Beta			o	o	o		o	o
	Sumatorio normalizado banda Delta				o	o			o
	Sumatorio normalizado banda Mu	o	o		o				
	Sumatorio normalizado banda Beta	o	o	o		o		o	
<b>Temporales</b>	Desv. Típica señal EEG	o	o	o	o	o	o		o
	Desv. Típica transformada FFT señal EEG	o	o	o		o	o	o	o
	Desv. Típica transformada Hilbert señal EEG	o	o	o	o	o	o	o	o
	Valor Absoluto Relativo	o	o	o	o			o	o
	Energía	o	o		o	o	o	o	o
	Entropía	o	o				o	o	o
	Máximo Yule-Walker	o			o	o		o	o
	Parámetro Weibull 1	o	o	o	o	o	o	o	o
	Parámetro Weibull 2	o	o	o		o		o	o
	Actividad	o	o	o	o	o	o	o	o
	Mobilidad	o		o	o		o	o	o
	Complejidad	o	o		o	o	o	o	o

En la tabla anterior, se observa como ninguno de los sujetos selecciona todas las características completas. Algunos como S1.1 o S4.2 si seleccionan todas las características temporales, pero ninguno de logra elegir todas las características frecuenciales.

En referencia a las características frecuenciales, ninguna de ellas es elegida por todos los sujetos y existe una gran diversidad en la selección. Sin embargo, las características Relación Delta-Mu y Mu-Beta, así como los Máximos Normalizados de Delta y Mu, son las más elegidas por la mayoría de las sesiones para este tipo de caracterización. Esto podría ser indicativo una mayor variabilidad en cuanto a las potencias de las señales generadas por los distintos usuarios.

Por el contrario, entre las características temporales si existen algunas que son elegidas por todas las sesiones de los sujetos, como son la Desviación Típica de la transformada de Hilbert de la señal EEG, el Parámetros de Weibull 1 y la Actividad. Asimismo, otras características como la Desviación Típica de la señal EEG y de la señal EEG de la transformada FFT, la Energía y la Complejidad también se repiten en la mayoría de los casos.

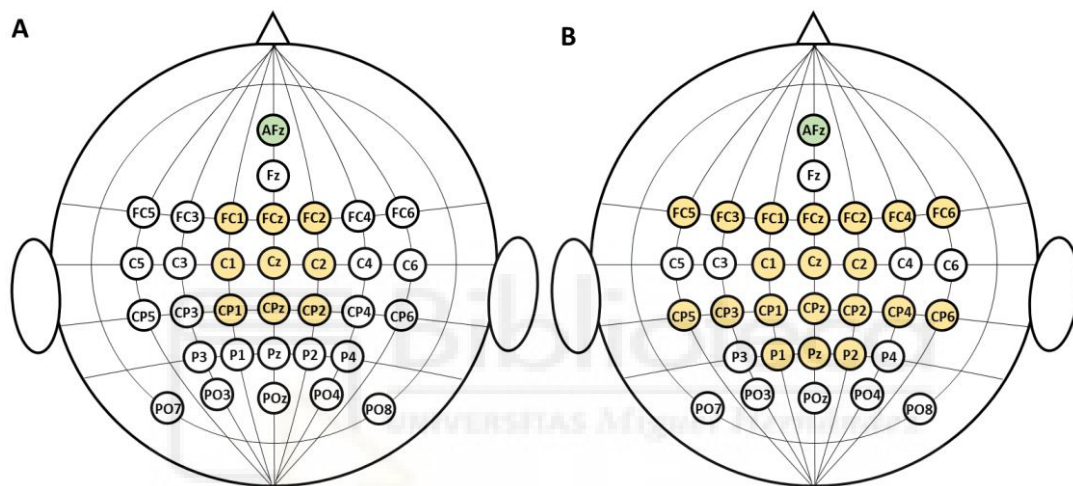
Por tanto, estas selecciones podrían denotar la importancia de las características temporales basadas en la forma y parámetros estadísticos en la diferenciabilidad entre

clases, frente a las características frecuenciales basadas en la potencia, cuya variabilidad se hace más presente tanto entre sujetos, como entre las sesiones de un mismo sujeto.

#### 4.1.2. Selección manual

Adicionalmente, se realiza otra selección de electrodos manual basada en las regiones del cerebro que generalmente concentran mayor cantidad de potenciales motores, con el objetivo de establecer una comparativa entre los resultados de cada sesión y, también, entre sujetos.

Con el fin de no seleccionar todos los electrodos a la vez, se decide crear dos tipos de disposiciones que abarquen distintas áreas cerebrales: zona motora (A en la Figura 42) y zona motora más región premotora y occipital (B en la Figura 42).



**Figura 42.** Electrodos elegidos de forma manual. A: electrodos en el área motora; B: electrodos en el área motora y regiones premotoras y occipital.

En estos dos casos, no se realiza una selección de características ya que es muy probable que, al igual que ocurría en la selección automática, las características seleccionadas entre sesiones sean muy diversas. En consecuencia, el modelo podría potenciar características con baja diferenciabilidad en algunos casos, obteniéndose resultados de clasificación erróneos. Por este motivo, el análisis con estos grupos de electrodos se realiza con todas las características, para los tres tipos (frecuenciales, temporales, combinación de frecuenciales y temporales), utilizando un vector largo.

## **4.2. Resultados del Análisis Offline**

A lo largo de la memoria, se han desarrollado los diferentes métodos para la caracterización de las señales y creación de múltiples modelos de entrenamiento del clasificador capaces de diferenciar la intención para cambiar de dirección frente a la marcha de los sujetos.

El análisis offline utilizando los distintos modelos formados a partir de los vectores explicados en el Apartado 3.5.2. es muy efectivo para conocer cuáles son los métodos que mejores resultados ofrecen. Aquellos procedimientos que mejor funcionen en la distinción de las clases por parte del clasificador adquirirán mayor importancia en el análisis pseudo-online y, en un futuro, online.

A la hora de valorar el método, se calculan 5 parámetros basados en la clasificación realizada por el clasificador: media de acierto total (Acc), Verdaderos Positivos de la clase walk (TP walk), Verdaderos Positivos de la clase cambio (TP cambio), Falsos Positivos de la clase walk (FP walk) y Falsos Positivos de la clase cambio (FP cambio) (Ecuaciones 24-28, respectivamente).


Los valores de los parámetros anteriores obtenidos del análisis offline para cada usuario son el resultado de la media de los valores resultantes de cada una de las iteraciones del proceso de validación cruzada. Por ello, todos los resultados poseen el valor medio de las iteraciones más la desviación típica.

La presentación de los resultados de este tipo de análisis se realiza en dos partes. Por un lado, los diferentes casos con todos los electrodos, selección automática de electrodos y reducción del modelo. Por otro lado, se añaden los resultados de un análisis offline seleccionando manualmente ciertos electrodos de interés para comparar a los usuarios.


### **4.2.1. Análisis offline con selección automática de electrodos**

Sucesivamente, se muestran los resultados obtenidos en cada uno de los casos planteados, donde se incluye una selección automática de electrodos. Esto quiere decir que se realiza un análisis para cada uno de los 7 tipos de vectores del Apartado 3.5.2. para tres grupos de características: características exclusivamente frecuenciales, características exclusivamente temporales y características tanto frecuenciales, como temporales a la vez.


