

UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE

ESCUELA POLITÉCNICA SUPERIOR DE ELCHE

GRADO EN INGENIERÍA ELECTRÓNICA Y
AUTOMÁTICA INDUSTRIAL



“Mejoras en la detección de la intención de giro durante la marcha mediante señales cerebrales”

TRABAJO DE FIN DE GRADO

Julio - 2020

AUTOR: Pablo Vicente Vidal

DIRECTORES: Eduardo Iáñez Martínez

Vicente Quiles Zamora

Resumen

A día de hoy, una de las causas que provocan mayores problemas en la movilidad de las personas son ciertas enfermedades que afectan al sistema nervioso, incomunicándolo del resto del cuerpo. Como solución la ingeniería propone las Interfaces Cerebro-Máquina (BMI), que permiten interpretar los pensamientos del usuario y convertirlos en comandos de control para una máquina. Estas BMI se podrán utilizar para controlar exoesqueletos que apoyen a personas con algún tipo de lesión, ya sea de manera asistencial o en terapias de rehabilitación.

Este trabajo buscará detectar la intención de cambiar de dirección durante la marcha mediante el análisis de las señales de electroencefalograma (EEG). Para ello se analizarán estas señales en busca de potenciales de desincronización relacionados a eventos (ERD) mediante la caracterización de la señal. Para optimizar el proceso de clasificación, se hará una selección de los electrodos y características más relevantes.

Tras aplicar la clasificación, se ha pasado de un 58,8% de acierto a un 68,8% con 2,7 de FP en el análisis offline. En el análisis pseudo-online los resultados han sido de un 80,6% pero con un FP/min de 34,1, por lo que se deberá seguir trabajando en él. La mejora en el análisis offline invita a pensar que en un futuro cercano se puedan implementar este tipo de BMI.



Agradecimientos

Primero de todo agradecer a mis tutores Eduardo Iáñez Martínez y a Vicente Quiles Zamora su apoyo y dedicación durante este trabajo, al igual que al grupo de investigación BMI Systems Lab por la oportunidad de trabajar en este proyecto.

También me gustaría agradecer a los voluntarios que hicieron las pruebas en su día porque sin ellos no habría sido posible llevar a cabo este trabajo.

Finalmente agradecer a mi familia y amigos por el apoyo y los ánimos durante estos meses tan duros durante la pandemia, ya que gracias a ellos este trabajo ha podido terminarse.





Índice

Capítulo 1. Introducción	11
1.1 Motivación	12
1.2 Objetivos	12
1.3 Estructura de la memoria	13
Capítulo 2. Estado del arte	15
2.1 Fundamentos del Sistema Nervioso	15
2.1.1 Lesiones del Sistema Nervioso	15
2.1.2 Rehabilitación y plasticidad neuronal	17
2.2 Electroencefalografía	18
2.2.1 Potenciales Evocados	20
2.2.2 Potenciales Relacionados a Eventos	21
2.3 Interfaces cerebro-máquina	22
2.3.1 Clasificación de BMI	23
2.4 Aplicaciones de las BMI	24
2.4.1 BMI y la rehabilitación	25
Capítulo 3. Materiales y métodos	27
3.1 Equipamiento	27
3.1.1 IMUs	27
3.1.2 Equipo EEG	32
3.2 Método experimental	33
3.3 Procesamiento	35
3.3.1 Cargar ficheros	36
3.3.2 Filtrado	37
3.3.3 Cálculo Potencia Relativa	38
3.3.4 Detección cambio de dirección	39
3.4 Extracción de características	42
3.4.1 Separación de señales por clases	42
3.4.2 Características frecuenciales	42
3.4.3 Características temporales	44
3.5 Clasificación	47
3.5.1 Clasificadores	47
3.5.2 Análisis Offline	49
3.5.3 Análisis Pseudo-Online	51
Capítulo 4. Resultados y discusión	53

4.1 Análisis offline	53
4.1.1 Mejora en detección mediante IMUs	53
4.1.2 Selección de electrodos y características	54
4.2 Análisis pseudo-online	69
Capítulo 5. Conclusiones y trabajos futuros	73
5.1 Trabajos futuros	73
Bibliografía	75



Índice de Figuras

Figura 1: Esquema de las lesiones medulares y el grado de parálisis	16
Figura 2: Representación de los tipos de accidentes cerebrovascular (ACV).....	16
Figura 3: Representación del proceso de plasticidad neuronal.....	17
Figura 4: Equipo de EEG	18
Figura 5: Sistema internacional 10/20.....	18
Figura 6: Representación de la señal EEG descompuesta por frecuencias	19
Figura 7: Representación del Potencia Evocado Cognitivo (P300) [11].....	20
Figura 8:Potencial de Error representado como diferencia de la potencia del evento correcto respecto a al incorrecto [12].	20
Figura 9: Representación de los Potenciales Evocados respecto a la referencia (línea discontinua). En azul, el Potencial de Desincronización (ERD), en rosa, el Potencial de Sincronización [13].....	21
Figura 10: Esquema de una Interfaz Cerebro-Máquina.....	22
Figura 11:Técnicas invasivas y no invasivas.....	23
Figura 12: Equipo Tech-MCS V3 y detalle de una IMU [24].....	28
Figura 13: Posicionamiento de las IMUs: 122 Lumbar, 123 Cuádriceps derecho, 124 Gemelo derecho, 125 Pie derecho, 130 Cuádriceps izquierdo 133 Gemelo izquierdo,134 Pie izquierdo.....	31
Figura 14: IMU BWT901CL de la marca WIT Motion [25]	31
Figura 15: Equipo de EEG: g.USBamp y gorro de electrodos.....	32
Figura 16: Disposición de los 32 electrodos según el sistema internacional 10/10. En azul el electrodo AFz que usaremos de tierra.	33
Figura 17: Señal IMU durante el procedimiento experimental. En azul, el usuario camina. En rojo, intervalo en el que el usuario cambia de dirección. En verde, el usuario para. En amarillo, rectificación y giro hacia la posición original.	34
Figura 18: Esquema del preprocesado. En naranja, el filtrado de las señales. En azul, el proceso de obtención de características de cada clase y en amarillo el proceso de clasificación.....	36
Figura 19: En naranja, la señal de la IMU remuestreada. En azul, la señal filtrada con el filtro S-Golay de orden 3.....	40
Figura 20: Señal filtrada de una tarea. En morado los picos detectados. En verde el par de picos correspondiente al cambio de dirección. En rojo el punto intermedio que marca el cambio de dirección.....	40
Figura 21: Detalle de la Figura 19. Entre el pico en la señal filtrada (azul) y la señal original (naranja) hay 700 muestras, aproximadamente 0.58 segundos.....	41
Figura 22: En azul, la señal de Xz de la IMU lumbar. Los puntos morados son los puntos de inflexión. El punto verde es el punto inicial del giro seleccionado.....	42
Figura 23: Representación de la PSD de una clase walk.....	43
Figura 24: Ejemplo de clasificador SVM. En azul y en rojo las dos clases, separadas por una línea que representa el hiperplano de decisión [27].....	48
Figura 25: Ejemplo de KNN. Tenemos dos clases, los puntos rojos y los azules, y queremos clasificar el punto verde. Si K=3, será de clase roja. Pero si K=5, la clase será azul [29].....	49

Figura 26:Proceso de selección de los mejores electrodos y las mejores características para esta selección.	51
Figura 27: Selección de electrodos de la zona motora, occipital y premotora. En amarillo la selección de electrodos y en azul el electrodo de tierra.....	55
Figura 28: Selección de electrodos de la zona motora. En amarillo la selección de electrodos y en azul el electrodo de tierra	55
Figura 29: Selección de electrodos por sujeto. En rojo, los 6 electrodos con mejores resultados. En verde, ampliación hasta los mejores 10 electrodos. En azul, el electrodo de tierra.....	57
Figura 30: Selección de electrodos por sesión. En rojo, los 6 electrodos con mejores resultados. En verde, ampliación hasta los mejores 10 electrodos. En azul, el electrodo de tierra.....	62
Figura 31: Precisión utilizando los 2 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.....	64
Figura 32: Precisión utilizando los 2 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.....	64
Figura 33: Precisión utilizando los 3 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.....	64
Figura 34: Precisión utilizando los 3 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.....	65
Figura 35: Precisión utilizando los 4 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.....	65
Figura 36: Precisión utilizando los 4 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.....	65
Figura 37: Precisión utilizando los 5 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.....	66
Figura 38: Precisión utilizando los 5 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.....	66
Figura 39: Precisión utilizando los 6 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.....	66
Figura 40: Precisión utilizando los 6 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.....	67
Figura 41: Ejemplo de detección del análisis pseudo-online. En negro, la señal IMU. En verde, el inicio a caminar. En rojo, la detección del giro. En azul, un margen de 1,5 segundos que marca la separación de la zona cambio y la zona walk. Las cruces azules son la salida del análisis: 0 walk, 1 cambio.....	69

Índice de Tablas

Tabla 1: Sujetos, cantidad de registro y nomenclatura para el registro de cada sujeto ..	34
Tabla 2: Frecuencias empleadas para obtener las características frecuenciales.....	43
Tabla 3: Características frecuenciales	44
Tabla 4: Características temporales extraídas.	44
Tabla 5: Comparativa detallada de la precisión por usuario utilizando el etiquetado de cambio de dirección anterior y el nuevo.....	53
Tabla 6: Comparación de la precisión de la detección EEG utilizando el etiquetado de cambio de dirección anterior y el nuevo.....	54
Tabla 7: Resumen de los resultados de las pruebas de la selección de electrodos de la zona motora y de la zona motora, premotora y occipital.	55
Tabla 8: Precisión media del análisis con características frecuenciales con tres selecciones de electrodos: todos los electrodos, electrodos de la zona motora y electrodos de la zona motora, premotora y occipital.....	56
Tabla 9: Precisión media del análisis con características frecuenciales con tres selecciones de electrodos: todos los electrodos, electrodos de la zona motora y electrodos de la zona motora, premotora y occipital.....	56
Tabla 10: Electrodos más relevantes por usuario. También se muestra la media de todos los sujetos.	58
Tabla 11: Características más relevantes para 5 electrodos por usuario. También se muestra la media de todos los sujetos.....	59
Tabla 12: Precisión media de todos los usuarios de la selección de electrodos y características por usuario.	59
Tabla 13: Electrodos más relevantes por sesión de pruebas.....	61
Tabla 14: Características más relevantes por sesión para los 5 mejores electrodos.....	63
Tabla 15: Resultados medios de la selección de electrodos y características por sesión.	67
Tabla 16: Comparativa de la selección final con la selección inicial.	68
Tabla 17: Características y electrodos empleados para el análisis pseudo-online.	69
Tabla 18: Resultados del análisis pseudo-online.....	70



Capítulo 1. Introducción

Según la OMS, año tras año aumentan las personas afectadas por algún tipo de enfermedad que afecta a su movilidad debido a daños en su sistema nervioso, ya sea por accidentes cerebrovasculares, lesiones en la espina dorsal o por algún tipo de neurodegeneración, entre otros [1].

Estas enfermedades tienen diversas consecuencias, entre ellas que se reduzca la movilidad de alguno de sus miembros total o parcialmente. En los casos más graves se traduce en la pérdida total de la movilidad por parte del paciente. Sin embargo, la capacidad locomotora puede seguir intacta, siendo el problema la conexión nerviosa. En los trabajos de rehabilitación se ayuda al paciente a repetir los movimientos en busca de reestablecer las conexiones cerebrales gracias a la plasticidad neuronal [2] [3].

En este punto entraría en juego la ingeniería, proponiendo soluciones que sirvan de apoyo en las tareas de rehabilitación y complementarias a los ejercicios realizados junto a fisioterapeutas. Un ejemplo son los exoesqueletos [4][5] que permitan la repetición de movimientos de manera exacta, además siendo una fuente de motivación para que los pacientes no abandonen la rehabilitación [6]. Otra herramienta que se está desarrollando son las interfaces cerebro-máquina (BMI: Brain-Machine Interface) basadas en señales electroencefalográficas (EEG) [7] para controlar estos exoesqueletos.

Este trabajo estudiará detectar la intención de cambiar de dirección durante la marcha basada en potenciales de desincronización relacionados con eventos (ERD) [7], ya que estos se producen con anterioridad al instante del movimiento, siendo de gran utilidad para el diseño de BMI para controlar exoesqueletos. El objetivo de aplicar BMI y exoesqueletos es aumentar la implicación del paciente, siendo el movimiento consecuencia de la tarea mental, eliminando mecanismos de movimiento basados en botones y otras tareas no mentales.

1.1 Motivación

Esta investigación forma parte del proyecto *Control de exoesqueletos de miembro inferior mediante interfaces cerebro-máquina para asistir a personas con problemas de marcha* (WALK) financiado por el Ministerio de Ciencia e Innovación (MCIU), la Agencia Estatal de Investigación (AEI) y la Unión Europea a través del Fondo Europeo de Desarrollo Regional (FEDER). Este proyecto tiene como objetivo desarrollar exoesqueletos que, en conjunto con BMI, apoyen y asistan durante la marcha. En este proyecto se están desarrollando tres BMI: detección de la intención de cambiar de velocidad, detección de obstáculos y la detección de cambiar de dirección.

Este trabajo buscará desarrollar la detección de la intención de cambiar de dirección tomando como punto de partida trabajos anteriores.

1.2 Objetivos

El objetivo principal de este trabajo es crear una BMI cuya función sea detectar la intención de giro durante la marcha mediante señales electroencefalográficas (EEG). Para ello se llevarán a cabo los siguientes pasos:

1. Detectar los cambios de dirección mediante señales provenientes de sensores inerciales de movimiento (IMU) y etiquetar dichos cambios en las señales EEG.
2. Cálculo de las características de las señales EEG.
3. Selección de las características y electrodos más relevantes en un procesamiento offline.
4. Búsqueda de algoritmos de Machine Learning para el procesamiento pseudo-online.
5. Comprobar el funcionamiento de los modelos para la implementación en una BMI.

1.3 Estructura de la memoria

La memoria presenta los siguientes capítulos:

- Capítulo 1. Introducción: Contiene la introducción, la motivación, objetivos y estructura del trabajo.
- Capítulo 2. Estado del arte: Explicación teórica de los conceptos previos como BMI, señales EEG y el estado en el que se encuentran las investigaciones.
- Capítulo 3. Materiales y Métodos: Exposición de la técnicas y procedimientos llevados a cabo para cumplir los objetivos.
- Capítulo 4. Resultados y discusión: Evaluación de los resultados obtenidos.
- Capítulo 5. Conclusiones y trabajos futuros: Conclusiones y líneas futuras de investigación.





Capítulo 2. Estado del arte

En los últimos años se han estudiado diversos métodos para implementar las interfaces cerebro-máquina (BCI), desde las técnicas de adquisición de las señales cerebrales, tanto invasivas como no invasivas, hasta las aplicaciones posibles [8] [9]. Entre las aplicaciones encontramos su uso en la ayuda en terapias de rehabilitación de personas con alguna lesión en el sistema nervioso o el apoyo en tareas del día a día mediante exoesqueletos [6].

En este capítulo se expondrán los conceptos mencionados anteriormente, ampliándolos y mostrando el estado actual de las investigaciones en el campo de las BCI, para poder tener una visión más amplia de las opciones que ofrecen y como pueden beneficiar a nivel físico y mental a los pacientes de lesiones nerviosas.

2.1 Fundamentos del Sistema Nervioso

El sistema nervioso es el conjunto de órganos que permiten la coordinación y control del cuerpo humano mediante el uso de señales químicas y eléctricas, siendo estas segundas las que estudiaremos. También es el encargado de percibir y procesar los estímulos tanto internos como externos. Por lo tanto, podemos distinguir tres funciones en el sistema nervioso central: función sensorial, que se encarga de los estímulos; función integradora, que se encarga de la toma de decisiones en función de los estímulos; y función motora, encargada de ordenar el movimiento.

Además, tenemos el sistema nervioso periférico, que es el encargado de transmitir las órdenes del sistema nervioso central al resto del cuerpo mediante los diversos tipos de señales. A continuación, se explicarán algunas enfermedades que interfieren en el normal funcionamiento y las distintas señales que se pueden obtener para el diseño de BMI.

2.1.1 Lesiones del Sistema Nervioso

En este campo podemos encontrar una multitud de causas, pero las más habituales suelen ser las lesiones medulares, tanto a causa de un traumatismo como de algún tipo de enfermedad o degeneración, aunque el 90% pertenece al primer caso y afecta a un número considerable de gente joven [1]. Entre las causas de degeneración que va en aumento

encontramos los accidentes cerebrovasculares, el Parkinson o la Esclerosis Lateral Amiotrófica, entre otras enfermedades.

