

UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE
ESCUELA POLITÉCNICA SUPERIOR DE ELCHE
GRADO EN INGENIERÍA ELECTRÓNICA Y
AUTOMÁTICA INDUSTRIAL



“MEJORAS EN LA DETECCIÓN DE LA APARICIÓN
INESPERADA DE UN OBSTÁCULO DURANTE LA
MARCHA MEDIANTE SEÑALES CEREBRALES”

TRABAJO DE FIN DE GRADO

Septiembre - 2020

AUTOR: Ramón Fontelles Congost

DIRECTOR/ES: Eduardo Iáñez Martínez

Vicente Quiles Zamora



RESUMEN

El objetivo del presente trabajo consiste en seguir mejorando un sistema BMI que permita detectar la aparición de un obstáculo inesperado mientras el sujeto se encuentra en marcha normal, a partir de señales EEG. También haremos uso de las IMUs durante la etapa de desarrollo, el objetivo es intentar reducir la tasa de falsos positivos por minuto con respecto a trabajos anteriores, ya que la finalidad del proyecto consiste en usar este BMI en un exoesqueleto para la rehabilitación de pacientes con problemas motrices.

Tras probar un nuevo sistema de detección para las IMUs y después de probar diferentes combinaciones para la selección de electrodos, incluir un método de selección automático de características, usar varios clasificadores en serie y añadir un nuevo algoritmo de selección para la clase que pertenece a la parada, se han obtenido unos resultados ligeramente superiores comparados con estudios anteriores.

Finalmente, se ha buscado una selección de *train/test* adecuado y se ha buscado una combinación óptima que maximizase los resultados para 5 ficheros de entrenamiento y otros 5 de test, con un porcentaje promedio final de $39,5 \pm 18,1$ y una tasa de *FP/min* de $5,1 \pm 2,2$ con la configuración personalizada para cada usuario.



AGRADECIMIENTOS

En primer lugar, me gustaría dar las gracias a Eduardo Iáñez Martínez y a Vicente Quiles Zamora por darme la oportunidad de participar en este proyecto y la confianza depositada en mí, además de todo el apoyo y dedicación que me han prestado en todo momento.

En segundo lugar, me gustaría dar las gracias a mi familia por haber estado siempre ahí, apoyándome en todos los pasos que he ido dando en mi vida hasta llegar a donde estoy ahora.

Por último, me gustaría dar las gracias también a todos mis amigos por haber estado ahí en todo momento y por la enorme paciencia que ello puede conllevar a veces.



Índice General

RESUMEN.....	III
AGRADECIMIENTOS	V
Capítulo 1. Introducción.....	1
1.1. Motivación	2
1.2. Objetivos	2
1.3. Estructura de la memoria.....	3
Capítulo 2. Estado del arte	5
2.1. Electroencefalografía	5
2.2. Lóbulos cerebrales.....	7
2.3. Sistema 10-10 y 10-20.....	9
2.4. Potenciales relacionados con eventos.....	10
2.4.1. Potencial relacionado con la aparición de un obstáculo	11
2.5. Interfaces Cerebro-Máquina.....	13
2.5.1. Adquisición de datos	14
2.5.2. Preprocesado.....	15
2.5.3. Extracción de características.....	15
2.5.4. Clasificación.....	15
2.6. Aplicaciones de las BMI.....	16
Capítulo 3. Materiales y métodos.....	19
3.1. Equipamiento.....	19
3.1.1. IMUs	19
3.1.2. Equipo de medición EEG	22
3.2. Método experimental	23
3.3. Método de detección de paradas IMUs	25
3.3.1. Detección automática de la parada con la función findchangepts	25
3.3.2. Preprocesado señales IMU.....	27
3.4. Procesamiento.....	29

3.4.1. Preprocesamiento	30
3.4.2. Selección de electrodos	31
3.4.3. Extracción automática de características.....	33
3.4.4. Clasificadores.....	36
3.4.4.1. SVM.....	36
3.4.4.2. LDA	37
3.4.5. Selección de ventanas	38
3.4.5.1. Selección de ventanas para la clase 1.....	39
3.4.5.2. Selección de ventanas para la clase 2, 3 y 4.....	41
3.4.6. Análisis pseudo-online.....	42
Capítulo 4. Resultados	45
4.1. Nuevas detecciones IMUs.	45
4.2. Selección train/test óptimo.....	47
4.3. Prueba y selección de las diferentes configuraciones.....	50
4.4. Resultados para una configuración promedio.....	58
4.5. Resultados para selección automática de características	59
4.6. Comparación resultados finales.....	62
Capítulo 5. Conclusiones y trabajos futuros.....	65
5.1. Posibles mejoras en futuras investigaciones.	66
Bibliografía	69
Anexos	71
Anexo I: Tablas del apartado 4.4.....	72
AI 1.1. Resultados para la configuración 1. Clasificadores en serie	73
AI 1.2. Resultados para la configuración 2. Número de características.....	76
AI 1.3. Resultados para la configuración 3. Selección muestra.....	79
AI 1.4. Resultados para la configuración 4. Selección de electrodos	83
AI 1.5. Resultados para la configuración 5. Selección de electrodos	86

Índice de figuras

Figura 1. Tipos de ondas cerebrales según su frecuencia.....	7
Figura 2. Ubicación de los 4 lóbulos cerebrales.....	8
Figura 3. Disposición de los 32 electrodos que usaremos según el sistema internacional 10-10.	10
Figura 4. Representación de los 22 electrodos y los distintos potenciales evocados que se pueden apreciar.	13
Figura 5. Arquitectura de un sistema BMI.	14
Figura 6. Equipamiento Tech-MCS V3.	20
Figura 7. Posición IMUs como se muestra en [17].	22
Figura 8. Casco g.GAMMAcap.	22
Figura 9. Montaje experimental de la prueba [7].	24
Figura 10. Ventana detección parada IMUs mediante el uso de findchangepts.....	26
Figura 11. Error en detección parada IMUs.	27
Figura 12. Gráfica sin ponderar ninguna de las señales.	28
Figura 13. Gráfica con una ponderación óptima para visualizar la parada.	28
Figura 14. Esquema simplificado del modelo empleado para el trabajo.....	29
Figura 15. Disposición de los 32 electrodos que usaremos. En rojo tenemos los electrodos descartados, en amarillo los que usaremos y en negro el que usaremos como referencia a tierra.	30
Figura 16. En azul se muestran los electrodos que corresponden a la zona parietal y en verde los de la zona occipital.....	32
Figura 17. Ploteo de los láseres de S9 y S5.....	38
Figura 18. Representación visual de las ventanas.	39
Figura 19. Representación de los 13 láseres de S2.....	39
Figura 20. Ploteo de 13 láseres en S5.....	40
Figura 21. Gráfica que muestra los instantes en los que se ha seleccionado cada clase.	41
Figura 22. Representación visual de los diferentes instantes.	43
Figura 23. Representación gráfica de la tabla 11.	50

Índice de tablas

Tabla 1. Ponderación empleada en las gráficas.....	27
Tabla 2. Ejemplo sobre el funcionamiento del seleccionador de características.....	34
Tabla 3. Características empleadas.	35
Tabla 4. Comparación resultados para los mismos datos con clasificador SVM.....	37
Tabla 5. Ejemplo tabla de resultados.	42
Tabla 6. Detección tiempos IMUs para S7.....	46
Tabla 7. Tiempos detección IMUs método [7].....	46
Tabla 8. Nuevos tiempos detección IMUs.	47
Tabla 9. Porcentaje de láseres detectados en función del volumen de datos de entrenamiento..	48
Tabla 10. FP/min en función del volumen de datos de entrenamiento.	48
Tabla 11. Medias totales extraídas de las tablas 9 y 10.....	49
Tabla 12. Configuración por defecto elegida para la prueba.....	50
Tabla 13. Resultados obtenidos tras probar un número diferente de clasificadores en los 10 sujetos.....	51
Tabla 14. Resultados obtenidos con una probabilidad a priori distinta en los 10 sujetos.	52
Tabla 15. Resultados obtenidos tras emplear un número distinto de características en los 10 sujetos.....	53
Tabla 16. Resultados obtenidos tras modificar la selección de muestra en los 10 sujetos.....	54
Tabla 17. Resultados obtenidos tras modificar la selección de los electrodos en los 10 sujetos.	55
Tabla 18. Recopilación de las configuraciones finales para cada usuario.	56
Tabla 19. Resultados de todos los usuarios con la mejor configuración para 5/5.....	57
Tabla 20. Configuración por defecto elegida para la prueba.....	58
Tabla 21. Resultados de todos los usuarios con la configuración promedio de la tabla 66.	58
Tabla 22. Mejores 5 características para cada usuario.	60
Tabla 23. Características ordenadas en función de las veces que han sido usadas por los clasificadores.....	61
Tabla 24. Resultados usuarios con la mejor configuración y una k que restringe los FP/min a 4.	62
Tabla 25. Resultados usuarios con la mejor configuración individual y una K que restringe los FP/min a 4 para un train/test de 5/5.....	63
Tabla 26. Resultados usuarios con una configuración genérica y una K que restringe los FP/min a 4 para un train/test de 5/5.	63
Tabla 27. Resultados finales de estudios previos.	64
Tabla 28. Muestra de cómo se obtiene cada una de las tablas que se mostrarán a continuación.	72
Tabla 29. Resultados obtenidos con un número diferente de clasificadores en serie para S1.....	73

Tabla 30. Resultados obtenidos con un número diferente de clasificadores en serie para S2.....	73
Tabla 31. Resultados obtenidos con un número diferente de clasificadores en serie para S3.....	73
Tabla 32. Resultados obtenidos con un número diferente de clasificadores en serie para S4.....	74
Tabla 33. Resultados obtenidos con un número diferente de clasificadores en serie para S5.....	74
Tabla 34. Resultados obtenidos con un número diferente de clasificadores en serie para S6.....	74
Tabla 35. Resultados obtenidos con un número diferente de clasificadores en serie para S7.....	75
Tabla 36. Resultados obtenidos con un número diferente de clasificadores en serie para S8.....	75
Tabla 37. Resultados obtenidos con un número diferente de clasificadores en serie para S9.....	75
Tabla 38. Resultados obtenidos con un número diferente de clasificadores en serie para S10...	76
Tabla 39. Resultados tras probar diferentes probabilidades a priori para S1.	76
Tabla 40. Resultados tras probar diferentes probabilidades a priori para S2.	76
Tabla 41. Resultados tras probar diferentes probabilidades a priori para S3.	77
Tabla 42. Resultados tras probar diferentes probabilidades a priori para S4.	77
Tabla 43. Resultados tras probar diferentes probabilidades a priori para S5.	77
Tabla 44. Resultados tras probar diferentes probabilidades a priori para S6.	78
Tabla 45. Resultados tras probar diferentes probabilidades a priori para S7.	78
Tabla 46. Resultados tras probar diferentes probabilidades a priori para S8.	78
Tabla 47. Resultados tras probar diferentes probabilidades a priori para S9.	79
Tabla 48. Resultados tras probar diferentes probabilidades a priori para S10.	79
Tabla 49. Resultados tras probar diferente cantidad de características para S1.	79
Tabla 50. Resultados tras probar diferente cantidad de características para S2.	80
Tabla 51. Resultados tras probar diferente cantidad de características para S3.	80
Tabla 52. Resultados tras probar diferente cantidad de características para S4.	80
Tabla 53. Resultados tras probar diferente cantidad de características para S5.	81
Tabla 54. Resultados tras probar diferente cantidad de características para S6.....	81
Tabla 55. Resultados tras probar diferente cantidad de características para S7.	81
Tabla 56. Resultados tras probar diferente cantidad de características para S8.	82
Tabla 57. Resultados tras probar diferente cantidad de características para S9.	82
Tabla 58. Resultados tras probar diferente cantidad de características para S10.	82
Tabla 59. Resultados de diferentes selecciones de muestras para S1.....	83
Tabla 60. Resultados de diferentes selecciones de muestras para S2.....	83
Tabla 61. Resultados de diferentes selecciones de muestras para S3.....	83
Tabla 62. Resultados de diferentes selecciones de muestras para S4.....	84
Tabla 63. Resultados de diferentes selecciones de muestras para S5.....	84
Tabla 64. Resultados de diferentes selecciones de muestras para S6.....	84
Tabla 65. Resultados de diferentes selecciones de muestras para S7.....	85
Tabla 66. Resultados de diferentes selecciones de muestras para S8.....	85

Tabla 67. Resultados de diferentes selecciones de muestras para S9.....	85
Tabla 68. Resultados de diferentes selecciones de muestras para S10.....	86
Tabla 69. Resultados tras selección de electrodos para S1.	86
Tabla 70. Resultados tras selección de electrodos para S2.	86
Tabla 71. Resultados tras selección de electrodos para S3.	87
Tabla 72. Resultados tras selección de electrodos para S4.	87
Tabla 73. Resultados tras selección de electrodos para S5.	87
Tabla 74. Resultados tras selección de electrodos para S6.	88
Tabla 75. Resultados tras selección de electrodos para S7.	88
Tabla 76. Resultados tras selección de electrodos para S8.	88
Tabla 77. Resultados tras selección de electrodos para S9.	89
Tabla 78. Resultados tras selección de electrodos para S10.	89



Capítulo 1. Introducción

Las enfermedades cerebrovasculares (ECV) son un problema de salud a nivel mundial, y son la causa principal de discapacidad en el ser humano [11]. Según los datos proporcionados por la Organización Mundial de la Salud (OMS), aproximadamente 15 millones de personas sufren un ictus cada año, de las cuales, el 30% termina provocándoles secuelas que incapacitan a los individuos para tener una autonomía en las actividades cotidianas o les puede provocar una discapacidad permanente [10].

La rehabilitación después de un accidente cardiovascular se considera una de las partes más importantes en el proceso de recuperación. El objetivo de la rehabilitación es tratar de que el paciente vuelva a recuperar las habilidades que han quedado mermadas debido a la ECV [12].

Una rehabilitación incluye entre otros, ejercicios de motricidad para mejorar la fuerza muscular, es aquí donde puede intervenir la tecnología, dentro del desarrollo de actividades físicas asistidas, se incluye el uso de exoesqueletos que faciliten la realización de los ejercicios durante la rehabilitación [12].

El uso de estos exoesqueletos viene acompañado de un software que actúe de interfaz cerebro-máquina (BMI: Brain-Machine Interface) y permita la realización de movimientos que sin ésta ayuda extra, podrían resultar difícil o imposibles en los comienzos de la rehabilitación, lo que podría provocar una desmotivación del paciente y su consecuente abandono [13].

En el presente trabajo se estudiará la intención de detener la marcha con el estudio de los potenciales relacionados con eventos (ERP), los cuales aparecen antes de que el usuario se haya detenido, la detección de las señales electroencefalografías (EEG) se realizará mediante métodos no invasivos, de los cuales se hablará a lo largo de la memoria.

1.1. Motivación

Cómo ya hemos comentado anteriormente, las enfermedades cardiovasculares son un gran problema que atañe a la sociedad, las cuales, cada vez son más los estudios relacionados con la rehabilitación asistida. La motivación principal de este trabajo es la de poder contribuir en la mejora de sistemas BMI que en un futuro puedan llegar a emplearse en una rehabilitación mediante el uso de exoesqueletos.

Me parece muy interesante a la par que motivador, el poder seguir aportando a este campo de estudio el cual puede en un futuro ayudar a personas con dificultades motoras a conseguir una mejora en la recuperación o de cualquier paciente con patologías similares y de esta forma mejorar su calidad de vida.

1.2. Objetivos

El objetivo de este trabajo es el de analizar los cambios producidos en las señales EEG cuando se produce un obstáculo inesperado mientras un usuario está caminando. Se realizarán mejoras en la detección del evento mediante IMUs respecto a diseños anteriores. Se realizarán mejoras en las diferentes etapas de preprocesamiento, procesamiento y clasificación para aumentar las correctas detecciones de los obstáculos y reducir los falsos positivos.

Para ello se pretenden llevar a cabo los siguientes pasos:

1. Mejoras en la detección mediante IMUs del instante de parada ante la aparición de un obstáculo.
2. Cálculo de nuevas características para las señales EEG.
3. Mejora en la selección de las clases que se usarán en la creación del modelo.
4. Comprobación del funcionamiento conseguido con las alternativas propuestas en un análisis pseudo-online, para la futura realización de pruebas en tiempo real.

1.3. Estructura de la memoria

La memoria viene estructurada de la siguiente manera:

- **Capítulo 1. Introducción:** Se hace una introducción al trabajo, incluye la motivación y cuáles son los objetivos del proyecto.
- **Capítulo 2. Estado del arte:** Se explican conceptos previos que más adelante se usarán en el transcurso del trabajo, por ejemplo, que es la encefalografía, que tareas desempeña cada lóbulo cerebral, los diferentes potenciales y frecuencias cerebrales o que es una BMI.
- **Capítulo 3. Materiales y métodos:** Contiene una explicación de los materiales que se han empleado durante el proyecto y que procedimientos se han llevado a cabo para el procesado de todos los datos obtenidos en el laboratorio.
- **Capítulo 4. Resultados:** Evaluación de los resultados obtenidos a partir de los métodos que se plantean en el capítulo anterior.
- **Capítulo 5. Conclusiones y trabajos futuros:** Se extrae una conclusión final y se plantean posibles investigaciones futuras para la mejora y desarrollo del presente trabajo.



Capítulo 2. Estado del arte

En este capítulo haremos una breve introducción a la electroencefalografía, con el fin de poder explicar y comprender mejor todos los conceptos empleados en este trabajo que tiene como fin el poder ayudar en futuros proyectos de rehabilitación mediante el uso de exoesqueletos.

Esto nos llevará a hablar desde las diferentes frecuencias cerebrales en el punto 2.1, pasando a comentar las áreas por las que se divide el cerebro en el punto 2.2, también hablaremos del sistema empleado para la obtención de los potenciales cerebrales en el punto 2.3, los cuales se desarrollarán en el apartado 2.4. Finalmente, en los puntos 2.5 y 2.6, hablaremos sobre que es una BMI y sus aplicaciones en las terapias de rehabilitación.

2.1. Electroencefalografía

La electroencefalografía es una técnica de exploración neurofisiológica no invasiva, que registra la actividad bioeléctrica cerebral mediante electrodos dispuestos sobre el cuero cabelludo, los cuales son colocados sobre diferentes áreas del cerebro permitiendo así registrar patrones de actividad eléctrica y diferentes anomalías. El registro obtenido mediante esta técnica se denomina encefalograma (EEG), las señales EEG son el resultado de las mediciones de potenciales generados en el córtex cerebral.

La electroencefalografía fue la disciplina que permitió, en primera instancia, que se pudiera considerar un uso no exclusivamente médico al estudio del cerebro, fue usada por primera vez por Hans Berger en 1924, cuando registró por primera vez la actividad cerebral de su hijo realizando, el que se considera el primer electroencefalograma (EEG) de la historia. Sin embargo, su historia se remonta a mucho antes, ya que se publicaron las primeras observaciones sobre la electricidad animal en el año 1770. Pero no fue hasta 1976 que se produjo la primera evidencia real de que se podría utilizar este tipo de señales para establecer sistemas de comunicación [6].

Fue Jacques J.Vidal, quien acuñó el término Brain Computer Interface (BCI), el que proporcionó la evidencia de que se podían registrar determinados potenciales, los cuales podían usarse como canal de comunicación entre el individuo y un ordenador. El movimiento del cursor de un ordenador, fue la primera prueba oficial de que se usaron señales cerebrales para el control de dispositivos externos al organismo [6].

Las ondas captadas mediante las EEGs se pueden clasificar en diferentes tipos según su frecuencia, dicha frecuencia presenta diferentes patrones de repetición dependiendo de la tarea mental que realice el sujeto. En función de su frecuencia, podemos distinguir 5 tipos diferentes de ondas cerebrales, las cuales podemos observar en la Figura 1.

- **Ondas Delta:** Son las que tienen mayor amplitud y oscilan entre los 0,5 y 4 Hz, se encuentran asociadas a estados de sueño profundo.
- **Ondas Theta:** Estas ondas, están asociadas a frecuencias comprendidas entre los 4 y 8 Hz y se dan en estados de calma profunda o somnolencia, con acceso a material inconsciente, meditación o inspiración creativa.
- **Ondas Alfa:** Estas ondas se originan sobre todo en el lóbulo occipital, durante periodos de relajación o atención pasiva, dichas ondas se presentan con frecuencias de entre 8 y 12 Hz.
- **Ondas Beta:** Comprenden frecuencias que van desde los 12 a los 35 Hz, se relacionan a una actividad neuronal intensa y de atención, por ejemplo, durante la resolución de problemas. Podemos encontrarlas principalmente en las regiones frontal y central del cerebro.
- **Ondas Gamma:** Estas son el tipo de ondas cerebrales con una mayor frecuencia, superior a los 35 Hz, se relacionan con tareas de en las que se requiere un alto procesamiento y con gestión de la memoria.