Primero, se representan gráficamente los resultados de todos los usuarios en cada uno de los casos planteados.



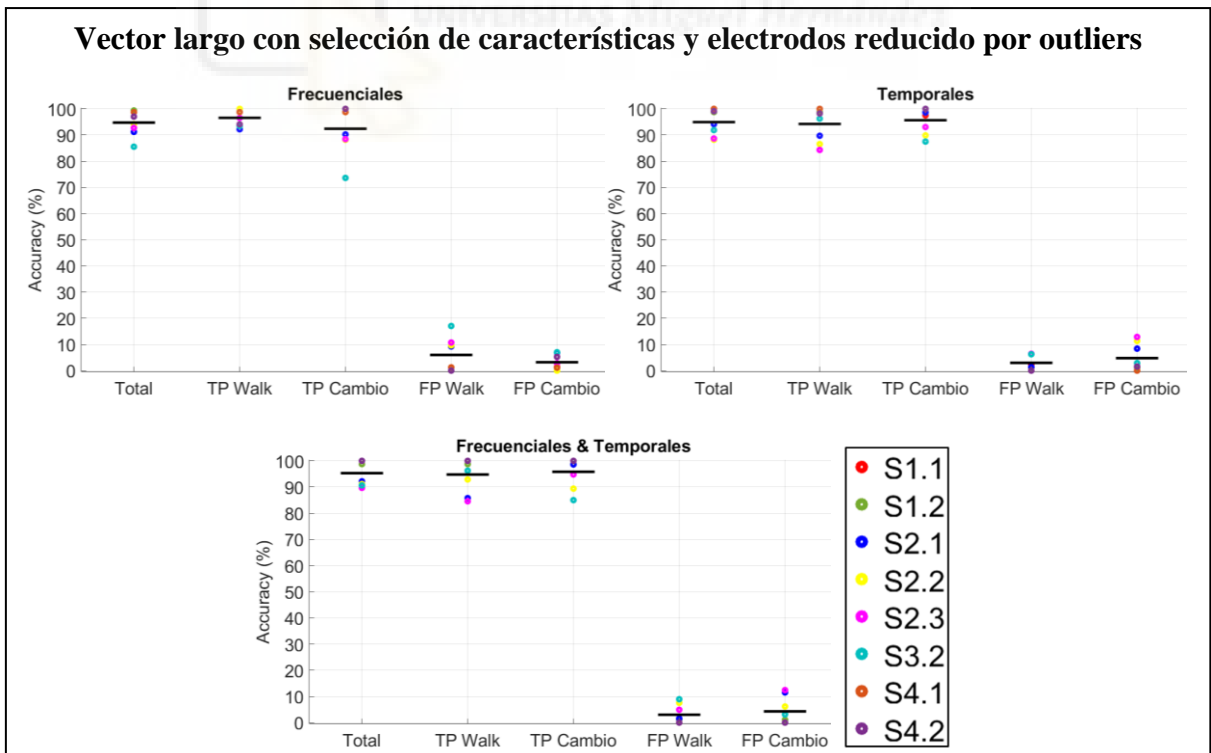
**Figura 43.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y electrodos. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



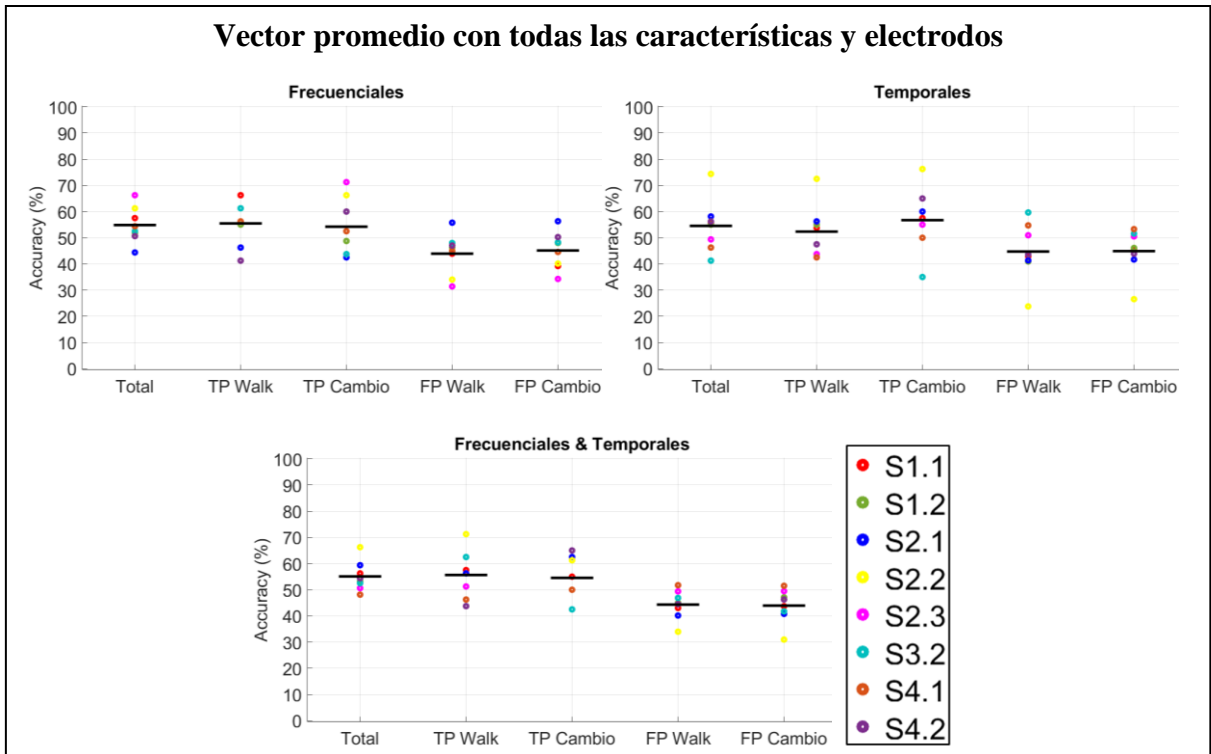
**Figura 44.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y electrodos reducido por potencial ERD. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