2.1.1.1 Lesión de la medula espinal

Esta es una de las lesiones del sistema nervioso más graves, ya que consiste en el seccionamiento de la medula espinal. Si a esta la consideramos como el canal de comunicación entre el cuerpo y el sistema nervioso central que lo controla, se ve la gravedad que implica su seccionamiento, ya que deja parte del cuerpo incomunicado y sin ningún tipo de capacidad de movimiento.

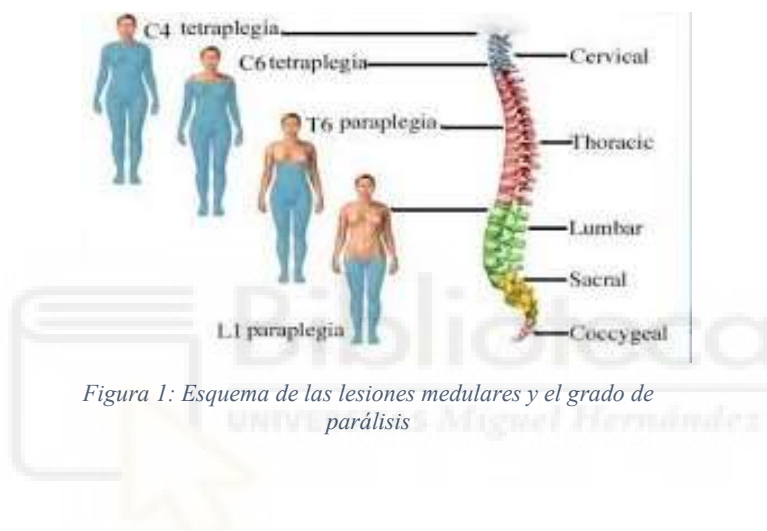


Figura 1: Esquema de las lesiones medulares y el grado de parálisis

Como se puede ver en la Figura 1, dependiendo de donde se encuentre la lesión la parálisis será mayor o menor: si se produce en la zona cervical, habrá una tetraplegia; y si se produce en la zona lumbar produce paraplegia.

2.1.1.2 Accidentes cerebrovasculares

Esta lesión también tiene severas consecuencias en la movilidad de las personas que la han padecido. Un accidente cerebrovascular (ACV), o ictus, consiste en la falta de riego



Figura 2: Representación de los tipos de accidentes cerebrovascular (ACV)

sanguíneo a alguna zona del cerebro, lo que provoca falta de oxígeno y que el tejido nervioso muera.

Puede tener dos orígenes (Figura 2): la ruptura de un vaso sanguíneo (ACV Hemorrágico) o la obstrucción de un vaso sanguíneo (ACV Isquémico). La muerte de este tejido provoca que el sistema nervioso central pueda perder algunas de sus funciones parcial o totalmente, por ejemplo, la movilidad o el habla, aunque en el peor de los casos puede desenlazar en la muerte. Las enfermedades neurodegenerativas también tienen unos síntomas similares.

2.1.2 Rehabilitación y plasticidad neuronal

Uno de los métodos para recuperar las funciones perdidas debido a algún tipo de enfermedad neuronal es la rehabilitación mediante la ejecución de ciertos ejercicios. Esto se debe a una capacidad que tiene el tejido nervioso llamada plasticidad neuronal, representada en la Figura 3, mediante la cual el tejido sufre transformaciones para adaptarse a las nuevas situaciones. Estas pueden ser debidas a nuevas situaciones del día a día como aprender un idioma o como respuesta a un daño en el tejido [2].

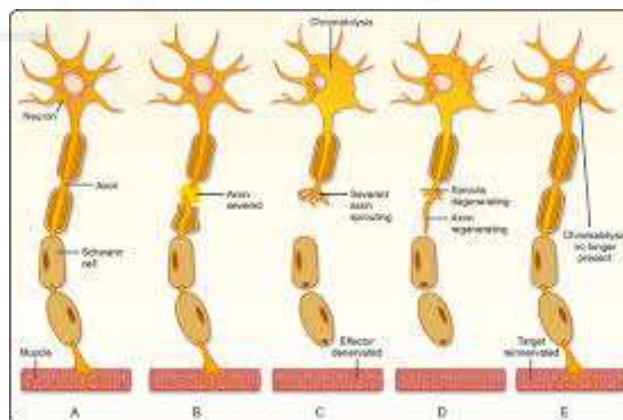


Figura 3: Representación del proceso de plasticidad neuronal

Esta capacidad es la que se pretende activar mediante la rehabilitación ya que ayudar al paciente a realizar esas ciertas tareas para las que tiene dificultades rehace las sinapsis perdidas.

2.2 Electroencefalografía

Resulta crítico obtener las señales del cerebro destinadas a ese control del cuerpo para poder hacer un estudio fiable. Para ello se utiliza de manera bastante habitual la electroencefalografía (EEG) debido a los motivos descritos en el punto 2.3.1.



Figura 4: Equipo de EEG

La electroencefalografía consiste en registrar la actividad eléctrica que se lleva a cabo en el cerebro. Para ello se utiliza un equipo similar al de la Figura 4, donde una malla o gorro sujeta los electrodos que captaran la señal. Para posibilitar la repetitividad de los experimentos se suele utilizar el sistema internacional 10/20, donde los electrodos se encuentran a una distancia del 10% o del 20% de la distancia total entre la parte frontal y posterior o la parte derecha o izquierda del cráneo. Al ser una medida relativa a la anatomía del paciente, permite que cada electrodo obtenga datos de una misma zona del cerebro, permitiendo una nomenclatura común para los electrodos según su disposición.




Figura 5: Sistema internacional 10/20

Esta disposición, que podemos ver en la Figura 5, permite un número limitado de electrodos, por lo que también es habitual utilizar un sistema de 10/10 que permite un número mayor de electrodos.

La señal EEG que se obtiene es muy compleja, por lo que se suele descomponer en ondas repartidas en las siguientes bandas de frecuencia [10]:

- Banda Delta (0.1-4 Hz): tienen gran amplitud. Aparecen en las fases de sueño profundo.
- Banda Theta (4-7 Hz): aparece principalmente en momentos de relajación profunda, normalmente en entre el sueño ligero y el despertar. También aparece durante la fase REM del sueño.
- Banda Alfa (8-15 Hz): aparece en momentos de relajación o momentos en los que se debe prestar una atención moderada. Se ve modificada por estímulos externos.
- Banda Mu (8-12 Hz): aparece espacialmente en la zona motora del cerebro. Se pueden apreciar modificaciones al realizar movimientos, aunque también con solo el hecho de pensar en hacerlos.
- Banda Beta (18-26 Hz): aparecen en situaciones en las que se debe prestar atención o estar alerta. También aparece ante situaciones en las que no se obtiene el resultado esperado.
- Banda Gamma (32-100 Hz): son ondas de poca amplitud. Están relacionadas con momentos de gran concentración.




Figura 6: Representación de la señal EEG descompuesta por frecuencias

A partir de esta descomposición, ejemplo en la Figura 6, se pueden obtener la potencia de las ondas, siendo de gran utilidad para identificar eventos y la intención de realizar alguna acción.

2.2.1 Potenciales Evocados

Los Potenciales Evocados surgen como respuesta a un estímulo. Entre ellos podemos encontrar los siguientes:

- Potencial Evocado Visual (PEV): aparecen como una respuesta en la señal eléctrica del sistema nervioso como respuesta a un estímulo visual, como podría ser una luz o un obstáculo en la trayectoria.
- Potencial Evocado Auditivo (PEA): aparecen como una respuesta en la señal eléctrica del sistema nervioso como respuesta a un estímulo auditivo.
- Potencial Evocado Cognitivo: en este caso destaca el P300 (Figura 7), llamado así ya que destaca mucho como a los 300 ms aparece una señal muy significativa y parecida en muchos sujetos. Aparece como respuesta a la toma de decisiones.




Figura 7: Representación del Potencia Evocado Cognitivo (P300) [11]

- Potencial de Error (ErrP): este caso aparece como respuesta a un hecho inesperado, apareciendo una caída de potencial (Figura 8).

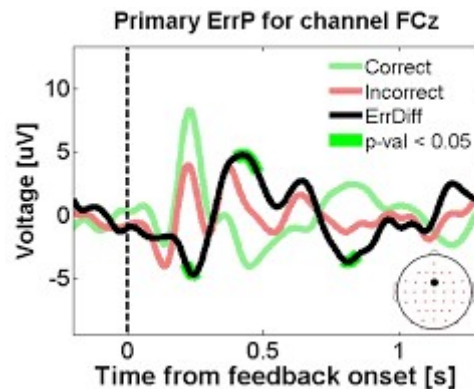


Figura 8: Potencial de Error representado como diferencia de la potencia del evento correcto respecto a al incorrecto [12].

2.2.2 Potenciales Relacionados a Eventos

Los Potenciales Relacionados a Eventos (ERP) surgen como una reacción a una situación específica, como puede ser la intencionalidad de realizar un movimiento. Existen varios tipos: motores, sensoriales y cognitivos, pero los más importantes son los potenciales motores. Aparecen en la banda Mu (8-13 Hz) y en la banda Beta (18-26 Hz) como respuesta a una acción motora. El potencial de desincronización relacionado a un evento (ERD) indica previamente la intención de realizar un movimiento con una bajada en el potencial. Tras ello aparece el potencial de sincronización relacionado a un evento (ERS) con una subida del potencial, como podemos ver en la Figura 9. Es por ello que el estudio del ERD es tan interesante para el diseño de BMI.

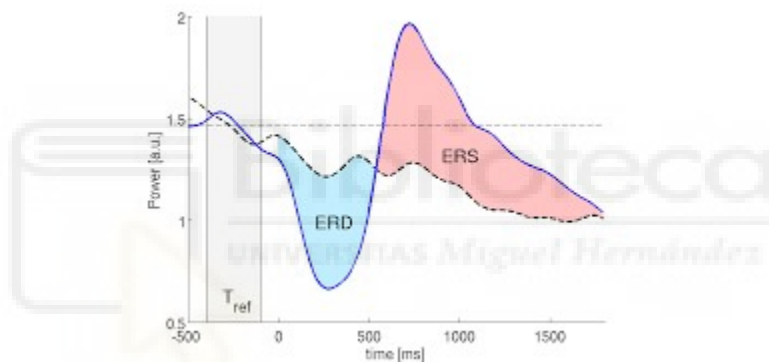


Figura 9: Representación de los Potenciales Evocados respecto a la referencia (línea discontinua). En azul, el Potencial de Desincronización (ERD), en rosa, el Potencial de Sincronización [13].

Además, en este apartado también cabe destacar los Potenciales Relacionados a Eventos cognitivos, es decir, el evento es un pensamiento. En esta rama encontramos la imaginación motora, donde el solo hecho de pensar en realizar un movimiento ya genera una respuesta similar a la de efectivamente hacer el movimiento [14]. Esta respuesta es la que permite abrir campos de estudio relacionados con la rehabilitación o el diseño de sistemas de apoyo controlados mentalmente para personas con movilidad reducida, ya que no pueden realizar el movimiento, pero si imaginarlo.

2.3 Interfaces cerebro-máquina

Una interfaz cerebro-máquina (BMI) se puede definir como un algoritmo que nos permite controlar un sistema mediante la decodificación de la señal cerebral del usuario, mediante el procesamiento de estas y la generación de los comandos de control correspondientes [15].

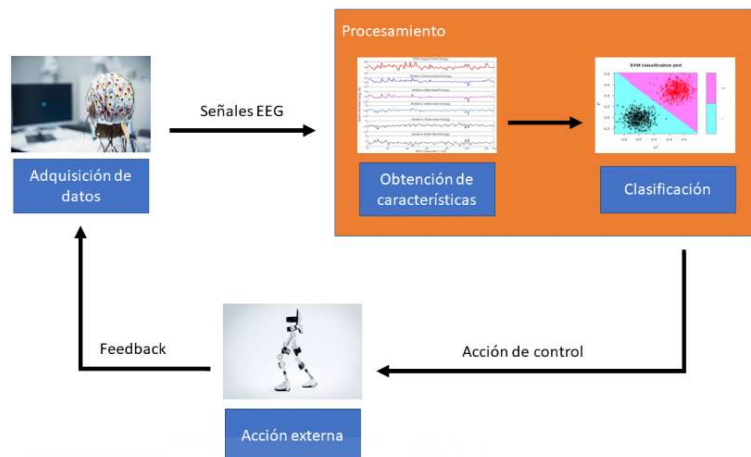


Figura 10: Esquema de una Interfaz Cerebro-Máquina

Su funcionamiento pasa por las fases representadas en la Figura 10:

Adquisición de datos: esta función es crítica ya que es la base de todo el proceso. Consiste en la adquisición de las señales cerebrales, que son analógicas, y las procesa para obtener una señal digital amplificada y de mayor calidad gracias a la aplicación de filtros que reduzcan el ruido.

Obtención de características: una vez tenemos la señal digitalizada, es preciso aplicar diversas técnicas para obtener las características (temporales, frecuenciales o potenciales) de la señal.

Clasificación: entre estas características de la señal se buscan eventos distintivos que puedan marcar el cambio entre estados y, por tanto, posibiliten la generación del correspondiente comando de control.

Acción externa: es el objetivo final, la realización de una función exterior como, por ejemplo, los actuadores de un exoesqueleto o una respuesta visual en el caso de comunicarse con un ordenador.

Realmente este proceso suele implementarse a modo de bucle de manera que haya una realimentación que propicie la mejora del sistema, reduciendo los falsos positivos y aumente la precisión de la BMI.

2.3.1 Clasificación de BMI

Las BMI se pueden clasificar según una amplia variedad de parámetros, pero los más significativos son las técnicas de adquisición de datos, el origen de la señal y los potenciales analizados.

2.3.1.1 Clasificación por técnicas de adquisición de datos

Podemos encontrar dos grandes grupos dentro de este apartado, donde la principal diferenciación se encuentra en los requerimientos de cirugía o no. En la Figura 11 vemos las más importantes.




Figura 11: Técnicas invasivas y no invasivas

Primeramente, encontramos las técnicas invasivas, que consisten en la colocación de electrodos en la región intracraneal de la cabeza. Esto permite adquirir una señal de gran calidad, pero a costa de tener que realizar una intervención quirúrgica compleja para ello, ya que en el proceso se requiere retirar un trozo del cráneo para poder poner los electrodos en contacto con el cerebro. Esta técnica no es muy recomendable por los riesgos y complicaciones que implican este tipo de cirugías.

Por otro lado, están las técnicas no invasivas, que consisten en el posicionamiento de los electrodos directamente sobre el cuero cabelludo. Estos electrodos empleados pueden ser activos o pasivos. Los activos tienen un amplificador en el propio electrodo antes de transmitirse por el cable para su adquisición. Los pasivos envían la señal obtenida

directamente. Estos sistemas propician que la señal sea más ruidosa ya que el hueso y la piel dificultan la obtención de la señal, apareciendo problemas de resolución espacial ya que varios electrodos pueden adquirir datos de la misma región. Para reducir el ruido se suele optar por sistemas que requieren de un gel conductor para aumentar la conectividad entre los electrodos y el cuero cabelludo, aunque a veces se recurre a sistemas en seco para reducir los tiempos de preparación y de limpieza. A pesar de estos inconvenientes, los costes y riesgos de estas técnicas no invasivas son mínimos. El equipamiento suele ser portátil, normalmente agrupados en un casco, lo cual facilita su uso. Estas ventajas hacen que las técnicas de electroencefalografía (EEG) y magnetoencefalografía (MEG) sean las más utilizadas a pesar de los problemas de ruido que presentan.

2.3.1.2 Clasificación según el origen de la señal

En este caso nos fijamos en el origen de la señal, ya que los potenciales a estudiar en cada caso son distintos y, por tanto, dependiendo del uso al que se va a aplicar convendrá estudiar un tipo de señales u otras.

Por un lado, están las BMI evocadas o exógenas, cuyo origen se encuentra en un estímulo exterior, generalmente visual o auditivo. En estos casos lo más conveniente es estudiar los Potenciales Evocados Visuales (PEV), los Potenciales Evocados Auditivos (PEA) y potenciales relacionados a eventos como el potencial de error (ErrP) y la P300.

Por otro lado, están las BMI endógenas o espontaneas, que se producen por el pensamiento voluntario del sujeto, ya sea una acción como iniciar la marcha, girar o simplemente parpadear. En este grupo también encontramos los generados debido a la imaginación motora. En este caso es interesante estudiar los potenciales motores relacionados con eventos, ya sean desincronizados (ERD) o sincronizados (ERS).

2.4 Aplicaciones de las BMI

Las BMI tienen una gran variedad de aplicaciones, pero se podrían agrupar en dos ramas, la lúdica y la médica.