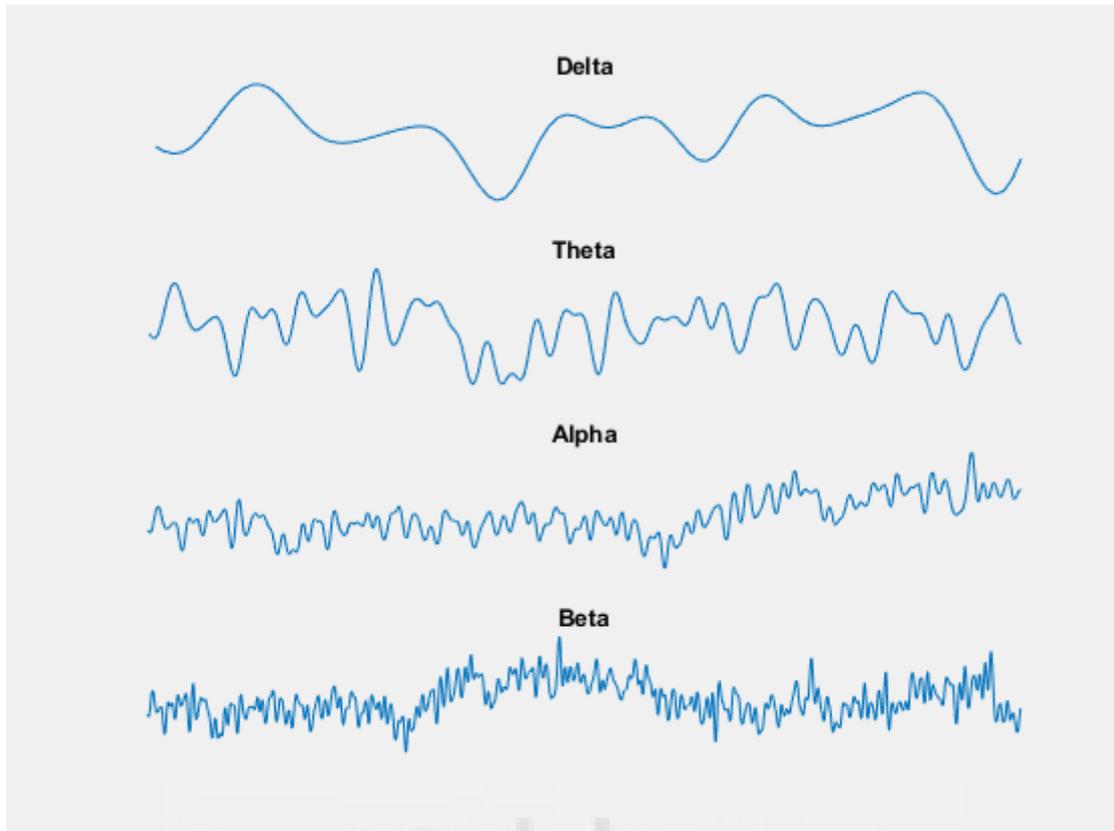


Figura 1. Tipos de ondas cerebrales según su frecuencia

2.2. Lóbulos cerebrales

El cerebro es uno de los órganos más complejos que existe, en el caso de los seres humanos adultos, tiene un peso aproximado de entre 1300 y 1500 gramos [14], lo que representa el 2% del peso corporal, aunque puede llegar a consumir una cantidad de energía igual a la de todo el músculo esquelético en reposo [15]. En relación al resto del cuerpo, los pesos relativos del sistema nervioso respecto al resto de los tejidos que conforman el organismo en su totalidad, sitúan al ser humano como uno de los mamíferos con los índices más altos [14].

Nuestro cerebro se encuentra dividido de forma simétrica en dos grandes estructuras, las cuales se conocen como hemisferios, cada uno de los hemisferios está formado por lóbulos, grandes estructuras anatómicas, funcionalmente conectadas a nivel subcortical, las cuales podemos dividir en 4 zonas, cómo se muestra en la Figura 2. Éstas son, la zona frontal, la temporal, la parietal y la occipital, las cuales describiremos a continuación [14].



Figura 2. Ubicación de los 4 lóbulos cerebrales.

Lóbulo frontal: Como su propio nombre indica, se encuentra situado en la parte frontal de la cabeza, este lóbulo es el encargado de la parte motora primaria del ser humano, es la responsable de los movimientos voluntarios, también los movimientos faciales y relacionados con el habla, entre otras muchas funciones, también destaca la resolución de problemas y la planificación.

Lóbulo parietal: Este lóbulo, se encuentra situado entre la zona más superior de la cabeza, entre el lóbulo frontal y el occipital, por encima del lóbulo temporal, es el encargado de la percepción de los distintos sentidos como el tacto, la presión, la temperatura o el dolor, además, se encarga de los estímulos procedentes de los órganos visuales. En resumen, engloba gran parte de la percepción sensorial de nuestro cuerpo.

Lóbulo temporal: Situado en la parte inferior del lóbulo parietal, el lóbulo temporal es el encargado del procesamiento de la información auditiva, también es una parte importante donde se procesa y produce el lenguaje.

Lóbulo occipital: Situado en la parte posterior de nuestro cerebro, detrás del lóbulo temporal y por debajo del lóbulo parietal, es el encargado del procesamiento de la visión además de procesar parte de los estímulos visuales que llegan a nuestro cerebro.

2.3. Sistema 10-10 y 10-20

Las potenciales eléctricos proceden de las células piramidales de la corteza cerebral. Para obtener una señal de la actividad eléctrica en cada una de las regiones cerebrales a través de la superficie craneal, hay que colocar los electrodos que captan la diferencia de potencial entre ellos. Para realizar un encefalograma, deben analizarse las señales cerebrales ampliando las diferencias de potencial entre los electrodos receptores [3].

El procedimiento que se seguirá para generar los EEG es una técnica no invasiva, por lo que es indolora, que puede ser de gran utilidad en la práctica clínica. Consiste en colocar electrodos adheridos a la superficie del cuero cabelludo. Mediante una jeringuilla y una aguja con punta roma, se introduce en cada uno de los electrodos un gel conductor que facilita la recepción de la señal a través del cuero cabelludo [3][4].

Se posicionarán de acuerdo al sistema internacional 10-10 denominado así porque los electrodos están espaciados entre el 10% y el 10% de la distancia total entre puntos reconocibles del cráneo [4]. Actualmente se utilizan unos gorros que llevan incorporados 32 electrodos y se coloca directamente sobre la cabeza del sujeto, en la Figura 3, podemos observar que electrodos que van a ser empleados. Los electrodos se unen en un conector y éste, a su vez, conecta con el cabezal del EEG [4].

Los distintos pares de electrodos se combinan, constituyendo los montajes. Hay dos tipos básicos de montajes: bipolar, que puede ser transversal o longitudinal y monopolar (o referencial). El montaje bipolar recopila la diferencia de voltaje entre dos electrodos colocados en áreas de actividad cerebral, mientras que el montaje monopolar, registra la diferencia de potencial entre un electrodo ubicado en una zona cerebral que se desea estudiar y otro colocado sobre un área sin actividad o neutra (por ejemplo el lóbulo de la oreja derecha), o bien, la diferencia de voltaje entre un electrodo colocado en una zona activa y el promedio de todos o algunos de los electrodos activos), el montaje monopolar es el que se utilizará durante las pruebas en este trabajo [3].

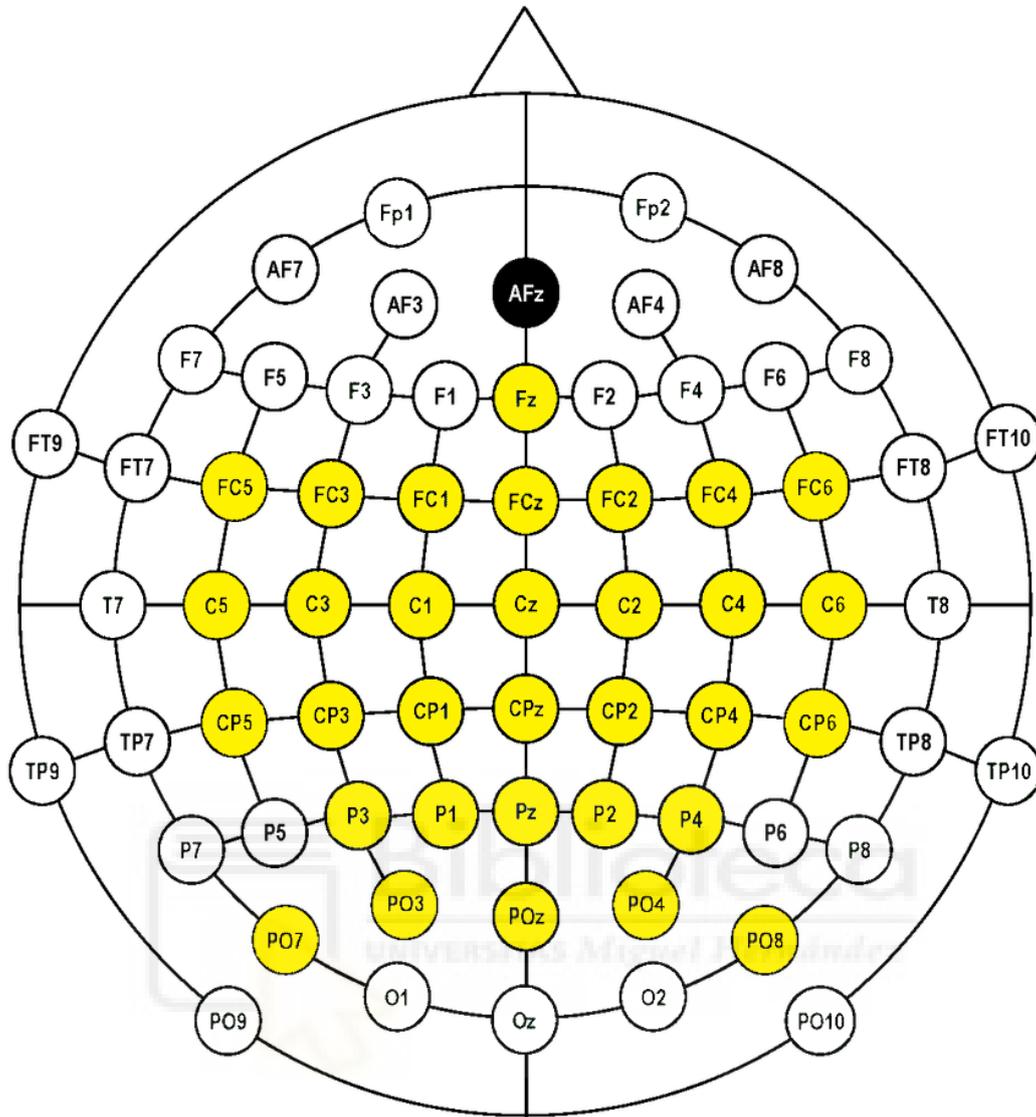


Figura 3. Disposición de los 32 electrodos que usaremos según el sistema internacional 10-10.

2.4. Potenciales relacionados con eventos

En general, cualquier Potencial Relacionado a un Evento (ERP) se encuentra totalmente enmascarado dentro de un ruido de fondo que presenta mayor amplitud, por tanto, será necesario utilizar alguna estrategia para conseguir extraer la señal del registro obtenido. Existen diversas fuentes de ruido, las cuales, pueden ser de origen instrumental, algunas podrán ser eliminadas con la utilización de correctos aparatos de registro, o bien de origen biológico, estas últimas pueden provenir de fuentes extracerebrales o bien ser generadas por la actividad basal del propio cerebro [1].

El potencial relacionado a un evento, es una de las señales EEG más estudiadas en diferentes campos como la neurología o psicología. Estas señales tienen una amplitud muy pequeña, de entre 1 y 30 microvoltios, se producen una serie de potenciales ligados temporalmente a dicho evento cuando estimulamos al cerebro a través de un evento sensorial, efectivo o cognitivo, pueden aparecer como potenciales visuales, auditivos, sensoriales o como un potencial que aparecería previamente a un movimiento voluntario.

La problemática que no encontramos a la hora de clasificar estas señales es que presenta un grado de variabilidad muy elevado entre los distintos sujetos, incluso las pruebas con un mismo sujeto no siempre arrojan el mismo resultado, esto obliga a los investigadores a un continuo reentrenamiento de los clasificadores.

2.4.1. Potencial relacionado con la aparición de un obstáculo

En el presente trabajo, analizaremos la activación cerebral que se genera cuando aparece un obstáculo inesperado durante la marcha normal, es por eso que estas señales están incluidas en los Potenciales Relacionados a Eventos (ERP), estas variaciones pueden ser percibidas tanto como variaciones positivas o variaciones negativas, la aparición de estas señales se produce en periodos de tiempo distintos, después de la aparición del estímulo.

En el estudio [5] se pretende analizar la señal producida por varios sujetos durante la marcha mientras andan en una cinta. En él, se intenta analizar la detección del ERP ligado a la aparición de un obstáculo repentino. Estas mediciones tienen una mayor probabilidad de captarse en el electrodo Cz.

Dentro del análisis de las señales ante la aparición de un obstáculo, podemos encontrar varios potenciales, muy ligados a uno de los ERPs más estudiados, el conocido como CNV (Variación Negativa Contingente), el cual es descrito por primera vez por Walter y se produce como consecuencia de un estado de alerta, el cual suele ir seguido de una respuesta mental o motora. Se pueden llegar a localizar 3 potenciales distintos cuando se analizan más en detalle estas señales.

Potencial de error

El potencial de error (ErrP) se trata de una señal exógena, los potenciales exógenos se generan mediante una estimulación exterior, ya sea mediante estimulación visual, auditiva u otras estimulaciones sensoriales. También están incluidos dentro de los ERPs.

El potencial de error se genera cuando el usuario percibe un estímulo distinto al esperado, se caracteriza por ser un potencial negativo, el cual se sitúa en un intervalo de entre 50 y 100 ms después del estímulo. Se encuentra localizado principalmente en la zona fronto-central del córtex, es por eso que usaremos el electrodo FCz (ver Figura 3). Será necesario una calibración para cada sujeto debido a la variabilidad de las señales ERP. Es poco probable observar dicha señal en éste estudio [5], ya que el sujeto mientras realiza la prueba, se encuentra a la espera de que se produzca la señal que le indica que debe detenerse, por lo que no es un estímulo inesperado, en algunos casos puede llegar a observarse una pequeña deflexión negativa en la señal a los pocos milisegundos de producirse la aparición del láser.

Potencial visual evocado

Un potencial visual evocado (VEP) es un pequeño cambio en las señales eléctricas del cerebro, se generan como respuesta a un estímulo visual. Cuando a un sujeto se le presenta un estímulo visual, se dispara un potencial de acción que se propaga a través de los nervios ópticos hasta la corteza visual y otras regiones del cerebro [16].

Se trata de una deflexión positiva, que tiene lugar unos 300 ms después de haberse producido el estímulo. En el caso del estudio [5], se produciría entre los 200 y 400 ms después del estímulo.

Potencial motor

Finalmente nos encontramos con el potencial motor, se trata de un estímulo negativo, el cual se produce entre los 700 y 900 ms después de producirse el estímulo visual y justo antes de producirse un movimiento voluntario, que en este caso correspondería con la parada del sujeto, el cual se encuentra estrechamente relacionado con el CNV.

En la Figura 4, podemos observar los 3 potenciales de los que hemos hablado, en un primer momento, unos 100ms después de la aparición del láser, en verde, encontramos el potencial de error, a continuación, casi medio segundo después, en rojo, nos encontramos con el potencial visual, que indica que el sujeto debe detenerse, por lo que casi un segundo después del estímulo, en magenta, se puede localizar el estímulo motor que está directamente relacionado con la parada.

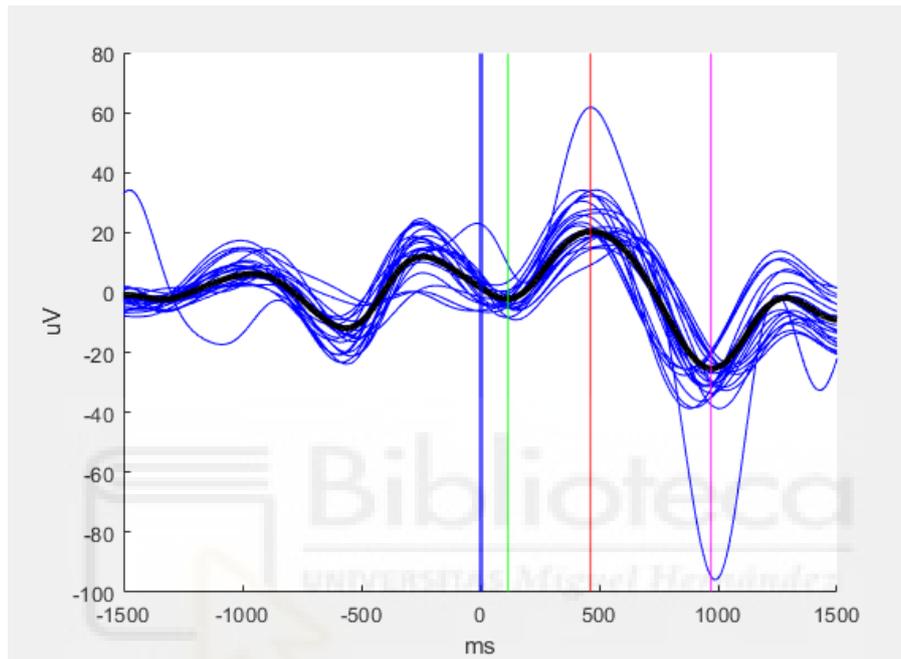


Figura 4. Representación de los 22 electrodos y los distintos potenciales evocados que se pueden apreciar.

2.5. Interfaces Cerebro-Máquina

Podemos definir una interfaz cerebro-máquina (BMI) como un sistema capaz de decodificar la actividad cerebral, obtenida por ejemplo a partir de un EEG y traducirla en comandos de control que permia la comunicación entre un sujeto y un dispositivo externo sin la necesidad de ningún movimiento muscular adicional.

Estas señales eléctricas pueden ser registradas a partir de electrodos situados en el interior del cerebro mediante técnicas invasivas o las no invasivas, en las cuales se centrarán nuestras pruebas, con el uso de electrodos en el cuero cabelludo.

Se trata de una herramienta muy útil, ya que, las aplicaciones de estos sistemas son muy numerosas, permitiendo realizar movimientos en otros dispositivos, como brazos robóticos, exoesqueletos o incluso manejar un ordenador exclusivamente con señales mentales, sin necesidad de que la persona haga ningún movimiento, esto es realmente útil para personas con discapacidad o conseguir restaurar parcialmente la movilidad de pacientes con parálisis. Es por ello que, este campo se encuentra en un constante avance y son cada vez más los investigadores que centran sus esfuerzos en mejorar estos sistemas.

Sin embargo, todos estos estímulos cerebrales deben ser traducidos por la propia máquina para así poder interpretarlos correctamente, esto implica la lectura de los estímulos procedentes de los electrodos, además se instalarán sensores inerciales (IMUs), acelerómetros, giróscopos, entre otros, para el posterior procesamiento de los datos.

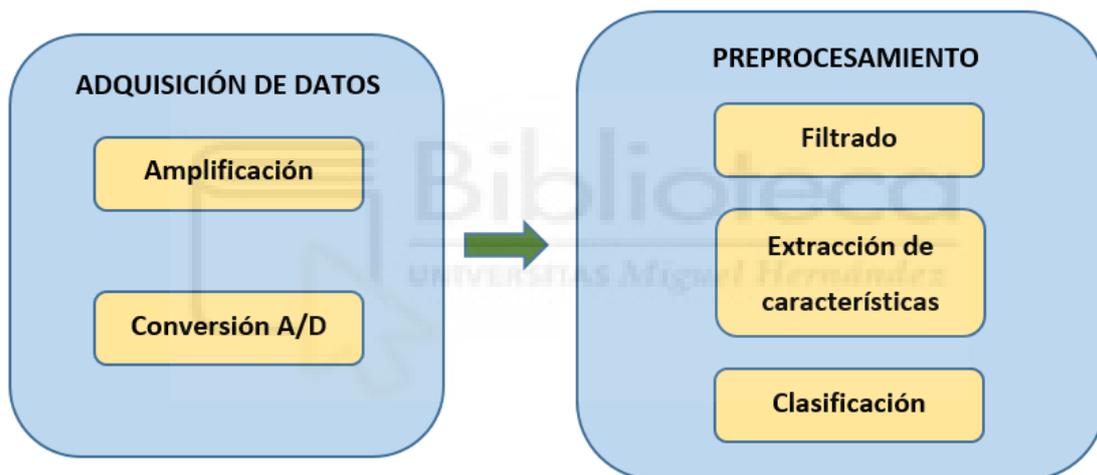


Figura 5. Arquitectura de un sistema BMI.

2.5.1. Adquisición de datos

El primer paso será el de capturar y registrar todos los datos que sean relevantes durante las pruebas para posteriormente, como se muestra en la Figura 5, poder ser procesados y clasificados correctamente.

La adquisición de los datos consta de dos partes, por un lado, la detección del movimiento se llevará a cabo a través del sistema de captura de Movimiento Tech-MCS V.3.0 el cual se trata de IMUs (Inertial Measurement Unit) que se colocarán en diferentes zonas del cuerpo y de esta forma saber en todo momento los movimientos del sujeto.

Por otro lado, se debe capturar la actividad cerebral durante la prueba, para este propósito se usará el equipo g.USBamp de la marca g.Tec. al que irá conectado g.GAMMAcap, un casco al con 32 electrodos, encargados de capturar todas las señales EEG.

2.5.2. Preprocesado

Antes de poder trabajar con las señales de forma correcta, deberán pasar una serie de filtros que eliminen posible ruido, como por ejemplo la señal de la red, la cual mediante el uso del filtro Notch, nos permitirá obtener una señal más clara, además se usarán filtros de paso banda que eliminen las frecuencias que no estén dentro del rango que se desee analizar para eliminar posibles picos indeseados en las señales. En [7] se usa un filtrado que elimina toda señal que no se encuentre entre los 0,3 y 4 Hz.

2.5.3. Extracción de características

Para poder clasificar las señales, una vez procesadas, es necesario hacer una selección de características, las cuales permitirán la distinción entre las diferentes clases.

Las características podemos dividir las en dos grandes grupos, por un lado, tenemos las características frecuenciales, ya que se obtienen como resultado de transformar la señal en el dominio de la frecuencia, tienen como objetivo determinar la potencia de cada señal y se basa en el análisis de la Transformada Rápida de Fourier (FFT) [17]. Por otro lado, nos encontramos con las características temporales, las cuales se extraen de las señales EEG una vez se han filtrado las señales y extraídas las frecuencias deseadas, esto se hace en el dominio del tiempo, de ahí que sean características temporales.

2.5.4. Clasificación

Una vez se han extraído las características, deberemos usar un método que nos ayude a clasificarlas e identificar a que clase pertenecen. Existen multitud de clasificadores como KNN (K-Nearest Neighbors), SVM (Support Vector Machine), LDA (Análisis Discriminante Lineal) o las famosas redes neuronales, entre otros.