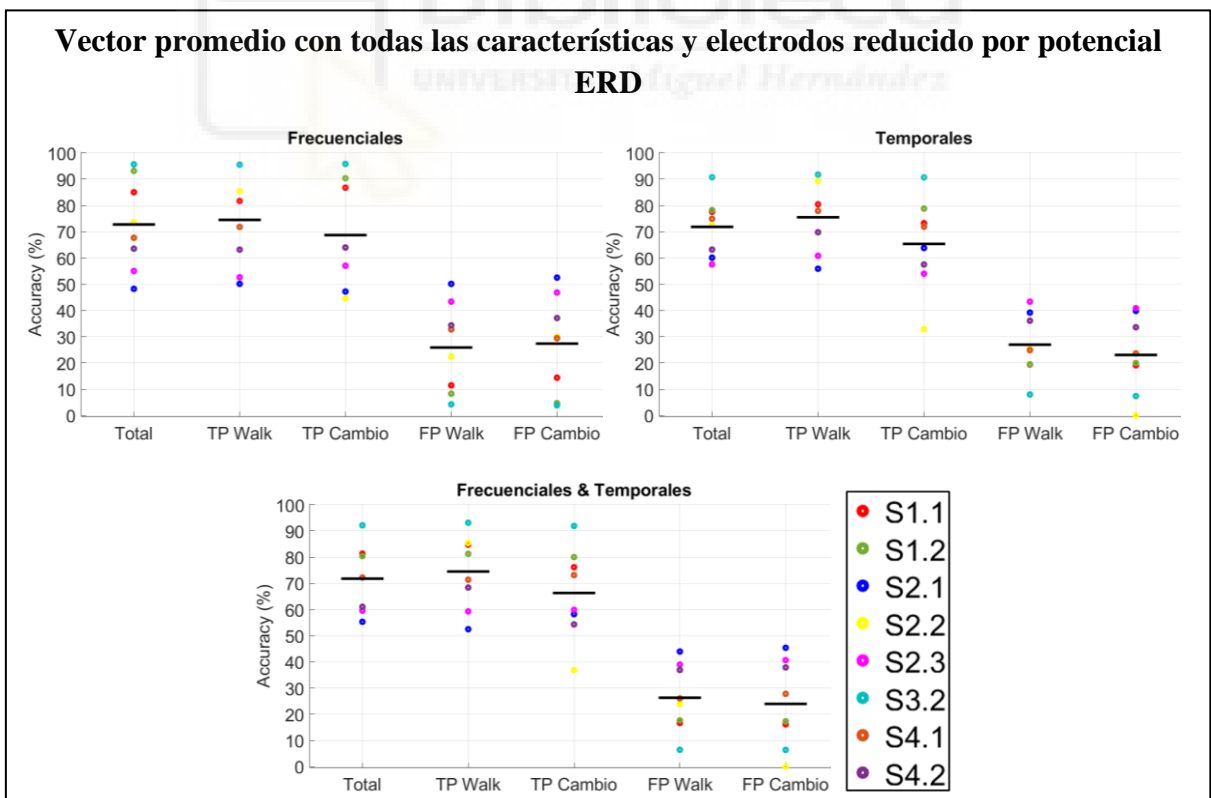
**Figura 45.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con selección de características y electrodos. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



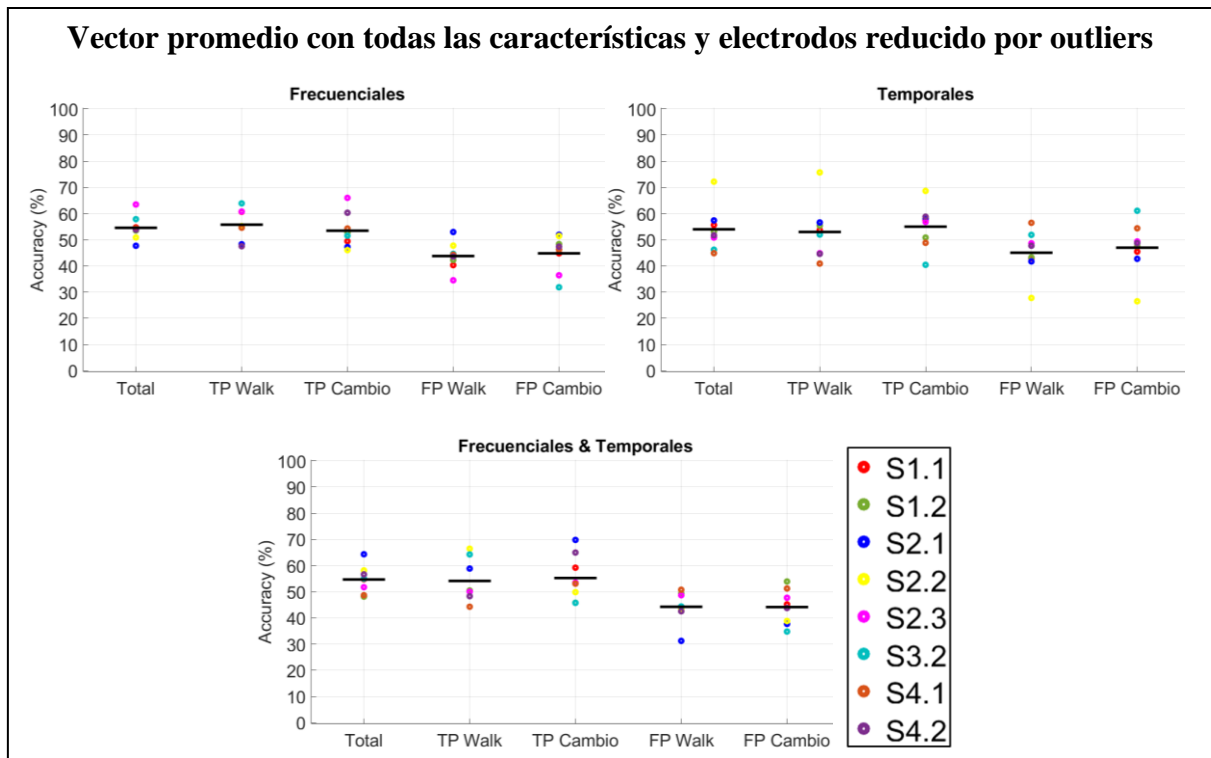
**Figura 46.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con selección de características y electrodos reducido por outliers. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



**Figura 47.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector promedio con todas las características y electrodos. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



**Figura 48.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector promedio con todas las características y electrodos reducido por potencial ERD. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



**Figura 49.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector promedio con todas las características y electrodos reducido por outliers. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.

Generalmente, en base a la información aportada por las gráficas de resultados, se observa como en la gran mayoría de las gráficas, el porcentaje de TP de la clase walk y el de los TP de la clase cambio son muy similares entre ellos. Este hecho tiene gran relevancia a la hora de hablar sobre los resultados, ya que los porcentajes de aciertos totales no están falseados como consecuencia de una gran cantidad de ciertos de una clase y muy pocos por parte de la otra clase.

Uno de los factores que más llama la atención de las gráficas es que a simple vista se puede observar una gran diferencia entre los resultados obtenidos con los modelos creados con vector largo y los creados con el vector promedio. Los resultados obtenidos con los distintos casos donde se utiliza el vector largo oscilan alrededor del 90%, mientras que los casos con modelos formados por vector promedio de las señales de todos los electrodos obtienen resultados alrededor de 54%, excepto en algunos casos que alcanza el 72,8%.

El principal motivo de esta disparidad de resultados sería el hecho de que, al promediar las señales de distintos electrodos, se estaría perdiendo información relevante acerca de la intención del cambio de dirección. Por tanto, esto podría justificar la necesidad de extraer las características de cada una de las señales por separado, a pesar de que la matriz resultante contenga mayor cantidad de datos.

Dentro de los métodos seguidos con el vector largo, se encuentra la selección de características y electrodos. Tal y como se observa en las gráficas, al llevar a cabo el



proceso de selección, la precisión de acierto es muy similar a la obtenida con todas las características y electrodos, encontrándose ambas entorno al 94%.

Sin embargo, si se encuentra una diferencia entre ambos casos y es que, al seleccionar las características y electrodos, se reduce la variabilidad de aciertos correctos entre las diferentes sesiones entorno al valor medio. Esto quiere que muchas de las sesiones si mejoran sus resultados al realizarse la selección.