En la primera rama, la lúdica, encontramos principalmente videojuegos. Aquí se pretende que la BMI actúe como sustituto de los típicos mandos, de forma que juegue mandando los comandos de control mediante la mente [16]. Esto implica, junto a la incorporación de la realidad virtual, un nuevo campo en el mundo de los videojuegos hacia donde la

industria se dirigirá en el futuro en busca de una experiencia más realista. También el uso que se le dé puede tener variedad de aplicaciones, no solo de ocio, sino que se podría aplicar a nuevas metodologías de enseñanza.

Por otro lado, está su utilización en medicina. Principalmente se busca ayudar a las personas que sufren algún tipo de discapacidad a interactuar con el mundo. Esto se puede llevar a cabo de manera asistencial para casos en fase crónica o como rehabilitación durante la fase aguda. Este trabajo podría valer para ambos casos. En este contexto se utiliza la imaginación motora en conjunto con un exoesqueleto para ayudar al movimiento u obtener información relevante que pueda servir a los facultativos para la evolución de la terapia. Entre las tareas que se realizan encontramos desde el estudio de cómo se comporta el cerebro, mediante el análisis de las señales EEG, ante distintas situaciones como la detección de obstáculos inesperados durante la marcha [17], la decisión de cambiar de dirección o la de cambiar de velocidad [18], hasta conceptos más abstractos como el vocabulario o la creatividad artística [19].

El objetivo de estos estudios es crear comandos de control, es decir, la BMI, que permitan manejar un equipamiento, ya sea de carácter asistencial o destinado a la rehabilitación, aunque también están apareciendo ramas de investigación en las que se añaden sistemas de realidad virtual a las BMI, por ejemplo, para darle sensación de avance a un paciente que trabaja en una cinta de correr.

2.4.1 BMI y la rehabilitación

Previamente se ha explicado la importancia de la rehabilitación en los pacientes con lesiones motoras. Es aquí donde la ingeniería aparece para aportar nuevos puntos de vista con tal de hacer la terapia más eficiente, sencilla y llevadera [20]. Por un lado, el uso de exoesqueletos permite realizar los movimientos con gran precisión, incrementando la repetitividad de los movimientos [5]. Un ejemplo de exoesqueleto es el Lokomat, que da apoyo al paciente de manera que lo sustenta y aporta la fuerza de la que puede carecer durante ejercicios de marcha. Por otro lado, están apareciendo nuevas terapias donde el sujeto está parado y realiza alguna actividad, por ejemplo, la movilidad de brazos con el apoyo de un exoesqueleto del miembro superior [21] o el control de una pedalina mediante la BMI de manera que se apoye la intención de pedalear [22] [23].

El problema que puede aparecer en estas terapias es que el proceso de mejora es lento y el paciente puede verse desmotivado y el riesgo de abandono es bastante alto. Esto es un gran problema ya que la eficacia de las terapias está relacionada con la implicación del paciente [6]. Es aquí donde podría intervenir los sistemas BMI, haciendo que el paciente se involucre en el proceso. Ver que el exoesqueleto realiza los movimientos que el paciente ordena puede ser una gran motivación para seguir con el tratamiento. Es más, con el tiempo, el desarrollo de BMI y exoesqueletos más ligeros y económicos, podrán aparecer equipos que den asistencia al movimiento de forma que permitan llevar una vida normal, ya no siendo estos equipos para rehabilitación, sino como robot asistencial.



Capítulo 3. Materiales y métodos

En este capítulo se expondrá una descripción del equipamiento utilizado durante el procedimiento experimental, el protocolo utilizado durante las pruebas, el procesamiento de las señales para su posterior clasificación y los clasificadores utilizados. Posteriormente, en el Capítulo 4 se expondrán los resultados y las conclusiones que se pueden obtener de ellos.

3.1 Equipamiento

Como parte del equipamiento cabe destacar el equipo de sensores inerciales de movimiento (en inglés: Inertial Measurement Unit, IMU) y el equipo de electroencefalograma (EEG). El primero el utilizaremos para detectar el momento exacto en el que se cambia de dirección, pudiendo determinar incluso hacia donde (izquierda o derecha). Con el segundo obtendremos las señales EEG, que deberán ser procesadas para obtener las características de la señal, la cuales se utilizarán posteriormente para clasificarlas en clases: andar o cambio de dirección.

3.1.1 IMUs

Los sensores inerciales de movimiento son unos dispositivos que pueden llegar a ser muy pequeños y que se basan en diversos circuitos que permiten el cálculo de diversos parámetros, principalmente orientación, velocidad y aceleración, aunque también pueden proporcionar otros datos adicionales dependiendo del modelo y fabricante. Son por tanto una herramienta muy útil para determinar diversos eventos durante una prueba. Nosotros únicamente lo utilizaremos para calcular el instante cuando se cambia de dirección, pero tiene multitud de aplicaciones como detectar el cambio de velocidad o conocer la disposición exacta de una extremidad mediante el uso de diversas IMUs.

En nuestro caso hemos utilizado para las pruebas el equipo Tech-MCS V3 de la empresa Technaid S.L. El equipamiento se puede dividir en tres elementos: Tech-MCS Studio, Tech-HUB y Tech-IMUs, además de los accesorios que permiten la sujeción de los Tech-IMUs y la conexión de los Tech-IMUs con el Tech-HUB y este al ordenador mediante un cable USB [24]. El equipo empleado lo podemos ver en la Figura 12.



Figura 12: Equipo Tech-MCS V3 y detalle de una IMU [24]

Tech-MCS Studio: es el software diseñado para gestionar y visualizar los datos registrados por los Tech-IMUs. Este programa no ha sido utilizado ya que se optó por la adquisición de los datos y su posterior procesamiento mediante MATLAB.

Tech-HUB: es el dispositivo que concentra los datos del Tech-MCS V3, admitiendo hasta 16 Tech-IMUs. Recibe la información de las IMUs y se encarga de su envío sincronizado al ordenador o su almacenamiento en la memoria interna. Para el envío de los datos dispone de tres métodos: conexión por cable USB, conexión inalámbrica mediante Bluetooth o almacenamiento en una tarjeta de memoria Micro SD, en cuyo caso no requiere un ordenador.

Tech-IMUs: son los pequeños dispositivos que contienen los sensores basados en tecnología MEMS (Micro Electro Mechanical Systems). En su interior encontramos un acelerómetro, un giroscopio y un magnetómetro, todos ellos tridimensionales ortogonales (3D), además de un sensor de temperatura y un microprocesador. A partir de estos datos, su algoritmo permite calcular la posición en tiempo real.

3.1.1.1 Principio de funcionamiento

Los sensores inerciales permiten obtener su posicionamiento a partir de las fuerzas de aceleración y velocidad angular que se ejercen sobre una pequeña masa de su interior. Normalmente se dispone de un sensor de cada tipo para cada eje, de forma que se puede obtener una representación tridimensional (espacio euclídeo tridimensional).

Esta tecnología inercial se basa en las dos primeras leyes de Newton. La primera establece que el movimiento de un cuerpo en uniforme y rectilíneo a no ser que exista una fuerza externa que actúe sobre él. La segunda define que esta fuerza externa ejercida sobre la masa producirá una aceleración proporcional a ella.

$$\sum \vec{F} = 0 \leftrightarrow \frac{d\vec{v}}{dt} = 0 \quad (1)$$

$$\sum \vec{F} = m\vec{a} \quad (2)$$

Un acelerómetro uniaxial consiste en una masa suspendida por un muelle en un receptáculo. La masa puede desplazarse por el eje a medir, siendo este desplazamiento una medida de la diferencia entre la aceleración y la gravedad sobre la dirección de medida. Un acelerómetro triaxial está compuesto por tres uniaxiales montados ortogonalmente.

La velocidad angular se calcula mediante giroscopios. Los usados por esta empresa emplean el principio de la aceleración de Coriolis basado en la vibración de una masa para la detección de una rotación angular inercial. Si el receptáculo rota con una velocidad angular perpendicular al plano, la masa experimentará una fuerza de Coriolis en la dirección perpendicular a la velocidad angular. Por tanto, el desplazamiento causado por la fuerza de Coriolis es proporcional a la velocidad angular. Del mismo modo, por integración de esta velocidad angular podemos obtener el ángulo de rotación del cuerpo sobre un eje. Así, utilizando tres giroscopios uniaxiales montados de manera perpendicular entre sí se puede formar un giroscopio triaxial que mide la rotación en 3D.

Además, se cuenta con un magnetómetro triaxial, sensible al campo magnético, que permite conocer la orientación respecto al polo norte magnético. Sirve principalmente para aumentar la precisión de la estimación de la orientación. Sin embargo, una incorrecta calibración del magnetómetro o un ambiente con mucho ruido magnético puede llevar a errores de medida.

A partir de estos datos extraídos se obtiene la Matriz de Cosenos Directores (DCM), también llamada matriz de rotación. Esta matriz expresa en columnas la orientación del eje X, eje Y, eje Z respectivamente con respecto a un sistema de coordenadas fijo donde el eje X apunta al polo norte magnético, el eje Z apunta en la misma dirección que la

gravedad y el eje Y es ortonormal a estos. Para su cálculo el proceso se divide en dos partes, el cálculo de la posición inicial y la estimación.

En la primera parte se hace una estimación inicial a través de las medidas del acelerómetro 3D (3D Acc) y el magnetómetro 3D (3D Mag). Se realiza una única vez, cuando la IMU está inmóvil y antes de que el usuario se mueva. Esquemáticamente se puede resumir con las siguientes ecuaciones:

$$3D\ Acc = \vec{W}_{(z)} \approx [0\ 0\ 9.8] \quad (3)$$

$$3D\ Mag = \vec{M} = [M_x\ M_y\ M_z] \quad (4)$$

$$\vec{U}_{(x)} = |\vec{W}_{(z)} \times \vec{M}| \quad (5)$$

$$\vec{V}_{(y)} = |\vec{W}_{(z)} \times \vec{U}_{(x)}| \quad (6)$$

$$D = [\vec{U}_{(x)}\ \vec{V}_{(y)}\ \vec{W}_{(z)}] = \begin{bmatrix} \hat{u}_x & \hat{v}_x & \hat{w}_x \\ \hat{u}_y & \hat{v}_y & \hat{w}_y \\ \hat{u}_z & \hat{v}_z & \hat{w}_z \end{bmatrix} \quad (7)$$

En el proceso de estimación se obtiene la velocidad angular del giroscopio 3D (3D Gyro) y posteriormente se integra para conocer la variación respecto a la última posición conocida:

$$3D\ Gyro = \vec{\omega} = [\omega_x\ \omega_y\ \omega_z] \quad (8)$$

$$DCM_{(t)} = DCM_{(t-1)} + \int \vec{\omega}_{(t)} \quad (9)$$

Para la realización de estas pruebas se ha utilizado el equipo de sujeción de las IMUs aportado por el fabricante, especializado en su uso para la determinación del movimiento de las personas. Se ha seguido la siguiente distribución de 7 IMUs: una en la zona lumbar y tres en cada pierna: una en el muslo, una en la tibia y otra en el pie, tal y como vemos en la Figura 13.




Figura 13: Posicionamiento de las IMUs: 122 Lumbar, 123 Cuádriceps derecho, 124 Gemelo derecho, 125 Pie derecho, 130 Cuádriceps izquierdo 133 Gemelo izquierdo, 134 Pie izquierdo.

Cada IMU aporta 19 señales con una frecuencia de muestreo de 30Hz: las nueve componentes de la DCM, tres señales del giroscopio, tres señales del magnetómetro y tres señales del acelerómetro. Adicionalmente cada IMU tiene un sensor de temperatura que aporta otra señal más.

3.1.1.2 IMUs Alternativas

Como alternativa a este sistema de sensores inerciales se buscó otro totalmente inalámbrico, ya que el equipo de Technaid, aunque funcione en modo inalámbrico, necesita la conexión entre los Tech-IMUs y el Tech-HUB. Como alternativa se encontraron las IMUs BWT901CL de la empresa WIT Motion (Figura 14).



Figura 14: IMU BWT901CL de la marca WIT Motion [25]

Estas IMUs tenían un funcionamiento similar, obteniéndose 12 datos: tres señales de ángulos respecto a los ejes X, Y, Z, tres señales de velocidad angular, tres de aceleración y tres de magnetómetro, con una frecuencia de muestreo seleccionable entre 0.1 a 200 Hz. El método de conexión era inalámbrico mediante Bluetooth.

La idea inicial era utilizar este equipo que permite una mayor comodidad de uso, pero debido al COVID-19 y a unos problemas con la sincronización con el equipo de EEG, no se llegó a hacer pruebas con estas IMUs.

3.1.2 Equipo EEG

Como se ha comentado en el apartado 2.1.3., el uso de un equipo de EEG es indispensable para este tipo de investigaciones debido a la gran cantidad de información que nos aporta. Estos experimentos se han realizado con un gorro de electrodos de 32 electrodos y dos amplificadores g.USBamp de la empresa g.Tec, ya que cada uno dispone de 16 canales de entrada. Además, estos amplificadores poseen un filtro Notch a 50Hz para eliminar las perturbaciones de la red. La señal recogida por estos amplificadores se procesa y sincroniza en el módulo g.INTERsync (Figura 15). Posteriormente se utiliza MATLAB para la adquisición de los datos.



Figura 15: Equipo de EEG: g.USBamp y gorro de electrodos.

Se ha utilizado el sistema internacional 10/10 para la disposición de los electrodos, utilizando el electrodo AFz como toma a tierra y una referencia en el lóbulo de la oreja derecha. La frecuencia de muestreo es de 1200 Hz y además se debe utilizar un gel que aumenta la conectividad entre el cuero cabelludo y los electrodos, los cuales son pasivos. La configuración de los electrodos es la siguiente: Fz, FC5, FC3, FC1, FCz, FC2, FC4,

FC6, C5, C3, C1, Cz, C2, C4, C6, CP5, CP3, CP1, CPz, CP2, CP4, CP6, P3, P1, Pz, P2, P4, PO7, PO3, POz, PO4, PO6. Vemos su posicionamiento en la Figura 16.




Figura 16: Disposición de los 32 electrodos según el sistema internacional 10/10. En azul el electrodo AFz que usaremos de tierra.

3.2 Método experimental

Las pruebas las han realizado cuatro voluntarios sanos entre 23 y 30 años (27 ± 3.6). Las pruebas se realizaron hace unos años ya que con motivo del COVID-19 no se han podido realizar nuevas pruebas. Los datos se dividen en registros de 10 cambios de dirección cada uno, a la elección del sujeto. Cada sujeto hacia pruebas en sesiones de 8 registros, haciendo un total de 80 cambios de dirección por sesión, cada una en distintos días. Cada registro se almacenará en una estructura de MATLAB llamada *session*. Esta estructura contiene la información de los 32 electrodos y de las 7 IMUs, el etiquetado de las tareas y la configuración utilizada.

Tabla 1: Sujetos, cantidad de registro y nomenclatura para el registro de cada sujeto

Sujeto	Cantidad registros	Nombre de la sesión
Sujeto 1	2 registros	S1.1
		S1.2
Sujeto 2	3 registros	S2.1
		S2.2
		S2.3
Sujeto 3	1 registro	S3.2
Sujeto 4	2 registros	S4.1
		S4.2

Como se puede ver en la Tabla 1, cada sujeto realizó dos sesiones, a excepción del Sujeto 2, que realizó 3. El Sujeto 3 también realizó 2, pero la señal de la primera era muy ruidosa y se tuvo que descartar ya que no se podían obtener datos fiables.

Cada cambio de dirección aparece como parte de una tarea. Cada tarea se compone de las siguientes etapas: sujeto parado, marcha, cambio de dirección, parada y rectificación de dirección hacia la posición original. Vemos este proceso en la Figura 17. En este estudio se analizará solo hasta el cambio de dirección marcado por las IMUs, extrayendo dos ventanas cuyo tamaño será una de las variables a estudiar. Estas dos ventanas corresponderán al intervalo de marcha y al intervalo previo al cambio de dirección, en busca de potenciales ERD.

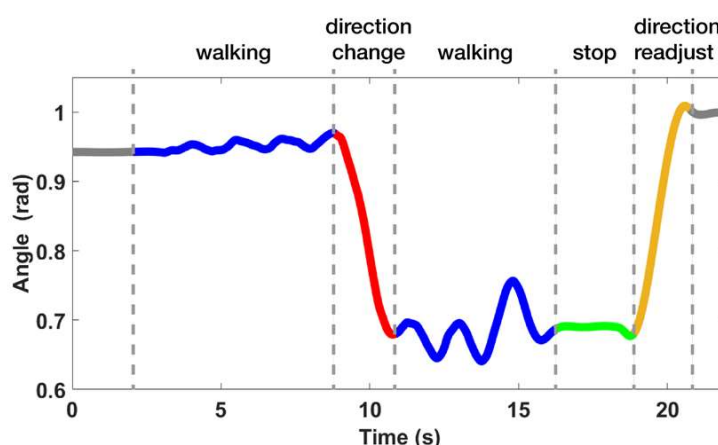


Figura 17: Señal IMU durante el procedimiento experimental. En azul, el usuario camina. En rojo, intervalo en el que el usuario cambia de dirección. En verde, el usuario para. En amarillo, rectificación y giro hacia la posición original.