En el presente trabajo, se ha probado sin mucho éxito el clasificador SVM y como clasificador definitivo para todas las pruebas y resultados, se ha empleado un LDA, que

presenta menos variabilidad en los resultados que se obtienen con un mismo input, además de poderse emplear una probabilidad a priori para ajustar la precisión del modelo.

Si se implementan de forma correcta, estos sistemas pueden ser capaces de interpretar en tiempo real los datos que van generándose durante la marcha de un individuo, que sería el objetivo final del proyecto.

2.6. Aplicaciones de las BMI

Como ya hemos comentado anteriormente, las enfermedades cerebrovasculares son una de las principales causas de discapacidad, se ha demostrado que un tratamiento de rehabilitación en los 6 primeros meses tras haber sufrido el accidente, es crucial para la recuperación o mejora de las habilidades motoras afectadas, debido a la plasticidad del sistema nervioso durante los primeros meses [18].

El principal problema es el esfuerzo y la dificultad que puede suponer para muchos pacientes la realización de los ejercicios necesarios para su recuperación, ya que puede obligar a retrasar estos ejercicios de rehabilitación lo que imposibilita una correcta terapia de recuperación, la cual conseguiría mejores resultados, ya que cómo hemos dicho, el tiempo en los primeros meses es crucial para maximizar los resultados.

En este punto es donde entra la tecnología y la investigación con BMIs que en los últimos años ha visto un incremento en los estudios enfocados al desarrollo de robots terapéuticos cómo los exoesqueletos, que permitan un proceso rehabilitación con unos resultados más prometedores que con técnicas más tradicionales [7], estos sistemas robóticos sirven de complemento a los ejercicios propuestos por los fisioterapeutas. Las BMI se adaptan al nivel de afectación de la lesión de cada sujeto, por lo que permiten una rehabilitación más personalizada, ya que algunos pacientes requieren de más ayuda que otros para realizar las repeticiones [19].

Un exoesqueleto actúa como un sistema cooperativo, el cual acompaña los movimientos del paciente, reduciendo el esfuerzo que puede suponer los inicios de una rehabilitación, pudiendo alargar las sesiones de entrenamiento o realizar movimientos que de otra forma no podrían realizarse.

Las BMI tienen como finalidad, detectar las intenciones motoras del paciente para que, de esta manera, puedan acompañar en todo momento los movimientos del sujeto, esto

permite no sólo andar en el caso de un paciente con problemas motrices en las piernas, sino que también pueden controlar otros movimientos implicados en la marcha como por ejemplo la detección de la intención de un usuario de detener su marcha [5].





Capítulo 3. Materiales y métodos

En este capítulo, en primer lugar, veremos cual ha sido el material empleado y los diferentes pasos seguidos durante las pruebas realizadas.

En segundo lugar, se describen punto por punto, todos los apartados de los que se compone el procedimiento de adquisición de datos, procesamiento y extracción de características, para finalmente ser clasificadas. Además, se expondrán los nuevos métodos que se emplearán para intentar mejorar los resultados que se obtuvieron anteriormente [7].

3.1. Equipamiento

Durante el proceso experimental, se ha medido en diferentes usuarios las señales EGG emitidas durante varias sesiones, para ello, se ha empleado un equipo g.USBamp de la marca g.Tec, al cual iba conectado un casco g.GAMMAcap que era el encargado de capturar dichas señales.

Además de las señales EEG, era necesario capturar en todo momento los movimientos del sujeto por lo que también se ha empleado un sistema de captura de Movimiento Tech-MCS V.3.0, incorporando 7 IMUs (Inertial Measurement Unit) que se han colocado en diferentes zonas del cuerpo para así, ayudarnos a determinar los instantes de parada.

3.1.1. IMUs

Para la correcta detección del movimiento de los sujetos en todo momento, se necesita saber en qué instantes se ha producido una parada, para ello, es necesario recurrir a algún tipo de tecnología que capture dicho movimiento.

Para este trabajo, se ha empleado el equipo Tech-MCS V3 de la empresa Technaid S.L. Se puede dividir el equipo empleado en tres elementos: Tech-MCS Studio, Tech-HUB y las Tech-IMUs, además de los accesorios que nos permite la sujeción de las Tech-IMUs y su conexión con Tech-HUB y este al ordenador mediante un cable USB [20]. Podemos observar el equipo empleado en la Figura 6.



Figura 6. Equipamiento Tech-MCS V3.

Tech-MCS Studio es un software diseñado para visualizar los datos que provienen desde Tech-IMU. Se trata de una aplicación con multitud de funciones, diseñadas para que el usuario pueda explorar al máximo las capacidades que incorpora el sistema. Finalmente, este programa no se llegó a utilizar, ya que se optó por la adquisición de datos y su posterior procesado en MATLAB.

El Tech-HUB es el dispositivo que se encarga de recibir la información capturada por los Tech-IMUs, se le pueden llegar a conectar hasta 16 sensores. El dispositivo tiene tres modos de funcionamiento, puede enviar la información a través de un USB hasta un PC, enviarla mediante Bluetooth por lo que pueden enviarse los datos de forma inalámbrica o simplemente almacenarla en su interior gracias a la incorporación de una tarjeta microSD.

Las Tech-IMUs son pequeños dispositivos que contienen diferentes sensores en su interior, entre los que se encuentra un acelerómetro, un giroscopio, un magnetómetro e incluso un sensor de temperatura, todos ellos controlados por un microprocesador.

Los sensores inerciales que incorporan, también llamados IMUs (Inertial Measurement Unit), son dispositivos electrónicos que nos permiten estimar la orientación de un cuerpo, solidario a este, esto se consigue a partir de las fuerzas inerciales que dicho cuerpo experimenta.

Las señales obtenidas del acelerómetro, el giróscopo y el magnetómetro son fusionadas para obtener la orientación de la IMU, representada por la Matriz de Cosenos Directores (DCM), también denominada matriz de rotación [20].

Esquemáticamente se puede resumir con las siguientes ecuaciones:

$$3D\ Acc = \vec{W}_{(z)} \approx [0 \quad 0 \quad 9.8] \quad (1)$$

$$3D\ Mag = \vec{M} = [M_x \quad M_y \quad M_z] \quad (2)$$

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

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

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

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

$$3D\ Gyro = \vec{\omega} = [\omega_x \quad \omega_y \quad \omega_z] \quad (6)$$

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

Se usarán 7 IMUS, las cuales se situarán por el cuerpo cómo se muestra en la Figura 7, una en cada pie, otras dos se situarán una en cada rodilla, una en cada muslo y finalmente una en la zona lumbar. Cada IMU nos aporta un total de 19 señales con una frecuencia de muestreo de 30Hz.

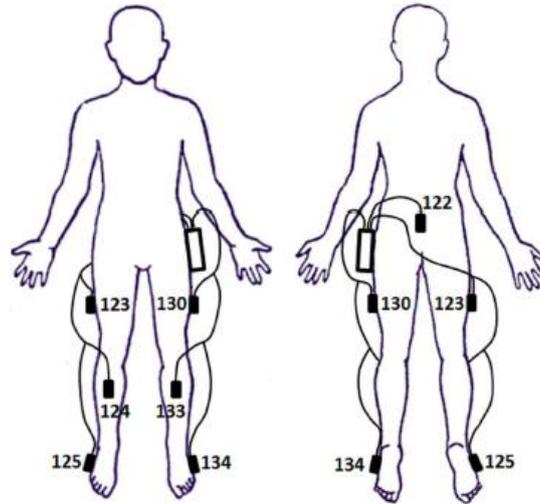


Figura 7. Posición IMUs como se muestra en [17].

3.1.2. Equipo de medición EEG

Un paso fundamental para la realización de este trabajo consiste en medir todos los impulsos eléctricos que se generen en la cabeza durante la marcha, para ello emplearemos como ya hemos comentado anteriormente, el equipo g.USBamp de la marca g.Tec. al que irá conectado g.GAMMAcap, un casco al con 32 electrodos, encargados de capturar todas las señales EEG. Se puede ver como es este casco en la Figura 8.



Figura 8. Casco g.GAMMAcap.

Se ha empleado el sistema internacional 10-10 que como ya comentamos en el apartado 2.3, se denomina así porque los electrodos están espaciados un 10% entre la distancia total de los puntos dónde se sitúan los electrodos.

Se utilizará el electrodo AFz como toma a tierra y una referencia en el lóbulo de la oreja derecha, la frecuencia de muestreo empleada es de 1200 Hz. Se debe emplear un gel en todos los electrodos para un buen contacto con el cuero cabelludo, ya que se trata de una técnica no invasiva dónde los electrodos simplemente están en contacto con la cabeza por la presión que ejerce el propio casco. La disposición de los 32 electrodos puede observarse en la Figura 3, dónde tenemos en negro la referencia a tierra y en amarillo, los electrodos empleados por el dispositivo g.GAMMAcap.

3.2. Método experimental

Todos los registros empleados en este trabajo fueron creados para los estudios anteriores [7] y [8], ya que debido a la COVID-19, no se han podido realizar nuevos registros.

Para el registro de los datos se ha usado la plataforma software basada en MATLAB: g.USBamp MATLAB API. Asimismo, se han empleado diferentes algoritmos incluidos en la librería del laboratorio, incluyendo una nueva estrategia offline para dicho experimento.

Para realizar una prueba, el sujeto deberá disponerse en una cinta de correr sin moverse, mientras se conecta la plataforma software con el equipo g.Tec y se procede a la calibración de las IMUs, puede verse un ejemplo del montaje en la Figura 9.

Una vez realizadas las calibraciones, se pone en marcha la cinta a una velocidad constante de 2 km/h y una inclinación de 0 grados, el sujeto deberá andar de forma libre, sin cogerse a la máquina y entonces se empezará la prueba.

Cada registro tiene una duración de unos 2 min, en los que irá apareciendo un láser de forma aleatoria en un rango de entre 6 y 9 segundos. Estos intervalos variables se deben a que se pretende que el usuario no pueda predecir en que instante va a aparecer el láser que se proyectará durante 1 segundo, el cual indica que el sujeto debe detenerse de forma momentánea, poco después volverá a su marcha normal, cuando llegue al final de la cinta, que no se detendrá en ningún momento.



Figura 9. Montaje experimental de la prueba [7].

Este procedimiento se ha llevado a cabo para los registros offline en 15 sujetos sanos, con edades comprendidas entre los 21 y 54 años, con ningún desorden neurológico. Cada uno de los sujetos ha realizado un total de 10 registros, teniendo por tanto entre 120 y 140 ejemplos de reacciones al obstáculo por persona. Cada registro tiene una duración de 120 segundos y contiene entre 12 y 14 apariciones del láser. El sujeto S1, a diferencia de los demás, hizo sólo 5 registros.

Finalmente, de todas estas pruebas, en 5 sujetos no se consiguió una relación señal-ruido buena, por lo que se descartaron del estudio.

Haciendo uso de una nueva estrategia de registro offline diseñada específicamente para la tarea, se han ido capturado los datos y posteriormente se han guardado en una estructura llamada '*session*', en la cual se almacenan todos los datos generados durante la prueba, desde IMUs, EEG, duración de la prueba hasta las apariciones de los láseres.

3.3. Método de detección de paradas IMUs

En el análisis pseudo-online ha sido necesario detectar el momento en el que el usuario realizaba la parada, con el fin de poder asegurar así que la respuesta del sistema BMI fuera anterior a la reacción normal de la persona, para ello, se ha planteado un nuevo método de detección de paradas de las IMUs, el cual expondremos a continuación.

3.3.1. Detección automática de la parada con la función *findchangepts*

La función *findchangepts* es una función que devuelve el índice en el que la media de los cambios es más significativa, dicho de otra manera, te devuelve los puntos donde se producen cambios bruscos en una señal. Tras el procesado de las IMUs, de una forma visual, se puede detectar un gran cambio en la parada, como puede verse en la Figura 10, es por eso que nos es muy útil a la hora de detectar de forma automática el instante de la parada.

Este método nos aporta una mejora y un inconveniente respecto al método anterior en el que se usaba la CWT (Continuous Wavelet Transform) para la detección de paradas en las IMUs [7]. Por un lado, mejora la cantidad de detecciones, ya que en el anterior caso, no siempre se detectaba todas las paradas o podían detectarse paradas en lugares que no correspondían.

Sin embargo, con el nuevo método, sólo se le pasan las ventanas dónde a priori ya se sabe que se encuentra la parada y simplemente se encarga de buscar el instante exacto de la parada dentro de la ventana, esto nos garantiza que se detectarán todas las paradas, sin embargo, no es un método que se pueda emplear en una aplicación en tiempo real, ya que requiere saber el intervalo donde se localizan las paradas a priori.

A continuación, en la en la Figura 10 podemos observar cómo se maca en verde los dos cambios más significativos de la señal, de los cuales, nosotros nos quedaremos con el primero de ellos, ya que el segundo se corresponde con la reanudación de la marcha.

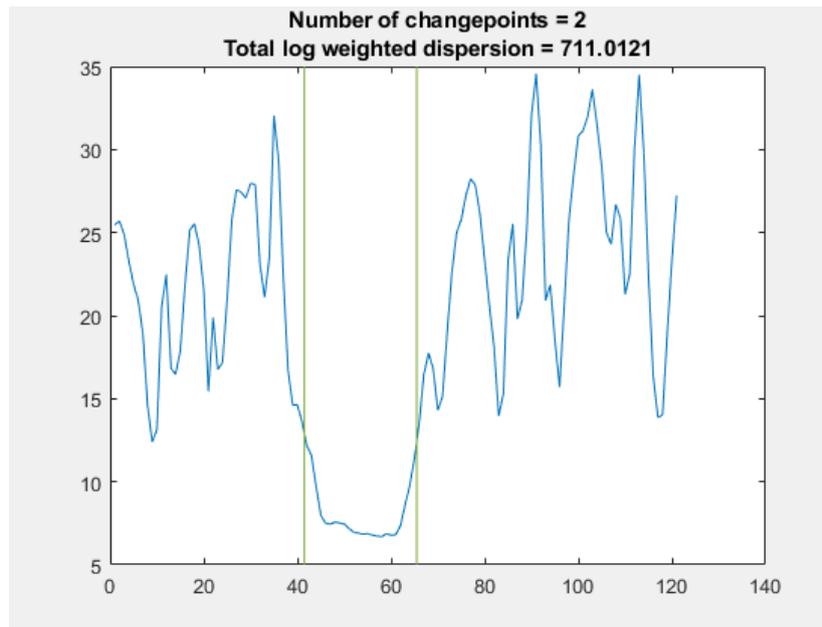


Figura 10. Ventana detección parada IMUs mediante el uso de *findchangepts*.

Uno de los problemas que nos encontramos al emplear este método, como se puede observar en la Figura 11, se trata de un láser en el que posiblemente no hubo una parada, ya que a diferencia de la Figura 10, no se puede apreciar ni de forma visual el instante de la parada, en estos casos la función *findchangepts* nos devuelve un vector vacío.

Otro problema, algo más común que el anterior, consiste en que, para algunos láseres, la detección no se ha producido en el instante que se producía la parada, como podría ser el caso de la Figura 12.

Para abordar ambos problemas, se ha recurrido al cálculo de la mediana de todas las paradas de un usuario y sustituir por esta, todos los puntos conflictivos, que son tanto los láseres no detectados como los que, al calcular el tiempo, estos tengan una variación muy elevada en comparación con la mediana calculada para todos los demás.

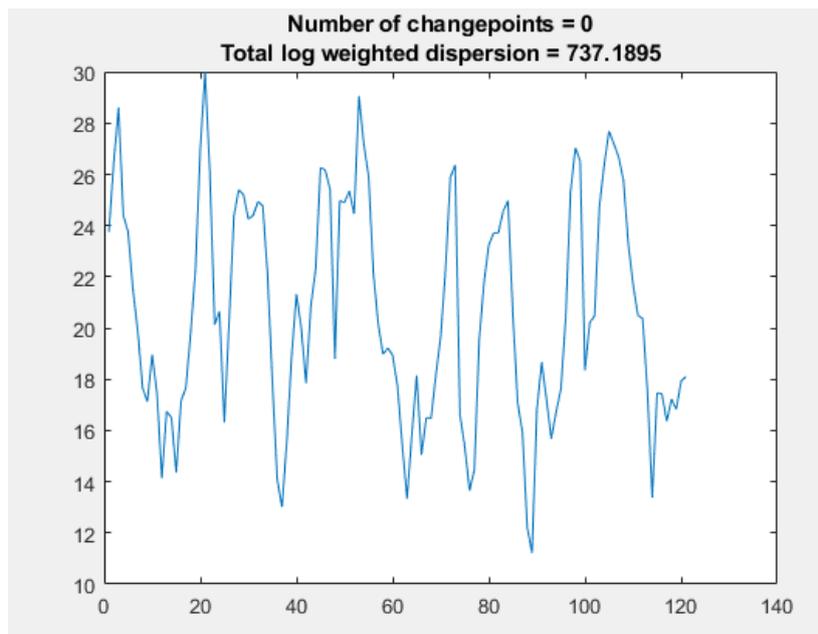


Figura 11. Error en detección parada IMUs.

3.3.2. Preprocesado señales IMU

a diferencia de trabajos anteriores donde se usaban sólo los acelerómetros, en esta nueva investigación, nos hemos ayudado de las diferentes mediciones que nos aportan las 7 IMUs, es por eso que se ha creado una señal única con la suma ponderada en valor absoluto de los nueve Ejes (eje), los tres acelerómetros (acc) y los tres giroscopios (gir), de esta forma, se ha conseguido una señal muy clara para localizar la parada.

A continuación, se muestra la fórmula empleada, además, en la Tabla 1 podemos ver que ponderación se ha empleado para las gráficas de la Figura 12 y la Figura 13.

$$\text{Señal} = e \cdot \text{eje} + a \cdot \text{acc} + g \cdot \text{gir} \quad (8)$$

Tabla 1. Ponderación empleada en las gráficas.

Figura 12		Figura 13	
Ejes (e)	1	Ejes (e)	0
Acelerómetros (a)	1	Acelerómetros (a)	0,025
Giroscopios (g)	1	Giroscopios (g)	15

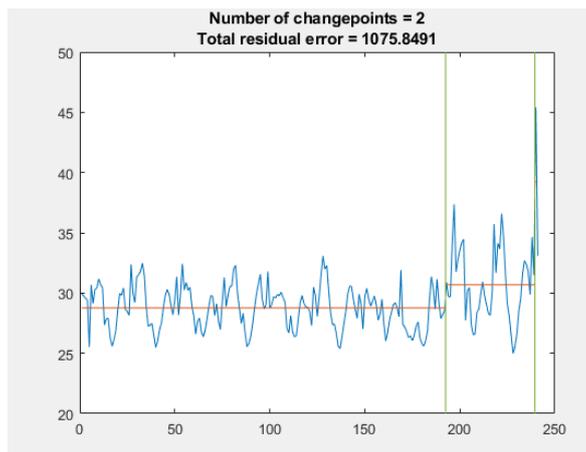


Figura 12. Gráfica sin ponderar ninguna de las señales.

Claramente podemos ver cómo en el caso de la Figura 12, no se llega a apreciar la parada, la cual puede confundirse con la parte final de la gráfica, como le ha ocurrido en este caso a la función que estamos usando, esto sucede porque la señal de los ejes es muy dispersa, ya que se trata de 3 triedros, cada uno en una dirección distinta y que simplemente nos indica la dirección, es por eso que para la Figura 13, los ejes se ponderarán a 0.

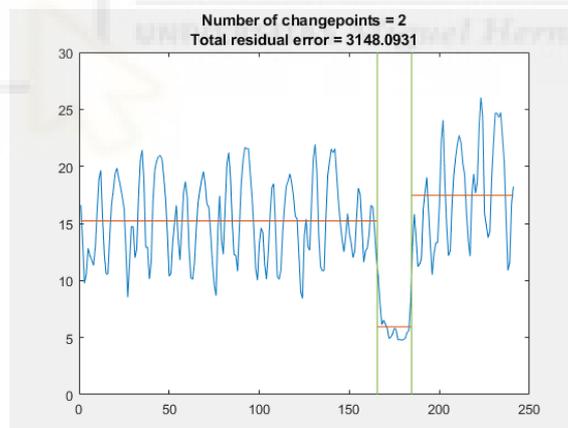


Figura 13. Gráfica con una ponderación óptima para visualizar la parada.

Los valores tan bajos empleados para las aceleraciones (0,025) se deben a que su magnitud era mucho mayor que la magnitud que nos ofrecían los giroscopios, de esta forma, conseguimos una mayor cantidad de datos con un peso similar. En la Figura 13 vemos como hay una clara depresión instantes después de producirse la parada que estaría situada en el instante 120, justo en el centro de la gráfica, la frecuencia de muestreo es de 30Hz por lo que la parada se localiza aproximadamente, segundo y medio después del láser.

3.4. Procesamiento

En el siguiente apartado se describe la estrategia para el procesamiento de los datos. La Figura 14 recoge, a modo de esquema general, los pasos que se van a ir planteando y detallando en los distintos apartados de este capítulo.