Además de la selección de características, también se eliminan los vectores que no aportan información relevante en el modelo mediante dos tipos: por potencial ERD y por outliers. Cuando se utiliza el vector largo, en ambos casos, los resultados con reducción del modelo son muy similares a los obtenidos sin reducir el modelo, tanto en el porcentaje medio de acierto, como en el porcentaje individual de las sesiones de los sujetos.

Por el contrario, cuando se utiliza el vector promedio, si se puede observar cómo al seguir el método de reducción por potencial ERD, el porcentaje de acierto aumenta hasta el 72,8%. No obstante, también aumenta la variabilidad de entre los aciertos de las diferentes sesiones. Esto quiere decir que sólo algunos usuarios mejoran en gran medida los resultados, mientras que el resto se mantienen igual.

En lo referente a los sujetos, se puede observar cómo las sesiones de los sujetos S1.1 (rojo), S1.2. (verde) y S4.1. (naranja) ofrecen los mejores resultados en muchos de los casos. En cambio, las sesiones S2.1 (magenta) y S2.3 (azul oscuro) alcanzan los porcentajes de acierto más bajos en la mayoría de los casos.

Seguidamente, las Tablas 11-17 recogen los valores medios de cada uno de los casos. Así, es posible comentar los resultados generales de los métodos en cada uno de los tipos de características.

*Tabla 11. Porcentajes medios del análisis offline para el vector largo con todos los electrodos y características.*

<b>Vector largo todos electrodos y características</b>			
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	95,9 ± 4,1	89,8 ± 6,1	89,8 ± 6,1
<b>TP walk</b>	92,8 ± 7,7	88,4 ± 9,0	88,4 ± 9,0
<b>TP cambio</b>	98,9 ± 1,0	91,3 ± 5,0	91,3 ± 5,0
<b>FP walk</b>	1,2 ± 1,2	7,9 ± 4,2	7,9 ± 4,2
<b>FP cambio</b>	5,8 ± 6,1	9,5 ± 7,1	9,5 ± 7,1

**Tabla 12.** Porcentajes medios del análisis offline para el vector largo con todos los electrodos y características reducido por potencial ERD.

	<b>Vector largo todos electrodos y características reducido por pot. ERD</b>		
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	95,9 ± 4,3	89,9 ± 7,4	89,9 ± 7,4
<b>TP walk</b>	93,0 ± 8,1	89,4 ± 9,5	89,4 ± 9,5
<b>TP cambio</b>	99,1 ± 1,1	89,0 ± 12,6	89,0 ± 12,6
<b>FP walk</b>	0,9 ± 1,3	7,6 ± 5,0	7,6 ± 5,0
<b>FP cambio</b>	6,6 ± 6,4	9,9 ± 8,8	9,9 ± 8,8

**Tabla 13.** Porcentajes medios del análisis offline para el vector largo con selección de electrodos y características.

	<b>Vector largo selección de electrodos y características</b>		
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	92,3 ± 6,3	94,1 ± 5,2	94,1 ± 5,2
<b>TP walk</b>	93,9 ± 5,4	94,2 ± 6,1	94,2 ± 6,1
<b>TP cambio</b>	90,8 ± 8,9	93,9 ± 5,5	93,9 ± 5,5
<b>FP walk</b>	7,9 ± 7,2	4,6 ± 3,7	4,6 ± 3,7
<b>FP cambio</b>	5,5 ± 4,7	4,9 ± 5,2	4,9 ± 5,2

**Tabla 14.** Porcentajes medios del análisis offline para el vector largo con selección de electrodos y características reducido por outliers.

	<b>Vector largo selección de electrodos y características reducido por outliers</b>		
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	94,8 ± 4,9	94,9 ± 4,9	95,3 ± 4,8
<b>TP walk</b>	96,6 ± 2,9	94,2 ± 6,4	94,8 ± 6,4
<b>TP cambio</b>	92,4 ± 9,3	95,7 ± 4,9	95,8 ± 5,7
<b>FP walk</b>	5,9 ± 6,5	2,9 ± 2,9	3,0 ± 3,6
<b>FP cambio</b>	3,2 ± 2,8	4,8 ± 5,3	4,3 ± 5,2

**Tabla 15.** Porcentajes medios del análisis offline para el vector promedio con todos los electrodos y características.

	<b>Vector promedio todos electrodos y características</b>		
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	54,8 ± 6,8	54,5 ± 9,9	55,1 ± 5,7
<b>TP walk</b>	55,5 ± 8,2	52,3 ± 9,6	55,6 ± 8,8
<b>TP cambio</b>	54,2 ± 10,5	56,7 ± 11,9	54,5 ± 7,8
<b>FP walk</b>	43,9 ± 7,8	44,7 ± 10,9	44,3 ± 5,5
<b>FP cambio</b>	45,1 ± 7,1	44,9 ± 8,4	43,9 ± 6,4

**Tabla 16.** Porcentajes medios del análisis offline para el vector promedio con todos los electrodos y características reducido por potencial ERD.

<b>Vector promedio todos electrodos y características reducido por pot. ERD</b>			
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	72,8 ± 17,4	71,9 ± 11,1	71,8 ± 12,6
<b>TP walk</b>	74,5 ± 17,9	75,5 ± 12,7	74,5 ± 14,0
<b>TP cambio</b>	68,7 ± 19,8	65,4 ± 17,6	66,3 ± 17,4
<b>FP walk</b>	25,9 ± 16,9	26,9 ± 11,8	26,3 ± 12,8
<b>FP cambio</b>	27,4 ± 18,3	23,1 ± 14,7	23,9 ± 16,6

**Tabla 17.** Porcentajes medios del análisis offline para el vector promedio con todos los electrodos y características reducido por outliers.

<b>Vector promedio todos electrodos y características reducido por outliers</b>			
	<b>F (%)</b>	<b>T (%)</b>	<b>F&amp;T (%)</b>
<b>Accuracy</b>	54,6 ± 4,7	53,9 ± 8,5	54,7 ± 5,3
<b>TP walk</b>	55,8 ± 5,9	52,9 ± 10,8	54,1 ± 8,0
<b>TP cambio</b>	53,5 ± 6,8	55,0 ± 8,4	55,2 ± 8,8
<b>FP walk</b>	43,8 ± 5,4	45,0 ± 8,6	44,3 ± 6,1
<b>FP cambio</b>	44,8 ± 7,1	46,9 ± 10,0	44,2 ± 6,7

Las tablas anteriores denotan cómo el análisis del modelo creado mediante el vector largo con todos los electrodos y características de tipo frecuencial es el que mejores resultados proporciona, con un  $95,9 \pm 4,1$  de acierto, junto con el mismo modelo, pero reducido por potencial ERD, que obtiene un  $95,9 \pm 4,3$ . Ambos están seguidos por el modelo reducido por outliers creado con el vector largo con selección de electrodos y características combinadas de tipo frecuencial y temporal con un  $95,3 \pm 4,8$  de aciertos.

A pesar de que los resultados son muy similares entre los tres modelos, los TP de ambas clases del modelo con características temporales y frecuenciales de la Tabla 14 están más compensados ( $94,8 \pm 6,4$  para la clase walk y  $95,8 \pm 5,7$  para la clase cambio). En cambio, los TP de las clases en el modelo de características temporales de la Tabla 11 están un

poco más desequilibrados ( $92,8 \pm 7,7$  para la clase walk y  $98,9 \pm 1,0$  para la clase cambio). No obstante, continúan siendo grandes resultados para este tipo de análisis.