3.3 Procesamiento

En este apartado nos centraremos en los pasos previos al análisis offline, concretamente en los diversos filtrados que recibe la señal previa a su clasificación mediante diversos métodos. Para ello nos fijaremos en la Figura 18 que es un esquema del proceso.

Esquemáticamente se puede resumir el proceso en la siguiente secuencia: primero, se deben cargar los 8 registros que forman una sesión. Posteriormente se procede al filtrado de la señal. Se han implementado unos filtros basados en variables de estado como previsión a una implementación en tiempo real. Los filtros implementados son un filtro laplaciano y un filtro paso banda. A continuación, se trata la señal de las IMUs en busca de los puntos donde el usuario cambia de dirección. A partir de estos puntos se recorta la señal EEG de forma que nos quedamos con los puntos en torno a este cambio de dirección calculado con las IMUs y separándolo en intervalos correspondientes a la clase walk y la clase cambio, según si el usuario estaba caminando o cambiando de dirección, en esta segunda pudiendo ser hasta unos instantes antes del giro para buscar potenciales ERD. Finalmente se extraen las características frecuenciales y temporales propias de estos segmentos, los cuales compararemos en el análisis offline en busca de relaciones que permitan la distinción en la validación cruzada.

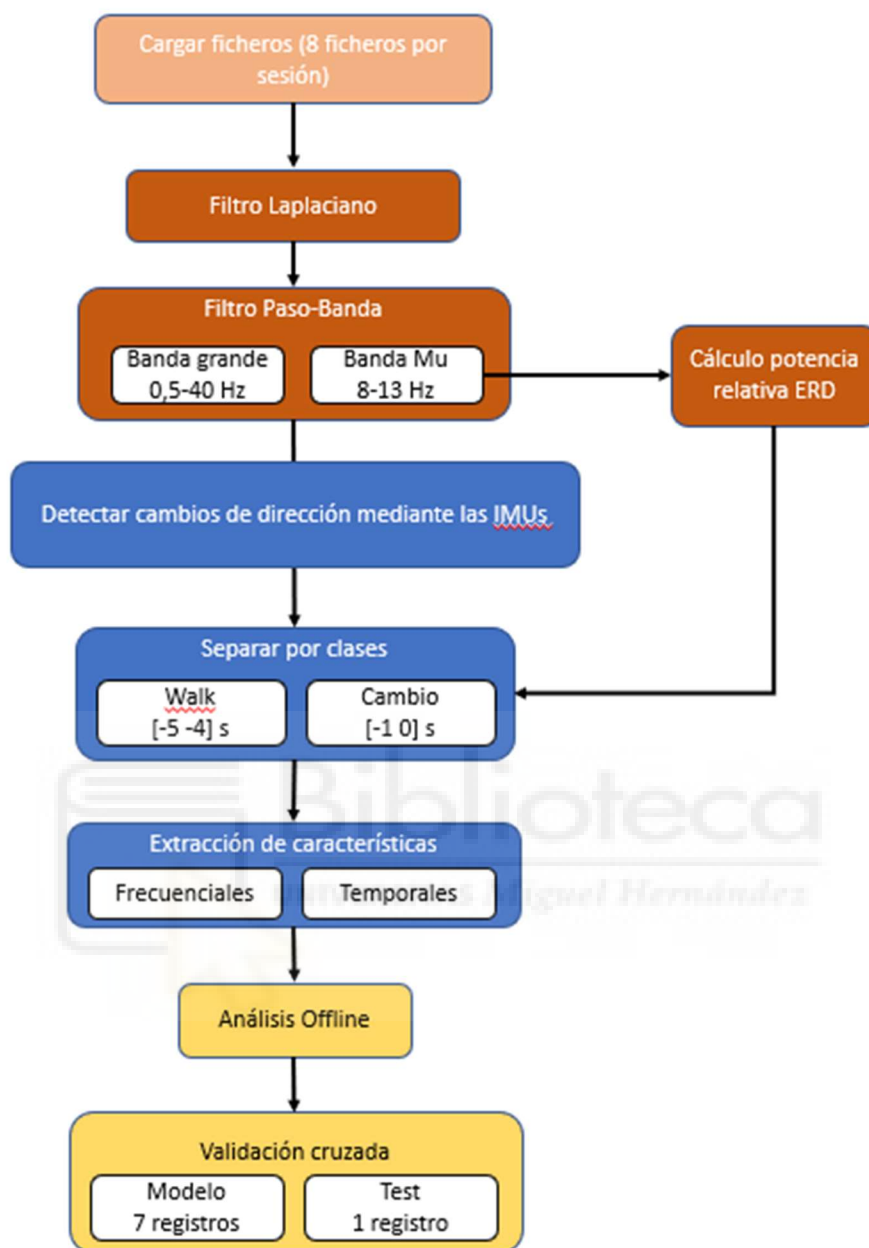


Figura 18: Esquema del preprocesado. En naranja, el filtrado de las señales. En azul, el proceso de obtención de características de cada clase y en amarillo el proceso de clasificación.

3.3.1 Cargar ficheros

Primeramente, se deben cargar los ficheros que contienen la información de cada registro de la experimentación. Esta información está contenida en una estructura llamada *session*, la cual contiene los datos EEG, los de las IMUs e información sobre la configuración utilizada (intervalos de la tarea, configuración de los electrodos y equipamiento

empleado). Recordemos que cada sesión está formada por 8 registros, por lo que a la hora de leer los datos se almacenan en una nueva variable que acumule todos los registros. Esto se realiza leyendo todos los registros que se encuentren en la carpeta ReadSession del path y reordenándolos en un nuevo *session* que será con el que trabajaremos.

3.3.2 Filtrado

En esta etapa encontramos dos filtros, un filtro laplaciano y un filtro paso-banda que nos permitirá trabajar con las señales para poder buscar esa diferenciación entre clases.

3.3.2.1 Filtro Laplaciano

Este es un filtro espacial, implementado mediante variables de estado, que permite reducir el ruido que se haya podido inducir en un electrodo por la proximidad del resto de los electrodos del casco. Para ello se realiza un bucle con los 32 electrodos por registro para filtrar la señal de cada uno de ellos.

Para ello se evalúa la distancia a la que se encuentra cada electrodo del resto, siendo los más cercanos los que teóricamente aportan un mayor ruido. Esta información de las distancias es uno de los parámetros que están guardados en *session* en forma de posición xy de cada electrodo. El proceso es el siguiente:

$$d_{ij} = \sqrt{(d_x)^2 + (d_y)^2} \quad (10)$$

$$g_{ij} = \frac{1 / d_{ij}}{\sum_{j \in S_i} 1 / d_{ij}} \quad (11)$$

$$ruido_{ij} = g_{ij} * V_j \quad (12)$$

$$V_i^{LAP} = V_i - \sum_{j \in S_j} ruido_{ij} \quad (13)$$

Donde d_{ij} es la distancia entre electrodos, g_{ij} el peso que tiene cada electrodo en la señal filtrada, V_j la potencia de la señal del electrodo cuyo ruido se quiere anular y $ruido_{ij}$ el ruido que se estima que cada electrodo proporciona a la señal. Finalmente, V_i^{LAP} es la señal filtrada [26].

3.3.2.2 Filtro Butterworth Paso-Banda

Tras el filtro laplaciano se utiliza un filtro Butterworth. Este filtro se ha implementado mediante variables de estado ya que se pretende implementar en ejecuciones online o pseudo-online. Este filtro está basado en los filtros analógicos básicos y proporcionan una ganancia unitaria hasta el punto de corte, donde la señal es filtrada. Esta propiedad hace que sea óptimo para mantener la señal intacta dentro de las frecuencias deseadas. En nuestro caso hemos necesitado dos filtros, uno para obtener la señal correspondiente entre 0.5 y 40 Hz y otro para obtener la señal entre 8 y 13 Hz (Banda MU). Con la primera obtendremos las características frecuenciales y con el segundo calcularemos los potenciales ERD.

Para cada filtro paso-banda se han utilizado dos filtros, uno paso-bajo y después paso-alto, ambos de orden 4. Un inconveniente que presentan estos filtros es que en la respuesta aparece una sobreoscilación en el régimen transitorio. En un principio la señal se separaba por tareas y después se aplicaba el filtro, dejando un tiempo para que la señal se estableciera y la oscilación se atenuara, sin embargo, a lo largo del estudio se descubrió que esta oscilación persistía y distorsionaba los resultados al hacer que en la clase walk tuviera parte de la distorsión que la distinguiera de la clase cambio. Es por ello que se ha optado por filtrar toda la señal primero y después separar entorno a los puntos de cambio de dirección.

3.3.3 Cálculo Potencia Relativa

El cálculo de la potencia relativa se realiza con el objetivo de encontrar los potenciales de desincronización relativos a un evento (ERD). Como se ha explicado en el apartado 2.1.3.2, estos potenciales motores surgen como respuesta a la intención de realizar un movimiento y se produce instantes antes de que ocurra, por lo que detectarlos es de gran interés.

La detección de estos potenciales puede ser muy complicada debido a la variabilidad de un sujeto a otro, o incluso en un mismo sujeto. El instante y el electrodo que lo detectan puede cambiar, además de que se puede ver enmascarado por otro potencial. En nuestro

caso pueden aparecer potenciales que provienen de la acción de andar, por lo que la dificultad en la detección aumenta.

Para calcular la potencia relativa lo primero de todo es obtener la envolvente de la señal de la banda Mu (8-13 Hz) mediante la transformada de Hilbert en valor absoluto. Posteriormente se suaviza para evitar los picos que puedan distorsionar los cálculos.

A continuación, se calcula la energía de la señal elevando al cuadrado cada muestra de la envolvente suavizada. Para calcular la potencia relativa se hace con respecto a una referencia del momento de relajación, en nuestro caso de la clase walk. Como se está caminando la energía oscila, por lo que se toma el valor medio de la ventana correspondiente a la clase walk. Por tanto, se quedaría la siguiente ecuación:

$$ERD_i(\%) = \frac{Energía_i - Referencia}{Referencia} * 100 \quad (14)$$

Para determinar si ha habido una bajada respecto a la media en el potencial se calcularán las características temporales de la señal de cada clase. Para que estas obtengan un resultado favorable es crucial que la etiqueta de las IMUs sea precisa, ya que sino el potencial ERD podría quedarse fuera de la ventana.

3.3.4 Detección cambio de dirección

En este apartado se expondrán los dos métodos para identificar el punto del cambio, el primero de ellos proviene de investigaciones anteriores y el segundo surge como un intento de detección más robusto ante la variabilidad en la detección y ruido que pueden tener las diversas IMUs dependiendo de su posicionamiento. Esto es crítico ya que una detección tardía o demasiado precoz puede provocar que en la ventana de la clase cambio no se encuentre el potencial ERD.

El primer método consiste en tratar la señal de la componente Xz de la IMU posicionada en el cuádriceps derecho. Este tratamiento consta de un remuestreo para pasar la señal de los 30 Hz en los que la señal originalmente se obtuvo a los 1200 Hz de la señal EEG. A continuación, se aplica un filtro Savitzky-Golay, también conocido como filtro S-Golay, de orden 3. Este es un filtro digital de tipo FIR suaviza la señal, reduciendo el ruido y picos que puedan dificultar la detección. El orden del filtro determina el grado de filtrado, cuanto menor es el orden mayor es el filtrado, aunque en cierta medida este filtro puede

ser contraproducente ya que deforma la señal. En este punto en el que se tiene la señal filtrada, se buscan los picos y se seleccionan los dos pares de picos consecutivos que tienen la mayor diferencia entre ellos, el primer par corresponde al cambio de dirección y el segundo a la rectificación. Se selecciona el primero de estos pares y se busca entre los valores un pico intermedio que se haya podido no detectar, el cual marcará el inicio del giro, como vemos en la Figura 20.




Figura 19: En naranja, la señal de la IMU remuestreada. En azul, la señal filtrada con el filtro S-Golay de orden 3.




Figura 20: Señal filtrada de una tarea. En morado los picos detectados. En verde el par de picos correspondiente al cambio de dirección. En rojo el punto intermedio que marca el cambio de dirección.

Este método tiene el inconveniente de que el filtrado deforma la señal, produciendo desfases de incluso 1 segundo, lo cual puede hacer que el etiquetado sea erróneo. Esto lo podemos apreciar en la Figura 21, un detalle de la Figura 19 donde se muestra el desfase entre los puntos donde se podría marcar el inicio del giro.




Figura 21: Detalle de la Figura 19. Entre el pico en la señal filtrada (azul) y la señal original (naranja) hay 700 muestras, aproximadamente 0.58 segundos.

Este desfase hace que surja la necesidad de buscar un segundo método que intente subsanar este defecto. Este método consiste en analizar la señal X_z de la IMU de la zona lumbar sin filtrar. Al utilizar la IMU de la zona lumbar el ruido se reduce y, por tanto, el filtrado no es necesario, evitando así posibles deformaciones de la señal. A continuación, se analizan los puntos de inflexión de cada tarea mediante una doble derivada. El punto del giro se determinará otra vez buscando aquellos puntos de inflexión cuya diferencia sea mayor, como se puede ver en la Figura 22. Además, también se realiza el mismo proceso con la señal del giroscopio del eje perpendicular al suelo en esta misma IMU, de manera que se detecta un punto similar y adicionalmente proporciona el punto inicial en el que se inicia la marcha.

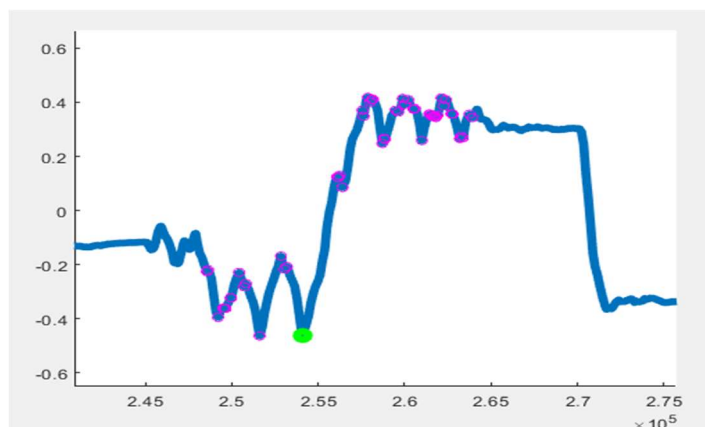


Figura 22: En azul, la señal de X_z de la IMU lumbar. Los puntos morados son los puntos de inflexión. El punto verde es el punto inicial del giro seleccionado.

3.4 Extracción de características

Tras obtener los instantes en los que se empieza a andar y cuando se cambia de dirección, se procede a la separación por clases en cada tarea y posteriormente a la obtención de las características de cada clase. Esto se realiza para 9 de las 10 tareas ya que la señal en la primera aún está afectada por los filtros. En posteriores experimentos se deberá tener en cuenta para evitar perder muestras ya que para este estudio no se han podido hacer nuevas pruebas.

3.4.1 Separación de señales por clases

En este proceso primero se separa en un intervalo de 12 segundos entorno al punto de cambio de dirección en cada tarea válida. Se seleccionarán 10 segundos antes del cambio y 2 después de la señal EEG. Posteriormente se seleccionan los intervalos para cada clase, en nuestro caso ambas tienen 1 segundo de duración, la clase walk entre 5 y 4 segundos antes y la clase cambio entre 1 segundo antes y el instante marcado como cambio de dirección.

3.4.2 Características frecuenciales

Este conjunto de características recibe este nombre de frecuenciales debido a que se obtienen como resultado de transformar la señal al dominio de la frecuencia. El objetivo es determinar la potencia que tiene cada frecuencia.

Para obtenerlo nos basamos en el análisis de la Transformada Rápida de Fourier mediante el cálculo de la densidad espectral de potencia (PSD: Power Spectral Density). Esta permite conocer la potencia correspondiente a cada frecuencia.

$$S_{xx}(\Omega) = \sum_{\tau=-\infty}^{\infty} R_{xx}[\tau] \cdot e^{-j\Omega\tau} \quad (15)$$

Para su cálculo recurriremos a la función pburg de Matlab. Esta obtiene la PSD mediante el método de Burg. Para ello se ha utilizado un paso de 0.5 Hz, desde 0 hasta 50 Hz.