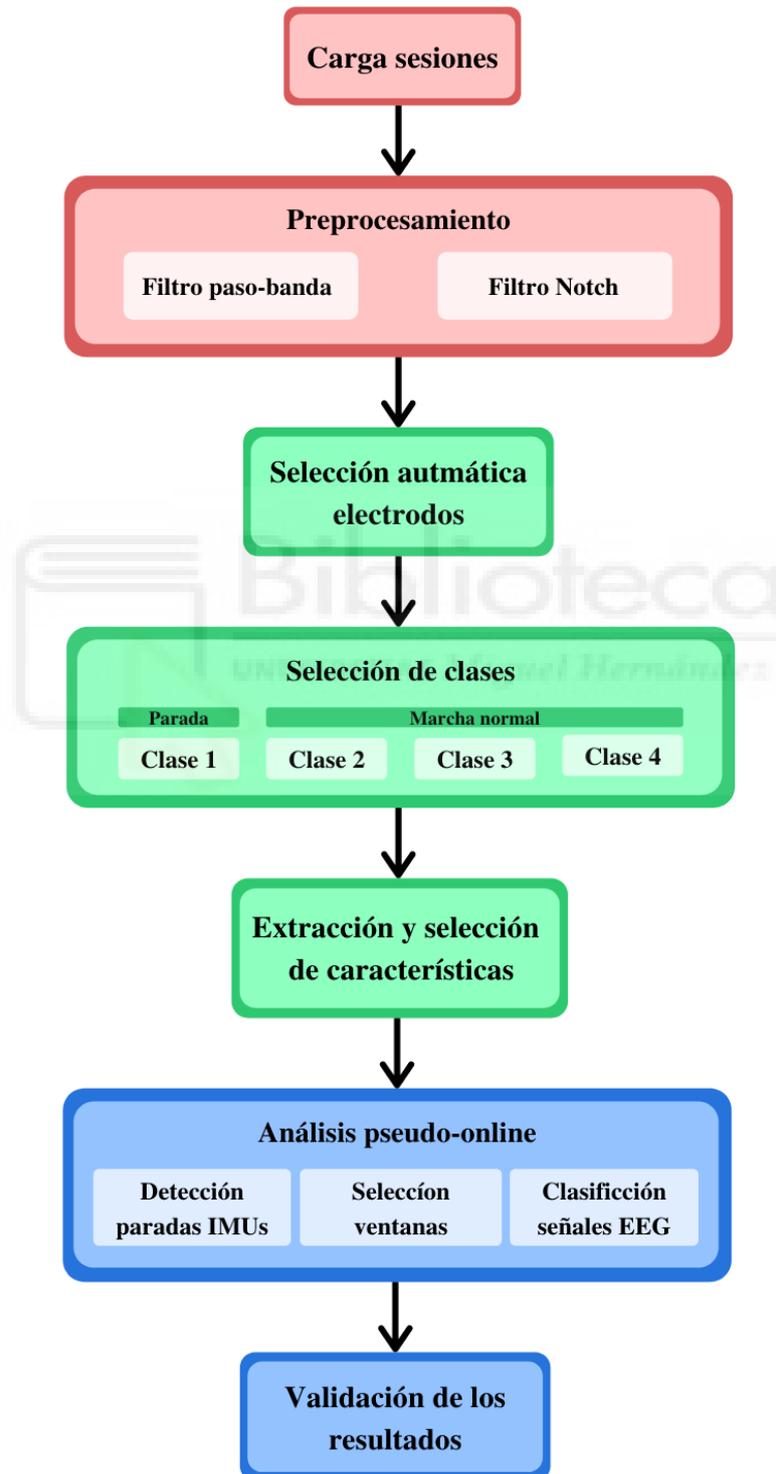


Figura 14. Esquema simplificado del modelo empleado para el trabajo.

3.4.1. Preprocesamiento

Para el procesamiento de las señales EEG, en primero lugar, se le aplicará un filtro Notch, el cual fijaremos a una frecuencia de 50 Hz, este se encarga de la eliminación del ruido producido por la red eléctrica [7].

A continuación, tras el análisis individual de los electrodos, se ha procedido a la eliminación de aquellos electrodos cuyas señales se han visto afectados por artefactos de movimiento, esto se debe a que se encuentran ubicados en la periferia del casco, lo que impide una buena conducción entre los electrodos y el cuero cabelludo, generando una señal poco válida para su análisis [7], a continuación, en la Figura 15 podemos ver representados en color rojo dichos electrodos.

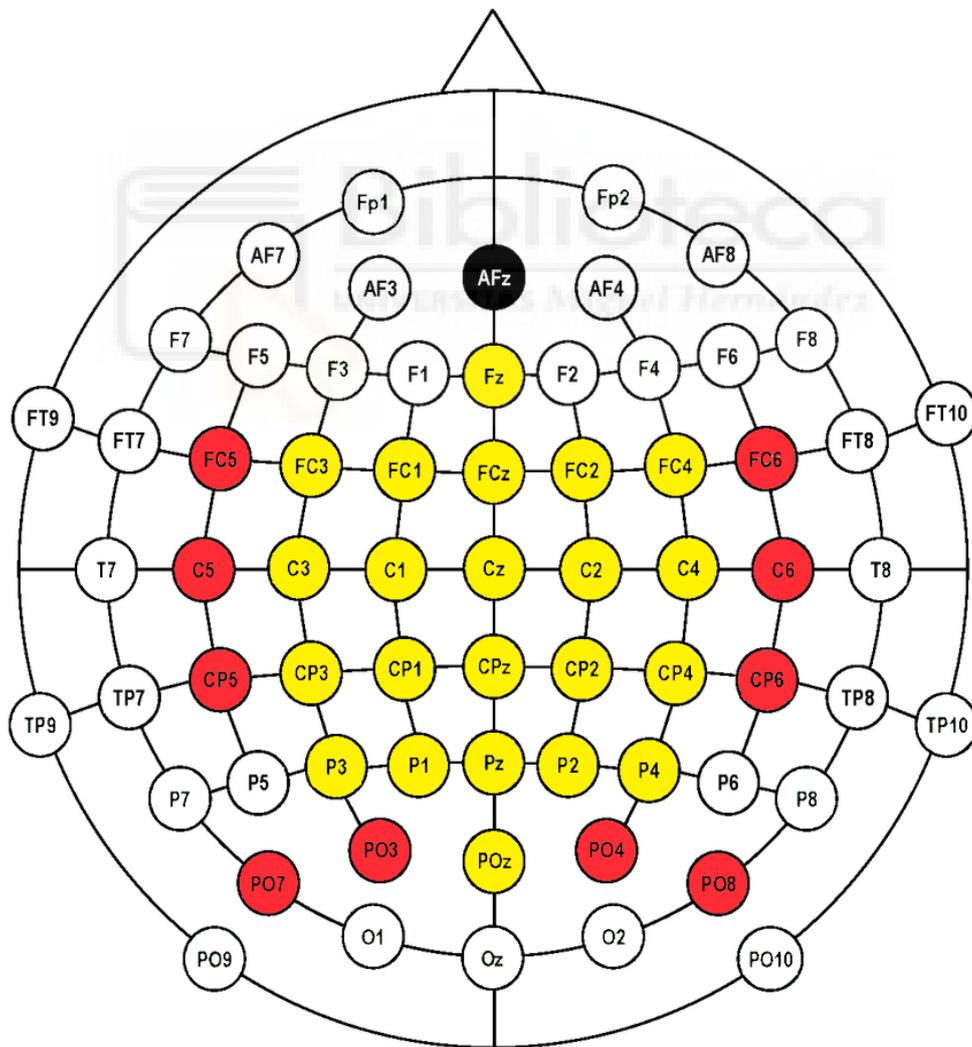


Figura 15. Disposición de los 32 electrodos que usaremos. En rojo tenemos los electrodos descartados, en amarillo los que usaremos y en negro el que usaremos como referencia a tierra.

Como ya hemos comentado anteriormente, el equipo empleado para capturar las señales EEG consta de 32 electrodos, de los cuales por los motivos que acabamos de comentar, se han eliminado 10 de ellos (FC5, FC6, CP5, CP6, PO3, PO4, PO7, PO8, C5, C6), estos 10 electrodos se eliminarán de forma definitiva para el resto de pruebas, es por ello que cuando digamos que se va a hacer una selección automática entre todos los electrodos, nos estaremos refiriendo a los 22 electrodos restantes, que se han representado en color amarillo (FZ, FC1, FCZ, FC2, C3, CZ, C4, CP1, CP2, P3, PZ, P4, FC3, FC4, C1, C2, CP3, CPZ, CP4, P1, P2, POZ).

Finalmente, como se indica en [7], se aplica un filtro paso-banda de 0.4 a 3 Hz. Se ha escogido este rango de frecuencias debido a que como se indica en el apartado 2.1, las señales EEG producidas por la aparición de obstáculos se manifiestan a bajas frecuencias.

3.4.2. Selección de electrodos

Los datos registrados a través de los electrodos, puede considerarse la información más relevante para la realización de este trabajo, es por eso que una mala elección de los mismos, puede conllevar una considerable reducción de las detecciones. Para intentar seguir mejorando este apartado, añadiremos una nueva selección que probaremos más adelante en el capítulo de resultados.

En primer lugar, se usará un método de selección automática, ya planteado en [7], que reduce el tiempo de selección, consiste en seleccionar aquellos electrodos con mayor diferencia entre el instante anterior al laser y el instante posterior y que al sumar la señal con el resto de electrodos, contribuye a aumentar esa diferencia. Este método se realizará con los 22 electrodos válidos que se planteaban en el apartado anterior.

En segundo lugar, trataremos de darle un enfoque distinto a la selección de los electrodos, ya que como hemos visto en el apartado 2.2, podemos dividir el cerebro en diferentes lóbulos, los cuales se encargan de realizar diferentes funciones cómo razonar, memorizar, o reaccionar a estímulos, entre otras.

Para el presente trabajo, nos interesa la zona referente a los estímulos visuales, las cuales se encuentra en el lóbulo parietal y el occipital, que engloban la percepción sensorial y los estímulos visuales de nuestro cuerpo. En un primer momento se iban a probar por separado, pero debido al bajo número de electrodos que suponía cada grupo (6), se decidió hacer la prueba con las dos zonas juntas, dando como resultado, la selección de los siguientes 12 electrodos: CZ, CP1, CP2, PZ, P4, C1, C2, CP3, CPZ, P1, P2, POZ. Es en esta zona donde se deberían englobarse la mayor parte de potenciales cerebrales que se pretenden analizar.

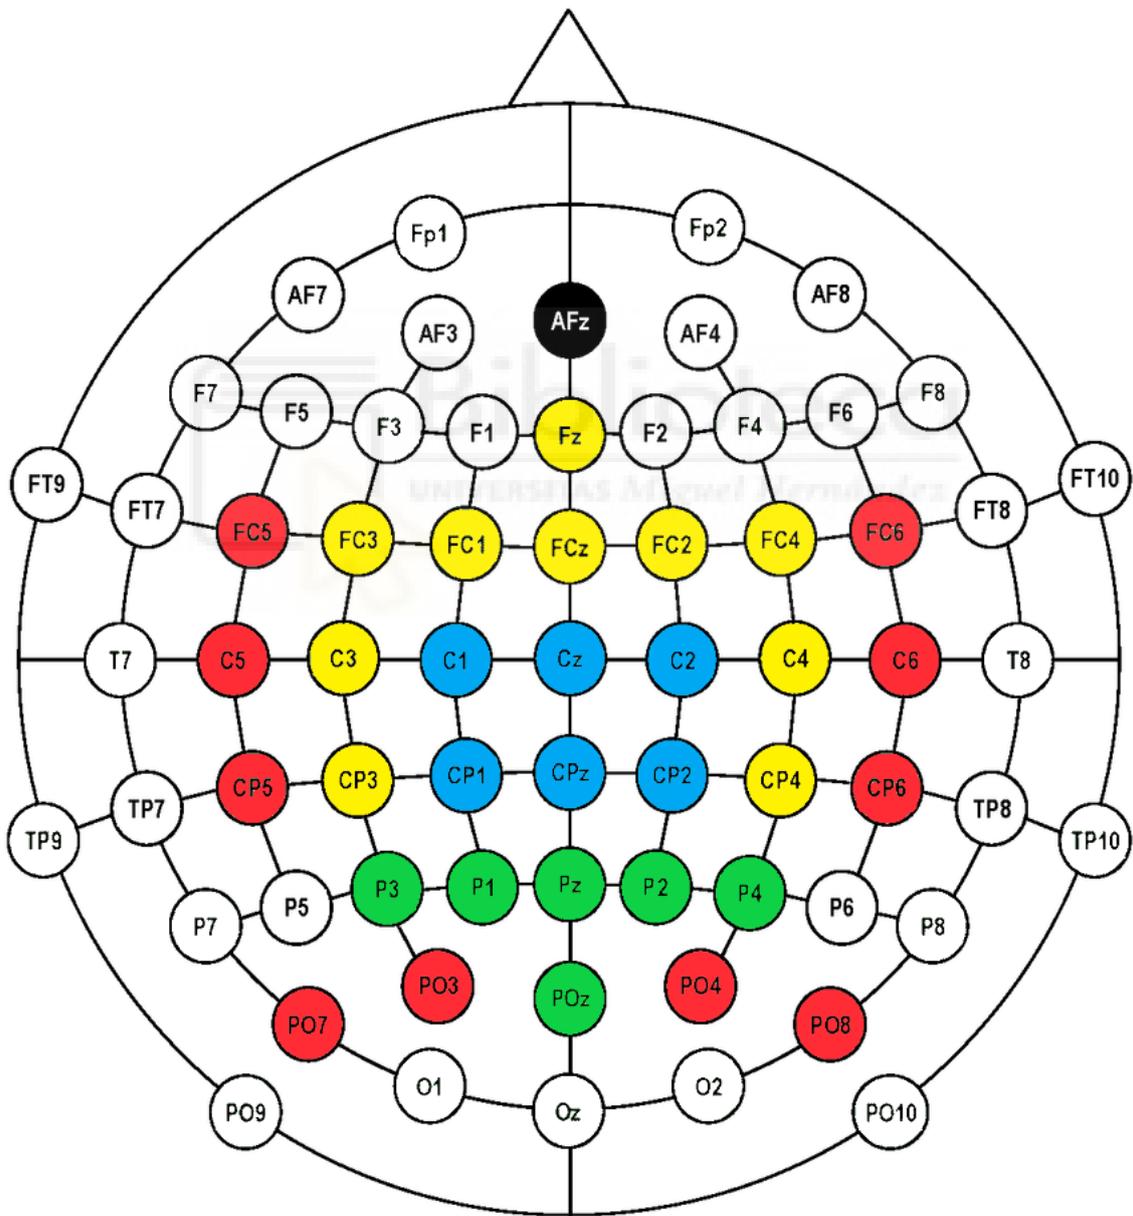


Figura 16. En azul se muestran los electrodos que corresponden a la zona parietal y en verde los de la zona occipital.

3.4.3. Extracción automática de características

Uno de los principales inconvenientes que nos encontramos a la hora de diseñar un sistema BMI, es la de trabajar con la elevada cantidad de datos de los que se parten, es por este motivo que es tan importante el paso de escoger un subconjunto de características que nos permita la mayor distinción entre las distintas clases con las que cuente el modelo.

Las características pueden separarse en dos grupos, por un lado, las que se encuentran en el dominio de la frecuencia, muy utilizadas en sistemas BMI que se centran en los diferentes estados mentales del sujeto. Y, en segundo lugar, nos encontramos con las características temporales, que se basan en el dominio temporal.

En nuestro caso lo que se busca es un ERP, que se caracteriza por una variación en la amplitud de la señal, la cual se encuentra relacionada temporalmente a la aparición del estímulo, por otro lado, es importante tener en cuenta que la finalidad de este estudio es la aplicación en tiempo real, por lo que el tiempo de computo debe tenerse en cuenta a la hora de calcular las características, que en el caso de las frecuenciales, el cálculo de una FFT (Fast Fourier Transform) puede suponer grandes tiempos de cálculo.

Para los distintos clasificadores empleados en el presente trabajo, se han extraído 17 características, 5 de ellas, corresponden a las ya usadas en [7], al ampliar el rango de características, debería conseguirse una mayor precisión en las detecciones, pero no todas las características son igual de buenas a la hora de detectar las paradas.

En este punto, surgen dos posibles preguntas, ¿Cuáles son las mejores características?, ¿Cuál es el número de características que maximiza la precisión de los clasificadores?

Para contestar a la primera pregunta sobre cuáles pueden ser las mejores características, se ha diseñado un script, el cual busca las características que, de forma independiente, separan mejor entre clases.

A continuación, y con la ayuda de las Tablas 2.1, 2.2 y 2.3, se explicará el procedimiento empleado para ordenar las características según su capacidad individual de distinguir entre clases, posteriormente en el apartado de resultados, trataremos de responder a la pregunta sobre cuál es la cantidad de características idónea.

Tabla 2. Ejemplo sobre el funcionamiento del seleccionador de características.

Clase	feat 1	feat 2
0	94,30	1,45
0	84,17	1,03
0	54,92	0,51
0	65,91	0,66
0	69,19	0,88
1	30,43	0,76
1	23,22	0,63
1	31,21	0,85
1	25,46	0,80
1	32,96	0,81

Tabla 2.1

Clase	feat 1	feat 2
0	94,30	1,45
0	84,17	1,03
0	69,19	0,88
0	65,91	0,66
0	54,92	0,51
1	32,96	0,81
1	31,21	0,85
1	30,43	0,76
1	25,46	0,80
1	23,22	0,63

Tabla 2.2

Clase	feat 1	feat 2
0	94,30	1,45
0	84,17	1,03
0	69,19	0,88
1	31,21	0,85
1	32,96	0,81
1	25,46	0,80
1	30,43	0,76
0	65,91	0,66
1	23,22	0,63
0	54,92	0,51

Tabla 2.3

En la Tabla 2.1 se pueden observar las características ordenadas por clases, la primera mitad corresponde a la clase 0 y la segunda mitad corresponde a la clase 1.

A continuación, en la Tabla 2.2, ordenamos *feat 1* de mayor a menor, de esta forma modificamos el orden de los datos de la columna, pero respetando la misma posición para el resto de componentes de cada fila.

Como podemos observar en la Tabla 2.2, tras haber ordenado de mayor a menor la columna *feat 1*, vemos que en la columna *Clase* no se han mezclado las diferentes clases, esto en una muestra mucho mayor, nos puede dar una idea de cómo de buena puede llegar a ser esa característica de forma individual a la hora de separar las clases.

En la Tabla 2.3, vemos que al ordenar de mayor a menor la columna *feat 2*, dos de las características de la clase 1, se han mezclado con la clase 0, por lo que, de una forma rápida y automatizada, podemos seleccionar que características tienen un mayor potencial a la hora de separar entre las diferentes clases.

Esto no implica que esa característica sea mejor, ya que la combinación de varias o la propia función que separa las clases, es más compleja que esta simple aproximación, pero nos da una idea del potencial que cada característica tiene de forma individual y simplifica la tarea de encontrar las mejores características para cada usuario que con este método, podremos automatizar y personalizar para cada usuario.

En la Tabla 3 se puede observar las 17 características empleadas en el trabajo. Algo que se observó cuando se probó este sistema, fue que las características como la amplitud, la varianza, la integral y la desviación estándar, solían estar siempre entre las mejores características, es por eso que posteriormente, se calculó la envolvente y con esta señal, se recalcularon estas características con el vector obtenido de la envolvente.

Tabla 3. Características empleadas.

Características	
1	Error cuadrático medio
2	Desviación absoluta media
3	Mediana de la desviación absoluta
4	Frecuencia media
5	Amplitud
6	Varianza
7	Desviación estándar
8	Distancia euclídea entre señales
9	Integral
10	Varianza de la derivada
11	Amplitud de la derivada
12	Coefficiente de correlación
13	Acumulada
14	Amplitud de la envolvente
15	Varianza de la envolvente
16	Integral de la envolvente
17	Desviación estándar de la envolvente

3.4.4. Clasificadores

Una vez se han obtenido las características para las diferentes clases, se deberá emplear algún método de clasificación supervisada, el cual debe entrenarse empleando una serie de datos conocidos a priori, con los que se decidirá a que clase pertenece los datos de entrada. La eficacia de estos clasificadores reside en lo bien diferenciados que estén los datos y la cantidad de estos, es por eso que adquiere tanta importancia el apartado anterior. En nuestro caso utilizaremos dos clasificadores distintos, en primer lugar, probaremos un clasificador de Máquina de Soporte de Vectores (SVM) y por último con el Análisis Discriminante Lineal (LDA) que pasaremos a comentar en los siguientes apartados.

3.4.4.1. SVM

El método de clasificación SVM (Vector Support Machines) se desarrolló en la década de los 90, aunque en un principio era un método de clasificación binaria, sus aplicaciones se han extendido a problemas de clasificación múltiple. SVM ha resultado ser uno de los mejores clasificadores, por lo que es considerado un referente dentro del ámbito del aprendizaje estadístico y el *machine learning* [21].

La máquina de vector soporte se basa en el *Maximal Margin Classifier*, el cual trata de buscar el hiperplano que se encuentre más alejado de todas las observaciones de entrenamiento. Aunque esta idea suena razonable, no se puede aplicar, ya que hay infinitos hiperplanos con los que medir las distancias. En su lugar, se recurre a métodos de optimización.

Para este proyecto, en un primer momento se probó a detectar las paradas en las señales EEG usando el clasificador SVM y los resultados eran bastante aceptables, pero tras varias pruebas, los resultados para una misma configuración, no eran siempre los mismos, esto se debe a la aleatoriedad con las que se inician las variables con las que se entrena el SVM, esto hace que no se obtenga siempre la misma precisión, lo que no lo hace del todo apto para probar las diferentes combinaciones y buscar los pequeños cambios.

A continuación, en la Tabla 4, se muestran dos tablas, las cuales han sido entrenadas con los mismos datos y la misma configuración pero que como se puede observar, los resultados son notablemente distintos debido a la aleatoriedad que hemos comentado.

Tabla 4. Comparación resultados para los mismos datos con clasificador SVM.

K	FP/min	TP(%)	K	FP/min	TP(%)
1	9,87	100	1	4,56	83,33
2	3,8	91,67	2	0,76	83,33
3	2,28	83,33	3	0,76	75
4	0,76	58,33	4	0	41,67
5	0	25	5	0	25

Es por este motivo que, en el capítulo de resultados no se ha usado este método de clasificación, ya que, no nos permite encontrar y evaluar las pequeñas variaciones que se obtienen al probar las diferentes configuraciones y así, ver cual da mejores resultados.

3.4.4.2. LDA

Dentro de los diferentes algoritmos de aprendizaje supervisado que disponemos actualmente y tras descartar la opción del SVM, se ha optado por el Análisis Discriminante Lineal (LDA), se trata de un método de clasificación supervisado de variables cualitativas en el cual, los grupos son conocidos a priori y las nuevas observaciones se clasificarán en uno de ellos en función de sus características. Haciendo uso del teorema de Bayes, se estima la probabilidad de que las observaciones, dado un determinado valor de los predictores, pertenezca a una clase u otra.