Por otro lado, los porcentajes de acierto de las tablas anteriores indican como existe una tendencia general donde los modelos que contienen vectores con características de tipo temporal y los que combinan temporales con frecuenciales, alcanzan resultados muy similares entre ellos. Esto podría hacer referencia a que las características basadas en la forma de la señal tienen mayor peso a la hora de clasificar que las basadas en la potencia, significando así que, en algunos casos, la diferencia de potencial entre bandas no se hace tan notable para distinguir el potencial ERD como podrían serlo determinados parámetros estadísticos.

A partir de las tablas, es posible conocer cómo se modifican los porcentajes de acierto cuando se lleva a cabo el proceso de selección de electrodos y características. Esta selección mejora los resultados cuando las características son de tipo temporal y la combinación de características temporales y frecuenciales, pasando de un  $89,8 \pm 6,1$  a un  $94,1 \pm 5,2$  por ciento de aciertos.

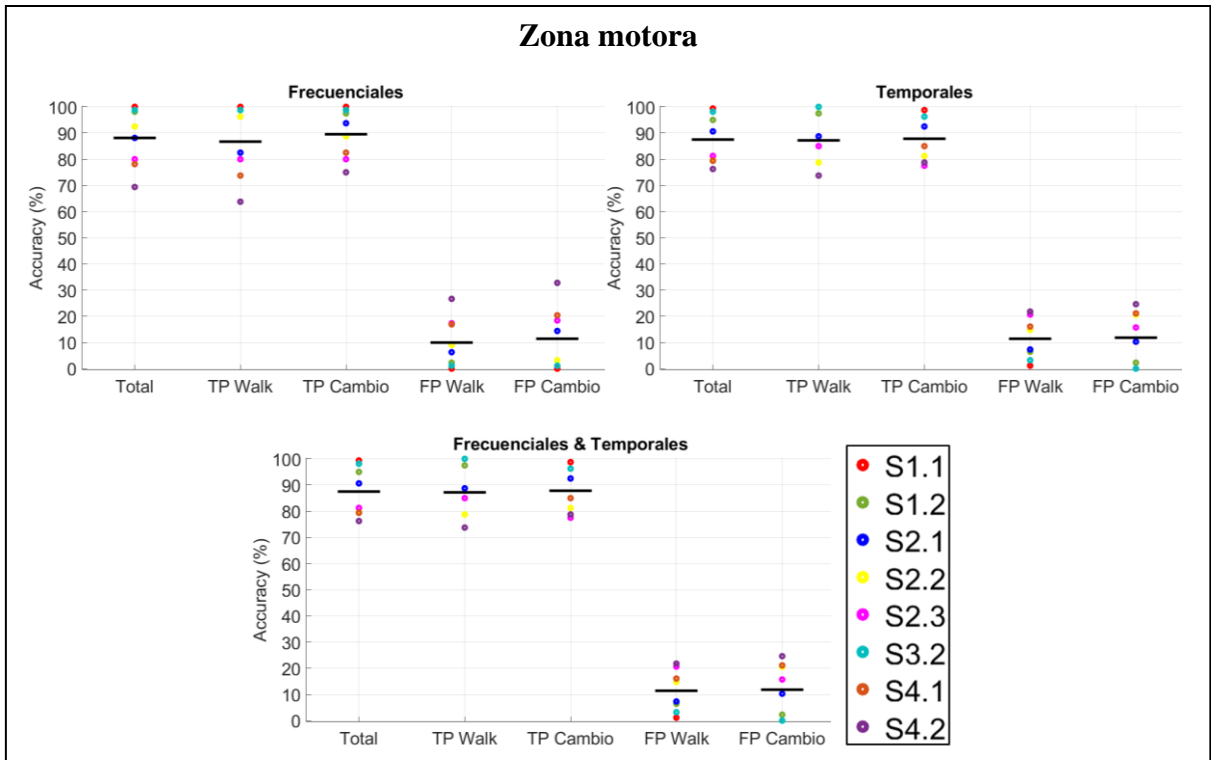
Además, cuando se eliminan algunos vectores del modelo, tanto por el método del potencial ERD, como por el método de outliers, se puede comprobar cómo esta reducción del modelo logra mejorar los resultados, pero no tan sólo en unos pocos decimales. Por ejemplo, el modelo con características temporales y frecuenciales en la Tabla 13 del modelo sin reducir tiene un porcentaje de acierto del  $94,1 \pm 5,2$  y, cuando se reduce el modelo por outliers, en la Tabla 14, el porcentaje es del  $95,3 \pm 4,8$  de aciertos.

En general, los resultados obtenidos con la mayoría de los modelos formados por vectores largos son realmente buenos y satisfactorios. Sin embargo, estos resultados tan buenos hacen más difícil comprobar si las mejoras producidas por los distintos métodos de selección y reducción tienen un efecto destacable en el proceso.


#### **4.2.2. Análisis offline con selección manual de electrodos**

Adicionalmente, tal y como se comentaba en el Apartado 4.1.2., se realiza una selección manual de electrodos que permita comparar a todos los sujetos en igualdad de condiciones. Para ello, se seleccionan unas regiones estándar a partir de los resultados obtenidos de la selección automática y la región motora.

A continuación, se representan gráficamente los resultados del análisis offline para las diferentes sesiones en la zona motora y en la combinación de la zona motora, premotora y occipital, con todos los electrodos para los tres tipos de características: exclusivamente todas las características frecuenciales, exclusivamente todas las características temporales y tanto las características frecuenciales, como las temporales juntas.



**Figura 50.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y los electrodos seleccionados manualmente en la zona motora. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.



**Figura 51.** Gráficas con los resultados del análisis offline de todas las sesiones de los sujetos para el vector largo con todas las características y los electrodos seleccionados manualmente en la zona motora, premotora y occipital. En negro, el porcentaje medio; de diferentes colores, los porcentajes de cada sujeto.

**Tabla 18.** Resultados del análisis offline de las sesiones de los sujetos para el vector largo con todas las características y los electrodos en la zona motora y en la zona motora combinada con las regiones premotora y occipital.

Sujeto	Zona motora			Zona motora, premotora, occipital		
	F (%)	T (%)	F&T (%)	F (%)	T (%)	F&T (%)
<b>S1.1</b>	100,0 ± 0,0	99,4 ± 1,8	99,4 ± 1,8	100,0 ± 0,0	100,0 ± 0,0	100,0 ± 0,0
<b>S1.2</b>	98,1 ± 2,6	95,0 ± 3,8	95,0 ± 3,8	100,0 ± 0,0	98,8 ± 2,3	98,8 ± 2,3
<b>S2.1</b>	88,1 ± 6,5	90,6 ± 4,9	90,6 ± 4,9	93,8 ± 5,8	90,0 ± 8,9	90,6 ± 8,2
<b>S2.2</b>	92,5 ± 5,9	80,0 ± 9,3	80,0 ± 9,3	95,6 ± 1,8	82,5 ± 8,5	82,5 ± 8,5
<b>S2.3</b>	80,0 ± 6,6	81,3 ± 10,3	81,3 ± 10,3	81,9 ± 7,9	76,9 ± 13,9	76,9 ± 13,9
<b>S3.2</b>	98,8 ± 2,3	98,1 ± 3,7	98,1 ± 3,7	98,8 ± 2,3	90,6 ± 17,2	90,6 ± 17,2
<b>S4.1</b>	78,1 ± 15,8	79,4 ± 14,0	79,4 ± 14,0	98,8 ± 2,3	96,3 ± 4,4	96,3 ± 4,4
<b>S4.2</b>	69,4 ± 10,2	76,3 ± 8,4	76,3 ± 8,4	93,1 ± 8,4	93,1 ± 8,4	93,1 ± 8,4
<b>Media</b>	<b>88,1 ± 6,2</b>	<b>87,1 ± 5,9</b>	<b>87,1 ± 5,9</b>	<b>95,1 ± 3,6</b>	<b>91,0 ± 7,9</b>	<b>91,1 ± 7,9</b>