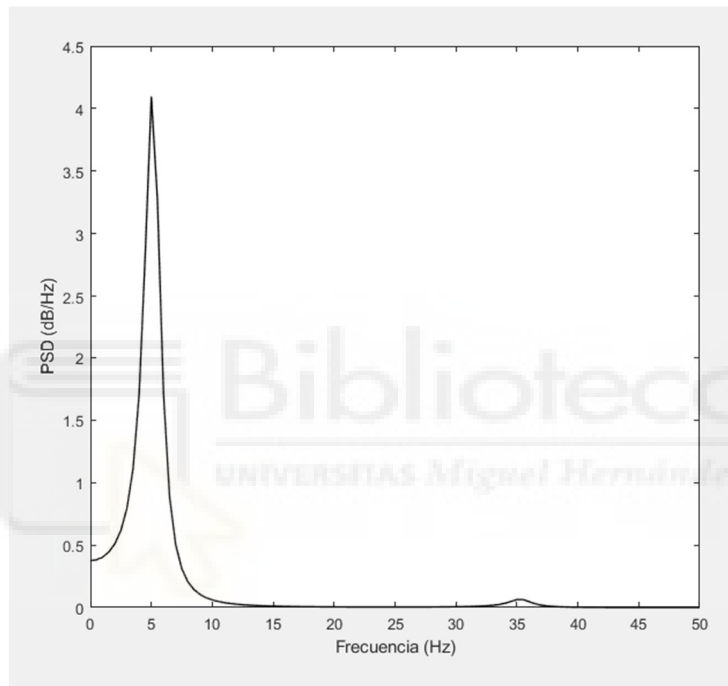


Figura 23: Representación de la PSD de una clase walk.

Como podemos ver en la Figura 23, la mayoría del potencial recae en las frecuencias más bajas, mayoritariamente en la banda Theta y Mu (4-7 Hz y 8-12 Hz respectivamente).

Las características temporales las consideraremos como la relación entre la potencia de las distintas bandas. Para este apartado usaremos las que se ven en la Tabla 2.

Tabla 2: Frecuencias empleadas para obtener las características frecuenciales

Banda de frecuencias PSD		
Banda	Inicio	Fin
Delta (δ)	0.5	3
Theta+Mu ($\theta + \mu$)	3	14
Beta (β)	14	40
Banda grande	0.5	40

Para obtener las características obtendremos dos valores de cada banda: el máximo y la suma de las potencias. Debido a la gran variabilidad que existe en una misma clase debido a factores ajenos a la tarea que queremos estudiar, como empezar a caminar o algún estímulo, se opta por normalizar las características respecto a los potenciales de las otras bandas. Por tanto, obtenemos las características de la Tabla 3.

Tabla 3: Características frecuenciales

Características temporales		
Relación entre bandas		
Bandas δ / μ	Bandas β / μ	Bandas β / δ
$\frac{\text{Sumatorio } \delta}{\text{Sumatorio } \mu} \cdot 100$	$\frac{\text{Sumatorio } \delta}{\text{Sumatorio } \mu} \cdot 100$	$\frac{\text{Sumatorio } \delta}{\text{Sumatorio } \mu} \cdot 100$
Porcentaje máximo bandas		
Bandas δ	Bandas μ	Bandas β
$\frac{\text{Máximo } \delta}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Máximo } \mu}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Máximo } \beta}{\text{Sumatorio Total}} \cdot 100$
Porcentaje sumatorio bandas		
Bandas δ	Bandas μ	Bandas β
$\frac{\text{Sumatorio } \delta}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Sumatorio } \mu}{\text{Sumatorio Total}} \cdot 100$	$\frac{\text{Sumatorio } \beta}{\text{Sumatorio Total}} \cdot 100$

El motivo de utilizar estas características reside en que se busca la diferenciabilidad en la misma señal, ya que los potenciales ERD surgen una diferencia entre el estado de reposo (clase walk) y la tarea (clase cambio). Por tanto, se espera que habrá un cambio en las características de ambas clases por esta diferencia en la potencia.

3.4.3 Características temporales

Este conjunto de características proviene de la señal EEG tras ser filtrada con los filtros Laplaciano y paso-banda entre 0.5 y 40 Hz en el dominio del tiempo, de ahí que sean características temporales.

Tabla 4: Características temporales extraídas.

Desviación EEG	Desviación en frecuencia	Desviación de Hilbert	Media valor absoluto	
Energía		Entropía de Wavelet		Yule Walker
Weibull parámetro 1	Weibull parámetro 2	Hjörth Actividad	Hjörth Movilidad	Hjörth Complejidad

En la Tabla 4 se muestran las características extraídas. A continuación, se explicarán una a una. Las primeras provienen de la desviación típica (S), la cual obtendremos mediante la función std de Matlab. La función sigue la siguiente ecuación:

$$S = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2} \quad (16)$$

Donde S es la desviación típica, A_i los componentes del vector a analizar, N la cantidad de valores que contiene el vector y donde μ es la media:

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \quad (17)$$

Esta desviación típica la obtendremos de tres señales: la señal EEG filtrada, la señal EEG transformada al dominio de la frecuencia mediante la FFT y la señal EEG aplicándole la transformada de Hilbert (función hilbert en Matlab). Así obtendríamos las tres primeras características temporales, aunque técnicamente no todas están en el dominio temporal, pero por simplicidad a la hora de agrupar se ha determinado así.

La siguiente es el Valor Medio Absoluto (MAV), que consiste en obtener el valor absoluto de todos los valores y después obtener su media:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_j| \quad (18)$$

También se obtiene la energía de la señal (SSI). Es un cálculo parecido al utilizado para la potencia relativa, pero esta vez obtendremos la suma de sus componentes.

$$SSI = \sum_{i=0}^N x_i^2 \quad (19)$$

El siguiente parámetro a estudiar es la entropía. Para calcularlo recurriremos a los fundamentos de Wavelet de descomponer la señal en tramos para evaluar el desorden y variaciones que se pueden encontrar en la señal. Para ello utilizaremos la función wentropy de Matlab. Esta función tiene varios métodos de ejecución, pero se ha optado por la entropía de tipo 'log energy' que sigue la siguiente ecuación:

$$WE = \sum_{i=1}^N \log (s_i^2) \quad (20)$$

Donde s es la señal analizada y WE es la entropía total calculada.

A continuación, se calcula de nuevo el valor PSD, pero esta vez aplicando la transformada Yule-Walker, la cual calcula el valor PSD de manera autorregresiva, es decir, considera los instantes previos de la señal para calcular la potencia. Para ello se ha utilizado la función `pyulear` de Matlab, la cual tiene como argumentos la señal y el orden del modelo autorregresivo. En nuestro caso el orden del modelo será 3.

A continuación, se hace un análisis estadístico mediante el cálculo de los Parámetros de Weibull, obtenidos a partir de la distribución estadística de Weibull. Estos dos se calculan mediante la función `wblfit` de Matlab y representan la estimación de la probabilidad de la distribución estadística. Esta distribución se representa mediante la siguiente ecuación:

$$f(x|\lambda, k) = \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-\left(\frac{x}{\lambda}\right)^k} \quad (21)$$

Donde k y λ son los parámetros calculados y que formaran parte del vector de características.

Las últimas tres características son los Parámetros de Hjörth. Son otros parámetros estadísticos que hacen referencia a la señal en el dominio del tiempo. Estos son Actividad (A_x), Movilidad (M_x) y Complejidad (C_x). Estas representan respectivamente la varianza de una función temporal, la desviación media de la potencia de la señal y la similaridad respecto a una señal senoidal. Para calcularlas se han implementado las siguientes operaciones en Matlab:

$$A_x = \text{var}(y(t)) \quad (22)$$

$$M_x = \frac{\text{std}(\dot{y}(t))}{\text{std}(y(t))} \quad (23)$$

$$C_x = \frac{M_x(\dot{y}(t))}{M_x(y(t))} \quad (24)$$

Este conjunto de características hace un total de 12, lo cual, sumadas a las 9 frecuenciales, hace que contemos con 21 características por electrodo y clase, es decir, tenemos 672 valores en cada tarea para decidir a qué clase pertenece una tarea. Ante tantos datos resulta necesario un método para obtener que electrodos y características son óptimos para la clasificación e implementación de un sistema online o pseudo-online.

3.5 Clasificación

Una vez obtenidas las características de cada clase se tendrá que decidir a ciegas a que clase pertenecen estas características, ya que todo este proceso tiene como objetivo detectar la intención de giro en tiempo real. Para ello utilizaremos una serie de clasificadores, es decir, unos algoritmos de Machine Learning que dados una serie de datos de entrenamiento decidirán a que clase pertenece otra serie distinta de datos. En nuestro caso utilizaremos dos: un clasificador de Máquina de Soporte de Vectores (SVM) y K Vecinos Más Cercanos (KNN).

Estos algoritmos nos permitirán analizar similitudes y discrepancias entre clases. La eficacia de estos clasificadores depende de la diferenciación de los datos y la cantidad de estos. Recordemos que inicialmente contamos con 672 características por clases, lo cual pueden ser demasiados ya que no todos ayudan a seleccionar la clase adecuada y será necesario realizar un descarte de ciertas características y electrodos. Este es el objetivo del análisis offline, analizar los datos tras las pruebas e identificar cuáles pueden ser las mejores características para cada usuario. Posteriormente se debería analizar en tiempo real. Esta opción a veces es costosa o difícil de implementar debido a situaciones ajenas a las investigaciones, por lo que se suele recurrir a un análisis pseudo-online donde los datos se suministran al algoritmo de adquisición de datos como si se tratara de tiempo real, permitiendo una simulación del proceso. Esto es altamente recomendable para probar nuevos métodos sin necesidad de realizar experimentación.

3.5.1 Clasificadores

Como se ha explicado anteriormente, los clasificadores son algoritmos que pueden ser entrenados a partir de una serie de pares de datos de entrada y salida para que al introducir datos devuelva la salida deseada según el entrenamiento, es decir, el algoritmo aprende según unos datos a devolver la respuesta deseada, aunque como el proceso consiste en la estimación de una función puede dar lugar a fallos. Este concepto forma parte de las

técnicas de Machine Learning y se denomina aprendizaje supervisado. En nuestro caso las salidas son 0 y 1, haciendo referencia a las clases walk y cambio respectivamente, y la entrada es el vector de características. Hay una amplia variedad de algoritmos, pero nosotros solo usaremos dos de ellos para ver cuál puede ser mejor: SVM y KNN.

3.5.1.1 SVM

Una Máquina de Vectores de Soporte, más conocida como SVM por sus siglas en inglés (Support Vector Machine) genera un hiperplano en forma de superficie de decisión, de manera que separa dos regiones que corresponderá a cada clase [27]. Cabe destacar que este método solo se puede utilizar con clases binarias, es decir, solo hay dos clases. Un espacio multidimensional con una gran cantidad de características dificultará la generación de la superficie de decisión, por lo que es recomendable que la cantidad de características sea reducida. Vemos un ejemplo gráfico en la Figura 24.

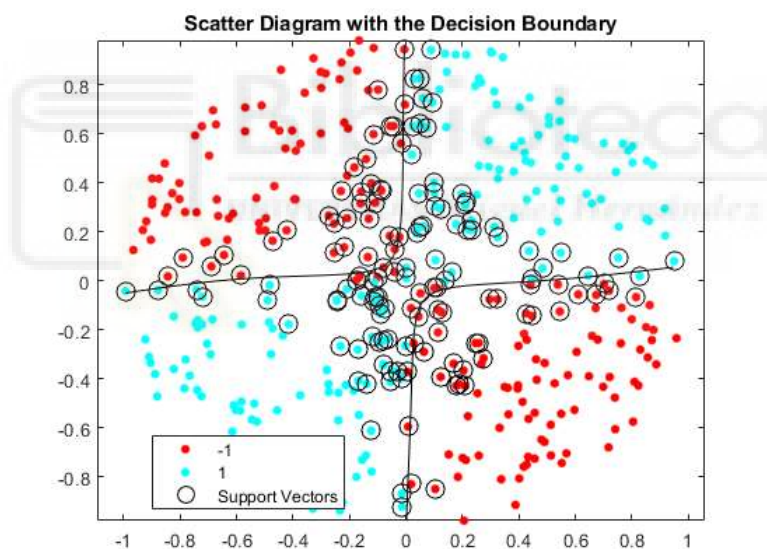


Figura 24: Ejemplo de clasificador SVM. En azul y en rojo las dos clases, separadas por una línea que representa el hiperplano de decisión [27].

3.5.1.2 KNN

El algoritmo de los K-Vecinos Más Cercanos (K-Nearest Neighbors) básicamente compara el punto deseado con los K puntos de entrenamiento más cercanos dentro del espacio multidimensional, tomando como salida la clase que tenga más puntos cercanos, siendo K un entero positivo que introduciremos como entrada [28]. La precisión de este algoritmo se puede ver afectada por la presencia de características irrelevantes, ya que se

les dará la misma importancia que al resto de características, por lo que deberán ser descartadas. En nuestro caso usaremos un KNN con $K=5$.




Figura 25: Ejemplo de KNN. Tenemos dos clases, los puntos rojos y los azules, y queremos clasificar el punto verde. Si $K=3$, será de clase roja. Pero si $K=5$, la clase será azul [29].

Como podemos ver en la Figura 25, la elección de K puede ser determinante y debe adaptarse a la cantidad de puntos que se le suministren al clasificador.

3.5.2 Análisis Offline

Para el análisis offline se ha establecido un proceso de validación cruzada donde se introducen los 8 registros en un bucle donde sucesivamente se compara un registro al modelo generado por los otros 7. Cada registro está compuesto por 9 tareas en vez de 10, ya que la primera tarea se ve descartada por los filtros que la deforman. Cada una de estas tareas contiene dos clases, walk y cambio, compuestas a su vez por el vector de 672 características. En resumen, contamos con 72 tareas, donde cada una se comparará con un modelo creado con 126 vectores de características, la mitad de clase walk y la otra mitad de clase cambio. Tras esto se obtendrá la clase estimada con el modelo. El objetivo es que la cantidad de aciertos de las clases estimada respecto a las clases reales sea máxima, para lo cual se tendrán que descartar características y electrodos. Una vez obtenida la selección de electrodos y características óptima, se trabajará con él en el análisis pseudo-online.

Para estimar la eficacia del proceso obtenemos los siguientes valores de la comparación de las clases obtenidas del modelo y de las clases que deberían haberse obtenido:

$$\text{Precisión} = \frac{\text{Total de aciertos}}{\text{Total de eventos}} \quad (26)$$

$$TP_{\text{walk}} = \frac{\text{Total de aciertos de clase walk}}{\text{Total de eventos de clase walk}} \quad (27)$$

$$TP_{\text{cambio}} = \frac{\text{Total de aciertos de clase cambio}}{\text{Total de eventos de clase cambio}} \quad (28)$$

$$FP_{\text{walk}} = \text{Total de eventos de clase walk} - \text{Total de aciertos de clase walk}$$

$$FP_{\text{cambio}} = \text{Total de eventos de clase cambio} - \text{Total de aciertos de clase cambio} \quad (29)$$

El primer valor, Precisión, hace referencia a la eficacia total del clasificador. Después tenemos los valores de verdadero positivo (TP) que hace referencia a los aciertos por clase y los falsos positivos (FP) que hacen referencia a los errores en el clasificador. Estos valores se obtienen para cada clase para comprobar que los resultados están equilibrados.

3.5.2.1 Selección de electrodos y características

Hemos visto que los métodos de clasificación puede que no soporten una cantidad tan grande de características o que estas afecten a su rendimiento y, por lo tanto, surge la necesidad de reducir el número de estas. Para ello se ha diseñado un algoritmo en el que primero se valora individualmente la precisión de cada electrodo para cada usuario. Posteriormente se determinan las características que individualmente obtienen un mejor resultado a partir de una selección de electrodos de tamaño variable. En ambos casos utilizando un clasificador KNN con K=5, ya que con SVM y tantas características se obtienen peores resultados. Por tanto, agrupamos los mejores electrodos y las mejores características para estos electrodos. La cantidad de cada uno será una variable a estudiar en busca de las mejores combinaciones. También se intentó utilizar el algoritmo ReliefF, el cual obtiene una puntuación para cada característica dependiendo de si ayudan a predecir la clase en un clasificador KNN con acierto, pero la selección era muy variable y se obtenían resultados peores que los obtenidos con el método finalmente implementado.

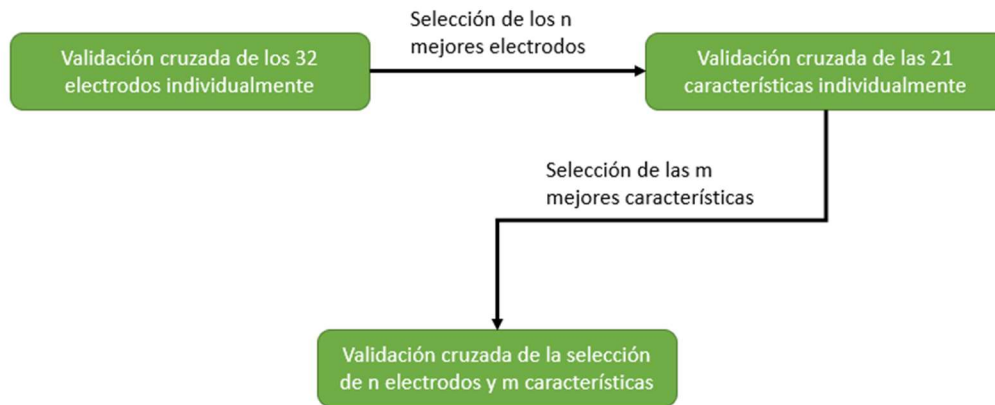


Figura 26: Proceso de selección de los mejores electrodos y las mejores características para esta selección.