En resumen, podemos decir que un LDA funciona a partir de un conjunto de datos (datos de entrenamiento), de los cuales se calcula una probabilidad a priori para que una observación pertenezca a una clase u otra, para eso se calcula una función discriminante, la cual determinará a que grupo pertenece [22].

La principal diferencia con los anteriores trabajos [7] a la hora de emplear este clasificador, es que hemos empleado 3 clasificadores en serie en lugar de 1. Para los tres clasificadores se usará la misma clase 1 que corresponderá a la clase de la detección de parada, sin embargo, la segunda clase corresponderá a distintos instantes de la marcha normal, se hará una explicación más detallada en el siguiente apartado.

Será necesario que los tres clasificadores den como salida un 1 (clasificadores en serie), correspondiente a la detección de una parada, para que el programa lo contabilice como una detección del clasificador, más adelante se comprobará si es válida o si ha sido un falso positivo, con esto lo que se pretende conseguir es reducir el número de falsos

positivos por minuto (FP/min), ya que dispondremos de instantes de marcha normal adicionales. Este método se implementará y comparará con la variante de un solo clasificador en el capítulo de resultados.

3.4.5. Selección de ventanas

Los ERP presentan una gran variabilidad entre los distintos individuos, esto quiere decir que los tiempos de reacción de cada usuario son distintos. Como ya se comentó en [7], esto plantea un problema a la hora de escoger las ventanas que corresponden con la detección del ERP, ya que como podemos observar en la Figura 17, en $S9$ (con un tiempo promedio de 159), el tiempo de reacción es mucho menor que en el caso de $S5$ (con un tiempo promedio de 863), teniendo en cuenta que las ventanas son de 960 muestras, esto puede suponer un problema y dejar el pulso generado fuera de la ventana, la cual debería contener la detección del impulso a principios de la ventana, para mejorar la detección de esta, haremos una selección personalizada de las ventanas que corresponden con la clase 1 y pertenecen al estímulo generado al visualizar el láser.

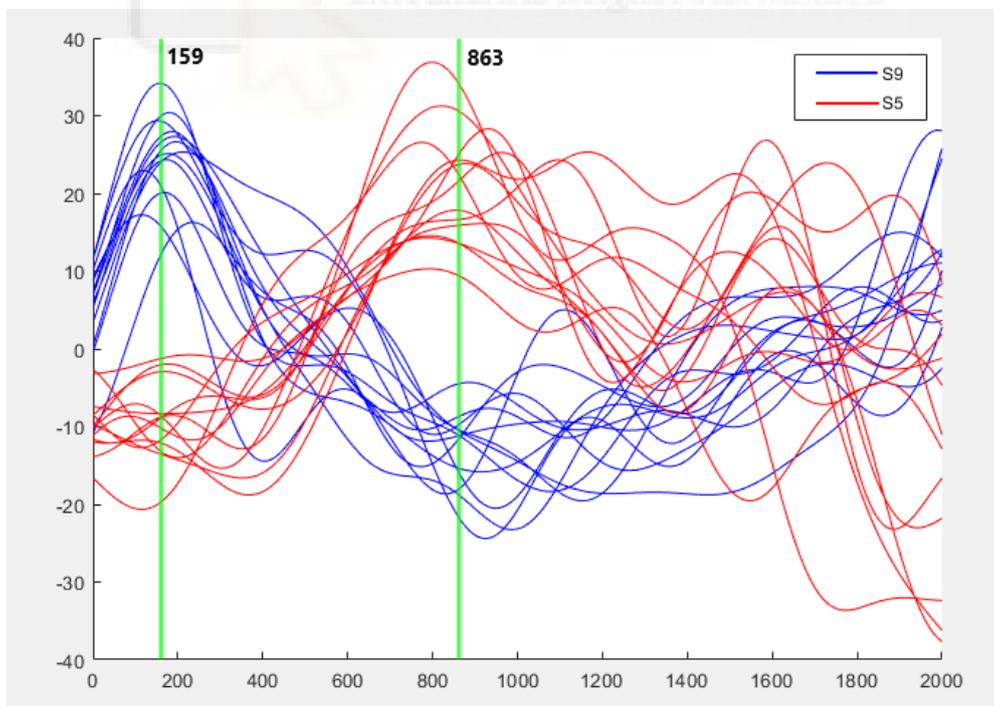


Figura 17. Ploteo de los láseres de $S9$ y $S5$.

Como se muestra en la Figura 18, las ventanas son señales de 960 muestras, que corresponden con 0,8s en tiempo real, ya que la frecuencia de muestreo es de 1200 Hz y se capturan en intervalos de 0,1 segundos.

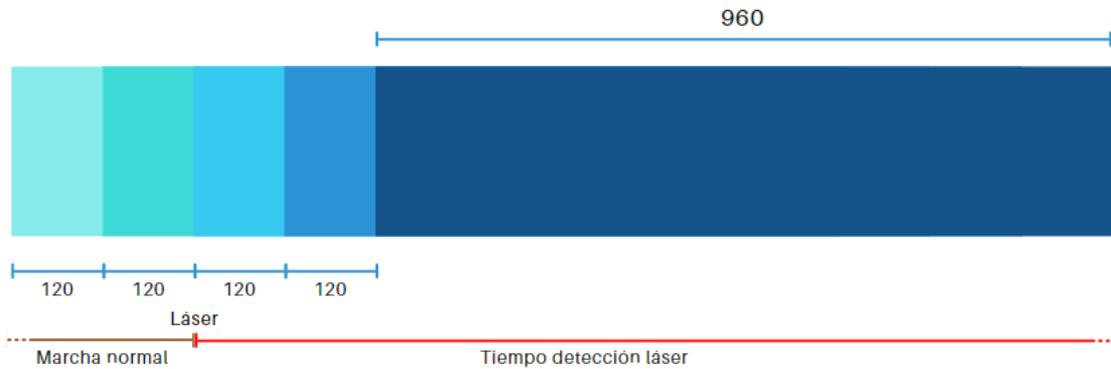


Figura 18. Representación visual de las ventanas.

3.4.5.1. Selección de ventanas para la clase 1

Como hemos comentado, la selección de la ventana que corresponde con la clase 1, haciendo uso de lo comentado en [7], se calcula a partir del tiempo medio de cada usuario, en el cual se encuentra el pico de la señal tras la aparición del láser, como puede observarse en la Figura 19, el tramo anterior a la línea vertical roja, situada en 559 (tiempo medio del usuario S2) antes de la clase 1, no se incluirá dentro de las ventanas de la clase 1 y serán las 960 muestras siguientes las que se sí se incluyan en la ventana de la clase 1.

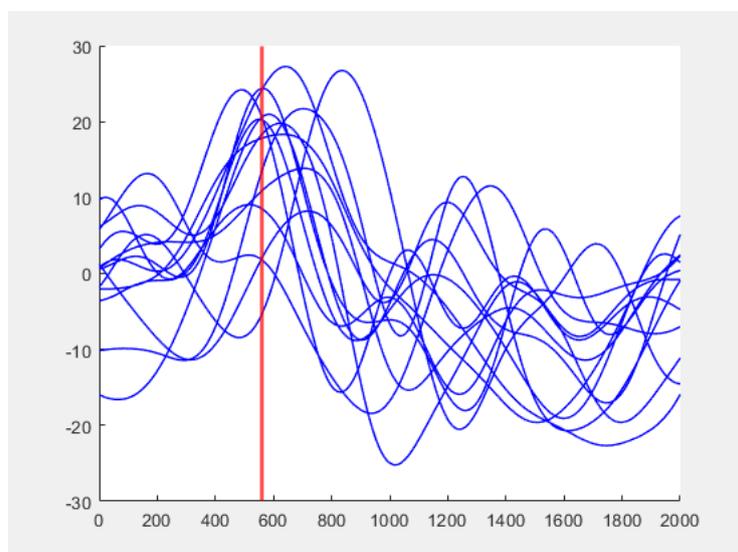


Figura 19. Representación de los 13 láseres de S2.

La selección de estas ventanas mejora bastante la detección de las paradas, pero incluso para un mismo sujeto, los ERP también presentan cierta variabilidad. Es por esto que se plantea como solución a esta diferencia de tiempos, la posibilidad, no sólo de fijar un tiempo promedio para cada usuario, calculado a partir de los 12-14 láseres, si no, sacar el tiempo para cada uno de los láseres de forma automática y personalizada.

El único inconveniente que encontramos con este método, es que, como se muestra en la Figura 20, no todos los láseres tienen el pico máximo en el lugar que correspondería, es por esto que se han añadido unas líneas de código en las que una vez calculamos todos los tiempos de los láseres, calculamos la mediana y recorremos el vector generado, si alguna de las detecciones se aleja demasiado de la mediana, se sustituye por este valor.

El uso de la mediana en lugar de la media se debe a que las detecciones correctas se encuentran muy concentradas y las erróneas se dispersan mucho, por lo que la media crearía una mayor distorsión.

Otra modificación con respecto al primer método, es que, la ventana se obtendrá 300 muestras antes del pico, de esta forma generamos una ventana con una señal en la cual el pico se encontrará más centrado en la ventana.

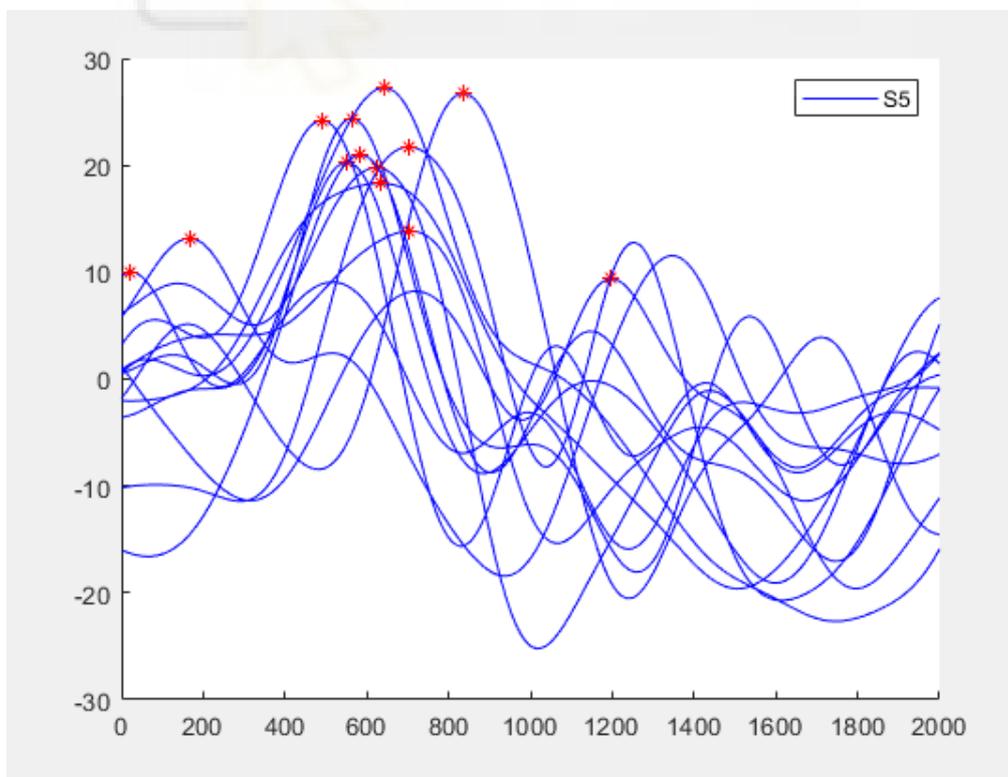


Figura 20. Ploteo de 13 láseres en S5.

3.4.5.2. Selección de ventanas para la clase 2, 3 y 4

Como ya hemos mencionado en el apartado 3.4.4.2, usaremos 3 clasificadores LDA en serie, los cuales clasificarán dos clases, para la primera de ellas, en los tres casos usaremos la clase 1 y para la segunda clase, en cada clasificador usaremos diferentes datos de entrenamiento capturados durante la marcha normal, estas clases corresponden con la clase 2, 3 y 4, como se muestra en la Figura 21.

Para la extracción de estas clases, nos bastará con la extracción de ventanas en instantes en los que sepamos que no se va a producir ningún ERP debido a la aparición del láser, para eso, se han escogido instantes anteriores de la aparición del estímulo visual, asegurándonos que el sujeto se encuentra andando de forma normal.

Como se muestra en la Figura 21, para la clase 2, cogemos una ventana de 960 muestras, que tiene lugar 2 segundos antes de la aparición del láser, 2400 muestras antes del láser. La clase 3 corresponde a 3 segundos antes de la aparición del láser y, por último, la clase 4, que se obtendrá 4 segundos antes de la aparición del láser, con lo que nos aseguramos 3 ventanas completamente distintas pero que hacen referencia a momentos de marcha normal, lo que nos aporta una mayor cantidad de datos para un mismo número de registros.

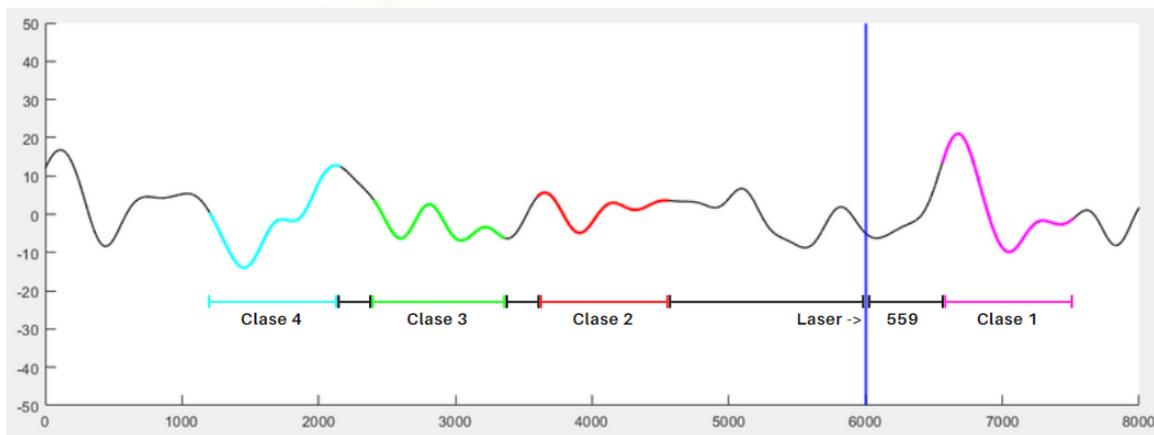


Figura 21. Gráfica que muestra los instantes en los que se ha seleccionado cada clase.

3.4.6. Análisis pseudo-online

Para este trabajo, se contaba con trabajos previos [7] en los que se planteó un primer análisis offline pero los resultados que arrojó eran muy distintos a los obtenidos con el modelo pseudo-online, es por eso que se ha optado por omitir el apartado offline, ya que el estudio tiene como finalidad una aplicación en tiempo real y para ello es necesario un entorno de simulación que se asemeje lo máximo posible.

Para la realización de este método, se empleará como input, los registros de un usuario, cada uno de ellos contiene pruebas de una duración aproximada de 2 minutos, en los que se ha registrado diferentes parámetros para su posterior análisis. Entre ellos se encuentran las 32 señales EEG, las IMUs o los tiempos de activación del láser.

El método consiste en usar una parte de los registros para entrenar al modelo y usar el resto para el test, el cual consiste en seleccionar ventanas de 960 muestras (0,8s) cada 120 muestras de un registro que no haya sido usado para el entrenamiento y analizarlas una por una para su posterior evaluación de los resultados.

Una vez realizado el análisis pseudo-online, el programa nos arroja una tabla como la Tabla 5, la cual conviene mencionar, ya que, en el apartado de resultados, se usarán varios de éstos campos a la hora de analizar todas las posibles mejoras del trabajo.

Tabla 5. Ejemplo tabla de resultados.

K	FP/min	TP(%)
1	22,77	100,00
2	8,76	75,00
3	0,88	66,67
4	0,00	25,00
5	0,00	8,33

Empezaremos hablando por la primera columna, *K*, este número nos indica el número de detecciones que el clasificador debe detectar de forma consecutiva para que se considere como parada (no confundir con lo comentado en el apartado 3.4.4.2 que, para el caso de los 3 clasificadores en serie, una detección de parada requiere que los 3 clasificadores la detecten).

A continuación, nos encontramos con los *FP/min*, esta medida nos indica cuantas detecciones se han producido fuera del rango de “*tiempo detección laser*” y “*Eliminación FP/min*”, que se muestran en la Figura 22, el cual, es un tramo en el que el usuario se detiene y vuelve a reanudar la marcha, por lo que no nos interesa analizar, ya que introduce mucho ruido. Este es un dato que pretendemos reducir ya que lo consideramos una detección errónea por parte del clasificador.

Finalmente, tenemos los *TP (%)* que nos indica la cantidad de láseres que se han detectado correctamente dentro del tramo “*Tiempo detección láser*”. En este caso, buscaremos maximizar el porcentaje de detecciones correctas siempre que eso no conlleve un incremento desproporcionado de los *FP/min*.

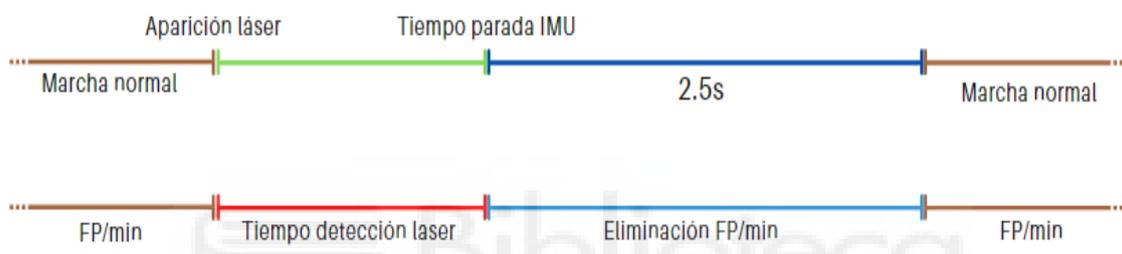


Figura 22. Representación visual de los diferentes instantes.



Capítulo 4. Resultados

En este apartado se expondrán todos los resultados que se obtienen a partir de los métodos planteados en el capítulo 3.

Dividiremos los resultados en 6 grandes bloques. En primer lugar, mostraremos los resultados obtenidos con las nuevas detecciones de las IMUs, a continuación, introduciremos un nuevo concepto, el cual todavía no se había calculado donde trataremos de buscar el numero óptimo de *train/test* sin que los resultados empeoren demasiado. En el apartado 4.3 probaremos diferentes configuraciones para encontrar la que mejor se ajuste a cada usuario, en base a estos resultados, una vez obtenidos los mejores resultados para cada sujeto, en el apartado 4.4 se probará una configuración promedio, después, se analizarán las mejores características. Por último, en el apartado 4.6 buscaremos una configuración promedio que se ajuste a todos los usuarios.

4.1. Nuevas detecciones IMUs.

Como se ha planteado en 3.3, se ha cambiado por completo el método para la detección de IMUs por uno que registra todas las paradas. Este cambio tiene como objetivo, poder realizar una mejor evaluación final de los *TP (%)*, ya que los tiempos de las IMUs se usan para delimitar el periodo que se considera válido para la detección del láser y a partir del cual se eliminan 2,5 segundos posteriormente, los cuales eliminan el ruido posterior a la parada del sujeto, esto se entiende mejor en la Figura 22.

A continuación, se muestra una tabla con los resultados de los tiempos de parada, calculados con anterior método, si nos fijamos en la Tabla 6, la cual, se ha extraído de uno de los sujetos con un índice muy bajo de aciertos, puede verse muchos ceros, que se corresponden con una mala detección de ese láser.

Tabla 6. Detección tiempos IMUs para S7.

Láseres															
n° sesión	1	2	3	4	5	6	7	8	9	10	11	12	13	14	Media
1	1,4	1,5	0	1,4	1,5	1,1	0	0	1,5	1,6	0	1,6	1,6	1,5	1,6
2	1,4	1,7	1,6	2,1	1,6	0	1,5	1,4	1,5	0	1,6	1,3	1,8	-	1,6
3	0	1,5	1,4	1,8	1,4	1,5	1,4	1,6	1,8	0	1,6	1,6	-	-	1,6
4	1,7	1,6	1,6	1,5	1,7	1,4	1,5	0	1,7	1,3	1,4	0	1,5	-	1,5
5	1,5	0	1,5	1,3	1,4	1,3	1,2	1,6	1,5	1,7	0	0	1,6	-	1,5
6	1,2	0	1,5	1,7	1,7	1,7	1,4	1,6	1,6	1,7	1,6	1,5	1,5	-	1,6
7	0	1,9	1,6	1,7	1,9	1,8	1,6	1,7	0	1,7	1,6	1,4	0,0	-	1,7
8	1,8	1,5	1,6	1,7	0	1,8	1,8	1,8	1,8	1,5	1,6	1,6	1,5	-	1,7
9	0,7	0,8	0	0,9	0	0	1,0	1,3	1,3	0	1,2	1,2	-	-	1,0
10	1,1	1,3	0	1,2	1,3	1,2	1,3	1,6	1,2	1,6	1,2	1,2	1,3	-	1,3

A continuación, mostraremos una comparativa con los tiempos obtenidos de calcular todas las paradas con el antiguo método [7], el cual se presenta en la Tabla 7 y después, en la Tabla 8, mostramos las mismas detecciones calculadas con el nuevo método, el cual comentamos en el apartado 3.3.1. Como podemos observar, ambos métodos consiguen una detección de los tiempos muy parecida, pero ahora se registrarán todas las paradas.