En la Tabla 18, se pueden establecer diferencias entre las sesiones de los sujetos y estas diferencias serán muy útiles de cara al análisis pseudo-online. Las sesiones que mejores resultados obtienen, en general, son S1.1, S1.2, S3.2. Además, S4.1. y S4.2. logran unos resultados muy buenos con la disposición de los electrodos en las zonas motora, premotora y occipital, mientras que en la zona motora sus resultados son mucho más bajos.

Por otro lado, en algunos casos como por ejemplo S1.2., S2.2., en ambas zonas, y S2.3. y S3.2. en la zona motora, premotora y occipital, siguen una tendencia de empeorar los resultados con las características temporales y la combinación de temporales y frecuenciales.

Además, cabe destacar que el porcentaje de acierto alcanzado en la zona motora, premotora y occipital para las características frecuenciales es del  $95,1 \pm 3,6$ . Este porcentaje es casi tan elevado como el mejor resultado alcanzado en el Apartado 4.2.1.

### 4.3. Resultados del Análisis Pseudo-Online

Finalmente, en este apartado se exponen los resultados obtenidos con el clasificador pseudo-online, que trata de simular un procedimiento online, pero con todas las señales ya almacenadas.

En el Apartado 3.6.2., se explica el procedimiento para llevar a cabo el análisis pseudo-online, donde se procesan las señales de 6 registros y se seleccionan los electrodos y las características, tanto frecuenciales, como temporales, con mayor diferenciabilidad entre clases. Entonces, se crea el modelo y se valida con los dos registros restantes.

La elección de este método para la creación del modelo se debe a que en el análisis offline aporta un porcentaje de acierto muy elevado, con porcentajes de TP en ambas clases muy similares y bajo porcentaje de FP, de la misma manera que muestra la Tabla 13. Además,

se prefiere este método al resto porque, tal y como muestra la Figura 45, la variabilidad entre los resultados de las sesiones de los sujetos es mucho más baja que en otros casos, donde a pesar de obtener grandes resultados, la disparidad entre porcentajes de acierto de los sujetos es muy elevada.

Los resultados mostrados a continuación constan de dos partes: el porcentaje de cambios detectados correctamente (TP cambio) y el porcentaje de FP/min de la clase cambio, es decir, cuántas veces se detectan cambios de dirección cuando el sujeto sólo tiene que caminar. Estos porcentajes son el resultado de las medias entre los valores obtenidos del análisis en cada uno de los dos registros utilizados para test.

*Tabla 19. Resultados del análisis pseudo-online para las sesiones de cada uno de los sujetos.*

<b>Usuarios</b>	<b>TP cambio</b>	<b>FP/min</b>
<b>S1,1</b>	100,0 ± 0,0	4,3 ± 1,5
<b>S1,2</b>	95,0 ± 7,1	9,7 ± 0,4
<b>S2,1</b>	95,0 ± 7,1	50,7 ± 6,2
<b>S2,2</b>	95,0 ± 7,1	31,2 ± 0,1
<b>S2,3</b>	100,0 ± 0,0	46,0 ± 0,8
<b>S3,2</b>	90,0 ± 14,1	42,3 ± 4,1
<b>S4,1</b>	70,0 ± 14,1	48,4 ± 1,4
<b>S4,2</b>	100,0 ± 0,0	53,4 ± 2,4
<b>Media</b>	<b>93,1 ± 6,2</b>	<b>35,8 ± 2,1</b>

La tabla anterior indica un porcentaje de acierto medio muy elevado, del  $93,1 \pm 6,2$ . No obstante, el porcentaje de FP/min es de  $35,8 \pm 2,1$ , siendo también es muy elevado. Esto quiere decir que, además de la intención de cambiar de dirección real, también se detectan otras 35 intenciones de giro en un solo minuto. Desde el punto de vista un sujeto con el exoesqueleto colocado en sus piernas supone casi un impedimento poder realizar la sesión de rehabilitación correctamente.

A pesar de que los resultados de FP/min son muy demasiado elevados en la mayoría de los sujetos, las dos sesiones correspondientes al S1 obtienen muy buenos resultados, del  $100,0 \pm 0,0$  y  $95,0 \pm 7,1$  respectivamente, con un porcentaje de FP/min muy bajo, de  $4,3 \pm 1,5$  y  $9,7 \pm 0,4$ . Precisamente, son dos de las sesiones que mejores resultados obtenían en el análisis offline realizado con selección manual de electrodo para la comparativa entre sujetos y sesiones en el Apartado 4.2.2.

En un intento por reducir los FP/min, se contemplan una serie de alternativas, donde la creación del modelo con los vectores es exactamente igual, pero modificando ciertos



parámetros como el ancho de la ventana deslizante o el tamaño de avance. Sin embargo, resultados obtenidos no son mejores. En algunos casos, se reduce en gran medida el porcentaje de FP/min, pero a su vez los porcentajes de acierto caen entorno al 30%. En otros casos, los resultados son mucho peores, ya que la cantidad de FP/min aumenta hasta niveles inconcebibles en una prueba online.

Esto encuentra su explicación en el hecho de que, por un lado, ventanas deslizantes más pequeñas pueden dificultar la diferenciación de la intención, ya que podrían coger un trozo de la oscilación de la marcha y ser confundido con un potencial ERD. Esta situación, aumenta los FP/min. Mientras que, por otro lado, ventanas deslizantes muy grandes pueden suponer un problema a la hora de extraer las características temporales, porque la ventana podría coger un trozo grande de marcha junto con el potencial ERD y obtener unos valores de este tipo de características muy alejados de los valores habituales. Dado que se trata de características que se basan en la forma de la señal y parámetros, como la entropía, son muy sensibles a estas variaciones. Esta otra situación, provoca una reducción de los FP/min, a la vez que los TP de cambio.

Por esta razón, sería interesante un análisis pseudo-online con los parámetros personalizados para cada uno de los sujetos en función del tamaño y ubicación del potencial ERD respecto al instante de cambio.





## Capítulo 5. Conclusiones

En este trabajo, se han analizado las señales EEG de múltiples sujetos en dos estados diferentes: mientras caminan y cambiando de dirección. Durante el análisis, se ha demostrado que, instantes antes del cambio de dirección, la potencia relativa de la señal en la banda Mu (8-13Hz) experimenta una caída de potencial, conocida como potencial ERD.

Esta información acerca de la potencia de la señal ha sido el pilar fundamental del proceso de creación de una BMI basada en la intención de la persona de cambiar de dirección mientras camina. Gracias a los potenciales ERD es posible la diferenciación de la intención de girar frente a la marcha por medio de una serie de características, extraídas tanto en el dominio de la frecuencia, como en el dominio del tiempo.