Como se puede ver en la Figura 26, en el proceso primero se hace una validación cruzada con cada electrodo tomando sus 21 características. A continuación, se determina la cantidad n de electrodos a seleccionar, tomando los que han obtenido los mejores resultados, y se realiza una validación cruzada tomando cada una de las características a evaluar de estos n electrodos. Finalmente, la selección final estará formada por los n electrodos elegidos y las m mejores características. Se buscará, por tanto, la mejor combinación de estos.

3.5.3 Análisis Pseudo-Online

El concepto de análisis pseudo-online se centra en simular la adquisición de datos real e ir analizando la señal conforme se adquiere. Para ello se ha elaborado un algoritmo que filtra la señal original con los filtros de variables de estados mencionados anteriormente con un paso que simula la adquisición real, en nuestro caso 0,1 segundos o 120 muestras (con una frecuencia de muestreo de 1200 Hz), y se obtienen las características de la señal filtrada en ventanas de 1 segundo. Esta ventana se desplaza con el paso, es decir, cada 0,1 segundos se analiza la información de los últimos 1200 datos. Estos datos se analizan con el clasificador seleccionado, en nuestro caso KNN con $K=5$, con el modelo offline generado. Este modelo offline proviene del análisis offline, utilizando para sesión los cuatro primeros registros para el modelo y los otros cuatro se utilizarán para el análisis pseudo-online.

Para comprobar la validez del modelo hay que clasificar la salida del análisis, ya que obtenemos una gran cantidad de respuestas. Para aumentar la fiabilidad de estas se han agrupado en paquetes de 3 respuestas, de las cuales se obtiene la moda y esta será la respuesta válida para este paquete. Posteriormente se considerará como cambio aquellos que tengan una respuesta cambio 3 veces seguidas. Se considerará un verdadero positivo (TP) si hay un cambio en las últimas 2 respuestas antes del cambio y se considerará un falso positivo (FP) todos aquellos que se encuentren entre el inicio a caminar y el inicio de la ventana de cambio. Para comprobar la eficacia de los análisis online (o pseudo-online en nuestro caso) se comprueba la cantidad de falsos positivos por unidad de tiempo para facilitar su comparación.

$$FP_{walk/min} = \frac{\text{Total de detecciones cambio en intervalo walk}}{\text{Duración del intervalo (minutos)}}$$

También se ha realizado este mismo procedimiento, pero aplicando una moda de 5 y la condición de que los 5 valores anteriores tengan una respuesta cambio para considerarlo un cambio.



Capítulo 4. Resultados y discusión

En este capítulo se expondrán los diversos resultados obtenidos durante el proceso de mejora en la detección de la intención de giro mediante señales EEG. Para ello se expondrán los resultados obtenidos paso a paso durante el proceso y las decisiones tomadas a partir de estos hasta llegar a los resultados finales. Posteriormente, en el siguiente capítulo, se obtendrán las conclusiones a partir de estos resultados finales.

4.1 Análisis offline

En este apartado se valorará la progresión de los diversos métodos empleados para mejorar la detección del cambio de dirección para la creación del modelo que utilizaremos para el análisis pseudo-online.

4.1.1 Mejora en detección mediante IMUs

Como se ha comentado previamente en el apartado 3.3.4, en la detección física del cambio de dirección se han implementado cambios para que esta sea más precisa. En las Tablas 5 y 6 se muestran la precisión medio de cada sesión y la media total, respectivamente, de la validación cruzada mediante KNN con $k = 5$ y todas las características.

Tabla 5: Comparación de la precisión de la detección EEG utilizando el etiquetado de cambio de dirección anterior y el nuevo usuario a usuario. También se muestra la diferencia de tiempo entre ambas.

	IMU original	IMU nueva	$\Delta T(s)$
S1.1	53,5 ± 5,9	63,9 ± 8,9	-0,2 ± 0,6
S1.2	54,9 ± 12,4	66,0 ± 9,6	0,0 ± 0,6
S2.1	50,7 ± 8,1	62,5 ± 11,8	-1,2 ± 2,1
S2.2	81,3 ± 5,9	64,6 ± 6,6	-1,3 ± 1,9
S2.3	59,7 ± 11,8	68,1 ± 13,5	-1,7 ± 2,8
S3.2	54,9 ± 3,6	55,6 ± 7,9	-0,2 ± 0,6
S4.1	49,3 ± 10,0	57,6 ± 13,6	-0,5 ± 1,1
S4.2	72,9 ± 10,0	54,9 ± 10,5	-1,7 ± 2,8
Media	58,8 ± 7,9	61,5 ± 10,0	-0,9 ± 1,3

Como se puede ver en la Tabla 5, se aprecia una mejoría sesión a sesión, aunque en la media no se aprecie tanto ya que en las sesiones S2.2 y S4.2 se obtuvieron muy buenos resultados en el sistema original. Además, también se ve la diferencia de tiempos entre una detección nueva y la detección anterior (ΔT).

Tabla 6: Comparación de la precisión de la detección EEG utilizando el etiquetado de cambio de dirección anterior y el nuevo.

	IMU original	IMU nuevo
VP walk (%)	56,3± 15,8	60,1± 15,6
FP walk	3,9± 1,4	3,6± 1,4
VP cambio (%)	63± 17,5	63,2± 18,2
FP cambio	3,3± 1,6	3,3± 1,6
Precisión (%)	59,6± 8,5	61,6± 10,3

Este cambio surge con la hipótesis de que la deformación de la señal de las IMUs era lo suficientemente significativa como para evitar que el cambio de dirección entrara dentro de la ventana de 1 segundo, ya que la diferencia entre los dos métodos supone tiempos de hasta 1 segundo o más como se puede ver en la Tabla 5, por lo que la deformación puede provocar que el etiquetado deje el cambio de dirección fuera del trozo de señal a analizar. El nuevo método utiliza la señal sin filtro, de manera que esta deformación no se da. Como se puede apreciar hay una mejora con solo cambiar el etiquetado, aportando una mayor precisión entre etiquetados, por lo que será el que utilizaremos a partir de ahora para la experimentación.

4.1.2 Selección de electrodos y características

En este apartado se mostrarán los resultados de la selección de electrodos y características explicado en el apartado 3.5.2.1, especificando la selección con mejores resultados y el proceso para llegar a estos. Antes de probar con los electrodos con mejores resultados se probó con una selección de electrodos en base a las zonas donde se esperaba una mayor actividad: todos los electrodos, sólo zona motora (Figura 27) y zona motora, premotora y occipital (Figura 28).




Figura 27: Selección de electrodos de la zona motora. En amarillo la selección de electrodos y en azul el electrodo de tierra

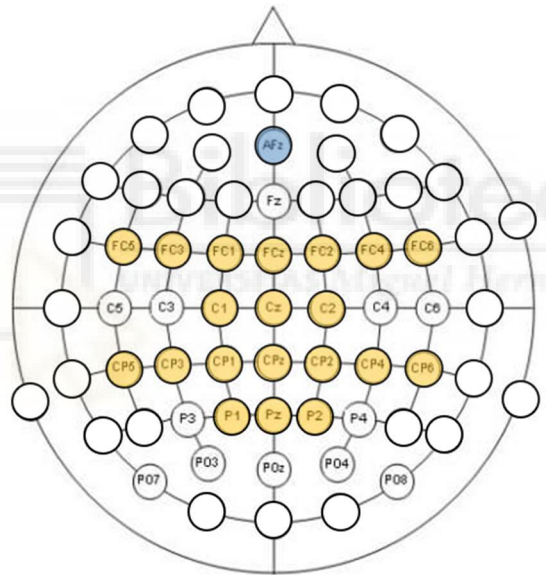


Figura 28: Selección de electrodos de la zona motora, occipital y premotora. En amarillo la selección de electrodos y en azul el electrodo de tierra

Tabla 7: Resumen de los resultados de las pruebas de la selección de electrodos de la zona motora y de la zona motora, premotora y occipital.

	Zona Motora KNN	Zona Motora, Premotora y Occipital KNN	Zona Motora SVM	Zona Motora, Premotora y Occipital SVM
VP walk (%)	54,5± 18,9	59,7± 15	63,5± 25,9	74,1± 24,6
FP walk	4,1± 1,7	3,6± 1,3	3,3± 2,3	2,3± 2,2
VP cambio (%)	60,2± 17,7	59,7± 16,9	37,7± 25,7	30,6± 27,5
FP cambio	3,6± 1,6	3,6± 1,5	5,6± 2,3	6,3± 2,5
Precisión (%)	57,4± 10,9	59,7± 9,6	50,6± 9	52,3± 6,5

A partir de los resultados de la Tabla 7 se pueden sacar dos conclusiones, la primera es que el clasificador SVM no funciona bien con tantos datos, obteniendo una gran tasa de falsos positivos en la clase cambio, por lo que sería recomendable disminuir la cantidad de características. Por otro lado, vemos que los resultados de la zona motora son peores que los de la zona motora, premotora y occipital, por lo que surge la hipótesis de que hay algunos electrodos que tienen una mayor diferenciación en sus características. Para ello evaluaremos electrodo a electrodo para buscar aquellos con mejor resultado para cada usuario. Antes de esta prueba por electrodos se ha realizado una prueba parecida a la anterior pero esta vez distinguiendo entre características frecuenciales y temporales.

Tabla 8: Precisión media del análisis con características frecuenciales con tres selecciones de electrodos: todos los electrodos, electrodos de la zona motora y electrodos de la zona motora, premotora y occipital.

	Características temporales					
	Todos los electrodos		Zona Motora		Zona Motora, Premotora y Occipital	
	KNN	SVM	KNN	SVM	KNN	SVM
VP walk (%)	61,8± 18,8	81,4± 26,2	55,6± 19,5	65,8± 25,7	66,5± 13,0	76± 23,5
FP walk	3,4± 1,7	1,7± 2,4	4,0± 1,8	3,1± 2,3	3,0± 1,2	2,2± 2,1
VP cambio (%)	59,7± 22,2	22,6± 26,5	56,1± 19,8	37,3± 28,6	52,6± 15,1	28,8± 26,5
FP cambio	3,6± 2,0	7,0± 2,4	4,0± 1,8	5,6± 2,6	4,3± 1,4	6,4± 2,4
Precisión (%)	60,8± 10,0	52,0± 5,8	55,8± 11,0	51,6± 10,0	59,5± 8,0	52,4± 6,2

Tabla 9: Precisión media del análisis con características temporales con tres selecciones de electrodos: todos los electrodos, electrodos de la zona motora y electrodos de la zona motora, premotora y occipital.

	Características frecuenciales					
	Todos los electrodos		Zona Motora		Zona Motora, Premotora y Occipital	
	KNN	SVM	KNN	SVM	KNN	SVM
VP walk (%)	53± 19,3	58,7± 18,9	49,7± 19,6	54,5± 20,0	56,3± 15,1	58,9± 18
FP walk	4,2± 1,7	3,7± 1,7	4,5± 1,8	4,1± 1,8	3,9± 1,4	3,7± 1,6
VP cambio (%)	68,1± 18,7	58,2± 19,0	58,7± 17,4	59,4± 17,9	63,0± 20,3	58,9± 17,8
FP cambio	2,9± 1,7	3,8± 1,7	3,7± 1,6	3,7± 1,6	3,3± 1,8	3,7± 1,6
Precisión (%)	60,5± 10,8	58,4± 10,9	54,2± 11,7	56,9± 11,3	59,6± 12,1	58,9± 12,0

En las Tablas 8 y 9 se ven los resultados medios con varias selecciones de electrodos y con una asignación de características divididas por tipo: temporales y frecuenciales. Se puede ver que con el clasificador KNN no hay una gran mejora, sin embargo, con el clasificador SVM sí que se aprecia una mejora considerable al reducirse las características, pero solo con las características frecuenciales, con resultados bastante

similares entre clases. Con las características temporales los resultados no salen balanceados, viendo que la cantidad de falsos positivos en la clase cambio es demasiado alta. A continuación, aplicaremos el método descrito en el apartado 3.5.2.1, donde primero analizaremos los electrodos que obtienen mejores resultados y posteriormente analizaremos que características funcionan mejor para una selección de estos electrodos. Finalmente se comprobarán para ver si esta combinación de mejores electrodos y mejores características mejoran los resultados, aunque nos encontramos ante el problema de que cantidad de electrodos y características utilizar. Para determinar la selección de estos se harán una serie de pruebas para buscar los mejores resultados, aunque puede que no sean los óptimos ya que los tiempos de computación son muy altos y no se han podido probar todas las combinaciones.

Se han seguido dos procesos, primero la selección de los mejores electrodos y características por usuario, es decir, a partir de la media de todas las sesiones por usuario; y después la selección por sesión para ver cuál puede ser mejor.

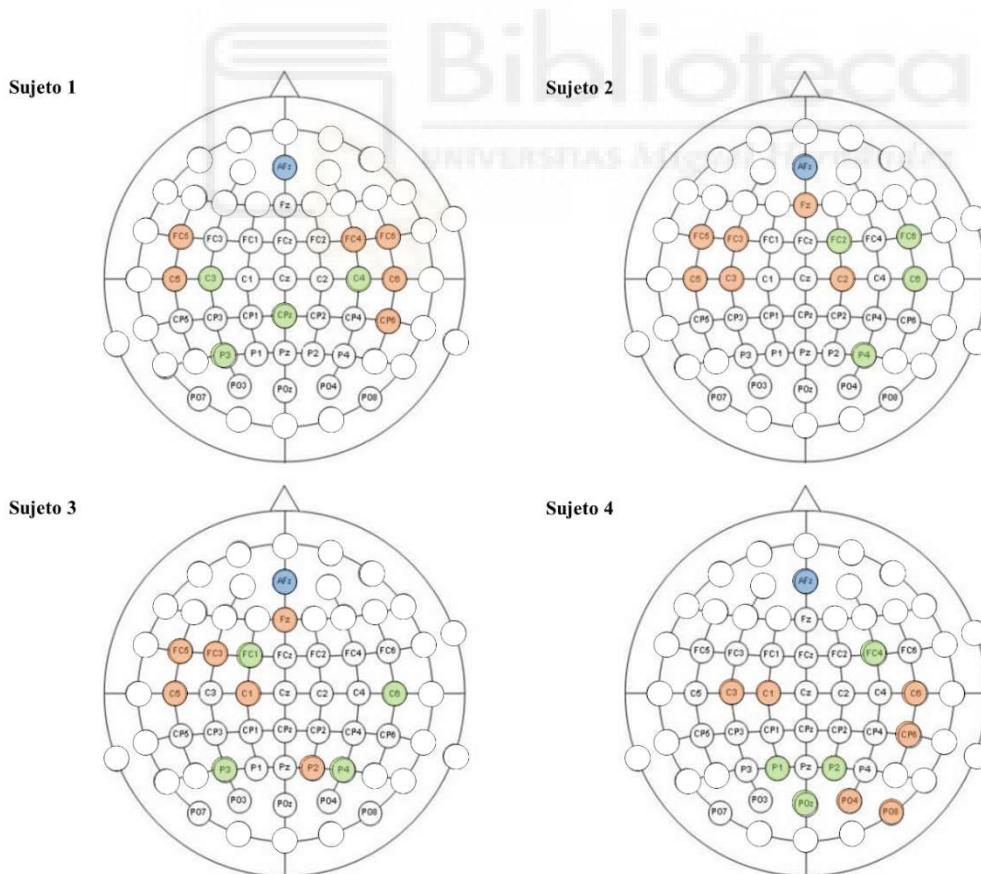


Figura 29: Selección de electrodos por sujeto. En rojo, los 6 electrodos con mejores resultados. En verde, ampliación hasta los mejores 10 electrodos. En azul, el electrodo de tierra.

Tabla 10: Electrodo más relevantes por usuario. También se muestra la media de todos los sujetos.