Tabla 7. Tiempos detección IMUs método [7].

n° sesión	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
1	0,68	1,24	1,2	1,2	1,7	1,81	1,6	1,3	1,12	1,56
2	0,80	1,28	1,3	1,2	1,5	1,48	1,6	1,3	0,93	1,42
3	0,81	1,26	1,3	1,2	1,6	1,34	1,6	1,2	0,84	1,34
4	0,73	1,22	1,4	1,2	1,4	1,81	1,5	0,8	1,03	1,38
5	0,65	1,34	1,4	1,2	1,5	1,45	1,5	0,9	1,14	1,25
6		1,32	1,5	1,1	1,5	1,41	1,6	1,2	1,00	1,33
7	-	1,23	1,5	1,2	1,8	1,79	1,7	0,9	1,11	1,34
8	-	1,23	1,6	1,1	1,6	1,39	1,7	1,0	1,07	1,26
9	-	1,24	1,4	1,1	1,4	2,09	1,0	0,9	0,95	1,30
10	-	1,27	1,5	1,1	1,5	1,62	1,3	0,8	1,02	1,22
Media	0,73	1,26	1,41	1,16	1,54	1,62	1,50	1,02	1,02	1,34

Tabla 8. Nuevos tiempos detección IMUs.

n° sesión	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
1	0,70	1,30	1,17	1,23	1,70	1,81	1,46	1,27	1,12	1,43
2	0,80	1,37	1,31	1,23	1,67	1,48	1,51	1,31	0,96	1,35
3	0,82	1,33	1,23	1,21	1,57	1,34	1,55	1,25	0,90	1,29
4	0,77	1,29	1,31	1,26	1,37	1,78	1,57	0,90	1,04	1,39
5	0,70	1,36	1,36	1,19	1,52	1,45	1,50	0,93	1,09	1,27
6	-	1,33	1,38	1,14	1,48	1,41	1,56	1,26	1,03	1,35
7	-	1,27	1,38	1,18	1,55	1,79	1,72	0,87	1,09	1,38
8	-	1,25	1,30	1,11	1,56	1,39	1,34	0,97	1,05	1,34
9	-	1,28	1,38	1,13	1,21	2,09	1,00	0,92	0,97	1,28
10	-	1,29	1,51	1,17	1,49	1,61	1,31	0,84	0,99	1,28
Media	0,76	1,31	1,33	1,19	1,51	1,61	1,45	1,05	1,02	1,34

4.2. Selección train/test óptimo.

Excepto en el caso de *S1*, el resto de sujetos cuentan con una cantidad de 10 sesiones, con un tiempo aproximado de unos 2 minutos, lo que nos proporciona una cantidad bastante limitada de datos con los que entrenar el modelo, es por eso que hasta ahora, sólo se había contemplado la opción de usar 9 registros para la creación del modelo y simplemente se usaba el décimo como test, y de esta forma, maximizar la cantidad de datos con los que poder entrenar.

Pero en este nuevo proyecto, se ha querido comprobar, que cantidad de *train/test* puede llegar a usarse sin que los resultados se vean gravemente perjudicados, de esta forma, en futuros trabajos, no sería necesaria la creación de tantos registros.

Como curiosidad, a la hora de ejecutar el registro *S1* con el nuevo método de detección de IMUs mencionado en el apartado 4.1, no se conseguía detectar casi ningún láser, es por eso que para *S1*, las pruebas se realizarán con el tiempo medio usado en el anterior trabajo [7].

Otro sujeto que ha sufrido una modificación, ha sido *S7*, al cual, debido a una condición que eliminaba todas las señales con una desviación típica superior a 40, no conseguía crearse el vector con las distintas clases, ya que todas las señales tenían una desviación típica mayor, para este caso se ha eliminado esta condición como algo excepcional.

A continuación, en la Tabla 9 y la Tabla 10 se muestra un resumen en el que se ha ido reduciendo progresivamente la cantidad de sesiones que usábamos para el entrenamiento y se han usado para testear.

Tabla 9. Porcentaje de láseres detectados en función del volumen de datos de entrenamiento.

train/test	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	Media ± σ
9/1	76,92	69,2	38,5	7,7	38,5	76,9	30,8	15,4	64,3	66,7	48,5 ± 25,6
8/2	57,69	57,7	26,1	19,2	38,5	76,9	38,5	11,5	59,1	54,2	43,9 ± 20,7
7/3	48,72	64,1	23,2	12,8	51,3	71,8	5,1	15,4	49,8	48,7	39,1 ± 23,1
6/4	51,12	75,0	25,3	14,0	48,1	65,4	33,3	23,1	38,1	45,2	41,9 ± 19,1
5/5	-	66,2	49,4	21,5	49,9	63,1	31,3	6,5	73,7	50,8	45,8 ± 22,1
4/6	-	78,2	27,0	26,9	43,8	65,4	40,0	14,4	92,3	48,8	48,5 ± 25,7
3/7	-	71,4	24,3	26,4	51,7	46,2	5,7	0,0	90,3	51,7	40,9 ± 29,6
2/8	-	53,8	21,4	21,4	43,6	61,5	14,2	0,0	90,5	44,1	38,9 ± 27,8
1/9	-	49,9	25,4	38,0	46,2	10,3	64,2	6,0	94,9	33,3	40,9 ± 27,5

Tabla 10. FP/min en función del volumen de datos de entrenamiento.

train/test	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	Media ± σ
9/1	0,91	1,74	3,33	3,48	5,14	0,00	3,53	9,71	8,51	0,88	3,7 ± 3,2
8/2	4,44	5,16	3,79	4,32	4,38	4,14	8,73	5,29	8,00	3,55	5,2 ± 1,8
7/3	2,64	10,05	0,84	3,82	4,73	3,04	1,17	4,11	6,13	4,75	4,1 ± 2,6
6/4	4,83	12,02	1,92	3,98	3,08	3,80	12,26	4,04	4,62	3,55	5,4 ± 3,6
5/5	-	11,57	5,14	5,29	3,31	5,59	4,63	3,34	5,90	4,43	5,5 ± 2,5
4/6	-	13,38	3,15	5,10	2,72	4,71	4,58	5,28	6,75	4,72	5,6 ± 3,1
3/7	-	12,52	3,12	3,37	2,85	3,58	2,08	0,62	6,13	4,18	4,3 ± 3,4
2/8	-	8,17	9,07	4,93	2,17	4,10	6,49	0,22	4,63	4,83	5 ± 2,8
1/9	-	9,39	4,64	7,75	2,31	0,10	20,89	1,75	2,72	5,76	6,1 ± 6,3

Para tomar la decisión de que proporción de *train/test* es la mejor, se han resumido las dos tablas anteriores en la Tabla 11, donde se ha calculado la media de los diez sujetos para cada *train/test* y con las medias se ha calculado la *Relación* entre la media de los *TP(%)* y la media de los *FP/min*, ya que lo que nos interesa es maximizar esta relación, aunque no tiene por qué ser un parámetro determinante, por lo que no será el único dato que nos apoyaremos para tomar la decisión.

Para 9/1 nos da un resultado muy alto, ya que, desde un primer momento, la configuración para cada sujeto se ha hecho intentando maximizar sólo esta opción, por lo que buscaremos entre las siguientes opciones.

Los siguientes resultados más favorables son 7/3 y 3/7, lo que no es lo que debería esperarse, ya que esta relación debería de ir reduciéndose gradualmente. Es por esto que usaremos este dato como algo orientativo, pero no siempre será determinante.

Tabla 11. Medias totales extraídas de las tablas 9 y 10.

train/test	Media TP(%)	Media FP/min	Relación
9/1	48,48	3,72	13,02
8/2	43,93	5,18	8,48
7/3	39,09	4,13	9,47
6/4	41,86	5,41	7,74
5/5	45,80	5,47	8,38
4/6	48,53	5,60	8,67
3/7	40,86	4,27	9,56
2/8	38,95	4,96	7,86
1/9	40,89	6,15	6,65

Ante la incertidumbre de cual elegir, hemos expresado estos datos en forma de gráfica, la cual podemos ver en la Figura 23, que nos ayudará a observar mejor como varían las diferentes opciones. Vemos que los resultados son muy parecidos, ya que para una bajada de *FP/min*, lo cual es algo que buscamos, también se genera una bajada en los *TP (%)*, siendo este un dato que intentamos maximizar.

Finalmente, para una mayor representación de los futuros datos y en vista de que para 5/5 se genera una bajada de *FP/min* a la vez que suben los *TP (%)*, nos decantaremos por esta opción, que nos dará una media más estable a la hora de elegir la mejor configuración en el apartado 4.3, en la que sólo se usará la configuración *train/test* de 5/5, excepto para *S1* que, al tener sólo 5 sesiones, usaremos una proporción de *train/test* de 3/2, ya que son muy pocos registros para entrenar el modelo.

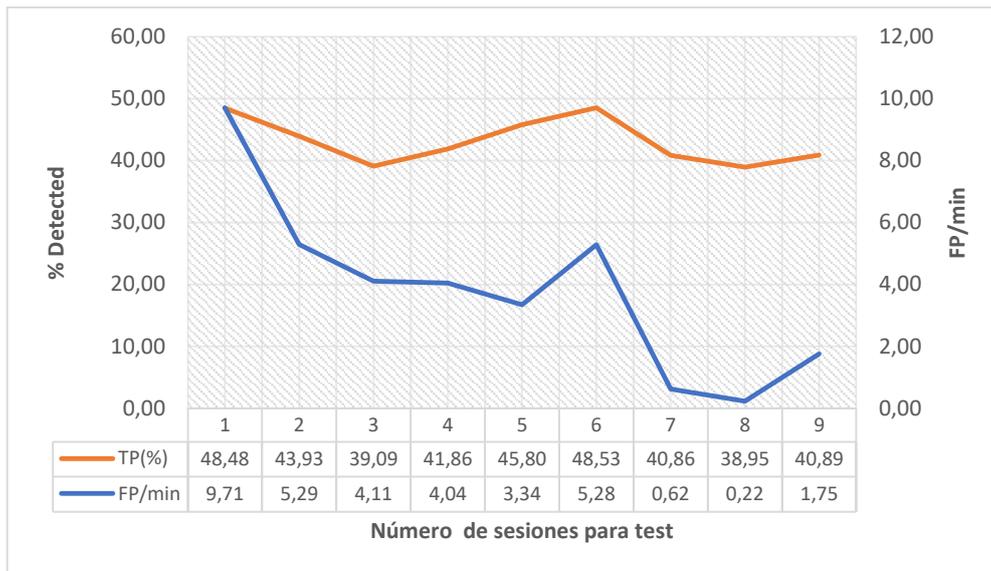


Figura 23. Representación gráfica de la tabla 11.

4.3. Prueba y selección de las diferentes configuraciones.

Para intentar conseguir una configuración óptima, probaremos de forma independiente las diferentes configuraciones para escoger la mejor de cada una de ellas, las cuales explicaremos a continuación.

Para esta prueba, todos los sujetos se inicializarán con la misma configuración, la cual mostramos en la Tabla 12, y sólo se modificará uno de los parámetros cada vez, *conf 6* serán siempre igual excepto para *S1*, el cual, como se comentó en el apartado 4.3, debemos cambiarla para que funcione correctamente.

Tabla 12. Configuración por defecto elegida para la prueba.

conf 1	conf 2	conf 3	conf 4	conf 5	conf 6
3	4	5	M	1:22	A

Configuración 1: Clasificadores en serie

Con el objetivo de reducir los *FP/min*, se ha probado la posibilidad de introducir más de un clasificador en serie, para comprobar que cantidad de clasificadores en serie puede ser la óptima, en esta configuración probaremos a variar la cantidad de clasificadores que hemos empleado en el modelo. Esta configuración la podemos ver en la Tabla 13.

Tabla 13. Resultados obtenidos tras probar un número diferente de clasificadores en los 10 sujetos.

	Clasificadores en serie (Conf 1)								
	3 clasificadores			2 clasificadores			1 clasificador		
	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación
S1	4,61	46,15	10,02	5,05	48,46	9,60	4,70	48,46	10,32
S2	10,91	48,31	4,43	8,70	42,46	4,88	11,06	44,92	4,06
S3	5,86	42,84	7,32	6,89	45,31	6,58	6,99	45,31	6,48
S4	5,57	18,46	3,31	10,86	27,08	2,49	10,97	27,38	2,50
S5	5,34	48,95	9,17	6,04	49,59	8,21	6,04	49,59	8,21
S6	8,18	66,46	8,13	11,19	73,85	6,60	11,29	74,15	6,57
S7	6,24	32,54	5,22	7,02	38,51	5,48	17,53	57,13	3,26
S8	8,25	19,38	2,35	12,88	23,38	1,82	15,95	28,92	1,81
S9	8,68	68,58	7,90	10,14	71,83	7,08	9,62	80,92	8,41
S10	13,36	56,33	4,22	13,71	56,67	4,13	14,45	58,59	4,05

Como podemos observar, si nos fijamos en la columna de *Relación*, para casi todos los sujetos, la configuración más óptima la encontramos para los tres clasificadores en serie, sin embargo, no dista mucho de los resultados obtenidos para la segunda opción, que consiste en emplear dos clasificadores.

Finalmente, como hemos comentado, para un solo clasificador, los *FP/min* tienen un ligero incremento, aunque también incrementa el porcentaje de detecciones, es por eso que empleamos la columna de la *Relación*, para ver en qué proporción suben las detecciones respecto a los *FP/min* y de esta forma poder tomar una decisión un poco más objetiva sobre cual es mejor.

Configuración 2: Probabilidad a priori

Este concepto ya se planteó en trabajos anteriores [7], se trata de una de las distintas configuraciones que nos incorpora el clasificador LDA y que consiste en introducir al clasificador una probabilidad a priori para que a la hora de clasificar, modifique los pesos que le da a cada clase, nosotros lo usaremos para que reduzca la cantidad de *FP/min*, ya que en pseudo-online, la cantidad de muestras empleadas para la marcha normal es mucho mayor que las ventanas que corresponden a la parada, sin embargo, una probabilidad a priori muy alta, también puede provocar una notable reducción de los *TP (%)*, algo que no nos interesa. Es por eso que en la Tabla 14 probaremos diferentes probabilidades a priori con el objetivo de buscar el número óptimo para cada sujeto.

Tabla 14. Resultados obtenidos con una probabilidad a priori distinta en los 10 sujetos.

	Probabilidad a priori (Conf 2)								
	Probabilidad 3			Probabilidad 4			Probabilidad 5		
	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación
S1	5,49	50,77	9,25	4,61	46,15	10,02	3,90	42,31	10,85
S2	12,92	53,85	4,17	10,91	48,31	4,43	9,45	44,31	4,69
S3	8,13	48,77	6,00	5,86	42,84	7,32	4,63	36,94	7,98
S4	6,88	20,00	2,91	5,57	18,46	3,31	5,15	16,92	3,29
S5	5,89	52,41	8,89	5,34	48,95	9,17	4,91	46,18	9,40
S6	8,87	69,85	7,87	8,18	66,46	8,13	7,76	64,31	8,28
S7	6,72	33,79	5,03	6,24	32,54	5,22	5,93	30,67	5,17
S8	10,64	22,15	2,08	8,25	19,38	2,35	6,97	17,54	2,52
S9	8,65	68,34	7,90	8,68	68,58	7,90	8,45	67,36	7,97
S10	14,35	57,62	4,02	13,36	56,33	4,22	12,29	56,00	4,56

En este caso, se puede observar de una forma muy clara, que, en la mayoría de sujetos, una probabilidad a priori de 5, genera unos resultados mucho más óptimos que probabilidades a priori menores, es por eso que nos quedaremos con esta opción para la configuración promedio.

Configuración 3: Número de características

Ya que la introducción de las 17 características usadas en el trabajo puede presentar casos de *overfitting*, debemos buscar cual es el número óptimo de características que maximice los resultados para cada sujeto, es por eso que, en esta configuración, probaremos diferentes combinaciones con el fin de encontrar el número óptimo para cada sujeto. Los datos se muestran en la Tabla 15.

Tabla 15. Resultados obtenidos tras emplear un número distinto de características en los 10 sujetos.

	Número de características (Conf 3)								
	4 características			5 características			6 características		
	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación
S1	3,99	35,38	8,87	4,61	46,15	10,02	5,49	48,46	8,82
S2	9,52	48,00	5,04	10,91	48,31	4,43	10,69	49,23	4,61
S3	6,30	43,18	6,85	5,86	42,84	7,32	6,34	43,74	6,90
S4	4,98	15,69	3,15	5,57	18,46	3,31	7,22	20,31	2,81
S5	4,92	48,67	9,89	5,34	48,95	9,17	5,62	50,51	8,99
S6	3,00	76,92	25,64	8,18	66,46	8,13	8,52	62,15	7,30
S7	11,65	44,67	3,84	6,24	32,54	5,22	7,81	37,21	4,77
S8	8,30	19,08	2,30	8,25	19,38	2,35	9,31	20,62	2,21
S9	7,87	79,68	10,12	8,68	68,58	7,90	8,51	62,62	7,35
S10	13,39	54,44	4,07	13,36	56,33	4,22	12,90	56,00	4,34

Como acabamos de comentar, para 6 características, se empiezan a obtener unos resultados peores que los obtenidos para 4 o 5 características, esto se debe a que no todas las características son igual de buenas, por lo que cuando añadimos un número demasiado elevado de ellas, empezamos a sesgar la información y se acaban obteniendo peores resultados que si añadimos un número menor y de mejor calidad.

Configuración 4: Selección muestra

La muestra hace referencia al intervalo de muestras que se sitúa entre la aparición del láser y el comienzo de la clase 1, cómo ya se comentó en 3.4.5.1, tenemos dos posibles opciones, por un lado, los tiempos previamente calculados en [7] y que son igual para todos los láseres, muestra manual (M), o el nuevo método que de forma automática (A), encuentra los máximos del ERP e inicializa la ventana 300 muestras antes, que correspondería con el inicio de la clase 1, de esta forma centramos el potencial generado en el centro de la ventana. Vemos los resultados obtenidos en la Tabla 16.

Tabla 16. Resultados obtenidos tras modificar la selección de muestra en los 10 sujetos.

	Muestra manual			Muestra automática		
	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación
S1	4,61	46,15	10,02	2,93	33,08	11,28
S2	10,91	48,31	4,43	2,91	33,85	11,61
S3	5,86	42,84	7,32	7,08	42,89	6,06
S4	5,57	18,46	3,31	6,52	20,31	3,11
S5	5,34	48,95	9,17	4,68	46,51	9,95
S6	8,18	66,46	8,13	6,99	61,54	8,80
S7	6,24	32,54	5,22	6,45	39,36	6,10
S8	8,25	19,38	2,35	7,04	22,46	3,19
S9	8,68	68,58	7,90	5,24	85,87	16,38
S10	13,36	56,33	4,22	3,82	38,74	10,13

Vemos de forma muy clara que, para casi todos los casos, el uso de una muestra detectada de forma automática, reduce notablemente la cantidad de *FP/min*.

Para el caso de los *TP (%)* observamos diferentes casos, en algunos sujetos, la cantidad de detecciones se reduce notablemente, para otros sujetos, las detecciones son muy parecidas y finalmente tenemos sujetos donde también se ha conseguido una notable mejoría en la detección de las paradas con el uso de la muestra automática.

Pero en todos ellos, menos en *S3* y *S4*, la relación es notablemente mayor para la configuración automática en la detección de muestras.

Configuración 5: Selección de electrodos

Los electrodos pueden seleccionarse de forma manual o de forma automática, de los cuales se buscarán los 22 mejores electrodos ya mencionados en 3.4.2, en este caso usaremos la selección manual (M) para escoger los electrodos de la zona occipital y parietal, que corresponden a los siguientes 12 electrodos: CZ, CP1, CP2, PZ, P4, C1, C2, CP3, CPZ, P1, P2, POZ, como se puede observar en la Figura 16. Para la selección automática (A), se escogerán entre los 22 electrodos válidos. Estos resultados se muestran en la tabla 17.

Tabla 17. Resultados obtenidos tras modificar la selección de los electrodos en los 10 sujetos.

	Electrodos 1:22			occipital + parietal		
	FP/min	TP(%)	Relación	FP/min	TP(%)	Relación
S1	4,61	46,15	10,02	4,61	46,15	10,02
S2	10,91	48,31	4,43	8,71	32,31	3,71
S3	5,86	42,84	7,32	4,05	7,05	1,74
S4	5,57	18,46	3,31	0,28	2,46	8,88
S5	5,34	48,95	9,17	3,17	34,92	11,01
S6	8,18	66,46	8,13	8,84	55,38	6,26
S7	6,24	32,54	5,22	0,24	0,62	2,56
S8	8,25	19,38	2,35	3,58	4,62	1,29
S9	8,68	68,58	7,90	9,83	58,68	5,97
S10	13,36	56,33	4,22	9,00	35,74	3,97

Aunque con la configuración manual no se han obtenido malos resultados, los datos generados con la configuración automática siguen siendo mejores que con la selección de la zona occipital y la parietal. Aunque las detecciones de *FP/min* se han reducido un poco en la selección manual, el decremento de los *TP (%)* es muy grande y produce una *Relación* algo menor que para el caso de la selección automática, que es con la que nos quedaremos finalmente.

Configuración 6: Tiempos de las IMUs

En esta configuración, elegimos si los tiempos de las IMUs queremos que sean con el nuevo método que los saca la parada de las IMUs para cada láser de forma individual y automática (A) o si usamos los tiempos medios calculados en [7], los cuales son iguales en todas las paradas de un mismo usuario, ya que se sacan a partir de la media de todos ellos de forma manual (M).

Debido a que sólo emplearemos la detección automática de IMUs, no se ha realizado ninguna comparación y por lo tanto no se ha asociado ninguna tabla a esta configuración.

Finalmente, escogemos los mejores resultados de cada tabla, los cuales mostramos en la Tabla 18 y volvemos obtener los resultados para cada sujeto, los cuales se resumen en la Tabla 19, en esta tabla, los resultados que se muestran son los obtenidos de las 5 tablas que se generan, de las cuales se calculará el valor medio para cada K .

Tabla 18. Recopilación de las configuraciones finales para cada usuario.

	conf 1	conf 2	conf 3	conf 4	conf 5	conf 6
S1	1	5	5	A	1:22	M
S2	2	5	4	A	1:22	A
S3	3	5	5	M	1:22	A
S4	3	4	5	M	1:22	A
S5	3	5	4	A	1:22	A
S6	3	5	4	A	1:22	A
S7	2	4	5	A	1:22	A
S8	3	5	5	A	1:22	A
S9	1	5	4	A	1:22	A
S10	1	5	6	A	1:22	A
Media	2,2	4,8	4,7			

Tabla 19. Resultados de todos los usuarios con la mejor configuración para 5/5.