En este sentido, se hace presente el hecho de que la información proporcionada por los electrodos posicionados en la zona motora y en el área occipital adquieren especial relevancia en el proceso de discriminación. En la mayoría de los casos, la zona motora es más influyente a través de características temporales, mientras que el área occipital lo es mediante características frecuenciales.

Tras el proceso de clasificación, los porcentajes medios resultantes del proceso de validación cruzada alcanzan un 95% de acierto con 3,7 falsos positivos. Igualmente, el análisis pseudo-online obtiene en algunos sujetos se consigue un 100% de acierto en cambios detectados y 4,3 FP/min, aunque la tendencia general es de sesiones con un elevado número de FP/min.

Este trabajo es uno de los primeros pasos en el proceso de alcanzar el objetivo de que los pacientes con lesiones en su aparato locomotor sean capaces de cambiar de dirección mientras caminan, sin limitaciones en su movimiento, del mismo modo que lo haría una persona sana, exclusivamente por medio de su cerebro.

### 5.1. Líneas futuras de investigación

El proyecto desarrollado es el inicio de una línea de investigación dedicada a diseñar una BMI capaz de detectar la intención de cambiar de dirección cuando un sujeto se encuentra caminando y asociarla a un exoesqueleto que ejecute el movimiento.

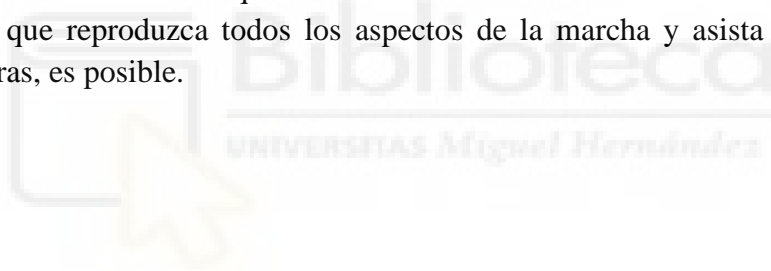
A pesar de que los resultados obtenidos en este trabajo son muy satisfactorios, el sistema todavía no es óptimo para su funcionamiento online con sujetos. Especialmente, interesa reducir los falsos positivos por minuto que aparecen durante la marcha cuando el usuario no quiere cambiar de dirección. Para ello, sería interesante llevar a cabo una selección de ventanas de las clases más personalizada, en función del tamaño e instante de aparición del potencial ERD antes del cambio de dirección. Así, el modelo sería mucho más preciso en la diferenciación de las clases.

En lo referente al modelo, también se podría mejorar la selección de las características y electrodos mediante un algoritmo más complejo basado en un sistema de clúster. Así, probando todas las opciones posibles de agrupaciones de características y electrodos, se obtendrían de forma precisa aquellos que mejor diferenciasen entre caminar y cambio de dirección.

En la línea de caracterizar la señal, podría ser útil aplicar a la señal EEG algún tipo de algoritmo, como el Filtro de Kalman, que contribuyese a reducir la variabilidad en cada repetición de la tarea y, a la vez, en las características extraídas para cada una de las dos clases.

Al sistema también se le podría añadir algunas mejoras que hiciesen más realistas los movimientos, como por ejemplo detectar hacia qué lado quiere girar el sujeto y cuántos grados. Para hacer esto posible, dentro de la complejidad que ya presenta la BMI, sería sugerente estudiar qué regiones del cerebro se activan más cuando se decide girar hacia un lado u otro.

Finalmente, los últimos pasos de la investigación serían combinar esta BMI con otras que incluyen la parada en caso de que se detecten obstáculos en el camino y cambios de velocidad en la marcha. Tal vez, para ello, todavía faltan unos años, pero hasta la fecha los resultados tienden a indicar que un sistema basado en una interfaz BMI ligada a un exoesqueleto, que reproduzca todos los aspectos de la marcha y asista a sujetos con lesiones motoras, es posible.



## Capítulo 6. Bibliografía

- [1] Abril, J., Planelles, D., Á., C., Iáñez, E., & Azorín, J. (2014). Clasificación de cambio de dirección durante la marcha mediante el uso de señales electroencefalográficas. *Actas de las XXXV Jornadas de Automática*, (págs. 42-48). Valencia, Spain,.
- [2] Ang, K. K., & Guan, C. (jun 2013). Brain-computer interface in stroke rehabilitation. *Journal of Computing Science and Engineering*, 7, 139–146.
- [3] Banala, S., Agrawal, S., & Scholz, J. (2007). Active leg exoskeleton (ALEX) for gait rehabilitation of motor-impaired patients. *2007 IEEE 10th International Conference on Rehabilitation Robotics*, (págs. 401-407). Noordwijk, The Netherlands.
- [4] BioMedical Sustainable Elastic Electronic Devices . (s.f.). *bmseed*. Obtenido de <https://www.bmseed.com/stretchable-electrodes-for-brain-implants>
- [5] Caria, A., Weber, C., Brötz, D., R. A., Ticini, L., Gharabaghi, A., . . . Birbaumer, N. (2011). Chronic stroke recovery after combined BCI training and physiotherapy: A case report. *Psychophysiology*, 48, 578-582.
- [6] Chatrian, G. L. (1985). Ten Percent Electrode System for Topographic Studies of 550 Spontaneous and Evoked EEG Activities. *American Journal of EEG Technology* 25 (2), 83-92.
- [7] Choi, J., & Kim, H. (2019). Real-time Decoding of EEG Gait Intention for Controlling a Lower-limb Exoskeleton System. *2019 7th International Winter Conference on Brain-Computer Interface (BCI)*, (págs. 1-3). Gangwon, South Korea.
- [8] Cramer, S. (2011). Harnessing neuroplasticity for clinical applications. *Brain*, 1591-609.
- [9] Dollar, A. a. (2008). Lower Extremity Exoskeletons and Active Orthoses: Challenges and State-of-the-Art. *IEEE Transactions on Robotics*, 24, 144-158.
- [10] Elvira, M., Iáñez, E., Quiles, V., Ortíz, M., & Azorín, J. (2019). Pseudo-online BMI based on EEG to detect the appearance of sudden obstacles during walking. *Sensors*.
- [11] g.USBamp. (s.f.). *USB Biosignal Amplifier: Instruction for use V2.11.03*. g.Tec Medical Engineering GmbH.
- [12] Good, D. C., Bettermann, K., & Reichwein, R. K. (jun 2011). Stroke rehabilitation. *Continuum (Minneapolis)*, 17, (3Neurorehabilitation), 545-567.
- [13] Hall, J. E., & Guyton, A. C. (2008). *Guyton & Hall Compendio de fisiología médica (11a. ed.)*. Barcelona: Elsevier.