	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 4	Media
FZ	-	4	5	-	7
FC5	3	1	4	-	2
FC1	-	-	7	-	-
FCZ	-	-	-	-	-
FC2	-	8	-	-	-
FC6	5	9	-	9	6
C3	8	5	-	1	3
CZ	-	-	-	-	-
C4	7	-	-	-	10
CP5	-	-	-	-	-
CP1	-	-	-	-	-
CP2	-	-	-	-	-
CP6	2	-	-	5	8
P3	-	-	9	-	-
PZ	-	-	-	-	-
P4	-	7	10	-	-
PO7	-	-	-	-	-
PO3	10	-	-	-	-
PO4	-	-	-	2	-
PO8	-	-	-	3	-
FC3	-	3	2	-	4
FC4	4	-	-	7	-
C5	1	6	1	-	1
C1	-	-	3	4	-
C2	-	2	-	-	9
C6	6	10	8	6	5
CP3	-	-	-	-	-
CPZ	9	-	-	-	-
CP4	-	-	-	-	-
P1	-	-	-	10	-
P2	-	-	6	-	-
POZ	-	-	-	8	-

Tabla 11: Características más relevantes para 5 electrodos por usuario. También se muestra la media de todos los sujetos.

	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 4	Media
Bandas δ / μ	-	-	-	-	-
Bandas β / μ	10	10	8	-	8
Bandas β / δ	-	1	7	9	5
Máximo Banda δ	-	-	-	2	-
Máximo Banda μ	-	-	-	-	-
Máximo Banda β	-	3	-	5	10
Sumatorio Banda δ	-	-	-	3	-
Sumatorio Banda μ	-	-	4	-	-
Sumatorio Banda β	7	4	6	-	4
Desviación EEG	3	8	-	6	6
Desviación frecuencia	2	7	1	10	2
Desviación Hilbert	4	9	-	7	7
Media Valor Absoluto	9	-	9	-	-
Energía	1	5	2	4	1
Entropía de Wavelet	-	6	10	-	-
Yule Walker	-	-	-	8	-
Weibull Parámetro 1	8	2	-	-	9
Weibull Parámetro 2	-	-	-	-	-
Parámetro Hjörth: Actividad	5	-	-	-	-
Parámetro Hjörth: Movilidad	6	-	3	1	3
Parámetro Hjörth: Complejidad	-	-	5	-	-

En la Figura 29 vemos la agrupación de los electrodos más relevantes para cada sujeto, tomando la media de las sesiones de cada uno de ellos para ello. A continuación, se mostrarán los resultados medios en la Tabla 12.

Tabla 12: Precisión media de todos los usuarios de la selección de electrodos y características por usuario.

	KNN				SVM			
	Características				Características			
	3	5	7	9	3	5	7	9
2 electrodos	64,5± 11,2	63,1± 12,3	62,8± 11,7	62,8± 11,8	58,4± 12,2	56,7± 11,9	50,2± 11,3	51,2± 12,5
3 electrodos	65,9± 10,6	65,0± 11,5	65,0± 11,3	65,7± 11,2	51,5± 13,4	50,4± 10,6	48,6± 11,9	49,1± 10,9
4 electrodos	66,3± 10,2	66,4± 10,4	64,7± 10,4	64,8± 10,4	55,4± 9,7	57,9± 11,7	54,2± 8,4	54,7± 9,8
5 electrodos	65,5± 10,5	65,8± 9,1	65,6± 8,7	65,7± 8,7	58,6± 10,3	51,2± 9,3	50,2± 8,5	51,9± 8,8
6 electrodos	64,8± 9,2	66,8± 9,4	65,6± 9,8	65,7± 9,8	61,0± 9,4	60,8± 10,5	53,0± 7,6	52,7± 7,7

En las Tablas 10 y 11 se muestran los electrodos y las características más relevantes para cada usuario, y adicionalmente se muestran aquellos que tienen una media total mayor en todas las sesiones. Analizando los electrodos con mayor actividad en la Tabla 10, parece que en todos los casos se activa el electrodo FC5 o los electrodos cercanos. Analizando las características con más relevancia en la Tabla 11, las características temporales tienen una mayor presencia, destacando la Energía, la Movilidad y la Desviación en frecuencia. Como se puede ver en la Tabla 12 hay una mejora en la precisión del clasificador KNN, respecto al resultado original el nuevo método de detección de IMUs (61,6%), gracias a la selección de características y electrodos, obteniendo un máximo de 66,8% con una desviación típica de 9,4, siendo el resultado de ambas clases considerablemente balanceado, aunque conforme aumenta la cantidad de características empleadas el clasificador SVM obtiene valores más desequilibrados. Este método permitiría que de un día a otro se pudiera tener una selección ya preparada de cara a la experimentación. Por otro lado, también se ha comprobado si una selección para cada sesión permitiría mejores resultados, lo cual se muestra a continuación.






Tabla 13: Electrodo más relevantes por sesión de pruebas.

	S1.1	S1.2	S2.1	S2.2	S2.3	S3.2	S4.1	S4.2
FZ	-	-	3	10	6	5	-	-
FC5	1	3	4	4	1	4	-	-
FC1	-	-	-	-	9	7	-	-
FCZ	-	-	-	-	-	-	-	-
FC2	-	-	-	6	-	-	7	-
FC6	3	10	-	-	-	-	10	7
C3	2	-	1	7	-	-	2	-
CZ	-	-	-	1	-	-	-	-
C4	9	6	6	-	-	-	-	-
CP5	-	-	-	-	-	-	-	-
CP1	-	-	7	-	-	-	-	-
CP2	-	-	-	-	-	-	-	-
CP6	6	2	-	-	-	-	3	-
P3	-	8	-	-	-	9	-	1
PZ	-	-	10	-	-	-	-	-
P4	10	-	5	-	-	10	-	-
PO7	-	-	-	-	-	-	-	-
PO3	-	5	-	-	7	-	-	-
PO4	-	-	-	-	8	-	4	3
PO8	-	-	-	-	2	-	1	-
FC3	-	-	8	3	4	2	8	-
FC4	4	4	-	-	-	-	-	4
C5	-	1	-	2	-	1	9	-
C1	-	-	-	-	-	3	6	6
C2	-	-	2	5	3	-	-	8
C6	5	7	-	-	5	8	5	9
CP3	-	-	9	8	-	-	-	-
CPZ	8	9	-	-	-	-	-	-
CP4	7	-	-	-	-	-	-	-
P1	-	-	-	-	-	-	-	5
P2	-	-	-	9	-	6	-	10
POZ	-	-	-	-	10	-	-	2

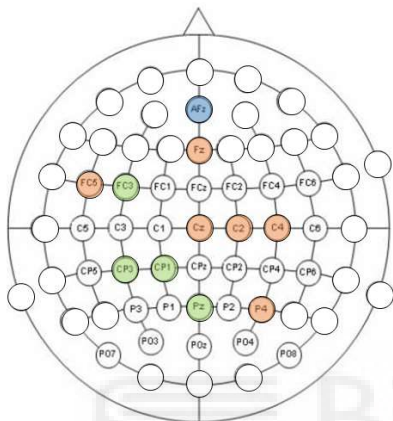
S1.1




S1.2




S2.1




S2.2




S2.3



S3.2



S4.1



S4.2




Figura 30: Selección de electrodos por sesión. En rojo, los 6 electrodos con mejores resultados. En verde, ampliación hasta los mejores 10 electrodos.

En la Figura 30 y en la Tabla 13 se muestran los mejores electrodos según el proceso de selección, donde destaca de nuevo la importancia del electrodo FC5 y los cercanos a este. Si evaluamos conjuntamente las sesiones de un mismo sujeto, se puede apreciar que en ambas sesiones del sujeto 1 se activan la zona del electrodo FC5 y la del FC6, lo cual coincide con los resultados de la prueba anterior por sujetos. En el sujeto 2, también se ve marcado el electrodo FC5 y parte de la zona prefrontal y sensorimotora, también coincidiendo con los resultados por sujetos. El sujeto 3 también tiene activa la zona prefrontal, pero con más relevancia la zona cercana a FC5. En este caso solo hay una sesión, por lo que obtienen los mismos resultados que el análisis por sujeto. Finalmente, el sujeto 4 obtiene unos resultados más variados, destacando el electrodo C1, PO4 y C6, obteniéndose esta vez también zonas parecidas que en el análisis por sujetos. A continuación, se muestran las características más relevantes (Tabla 14) y los resultados con diversas combinaciones (Figuras de la 31 a la 40).

Tabla 14: Características más relevantes por sesión para los 5 mejores electrodos.

	S1.1	S1.2	S2.1	S2.2	S2.3	S3.2	S4.1	S4.2
Bandas δ / μ	-	-	-	-	8	-	-	-
Bandas β / μ	9	-	-	6	-	8	-	-
Bandas β / δ	10	2	7	8	-	7	9	-
Máximo Banda δ	-	-	8	-	-	-	2	2
Máximo Banda μ	-	-	9	5	-	-	-	-
Máximo Banda β	-	-	3	-	-	-	5	-
Sumatorio Banda δ	-	-	-	-	-	-	3	-
Sumatorio Banda μ	-	-	-	1	-	4	-	-
Sumatorio Banda β	5	3	-	7	9	6	-	-
Desviación EEG	2	7	10	2	1	-	6	10
Desviación frecuencia	6	4	2	10	5	1	10	4
Desviación Hilbert	3	8	-	3	2	-	7	-
Media Valor Absoluto	-	6	-	-	10	9	-	3
Energía	7	1	1	9	-	2	4	5
Entropía de Wavelet	-	-	-	-	4	10	-	1
Yule Walker	-	5	-	-	-	-	8	-
Weibull Parámetro 1	-	9	-	-	3	-	-	7
Weibull Parámetro 2	-	-	-	-	-	-	-	-
Parámetro Hjörth: Actividad	1	-	4	4	7	-	-	9
Parámetro Hjörth: Movilidad	4	10	5	-	-	3	1	6
Parámetro Hjörth: Complejidad	8	-	6	-	6	5	-	8




Figura 31: Precisión utilizando los 2 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.




Figura 32: Precisión utilizando los 2 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.

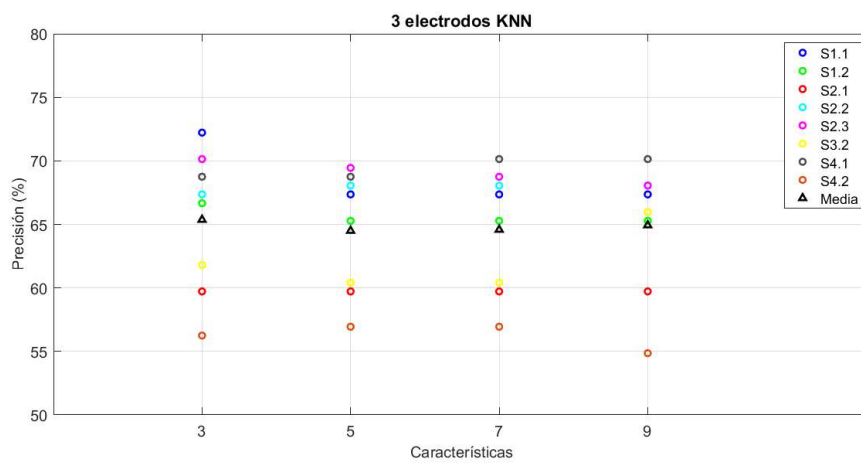


Figura 33: Precisión utilizando los 3 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.




Figura 34: Precisión utilizando los 3 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.




Figura 35: Precisión utilizando los 4 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.




Figura 36: Precisión utilizando los 4 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.

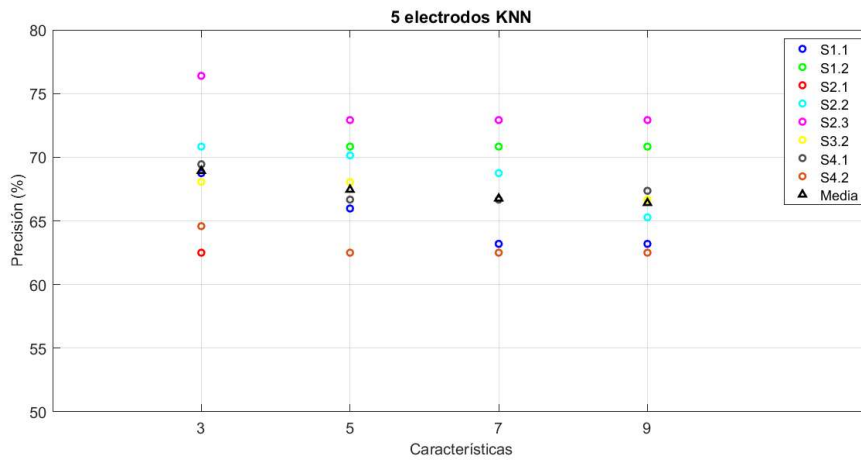


Figura 37: Precisión utilizando los 5 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.




Figura 38: Precisión utilizando los 5 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.




Figura 39: Precisión utilizando los 6 mejores electrodos, clasificador KNN y 3,5,7 o 9 características más relevantes.

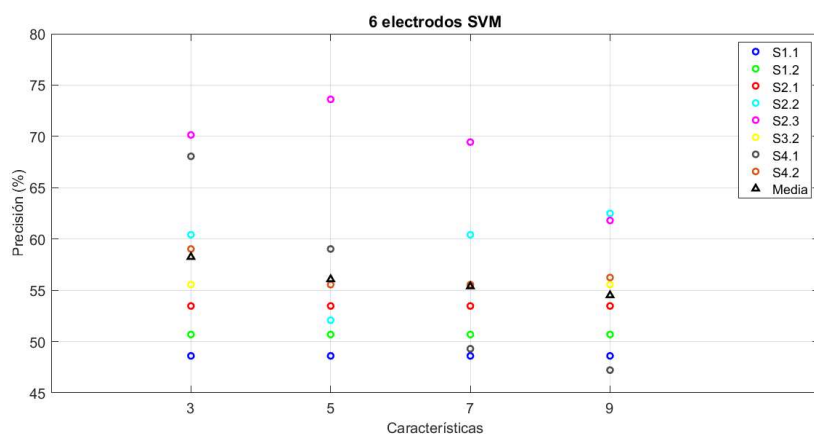


Figura 40: Precisión utilizando los 6 mejores electrodos, clasificador SVM y 3,5,7 o 9 características más relevantes.

En las características, en la Tabla 14 volvemos a apreciar que las características temporales suelen obtener mejores resultados, siendo las mejores la Energía, la Desviación en frecuencia, la Desviación temporal (EEG), la Desviación de Hilbert y los Parámetros de Hjörth (Actividad y Movilidad), coincidiendo en gran parte con el análisis por sujetos.

Tabla 15: Resultados medios de la selección de electrodos y características por sesión.

	KNN				SVM			
	Características				Características			
	3	5	7	9	3	5	7	9
2 electrodos	64,5± 10,0	64,1± 10,5	63,4± 11,1	63,5± 10,7	57,2± 12,4	53,9± 12,1	56,2± 12,4	55,9± 14,1
3 electrodos	65,4± 10,5	64,5± 11,1	64,6± 10,6	64,9± 11,1	60,5± 12,4	57,6± 9,8	53,0± 14,6	52,4± 11,2
4 electrodos	68,4± 11,2	67,5± 10,4	66,2± 9,5	66,1± 9,3	53,7± 11,5	55,6± 12,1	57,5± 10,4	53,6± 12,1
5 electrodos	68,9± 9,0	67,4± 8,9	66,8± 7,7	66,4± 7,9	63,1± 10,5	56,0± 9,5	54,3± 9,4	54,3± 8,9
6 electrodos	66,8± 8,8	66,6± 8,9	67,0± 8,9	66,6± 8,6	58,2± 8,7	56,1± 8,6	55,4± 8,4	54,5± 9,7

Respecto a los resultados, de la Figura 31 a la Figura 40 podemos ver los resultados por sesión y el valor medio para las diversas combinaciones probadas. Si nos fijamos en la Tabla 15, la cual muestra la media de cada combinación, con el clasificador KNN se observa una mejora de los 59.6% de media en la precisión del proceso original hasta el 68.9% que se obtiene de la combinación de 5 electrodos y 3 características. Se puede

apreciar que la tendencia es que al seleccionar más característica los resultados no mejoran, sin embargo, al ampliar la cantidad de electrodos sí que mejoran, siendo el máximo 5 electrodos. Con estos resultados es interesante acotar la cantidad de características entre 12 y 25, obteniéndose mejores resultados con 4 o 5 electrodos. Este método de selección por sesión ha obtenido unos resultados mejores que la selección por usuario

Este método ha obtenido unos resultados considerablemente mejores con el clasificador KNN que con el clasificador SVM ya que se ha utilizado el primero para la selección. Con SVM se obtenían resultados demasiado variables para la selección, por lo que se descartó realizar una selección de características en base al clasificador SVM.

Finalmente, para el análisis pseudo-online se utilizará un clasificador KNN con K=5, los mejores 5 electrodos y las mejores 3 características para cada sesión. Los resultados de esta combinación es la siguiente:

Tabla 16: Comparativa de la selección final con la selección inicial.