		K1	K2	K3	K4	K5	Media	Relación
S1	TP(%)	65,4	53,8	34,6	7,7	3,8	33,1	13,8
	FP/min	4,5	2,7	2,2	1,3	1,3	2,4	
S2	TP(%)	49,2	38,5	36,9	24,6	12,3	32,3	9,3
	FP/min	6,7	5,0	2,9	1,8	1,1	3,5	
S3	TP(%)	61,8	55,7	37,0	18,3	11,9	36,9	8,0
	FP/min	13,0	5,0	2,2	1,7	1,2	4,6	
S4	TP(%)	33,8	26,2	21,5	7,7	3,1	18,5	3,3
	FP/min	12,1	6,9	4,4	3,0	1,4	5,6	
S5	TP(%)	62,6	45,1	37,3	21,7	9,4	35,2	17,6
	FP/min	5,8	1,9	1,1	0,9	0,4	2,0	
S6	TP(%)	81,5	72,3	63,1	49,2	33,8	60,0	9,0
	FP/min	13,8	7,7	5,5	3,9	2,4	6,7	
S7	TP(%)	67,1	50,0	42,3	34,6	18,7	42,5	5,5
	FP/min	17,9	9,6	6,7	3,6	1,0	7,8	
S8	TP(%)	49,2	26,2	15,4	7,7	1,5	20,0	3,4
	FP/min	16,7	6,0	4,4	2,1	0,7	6,0	
S9	TP(%)	37,2	89,5	92,3	90,8	86,1	79,2	9,2
	FP/min	20,8	8,2	5,7	4,6	3,9	8,6	
S10	TP(%)	75,5	55,9	36,2	11,5	6,7	37,2	9,5
	FP/min	12,2	4,4	1,9	0,5	0,4	3,9	
Media + σ TP(%) total							39,5 \pm 18,1	8,8 \pm 4,4
Media + σ FP/min total							5,1 \pm 2,2	

Aparentemente los resultados no son tan buenos como cabría esperar, pero se debe destacar que al tratarse de un modelo con un *train/test* de 5/5, lo que para un registro puede ser una configuración óptima, no tiene por qué serlo para los otros 4, es por eso que no obtenemos la misma precisión para 9/1 que para 5/5 aun tratándose del mismo sujeto, además de que se hace la media con las 5 *K* para que los resultados sean más estables, pero el resultado óptimo se debería deducir de una sola *K*.

4.4. Resultados para una configuración promedio

Una vez planteadas todas las configuraciones personalizadas para cada usuario, se plantea la posibilidad de generar una configuración genérica que pueda generalizarse a todos los usuarios. A partir de las configuraciones individuales del apartado anterior, como se puede observar en la Tabla 18, se ha sacado la media de las diferentes configuraciones y de ahí sale la Tabla 20, con una configuración promedio que usaremos para todos los usuarios, cuyos resultados mostramos en la Tabla 21.

Tabla 20. Configuración por defecto elegida para la prueba.

conf 1	conf 2	conf 3	conf 4	conf 5	conf 6
2	5	5	A	1:22	A

Tabla 21. Resultados de todos los usuarios con la configuración promedio de la tabla 66.

		K1	K2	K3	K4	K5	Media	Relación
S1	TP(%)	61,5	46,2	30,8	3,8	3,8	29,2	12,2
	FP/min	4,5	2,7	2,2	1,3	1,3	2,4	
S2	TP(%)	46,2	36,9	33,8	23,1	10,8	30,2	11,0
	FP/min	6,5	4,1	2,0	0,9	0,2	2,7	
S3	TP(%)	67,8	47,7	40,0	29,4	20,2	41,0	6,8
	FP/min	13,5	6,2	4,7	3,4	2,6	6,1	
S4	TP(%)	43,1	32,3	27,7	9,2	3,1	23,1	2,7
	FP/min	19,7	10,4	7,3	3,9	1,4	8,5	
S5	TP(%)	68,8	54,6	49,9	34,2	20,3	45,6	10,0
	FP/min	9,8	4,9	2,8	2,6	2,6	4,5	
S6	TP(%)	80,0	75,4	66,2	58,5	35,4	63,1	8,7
	FP/min	16,5	8,8	5,3	3,7	2,0	7,3	
S7	TP(%)	65,4	48,5	40,8	32,9	18,7	41,3	5,9
	FP/min	16,5	8,6	6,2	3,1	0,8	7,0	
S8	TP(%)	49,2	26,2	15,4	7,7	1,5	20,0	3,4
	FP/min	16,7	6,0	4,4	2,1	0,7	6,0	
S9	TP(%)	38,7	93,8	92,3	92,3	87,7	81,0	12,4
	FP/min	15,9	5,5	4,6	3,7	2,9	6,5	
S10	TP(%)	75,3	54,2	29,6	9,9	6,7	35,1	11,4
	FP/min	10,3	3,4	1,2	0,4	0,2	3,1	
Media + σ TP(%) total							40,9 \pm 18,7	8,4 \pm 3,6
Media + σ FP/min total							5,4 \pm 2,1	

Como se puede ver en la Tabla 21, el uso de una configuración genérica para los resultados de ciertos usuarios, son incluso mejores que los obtenidos en la Tabla 19, como por ejemplo *S2*, *S7* o *S10*, donde la forma genérica ha resultado dar mejores resultados que con la configuración personalizada. Por otro lado, tenemos a sujetos como *S6*, el cual, para una configuración personalizada, se obtiene una relación notablemente mayor.

4.5. Resultados para selección automática de características

Tras el análisis de la configuración promedio del apartado anterior, hemos representado en la Tabla 22 las 5 mejores características de cada usuario, como ya hemos comentado, hemos usado tres clasificadores en serie para la detección de las paradas por lo que nos genera un total de 3 *datasets* de entrenamiento distintos, es por eso que de cada usuario obtenemos 3 vectores con las 5 mejores características según el algoritmo de selección automática ya comentado en el apartado 3.4.3.

Estas características, al obtenerse de forma automática, dependerán en todo momento de los datos de entrenamiento que seleccionemos, es por eso que pueden variar si escogemos un número distinto de electrodos, o si escogemos las muestras en diferentes instantes de tiempo, aunque como se puede observar en la Tabla 22, los tres grupos de características escogidos para cada usuario, son muy similares.

El objetivo de esta tabla es generar un registro de las veces que cada característica ha sido escogida de forma automática por el algoritmo para usarse posteriormente en el clasificador y de esta forma saber cuáles podrían llegar a ser las mejores características y cuales podrían descartarse en un futuro.

Tabla 22. Mejores 5 características para cada usuario.

Características	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
S1	1	1			1				1				1				
	1	1			1				1				1				
	1	1				1			1				1				
S2	1		1		1					1			1				
	1		1						1	1			1				
	1		1		1					1							
S3			1			1			1	1	1						
									1	1	1	1	1				
									1	1	1	1	1				
S4	1	1			1	1							1				
	1				1	1	1						1				
	1		1						1				1	1			
S5	1							1		1	1		1				
	1							1		1	1		1				
	1							1		1	1		1				
S6	1				1	1	1						1				
	1				1	1	1						1				
	1	1			1	1							1				
S7						1	1								1	1	1
		1			1	1	1					1					
		1			1	1	1									1	
S8	1								1	1		1	1				
	1								1	1		1	1				
	1								1	1		1	1				
S9	1	1			1	1	1										
	1	1			1	1	1										
	1				1	1	1		1								
S10	1				1			1	1				1				
	1				1			1	1				1				
	1				1			1	1				1				
Sumatorio	24	9	5	0	17	13	9	6	15	12	6	7	22	0	1	2	1

A continuación, en la Tabla 23, se muestran de forma ordenada las 17 características de la Tabla 22 en función de las veces que han sido seleccionadas para los clasificadores, esto nos da una muestra de cómo de buena puede llegar a ser una característica.

En una primera zona de la tabla, nos encontramos con las características más usadas, que serían la 1, 13, 5, 9, 6 y 10, que por cómo funciona nuestro algoritmo, indican que, de forma individual, tienen una mayor capacidad para separar entre clases.

En segundo lugar, nos encontramos con un grupo de características que, aunque se han usado con una frecuencia menor, han sido las mejores para determinados sujetos, estas son la 2, 7, 12, 8, 11 y 3.

En tercer lugar, nos encontramos con un grupo de características que sólo se han empleado para el sujeto *S7*, el cual tenía la peculiaridad de que se le debía eliminar la condición de la desviación típica menor a 40.

Finalmente, el último grupo, el cual está compuesto sólo por las características, 4 y 14, no se han llegado a encontrar nunca entre las mejores 5 características para ninguno de los sujetos evaluados en este estudio, lo que nos indica que estas características pueden llegar a confundirse y mezclarse entre una clase y otra.

Tabla 23. Características ordenadas en función de las veces que han sido usadas por los clasificadores.

Características con la numeración de la Tabla 24	nº veces
1 Error cuadrático medio	24
13 Acumulada	22
5 Amplitud	17
9 Integral	15
6 Varianza	13
10 Varianza de la derivada	12
2 Desviación absoluta media	9
7 Desviación estándar	9
12 Coeficiente de correlación cruzada	7
8 Distancia euclídea entre señales	6
11 Amplitud de la derivada	6
3 Mediana de la desviación absoluta	5
16 Integral de la envolvente	2
15 Varianza de la envolvente	1
17 Desviación estándar de la envolvente	1
4 Frecuencia media	0
14 Amplitud de la envolvente	0

4.6. Comparación resultados finales

Una vez realizadas todas las mediciones, realizaremos una comparativa tanto de los diferentes resultados obtenidos en este estudio como los resultados que se obtuvieron en trabajos anteriores.

Antes de pasar a los resultados con más de una sesión para testear (5/5), en la Tabla 24 se ha querido mostrar los resultados para la configuración más óptima de cada usuario, con un *train/test* de 9/1, empleando el mismo criterio que en anteriores trabajos donde se buscaba la mejor *K* para la cual los *TP (%)* eran mejores, sin que los *FP/min* superase el valor de 4.

No se muestra como se ha seleccionado la configuración de la Tabla 24, ya que es orientativa para mostrar como las nuevas configuraciones añadidas, mejoran para casi todos los sujetos, menos para *S9*, que, aunque para *K* igual a 3, se obtenían unos *TP (%)* del 85,7%, no se ha incluido porque daba 5,96 *FP/min*, lo cual, supera el límite propuesto de 4 *FP/min*.

Tabla 24. Resultados usuarios con la mejor configuración y una *k* que restringe los *FP/min* a 4.

Resultados de la mejor <i>K</i> para un <i>train/test</i> de 9/1									
	conf 1	conf 2	conf 3	conf 4	conf 5	conf 6	<i>K</i>	<i>TP (%)</i>	<i>FP/min</i>
S1	1	2	5	M	1:22	M	3	76,9	3,6
S2	2	2	4	M	1:22	A	2	84,6	1,7
S3	3	3	5	M	1:22	A	3	38,5	1,7
S4	3	4	6	M	1:22	A	2	69,2	3,5
S5	3	4	5	M	1:22	A	2	84,6	3,4
S6	3	5	5	M	1:22	A	2	76,9	1,8
S7	2	2	5	M	1:22	A	3	61,5	3,5
S8	3	6	4	M	1:22	A	1	30,8	2,6
S9	1	6	10	M	1:22	A	5	35,7	2,6
S10	1	8	7	M	1:22	A	3	91,7	0,9
	Media	4,2	5,6				Media ± σ	65,0 ± 22,4	2,5 ± 1

A continuación, en la Tabla 25, se muestran unos resultados similares a los de la tabla anterior, pero en este caso, los mejores valores de K , se obtienen realizando la media de las 5 tablas que se generan para cada usuario.

Tabla 25. Resultados usuarios con la mejor configuración individual y una K que restringe los FP/min a 4 para un train/test de 5/5.

Resultados de la mejor K para un train/test de 5/5 y configuración individual									
	conf 1	conf 2	conf 3	conf 4	conf 5	conf 6	K	TP(%)	FP/min
S1	1	5	5	A	1:22	M	2	53,8	2,7
S2	2	5	4	A	1:22	A	3	36,9	2,9
S3	3	5	5	M	1:22	A	3	37,0	2,2
S4	3	4	5	M	1:22	A	4	9,2	3,9
S5	3	5	4	A	1:22	A	3	49,9	2,8
S6	3	5	4	A	1:22	A	4	58,5	3,7
S7	2	4	5	A	1:22	A	4	32,9	3,1
S8	3	5	5	A	1:22	A	4	7,7	2,1
S9	1	5	4	A	1:22	A	4	92,3	3,7
S10	1	5	6	A	1:22	A	2	54,2	3,4
Media	4,8	4,7					Media $\pm \sigma$	43,2 \pm 24,8	3,1 \pm 0,6

La siguiente tabla corresponde a los resultados que se generan al emplear la configuración promedio que se deduce tras los resultados de las configuraciones individuales. En la Tabla 26 también se han escogido las mejores K promedio, como en la tabla anterior.

Tabla 26. Resultados usuarios con una configuración genérica y una K que restringe los FP/min a 4 para un train/test de 5/5.

Resultados de la mejor K para un train/test de 5/5 y configuración promedio									
	conf 1	conf 2	conf 3	conf 4	conf 5	conf 6	K	TP(%)	FP/min
S1	2	5	5	A	1:22	M	2	46,2	2,7
S2	2	5	5	A	1:22	A	3	33,8	2,0
S3	2	5	5	A	1:22	A	4	29,4	3,4
S4	2	5	5	A	1:22	A	4	9,2	3,9
S5	2	5	5	A	1:22	A	3	49,9	2,8
S6	2	5	5	A	1:22	A	4	58,5	3,7
S7	2	5	5	A	1:22	A	4	32,9	3,1
S8	2	5	5	A	1:22	A	4	7,7	2,1
S9	2	5	5	A	1:22	A	4	92,3	3,7
S10	2	5	5	A	1:22	A	2	54,2	3,4
							Media $\pm \sigma$	41,4 \pm 24,9	3,1 \pm 0,7

Finalmente, para tener una perspectiva con la que poder comparar los resultados obtenidos en este estudio, a continuación, en la Tabla 27, se muestran los resultados de los trabajos previos, cronológicamente, en primer lugar, tenemos el estudio [8] y después, antes que este trabajo, el estudio [7]. En ambos estudios se usó una relación *train/test* de 9/1, por los que no podremos relacionar de forma directa todos los resultados obtenidos.

Tabla 27. Resultados finales de estudios previos.

Primer estudio [8]				Estudio previo [7]				
	K	TP(%)	FP/min	M/A	K	TP(%)	FP/min	
S1	4	28,6	8,0	S1	M	2	53,9	3,2
S2	4	42,9	2,1	S2	A	4	61,5	2,9
S3	2	42,9	8,5	S3	A	3	46,2	3,5
S4	2	7,1	2,7	S4	A	4	69,2	3,0
S5	2	28,6	11,9	S5	M	3	46,2	2,9
Media ± σ	30,0 ± 14,6	6,7 ± 4,2		S6	A	4	83,3	2,6
				S7	A	4	61,7	0,0
				S8	M	5	15,4	3,0
				S9	A	4	100,0	3,6
				S10	M	3	91,7	2,3
				Media ± σ	62,9 ± 24,9	2,7 ± 1,0		

Una comparación clara que podemos hacer es la Tabla 24 con la Tabla 27, en ambos casos se ha buscado la mejor configuración para un *train/test* de 9/1. Podemos observar que, al añadir nuevos cambios, que se corresponden con las diferentes configuraciones, se logra pasar de un 62,9% a un 65,0%, una media un poco frustrada por culpa de S9, pero, aun así, con una ligera mejoría, además, la nueva selección automática para las IMUs, ha reducido el intervalo de tiempo valido para contabilizar los *TP* (%), algo que también ha hecho que se reduzca la tasa de detecciones.

Las Tablas 25 y 26 tienen unos resultados muy parecidos y bastante menores a los que se pueden observar en las Tablas 24 y 27, esto se debe a que son resultados promedio, obtenidos a partir de 5 tablas de distintos registros, para un mismo usuario, por lo que es muy complicado obtener el mejor resultado para los 5 registros, cuya mejor configuración individual, podría ser distinta. Si observamos la configuración de la Tabla 24 y 25, vemos que no son iguales aun siendo la mejor configuración individual para cada sujeto.

Capítulo 5. Conclusiones y trabajos futuros.

A continuación, evaluaremos todos los resultados que se han obtenido con las diferentes modificaciones y, por último, se expondrán las posibles mejoras que podrían llevarse a cabo en futuras investigaciones.

Empezaremos por el análisis de las IMUs, el nuevo método de detección no es el más óptimo ya que se basa en un algoritmo que nos limita a la hora de buscar la parada en tiempo real, que sería la finalidad de este proyecto, pero tiene como ventaja que nos detecta todos los láseres y esto es crucial a la hora de hacer la ejecución pseudo-online y obtener un correcto control de las detecciones. Debido a lo claro que se visualiza la parada cuando ponderamos la señal, será bastante sencillo en un futuro añadir un clasificador que las detecte con bastante precisión y pueda usarse en tiempo real, con el único inconveniente de que añadimos más carga computacional a la hora de ejecutar el programa.

En segundo lugar, comentaremos la nueva variable para la selección de electrodos, la cual ha consistido en añadir de forma manual los electrodos que corresponden con la zona occipital y parietal, aunque los resultados no han sido malos, siguen siendo mejores los resultados que nos arroja la selección automática de los 22 electrodos.

Se ha visto una gran mejoría en la mayoría de sujetos a los que se les han aplicado los tres clasificadores en serie, los cuales nos ha permitido reducir en gran medida la cantidad de *FP/min*, aunque a veces también ha reducido un poco la cantidad de paradas que se detectaban. La pega de usar este sistema es que estamos aumentando el coste computacional, el cual debería reducirse si se quiere conseguir un análisis en tiempo real.

La selección automática de ventanas ha dado mejores resultados en casi todos los sujetos, aunque en muchos de ellos también ha reducido no solo los *FP/min*, si no que el porcentaje de *TP* también se ha visto mermado.

La mejoría de los resultados obtenidos en la Tabla 24 respecto a la Tabla 27, nos indican que se puede seguir mejorando los resultados que obtenemos al ir añadiendo diferentes mejoras en la configuración que entrena el modelo. Además, en este trabajo, se ha probado a variar la cantidad de ficheros que empleábamos para crear el modelo y posteriormente testarlo. Los resultados para 5/5 distan bastante de los que se obtienen para 9/1 pero hay que tener en cuenta que la cantidad de ficheros que usamos para generar el modelo, se han reducido a casi la mitad, además de que se han ponderado los resultados que se generaban para un mismo usuario.

Como conclusión, lo que queda patente en vista de los resultados obtenidos es la variabilidad que existe entre los diferentes sujetos. Es por eso que, para la mayoría de casos en los que se ha automatizado las detecciones de las diferentes variables que intervienen en la creación del modelo, se ha notado una ligera mejoría, esto nos indica que uno de los principales objetivos para futuras investigaciones, debería ser el de automatizar los diferentes parámetros que se han ido evaluando y mejorar las detecciones que ya se realizan de forma automática, ya que es la forma de ahorrar tiempo en la configuración y además, poder mejorar las detecciones.

5.1. Posibles mejoras en futuras investigaciones.

En vista de lo sucedido con el sujeto 7 (S7), al cual se le ha tenido que eliminar la condición de la desviación típica, podría en un futuro analizarse esta condición para ver si es realmente necesaria, ya que es posible que, para muchos sujetos, elimine demasiadas señales, lo que reduciría los datos de entrenamiento, perjudicando un mejor entrenamiento del modelo.

Otro inconveniente que se ha encontrado a la hora de seleccionar los electrodos de forma automática es que, para ciertos casos, el número final de electrodos válidos es demasiado bajo, lo cual puede llegar a introducir demasiada variabilidad en las muestras y no llegar a tener un patrón claro de detecciones. En un futuro podría incluso añadirse un clasificador en la selección de electrodos, ya que éste es uno de los pasos más importantes dentro del procesamiento de las señales EEG.

En vista de los resultados obtenidos en la detección automática de muestras, es otro gran punto a mejorar, ya que, a parte de la búsqueda de máximos, podría añadirse alguna condición más para perfeccionar alguna de las malas detecciones o incluso usar estas detecciones erróneas como criterio a la hora de seleccionar los electrodos, de esta forma nos aseguraríamos una señal mucho más estable.

En futuras investigaciones, será crucial la realización de más pruebas y probar la eficacia de estos nuevos métodos, para este trabajo se han utilizado los registros de estudios anteriores debido a que la situación con del COVID-19, no nos ha permitido realizar nuevas pruebas.

También se podría optar por probar un mayor número de clasificadores para ver los resultados que se obtienen a la hora de diferenciar entre clases. Si se siguen haciendo pruebas y aumentando el *dataset*, se podría incluso llegar a probar las redes neuronales o algoritmos similares, los cuales requieren un gran volumen de datos de entrenamiento.