- [14] Hämäläinen, M., Hari, R., Ilmoniemi, R., Knuutila, J., & Lounasmaa, O. (1993). Magnetoencephalography—theory, instrumentation, and applications to noninvasive studies of the working human brain. *Reviews of Modern Physics*. 65 (2), 413–497.
- [15] Hill, N., Gupta, D., & Schalk, G. (2012). Recording Human Electrocorticographic (ECoG) Signals for Neuroscientific Research and Real-time Functional Cortical Mapping. *Journal of Visualized Experiments: JoVE* (64), 3993.
- [16] Hocoma AG Medical Engineering. (2007). *Lokomat Rehabilitation Device* . Obtenido de [www.hocoma.ch](http://www.hocoma.ch)
- [17] Huang, S., & Wu, X. (2010). Feature extraction and classification of EEG for imagery movement based on mu/beta rhythms. *3rd International Conference on Biomedical Engineering and Informatics*, (págs. 891-894).
- [18] Iturrate, I., Chavarriaga, R., Montesano, L., Minguez, J., & Millán, J. (2015). Teaching brain-machine interfaces as an alternative paradigm to neuroprosthetics control. *Scientific Reports*, vol. 5(13893).
- [19] Khorshidtalab, A., Salami, M., & Hamedí, M. (2012). Evaluation of time-domain features for motor imagery movements using FCM and SVM. *9th International Conference on Computer Science and Software Engineering (JCSSE)*, (págs. 17-22).
- [20] Kiddo Salud. (Diciembre de 2015). *Kiddosalud*. Obtenido de <https://www.kiddosalud.com/blog/noticias/fisioterapia/lesion-medular-incompleta>
- [21] Kwak, N., Müller, K., & Lee, S. (oct 2015). A lower limb exoskeleton control system based on steady state visual evoked potentials. *Journal of Neural Engineering* 12, 056009.
- [22] Lemm, S., Müller, K.-R., & Curio, G. (2009). A Generalized Framework for Quantifying the Dynamics of EEG Event-Related Desynchronization. *PLoS computational biology*, 5.
- [23] Lisi, G., Rivela, D., Takai, A., & Morimoto, J. (2018). Markov Switching Model for Quick Detection of Event Related Desynchronization in EEG. *Frontiers in neuroscience*, 12, 24.
- [24] Llamas, L. (7 de Septiembre de 2016). *luisllamas*. Obtenido de <https://www.luisllamas.es/medir-la-inclinacion-imu-arduino-filtro-complementario/>
- [25] Logothetis, N. K., Pauls, J., Auguth, M., Trinath, T., & Oeltermann, A. ((July 2001)). A neurophysiological investigation of the basis of the BOLD signal in fMRI. *Nature*. 412, 150-157.
- [26] Lu, J., McFarland, D., & Wolpaw, J. (feb 2013). Adaptive Laplacian filtering for sensorimotor rhythm-based brain-computer interfaces. *Journal of Neural Engineering*, 10 (1), 016002.

- [27] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/signal/ref/sgolayfilt.html#d117e158480%20//%20https://pubs.acs.org/doi/abs/10.1021/ac60214a047#>
- [28] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/signal/ref/butter.html>
- [29] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/stats/ranksum.html>
- [30] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/stats/wblfit.html>
- [31] MathWorks. (s.f.). *mathworks*. Obtenido de [https://es.mathworks.com/help/signal/ref/pyulear.html#btwmx8u-1\\_sep\\_shared-order](https://es.mathworks.com/help/signal/ref/pyulear.html#btwmx8u-1_sep_shared-order)
- [32] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/wavelet/ref/wentropy.html>
- [33] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/matlab/ref/std.html>
- [34] MathWorks. (s.f.). *mathworks*. Obtenido de <https://es.mathworks.com/help/signal/ref/pburg.html>
- [35] Mcfarland, D., & Wolpaw, J. (2011). Brain-Computer Interfaces for Communication and Control. *Communications of the ACM*, 54, 60-66.
- [36] Millán, J., Rupp, R., Mueller-Putz, G., Murray-Smith, R., Giugliemma, C., & Mattia, D. (sep 2010). Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges. *Frontiers in Neuroscience* 1, 161.
- [37] Niazi, I., Jiang, N., Tiberghien, O., Nielsen, J., Demstrup, K., & Farina, D. (2011). Detection of movement intention from single-trial movement-related. *Journal of Neural Engineering*.
- [38] Ono, T., Shindo, K., Kawashima, K., Ota, N., Ito, M., Ota, T., & Ushiba, J. (2014). Brain-computer interface with somatosensory feedback improves functional recovery from severe hemiplegia due to chronic stroke. *Frontiers in neuroengineering*, 7, 19.
- [39] Pfurtscheller, G., & Neuper, C. (jun 1994). Event-related synchronization of mu rhythm in the EEG over the cortical hand area in man. *Neuroscience Letters* 174, 93–96.
- [40] Pfurtscheller, G., Brunner, C., Schlögl, A., & Lopes da Silva, F. (may 2006). Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks. *NeuroImage* 31, 153–159.

- [41] Quiles, V. (2017). Detección de cambios de velocidad de la marcha humana a partir de señales EEG. *Trabajo de Fin de Grado, Universidad Miguel Hernández de Elche, España.*
- [42] Rao, R. (2013). *Brain-computer interfacing: an introduction.* Cambridge,: Cambridge University Press.
- [43] REX Bionics. (s.f.). *rex bionics.* Obtenido de <https://www.rexbionics.com/>
- [44] Roy, R., Sikdar, D., Mahadevappa, M., & Kumar, C. (2017). EEG based motor imagery study of time domain features for classification of power and precision hand grasps. *8th International IEEE/EMBS Conference on Neural Engineering (NER)*, (págs. 440-443).
- [45] Sanei, S., & Chambers, J. A. (2007). *EEG signal processing.*
- [46] Sburlea, A., Montesano, L., & de la Cuerda, R. (2015). Detecting intention to walk in stroke patients from pre-movement EEG correlates. *NeuroEngineering Rehabil 12*, 113.
- [47] Schmidt, H. H. (2005). Hapticwalker. a novel haptic foot device. *ACM Transactions on Applied Perception (TAP) 2(2)*, 166-180.
- [48] Sirvent, J. A., Iáñez, E., Úbeda, A., & Fernández, E. (2011). Interfaz Cerebral no Invasiva basada en Potenciales Evocados para el Control de un Brazo Robot. *Revista Iberoamericana de Automática e Informática Industrial*, vol. 8(2), 103-111.
- [49] Tariq, M., Uhlenberg, L., Trivailo, P., Munir, K., & Simic, M. (2017). Mu-Beta Rhythm ERD/ERS Quantification for Foot Motor Execution and Imagery Tasks in BCI Applications. *8th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*, (págs. 000091-000096). Debrecen, Hungary.
- [50] Technaid S.L. (jun 2014). *Manual de Usuario Sistema de Captura de Movimiento Tech-MCS V.3.0.*
- [51] Veneman, J., Kruidhof, R., Hekman, E., Ekkelenkamp, R., Van Asseldonk, E., & van der Kooij, H. (2007). Design and evaluation of the LOPES exoskeleton robot for interactive gait rehabilitation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 15 (3), 379-386.
- [52] Wolpaw, J., & Wolpaw, E. (2012). *Brain-computer interfaces: principles and practice.* Estados Unidos: OUP USA.
- [53] World Health Organization (WHO). (19 de Noviembre de 2013). *who.* Obtenido de <https://www.who.int/es/news-room/fact-sheets/detail/spinal-cord-injury>.
- [54] Zhang, X., Xu, G., Xie, J. I., Li, M. I., & Pei, W. (2015). An EEG-driven Lower Limb Rehabilitation Training System for Active and Passive Co-stimulation. *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 4582-4585.