	Selección características y electrodos					Todas las características y electrodos	
	TP walk (%)	FP walk	TP cambio (%)	FP cambio	TP total (%)	IMU original	IMU nueva
S1.1	77,8 ± 13,3	2,0 ± 1,2	59,7 ± 21,4	3,6 ± 1,9	68,8 ± 10,3	53,5 ± 5,9	63,9 ± 8,9
S1.2	68,1 ± 17,3	2,9 ± 1,6	73,6 ± 22,2	2,4 ± 2,0	70,8 ± 10,2	54,9 ± 12,4	66,0 ± 9,6
S2.1	59,7 ± 16,7	3,6 ± 1,5	65,3 ± 17,3	3,1 ± 1,6	62,5 ± 5,8	50,7 ± 8,1	62,5 ± 11,8
S2.2	62,5 ± 23,7	3,4 ± 2,1	79,2 ± 12,5	1,9 ± 1,1	70,8 ± 12,9	81,3 ± 5,9	64,6 ± 6,6
S2.3	80,6 ± 16,5	1,8 ± 1,5	72,2 ± 16,8	2,5 ± 1,5	76,4 ± 4,9	59,7 ± 11,8	68,1 ± 13,5
S3.2	62,5 ± 28,4	3,4 ± 2,6	73,6 ± 15,6	2,4 ± 1,4	68,1 ± 9,7	54,9 ± 3,6	55,6 ± 7,9
S4.1	65,3 ± 12,5	3,1 ± 1,1	73,6 ± 13,2	2,4 ± 1,2	69,4 ± 6,6	49,3 ± 10,0	57,6 ± 13,6
S4.2	56,9 ± 23,3	3,9 ± 2,1	72,2 ± 10,3	2,5 ± 0,9	64,6 ± 11,9	72,9 ± 10,0	54,9 ± 10,5
Media	66,2 ± 18,3	2,9 ± 1,6	70,9 ± 15,7	2,5 ± 1,4	68,8 ± 8,6	58,8 ± 7,9	61,5 ± 10,0

Como se puede ver en la Tabla 16, el nuevo sistema de IMUs más la selección de características y electrodos ha obtenido una gran mejora (10%) respecto al sistema original con todas las características y también respecto al nuevo sistema de IMUs pero con todas las características (7,3% de mejora, además de reducir la desviación típica ligeramente).

4.2 Análisis pseudo-online

Para el análisis pseudo-online hemos utilizado la combinación de 5 electrodos y 3 características, ya que previamente ha sido la combinación que ha obtenido mejores resultados. Adicionalmente, se ha empleado una ventana de análisis de 1 segundo que avanza con un paso de 0,1 segundo, como se explica en el apartado 3.5.3. El clasificador empleado ha sido KNN con $K=5$ y las características empleadas son las mostradas en la Tabla 17:

Tabla 17: Características y electrodos empleados para el análisis pseudo-online.

	Electrodos	Características
S1.1	FC5, C3, FC6, FC4, C6	Actividad, Desviación EEG, Desviación de Hilbert
S1.2	FC5, CP6, PO3, FC4, C5	Energía, Sumatorio Banda β , Bandas β / δ
S2.1	Fz, FC5, C3, P4, C2	Energía, Desviación frecuencia, Máximo Banda β
S2.2	FC5, Cz, FC3, C5, C2	Sumatorio Banda μ , Desviación EEG, Desviación Hilbert
S2.3	FC5, PO6, FC3, C2, C6	Desviación EEG, Desviación Hilbert, Weibull Parámetro 1
S3.2	Fz, FC5, FC3, C5, C1	Desviación frecuencia, Energía, Movilidad
S4.1	C3, CP6, PO4, PO6, C6	Movilidad, Máximo Banda δ , Sumatorio Banda δ
S4.2	P3, PO4, FC4, P1, POz	Entropía de Wavelet, Máximo Banda δ , Media Valor Absoluto




Figura 41: Ejemplo de detección del análisis pseudo-online. En negro, la señal IMU. En verde, el inicio a caminar. En rojo, la detección del giro. En azul, un margen de 1,5 segundos que marca la separación de la zona cambio y la zona walk. Las cruces azules son la salida del análisis: 0 walk, 1 cambio.

Para crear el modelo con el que compararemos la ventana, se utilizaran los 4 primeros registros de cada sesión, descartándose el primer giro ya que la sobreoscilación que produce el filtrado de la señal impide poder utilizarlo. Tampoco se contará en el análisis pseudo-online. Finalmente, se analizarán los 4 últimos registros de cada sesión.

Durante la realización de estas pruebas surgieron problemas con la adquisición de características, obteniendo valores muy superiores para algunas de las características a pesar de usar las mismas funciones y configuración, provocando que la respuesta del clasificador fuera siempre 1 o 0 en una misma prueba, excepto en las de S1.1. Ya que sus características eran relevantes en la mayoría de los sujetos, se ha optado por utilizar sus características para todos, pero manteniendo los electrodos.

En la Figura 41 vemos un ejemplo de detección, aunque también hay dos falsos positivos, los cuales se dividirán entre el tiempo transcurrido en la zona walk (entre la línea verde y la azul) para obtener los FP/min. Como el tiempo en este intervalo es tan corto, se obtienen resultados muy altos.

Tabla 18: Resultados del análisis pseudo-online.

	Moda 3 valores		Moda 5 valores	
	Aciertos (%)	FP/min	Aciertos (%)	FP/min
S1.1	69,4 ± 46,7	29,2 ± 6,1	-	-
S1.2	72,2 ± 45,4	36,3 ± 6,1	-	-
S2.1	97,2 ± 16,7	57,3 ± 13,6	63,9 ± 48,7	33,7 ± 15,9
S2.2	94,4 ± 23,2	36,5 ± 4,2	47,2 ± 50,6	17,8 ± 9,8
S2.3	94,4 ± 23,2	40,8 ± 10,3	58,3 ± 50	33,1 ± 3,7
S3.2	83,3 ± 37,8	28,4 ± 13,5	52,8 ± 50,6	22,2 ± 12,1
S4.1	97,2 ± 16,7	41,7 ± 2,7	83,3 ± 37,8	50 ± 6,3
S4.2	36,1 ± 48,7	2,5 ± 1,8	-	-
Media	80,6 ± 32,3	34,1 ± 7,3	-	-
Media común	93,2 ± 22,4	39,9 ± 7,3	59,9 ± 47,3	29,4 ± 8,5

Los resultados del análisis de pueden ver en Tabla 18. Se realizó primero un análisis completo tomando la moda de 3 valores y además debían aparecer 3 resultados seguidos cambio para marcar un cambio. También se ha hecho para 5 valores, pero debido a los largos tiempos de computación no se ha podido realizar todas las sesiones. Es por ello que aparece la fila “Media común” donde se realiza la media de las sesiones S2.1, S2.2, S2.3, S3.2 y S4.1, ya que son de las que tenemos registros analizados con ambas

metodologías y así se pueden comparar. En el análisis con 3 valores en la moda, la cantidad de aciertos es considerablemente alta, llegando en algunos casos superior al 90% como los sujeto 2 y la sesión S4.1, aunque con una gran cantidad de FP/min. El sujeto 3 ha obtenido la mejor cantidad de aciertos respecto a la cantidad de FP/min. La sesión ha obtenido una cantidad de acierto muy baja, pero con una cantidad de FP/min más baja. Esta cantidad tan alta de FP/min son a causa de los cortos intervalos de tiempo que se evalúan (entre 8 y 10 segundos) donde hay una cantidad bastante alta de respuestas. Si lo comparamos con el otro método de 5 valores, vemos que agrupándolo disminuye la cantidad de aciertos, pero también baja significativamente la cantidad de FP/min.

Por tanto, es importante buscar una manera robusta de agrupar la respuesta del clasificador y también será necesario reforzar este análisis mediante la obtención robusta de características, explorar la posibilidad de utilizar nuevos clasificadores o una selección distinta de electrodos y características.





Capítulo 5. Conclusiones y trabajos futuros

Para finalizar, en este capítulo evaluaremos los resultados y se propondrán futuras líneas de investigación a raíz de los resultados obtenidos.

Para detectar el cambio de dirección se ha realizado un análisis de las señales EEG, en el cual se han probado diversos métodos para clasificar las señales de dos clases distinta: en una el sujeto se encuentra caminando y en otra decide cambiar de dirección. Para realizar esta clasificación se han obtenido una serie de características provenientes de 32 electrodos. También se ha evaluado diversos métodos para detectar el cambio de dirección, demostrando que aplicar ciertos filtros puede afectar al instante en el que se detecta, provocando una detección inexacta. El cambio de un sistema de detección a otro provocaba errores de 0,9 segundos de media entre ambos etiquetados. Esto se puede ver en los resultados, ya que se ha pasado de un 58,8% en la precisión de la detección EEG a un 61,5%.

Para que el funcionamiento de los clasificadores sea óptimo, se deben seleccionar las características más relevantes en los electrodos con mayor diferencia en su actividad, entre la que destaca el electrodo FC5. Entre las características destacan las denominadas temporales, especialmente la Energía, la Desviación en frecuencia, la Desviación de Hilbert y los Parámetros de Hjörth (Actividad y Movilidad). Haciendo una selección de mejores electrodos y características para cada sesión se ha conseguido pasar de un 61,5% de media a un 68,8% en la precisión de la detección.

En el análisis pseudo-online se han obtenido unos resultados buenos de detección del giro, con un 80,6%, aunque con una gran tasa de FP/min, lo cual impide realizar pruebas en tiempo real con pacientes.

5.1 Trabajos futuros

Este trabajo forma parte de un proyecto que tiene como objetivo diseñar una BMI completa que dé respuesta a tres tareas: detección de obstáculos, cambio de velocidad y cambio de dirección, por lo que trabajar en su implementación conjunta será necesario para su buen funcionamiento.

En futuras investigaciones de esta rama de detección del cambio de dirección, será crucial realizar más pruebas en las que probar estos métodos para comprobar su eficacia, ya que para este trabajo se han utilizado un número limitado de registros anteriores debido a la situación del COVID-19. Además, sería recomendable la aplicación de un algoritmo más potente que evalúe la mejor combinación de electrodos y características teniendo en cuenta todas las combinaciones posibles. También probar un mayor número de clasificadores en busca de uno que diferencie mejor entre clases, probando incluso redes neuronales o algoritmos similares. Finalmente, se deberá implementar un sistema que distinga la dirección en el cambio, ya que es posible que se activen distintas zonas del cerebro, permitiendo una detección más clara, pero requiriendo clasificadores no binarios.

También se deberán realizar nuevas pruebas en tiempo real para validar los procedimientos y poder aplicarlo con pacientes.

Sin embargo, la mejoría respecto a métodos anteriores implica que una BMI que permita tanto la asistencia como el apoyo durante la rehabilitación puede estar más cerca.



Bibliografía

- [1] World Health Organization (WHO). (19 de Noviembre de 2013). Obtenido en la página web: <https://www.who.int/es/news-room/fact-sheets/detail/spinal-cord-injury> . Último acceso el 07/07/20.
- [2] Leon-Sarmiento, F. E., Bayona-Prieto, J., & Cadena, Y. (2008). Plasticidad neuronal, neurorehabilitación y trastornos del movimiento: el cambio es ahora. *Acta Neurol Col*, 24, 40-2.
- [3] Johansson, B. B. (2004). Brain plasticity in health and disease. *The Keio journal of medicine*, 53(4), 231-246.
- [4] Farris, R. J., Quintero, H. A., Murray, S. A., Ha, K. H., Hartigan, C., and Goldfarb, M. (2014). A preliminary assessment of legged mobility provided by a lower limb exoskeleton for persons with paraplegia. *IEEE Transactions on neural systems and rehabilitation engineering*, 22(3), 482-490.
- [5] Mao, Y., Jin, X., Dutta, G. G., Scholz, J. P., and Agrawal, S. K. (2015). Human movement training with a cable driven ARm EXoskeleton (CAREX). *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(1), 84-92.
- [6] Wodlinger, B., Downey, J. E., Tyler-Kabara, E. C., Schwartz, A. B., Boninger, M. L., and Collinger, J. L. (2014). Ten-dimensional anthropomorphic arm control in a human brain-machine interface: difficulties, solutions, and limitations. *Journal of neural engineering*, 12(1), 016011.
- [7] Abiri, R., Borhani, S., Sellers, E. W., Jiang, Y., & Zhao, X. (2019). A comprehensive review of EEG-based brain-computer interface paradigms. *Journal of neural engineering*, 16(1), 011001.
- [8] Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of neural engineering*, 15(3), 031005.
- [9] Ang, K. K., & Guan, C. (2013). Brain-computer interface in stroke rehabilitation.

- [10] Abhang, P. A., Gawali, B. W., & Mehrotra, S. C. (2016). Introduction to EEG-and speech-based emotion recognition. Academic Press.
- [11] Cipresso, P., Carelli, L., Solca, F., Meazzi, D., Meriggi, P., Poletti, B., ... & Riva, G. (2012). The use of P300-based BCIs in amyotrophic lateral sclerosis: from augmentative and alternative communication to cognitive assessment. *Brain and behavior*, 2(4), 479-498.
- [12] Salazar-Gomez, A. F., DelPreto, J., Gil, S., Guenther, F. H., & Rus, D. (2017, May). Correcting robot mistakes in real time using EEG signals. In 2017 IEEE International Conference on Robotics and Automation (ICRA) (pp. 6570-6577). IEEE.
- [13] Lemm, S., Müller, K. R., & Curio, G. (2009). A generalized framework for quantifying the dynamics of EEG event-related desynchronization. *PLoS Comput Biol*, 5(8), e1000453.
- [14] Mulder, T. (2007). Motor imagery and action observation: cognitive tools for rehabilitation. *Journal of neural transmission*, 114(10), 1265-1278.
- [15] Rodríguez-Ugarte, M., Iáñez, E., Ortiz, M., and Azorín, J. M. (2017). Personalized offline and pseudo-online BCI models to detect pedaling intent. *Frontiers in neuroinformatics*, 11, 45.
- [16] Dávila, J. A. V., Macías, J. V., & Lamas, M. V. (2017). Videojuegos basados en BCI (Interface cerebro computadora): Revisión Sistemática Literaria. *Programación Matemática y Software*, 9(2), 10-23.
- [17] Elvira, M., Iáñez, E., Quiles, V., Ortiz, M., & Azorín, J. M. (2019). Nuevos métodos para la detección de obstáculos inesperados durante la marcha normal a través de señales EEG. In XL Jornadas de Automática (pp. 55-62). Universidade da Coruña, Servizo de Publicacións.
- [18] Zamora, V. Q., Iáñez, E., Ortiz, M., & Azorín, J. M. (2019, November). Estudio preliminar de la detección de cambios de velocidad de la marcha a partir de señales EEG. In 11 Simposio CEA de Bioingeniería.

- [19] Ortiz, M., Contreras-Vidal, J. L., & Azorín, J. M. Can Creativity be Assessed? Your Brain on Art, When Art and Science Meet.
- [20] Aisen, M. L., Krebs, H. I., Hogan, N., McDowell, F., & Volpe, B. T. (1997). The effect of robot-assisted therapy and rehabilitative training on motor recovery following stroke. *Archives of neurology*, 54(4), 443-446.
- [21] Gopura, R. A. R. C., Bandara, D. S. V., Kiguchi, K., & Mann, G. K. (2016). Developments in hardware systems of active upper-limb exoskeleton robots: A review. *Robotics and Autonomous Systems*, 75, 203-220.
- [22] Rodríguez-Ugarte, M., Angulo-Sherman, I. N., Iáñez, E., Ortiz, M., & Azorín, J. M. (2017, November). Preliminary study of pedaling motor imagery classification based on EEG signals. In *2017 International Symposium on Wearable Robotics and Rehabilitation (WeRob)* (pp. 1-2). IEEE.
- [23] Ortiz, M., Rodriguez-Ugarte, M., Ianez, E., & Azorin, J. M. (2019). Analysis of Algorithms for Detection of Pedaling Intention in Brain-Machine Interfaces. *REVISTA IBEROAMERICANA DE AUTOMATICA E INFORMATICA INDUSTRIAL*, 16(2), 222-231.
- [24] Technaid S.L. (jun 2014). Manual de Usuario Sistema de Captura de Movimiento Tech-MCS V.3.0.
- [25] WIT Motion. Gyroscope Bluetooth Version BWT901CL.
- [26] Lu, J., McFarland, D. J., & Wolpaw, J. R. (2012). Adaptive Laplacian filtering for sensorimotor rhythm-based brain-computer interfaces. *Journal of neural engineering*, 10(1), 016002.
- [27] MathWorks “Support Vector Machines for Binary Classification” (2020). Obtenido en la página web: <https://es.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html?lang=en> . Último acceso el 07/07/20.
- [28] MathWorks “Classification KNN” (2020). Obtenido en la página web: <https://es.mathworks.com/help/stats/classificationknn.html?lang=en> . Último acceso el 07/07/20.

[29] Wikipedia “K-Nearest Neighbors Algorithm” (2020). Obtenido en la página web: https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm . Último acceso el 07/07/20.