Bibliografía

- [1] Oset, J. T. (1992). Detección y análisis del componente endógeno CNV. Barcelona: Universidad de Barcelona.
- [2] Ceballos, G. (2015). *Clasificación de estímulos adyacentes en el deletreador P300*.
- [3] F. Ramos-Argüelles, G. M. (Junio 2020). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. Pamplona. Obtenido de http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600006
- [4] García, T. T. (Junio 2020). Manual básico para enfermeros. Malaga. <http://www.sspa.juntadeandalucia.es/servicioandaluzdesalud/huvvsites/default/files/revistas/ED-094-07.pdf>
- [5] Salazar-Varas, R., Costa, A., Úbeda, A., Iáñez, E., & Azorín, J. M. (2015, April). Changes in brain activity due to the sudden apparition of an obstacle during gait. In *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)* (pages: 110-113). IEEE.
- [6] Palacios, L. (Julio 2020). Breve historia de la encefalografía. http://www.acnweb.org/acta/2002_18_2_104.pdf
- [7] Giner, M. E. (2019). *Detección de obstáculos durante la marcha a partir de señales eeg*. Elche: UMH.
- [8] Salazar-Varas, R., Costa, A., Iáñez, E., Úbeda, A., Hortal, E., & Azorín, J. M. (2015). Analyzing EEG signals to detect unexpected obstacles during walking. *Journal of neuroengineering and rehabilitation*, *12*(1), 101.
- [9] Webb, A. R. (2003). *Statistical pattern recognition*. John Wiley & Sons
- [10] Gort Hernández M, et al. Epidemiología de la enfermedad cerebrovascular en un Área Intensiva Municipal. Vol. 16, núm. 2 (2017): abril-junio. Pág. 69-79
- [11] GJ, Warlow C. Treatment and second prevention of stroke: evidence, costs and effects on individuals and populations. *Lancet*. 1999-354:1457-63.

- [12] Mayo Clinic. (Julio 2020). Obtenido de <https://cutt.ly/efhFITO>
- [13] 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: di culties, solutions, and limitations. *Journal of neural engineering*, 12(1), 016011.
- [14] Mateu-Mollá, J. (Agosto 2020). *medicoplus*. Obtenido de <https://medicoplus.com/neurologia/lobulos-del-cerebro>
- [15] M.A. Rosales-Reynoso, C. J.-V.-N. (2018). Evolución y genómica del cerebro humano. En *Neurología* (págs. 254-265).
- [16] Álvarez, A. M. (2015). *Desarrollo de interfaz cerebro-máquina basada en el análisis de eeg y potenciales visuales evocados en estado estable para el control de un objeto*. Universidad de los Andes.
- [17] Vidal, P. V. (2020). *Mejoras en la detección de la intención de giro*. Elche: UMH.
- [18] Murie-Fernández, M., Irimia, P., Martínez-Vila, E., Meyer, M. J., & Teasell, R. (2010). Neuro-rehabilitation after stroke. *Neurología (English Edition)*, 25(3), 189-196.
- [19] Segura, P. S. (2020). *Detección de la intención de cambios de dirección durante la marcha a partir de señales EEG*. Elche: UMH.
- [20] Technaid S.L. (jun 2014). Manual de Usuario Sistema de Captura de Movimiento Tech-MCS V.3.0.
- [21] Rodrigo, J. A. (Agosto 2020). *cienciadedatos*. Obtenido de <https://cutt.ly/MfhDWuh>
- [22] Rodrigo, J. A. (Agosto 2020). *rpubs*. Obtenido de https://rpubs.com/Joaquin_AR/233932

Anexos

Anexo I: Tablas del apartado 4.4



Anexo I: Tablas del apartado 4.4

El siguiente anexo cuenta con las 5 tablas extraídas para cada sujeto que se muestran de forma resumida en el apartado 4.4.

Cada una de las tablas está compuesta por diferentes combinaciones, las cuales son la media del resultado obtenido a partir de 5 tablas cómo se muestra en la Tabla 28.

Tabla 28. Muestra de cómo se obtiene cada una de las tablas que se mostrarán a continuación.

Resultados para un train/test de 5/5										Media	
FP/min	TP (%)	FP/min	TP (%)	FP/min	TP (%)	FP/min	TP (%)	FP/min	TP (%)	FP/min	TP (%)
13,9	84,6	24,0	53,8	27,3	69,2	13,9	84,6	22,1	92,3	20,2	76,9
3,5	61,5	12,9	38,5	19,1	69,2	3,5	61,5	9,7	69,2	9,7	60,0
2,6	46,2	5,1	30,8	14,5	38,5	2,6	46,2	4,4	38,5	5,9	40,0
0,0	30,8	5,1	30,8	12,7	30,8	0,0	30,8	3,5	30,8	4,3	30,8
0,0	23,1	2,6	15,4	3,6	15,4	0,0	23,1	0,9	15,4	1,4	18,5

Las tablas que van de la 29 a la 38, muestran los resultados de todos los usuarios para la configuración 1, las tablas 39 a 48, muestran los resultados de todos los usuarios para la configuración 2, las tablas 49 a 58, muestran los resultados de todos los usuarios para la configuración 3, las tablas 59 a 68, muestran los resultados de todos los usuarios para la configuración 4, y finalmente, las tablas 69 a 78, muestran los resultados de todos los usuarios para la configuración 5.

Cada una de las 10 tablas que pertenece a las diferentes configuraciones, se corresponde con cada uno de los sujetos evaluados en este estudio, cuyos datos se mostrarán de forma resumida en el apartado 4.3.

AI 1.1. Resultados para la configuración 1. Clasificadores en serie

Tabla 29. Resultados obtenidos con un número diferente de clasificadores en serie para S1.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	9,7	76,9	8,9	76,9	8,4	76,9
2	5,7	65,4	5,3	65,4	5,3	65,4
3	3,5	46,2	4,0	53,8	3,5	53,8
4	2,7	38,5	3,5	42,3	3,1	42,3
5	1,3	3,8	3,5	3,8	3,1	3,8
Media	4,6	46,2	5,0	48,5	4,7	48,5
Relación	10,02		9,60		10,32	

Tabla 30. Resultados obtenidos con un número diferente de clasificadores en serie para S2.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	24,3	73,8	20,6	69,2	25,5	70,8
2	13,3	61,5	10,4	53,8	13,8	56,9
3	8,0	44,6	6,0	40,0	7,6	44,6
4	6,1	36,9	4,6	30,8	5,4	33,8
5	2,9	24,6	1,9	18,5	3,0	18,5
Media	10,9	48,3	8,7	42,5	11,1	44,9
Relación	4,43		4,88		4,06	

Tabla 31. Resultados obtenidos con un número diferente de clasificadores en serie para S3.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	15,9	66,6	18,9	68,0	19,2	68,0
2	7,2	58,9	8,7	60,4	8,7	60,4
3	2,7	43,3	3,1	47,8	3,2	47,8
4	2,1	27,5	2,2	30,8	2,2	30,8
5	1,4	17,9	1,5	19,6	1,5	19,6
Media	5,9	42,8	6,9	45,3	7,0	45,3
Relación	7,32		6,58		6,48	

Tabla 32. Resultados obtenidos con un número diferente de clasificadores en serie para S4.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	12,1	33,8	23,9	46,2	24,4	47,7
2	6,9	26,2	12,0	32,3	12,0	32,3
3	4,4	21,5	8,3	26,2	8,3	26,2
4	3,0	7,7	6,2	21,5	6,2	21,5
5	1,4	3,1	3,9	9,2	3,9	9,2
Media	5,6	18,5	10,9	27,1	11,0	27,4
Relación	3,31		2,49		2,50	

Tabla 33. Resultados obtenidos con un número diferente de clasificadores en serie para S5.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	12,2	73,6	12,9	73,6	12,9	73,6
2	6,6	59,2	7,5	59,2	7,5	59,2
3	3,3	49,9	4,4	51,4	4,4	51,4
4	2,8	38,8	3,1	38,8	3,1	38,8
5	1,8	23,2	2,3	24,9	2,3	24,9
Media	5,3	48,9	6,0	49,6	6,0	49,6
Relación	9,17		8,21		8,21	

Tabla 34. Resultados obtenidos con un número diferente de clasificadores en serie para S6.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	15,4	84,6	23,3	89,2	23,2	89,2
2	9,0	75,4	12,4	81,5	12,7	81,5
3	6,7	70,8	8,4	75,4	8,6	75,4
4	5,5	64,6	6,4	69,2	6,5	69,2
5	4,4	36,9	5,5	53,8	5,5	55,4
Media	8,2	66,5	11,2	73,8	11,3	74,2
Relación	8,13		6,60		6,57	

Tabla 35. Resultados obtenidos con un número diferente de clasificadores en serie para S7.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	16,0	68,6	17,2	70,1	42,6	89,2
2	7,5	36,0	8,6	43,8	19,7	67,1
3	4,6	31,3	5,3	37,7	12,2	57,7
4	2,5	18,8	3,1	25,1	7,9	43,6
5	0,5	7,9	1,0	15,8	5,3	28,1
Media	6,2	32,5	7,0	38,5	17,5	57,1
Relación	5,22		5,48		3,26	

Tabla 36. Resultados obtenidos con un número diferente de clasificadores en serie para S8.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	22,7	53,8	35,5	55,4	42,5	60,0
2	10,5	21,5	15,4	33,8	18,9	36,9
3	5,2	15,4	8,0	21,5	10,3	29,2
4	2,1	4,6	3,7	4,6	5,1	13,8
5	0,7	1,5	1,7	1,5	3,0	4,6
Media	8,3	19,4	12,9	23,4	16,0	28,9
Relación	2,35		1,82		1,81	

Tabla 37. Resultados obtenidos con un número diferente de clasificadores en serie para S9.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	21,2	83,0	24,6	82,1	23,4	33,7
2	8,6	90,9	9,7	92,6	10,1	91,0
3	5,9	73,7	7,2	84,7	6,4	93,8
4	4,4	56,8	5,8	59,5	4,4	93,8
5	3,4	38,4	3,4	40,2	3,9	92,2
Media	8,7	68,6	10,1	71,8	9,6	80,9
Relación	7,90		7,08		8,41	

Tabla 38. Resultados obtenidos con un número diferente de clasificadores en serie para S10.

K	3 clasificadores		2 clasificadores		1 clasificador	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	41,8	98,3	43,4	98,3	45,0	98,3
2	15,1	88,5	15,2	88,5	15,8	88,5
3	6,4	60,4	6,4	60,4	7,3	62,1
4	3,0	22,9	3,0	24,6	3,6	32,6
5	0,5	11,5	0,5	11,5	0,7	11,5
Media	13,4	56,3	13,7	56,7	14,5	58,6
Relación	4,22		4,13		4,05	

AI 1.2. Resultados para la configuración 2. Número de características

Tabla 39. Resultados tras probar diferentes probabilidades a priori para S1.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	12,0	80,8	9,7	76,9	9,3	73,1
2	6,2	65,4	5,7	65,4	4,4	57,7
3	4,0	50,0	3,5	46,2	3,5	42,3
4	2,7	46,2	2,7	38,5	2,2	34,6
5	2,7	11,5	1,3	3,8	0,0	3,8
Media	5,5	50,8	4,6	46,2	3,9	42,3
Relación	9,25		10,02		10,85	

Tabla 40. Resultados tras probar diferentes probabilidades a priori para S2.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	26,0	78,5	24,3	73,8	21,1	72,3
2	16,7	63,1	13,3	61,5	11,5	56,9
3	10,0	52,3	8,0	44,6	7,5	40,0
4	7,3	43,1	6,1	36,9	5,0	32,3
5	4,6	32,3	2,9	24,6	2,1	20,0
Media	12,9	53,8	10,9	48,3	9,5	44,3
Relación	4,17		4,43		4,69	

Tabla 41. Resultados tras probar diferentes probabilidades a priori para S3.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	20,6	68,0	15,9	66,6	13,0	61,8
2	9,8	61,9	7,2	58,9	5,0	55,7
3	5,1	49,4	2,7	43,3	2,2	37,0
4	3,1	38,6	2,1	27,5	1,7	18,3
5	2,1	26,0	1,4	17,9	1,2	11,9
Media	8,1	48,8	5,9	42,8	4,6	36,9
Relación	6,00		7,32		7,98	

Tabla 42. Resultados tras probar diferentes probabilidades a priori para S4.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	15,3	35,4	12,1	33,8	10,9	32,3
2	8,1	27,7	6,9	26,2	6,4	26,2
3	5,3	21,5	4,4	21,5	4,4	16,9
4	4,1	10,8	3,0	7,7	2,8	6,2
5	1,6	4,6	1,4	3,1	1,2	3,1
Media	6,9	20,0	5,6	18,5	5,1	16,9
Relación	2,91		3,31		3,29	

Tabla 43. Resultados tras probar diferentes probabilidades a priori para S5.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	12,2	76,7	12,2	73,6	11,5	72,1
2	7,1	60,9	6,6	59,2	6,3	54,6
3	4,5	53,1	3,3	49,9	2,8	45,3
4	3,3	45,0	2,8	38,8	2,4	38,8
5	2,3	26,4	1,8	23,2	1,6	20,1
Media	5,9	52,4	5,3	48,9	4,9	46,2
Relación	8,89		9,17		9,40	

Tabla 44. Resultados tras probar diferentes probabilidades a priori para S6.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	16,9	86,2	15,4	84,6	14,5	84,6
2	9,8	78,5	9,0	75,4	8,6	73,8
3	6,7	73,8	6,7	70,8	6,7	67,7
4	5,6	67,7	5,5	64,6	5,3	61,5
5	5,3	43,1	4,4	36,9	3,7	33,8
Media	8,9	69,8	8,2	66,5	7,8	64,3
Relación	7,87		8,13		8,28	

Tabla 45. Resultados tras probar diferentes probabilidades a priori para S7.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	16,5	71,8	16,0	68,6	14,9	64,0
2	8,2	37,6	7,5	36,0	7,2	34,5
3	5,1	31,3	4,6	31,3	4,5	29,7
4	2,7	18,8	2,5	18,8	2,5	18,8
5	1,0	9,5	0,5	7,9	0,5	6,3
Media	6,7	33,8	6,2	32,5	5,9	30,7
Relación	5,03		5,22		5,17	

Tabla 46. Resultados tras probar diferentes probabilidades a priori para S8.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	30,1	55,4	22,7	53,8	20,7	49,2
2	12,3	30,8	10,5	21,5	7,7	18,5
3	6,5	18,5	5,2	15,4	4,0	13,8
4	3,1	4,6	2,1	4,6	1,9	4,6
5	1,2	1,5	0,7	1,5	0,5	1,5
Media	10,6	22,2	8,3	19,4	7,0	17,5
Relación	2,08		2,35		2,52	

Tabla 47. Resultados tras probar diferentes probabilidades a priori para S9.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	21,4	78,5	21,2	83,0	20,7	84,6
2	8,4	90,9	8,6	90,9	8,4	90,9
3	5,7	73,7	5,9	73,7	5,6	70,6
4	4,2	58,5	4,4	56,8	4,2	55,3
5	3,5	40,1	3,4	38,4	3,4	35,5
Media	8,6	68,3	8,7	68,6	8,4	67,4
Relación	7,90		7,90		7,97	

Tabla 48. Resultados tras probar diferentes probabilidades a priori para S10.

K	Probabilidad 3		Probabilidad 4		Probabilidad 5	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	43,7	98,3	41,8	98,3	39,3	98,3
2	16,1	88,5	15,1	88,5	13,3	88,5
3	7,4	63,7	6,4	60,4	5,5	60,4
4	3,5	26,0	3,0	22,9	2,8	21,3
5	0,9	11,5	0,5	11,5	0,5	11,5
Media	14,3	57,6	13,4	56,3	12,3	56,0
Relación	4,02		4,22		4,56	

AI 1.3. Resultados para la configuración 3. Selección muestra

Tabla 49. Resultados tras probar diferente cantidad de características para S1.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	6,7	65,4	9,7	76,9	12,4	76,9
2	4,4	50,0	5,7	65,4	6,2	61,5
3	3,5	38,5	3,5	46,2	3,5	53,8
4	3,1	19,2	2,7	38,5	3,1	38,5
5	2,2	3,8	1,3	3,8	2,2	11,5
Media	4,0	35,4	4,6	46,2	5,5	48,5
Relación	8,87		10,02		8,82	

Tabla 50. Resultados tras probar diferente cantidad de características para S2.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	20,6	72,3	24,3	73,8	22,3	73,8
2	11,0	60,0	13,3	61,5	13,5	63,1
3	7,5	44,6	8,0	44,6	8,4	44,6
4	5,7	35,4	6,1	36,9	6,1	38,5
5	2,9	27,7	2,9	24,6	3,2	26,2
Media	9,5	48,0	10,9	48,3	10,7	49,2
Relación	5,04		4,43		4,61	

Tabla 51. Resultados tras probar diferente cantidad de características para S3.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	16,8	65,0	15,9	66,6	17,1	68,0
2	7,9	60,4	7,2	58,9	8,2	58,9
3	3,4	43,3	2,7	43,3	3,1	46,2
4	2,1	29,2	2,1	27,5	2,1	27,5
5	1,4	17,9	1,4	17,9	1,2	18,2
Media	6,3	43,2	5,9	42,8	6,3	43,7
Relación	6,85		7,32		6,90	

Tabla 52. Resultados tras probar diferente cantidad de características para S4.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	10,6	32,3	12,1	33,8	16,9	40,0
2	6,5	24,6	6,9	26,2	9,0	29,2
3	3,9	15,4	4,4	21,5	5,3	21,5
4	2,6	4,6	3,0	7,7	3,3	9,2
5	1,2	1,5	1,4	3,1	1,6	1,5
Media	5,0	15,7	5,6	18,5	7,2	20,3
Relación	3,15		3,31		2,81	

Tabla 53. Resultados tras probar diferente cantidad de características para S5.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	10,8	75,1	12,2	73,6	12,4	75,1
2	5,9	57,7	6,6	59,2	6,6	59,2
3	3,2	48,3	3,3	49,9	3,8	53,1
4	3,0	38,8	2,8	38,8	3,3	43,5
5	1,8	23,3	1,8	23,2	1,9	21,7
Media	4,9	48,7	5,3	48,9	5,6	50,5
Relación	9,89		9,17		8,99	

Tabla 54. Resultados tras probar diferente cantidad de características para S6

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	8,8	84,6	15,4	84,6	19,2	83,1
2	3,5	84,6	9,0	75,4	9,6	75,4
3	1,8	84,6	6,7	70,8	5,5	64,6
4	0,9	76,9	5,5	64,6	4,6	55,4
5	0,0	53,8	4,4	36,9	3,7	32,3
Media	3,0	76,9	8,2	66,5	8,5	62,2
Relación	25,64		8,13		7,30	

Tabla 55. Resultados tras probar diferente cantidad de características para S7.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	30,7	81,5	16,0	68,6	21,4	71,9
2	13,5	53,1	7,5	36,0	9,3	46,8
3	7,7	42,1	4,6	31,3	4,8	35,9
4	4,6	34,2	2,5	18,8	2,5	23,5
5	1,7	12,4	0,5	7,9	1,0	7,9
Media	11,6	44,7	6,2	32,5	7,8	37,2
Relación	3,84		5,22		4,77	

Tabla 56. Resultados tras probar diferente cantidad de características para S8.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	24,0	52,3	22,7	53,8	26,9	55,4
2	9,8	23,1	10,5	21,5	11,4	23,1
3	4,7	13,8	5,2	15,4	5,3	18,5
4	2,3	4,6	2,1	4,6	2,3	4,6
5	0,7	1,5	0,7	1,5	0,7	1,5
Media	8,3	19,1	8,3	19,4	9,3	20,6
Relación	2,30		2,35		2,21	

Tabla 57. Resultados tras probar diferente cantidad de características para S9.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	20,2	40,2	21,2	83,0	21,0	84,6
2	7,9	92,4	8,6	90,9	8,6	90,8
3	4,7	92,3	5,9	73,7	5,9	69,1
4	3,7	87,6	4,4	56,8	3,9	44,1
5	2,9	85,9	3,4	38,4	3,2	24,6
Media	7,9	79,7	8,7	68,6	8,5	62,6
Relación	10,12		7,90		7,35	

Tabla 58. Resultados tras probar diferente cantidad de características para S10.

K	4 características		5 características		6 características	
	FP/min	TP(%)	FP/min	TP(%)	FP/min	TP(%)
1	43,0	98,3	41,8	98,3	40,0	98,3
2	14,7	88,5	15,1	88,5	14,7	86,8
3	6,2	52,4	6,4	60,4	6,4	58,8
4	2,5	23,1	3,0	22,9	2,8	26,2
5	0,5	9,9	0,5	11,5	0,5	9,9
Media	13,4	54,4	13,4	56,3	12,9	56,0
Relación	4,07		4,22		4,34	

AI 1.4. Resultados para la configuración 4. Selección de electrodos

Tabla 59. Resultados de diferentes selecciones de muestras para S1.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	9,7	76,9	6,2	65,4
2	5,7	65,4	3,1	50,0
3	3,5	46,2	2,7	34,6
4	2,7	38,5	1,3	11,5
5	1,3	3,8	1,3	3,8
Media	4,6	46,2	2,9	33,1
Relación	10,02		11,28	

Tabla 60. Resultados de diferentes selecciones de muestras para S2.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	24,3	73,8	7,1	52,3
2	13,3	61,5	4,6	41,5
3	8,0	44,6	1,8	35,4
4	6,1	36,9	0,9	27,7
5	2,9	24,6	0,2	12,3
Media	10,9	48,3	2,9	33,8
Relación	4,43		11,61	

Tabla 61. Resultados de diferentes selecciones de muestras para S3.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	15,9	66,6	15,5	72,5
2	7,2	58,9	7,3	49,5
3	2,7	43,3	5,5	40,0
4	2,1	27,5	4,2	30,9
5	1,4	17,9	2,9	21,6
Media	5,9	42,8	7,1	42,9
Relación	7,32		6,06	

Tabla 62. Resultados de diferentes selecciones de muestras para S4.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	12,1	33,8	15,3	36,9
2	6,9	26,2	8,5	29,2
3	4,4	21,5	5,1	23,1
4	3,0	7,7	3,2	10,8
5	1,4	3,1	0,5	1,5
Media	5,6	18,5	6,5	20,3
Relación	3,31		3,11	

Tabla 63. Resultados de diferentes selecciones de muestras para S5.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	12,2	73,6	9,8	68,8
2	6,6	59,2	5,2	54,6
3	3,3	49,9	3,0	51,5
4	2,8	38,8	2,8	37,3
5	1,8	23,2	2,6	20,3
Media	5,3	48,9	4,7	46,5
Relación	9,17		9,95	

Tabla 64. Resultados de diferentes selecciones de muestras para S6.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	15,4	84,6	15,2	81,5
2	9,0	75,4	7,9	73,8
3	6,7	70,8	5,5	64,6
4	5,5	64,6	4,3	53,8
5	4,4	36,9	2,2	33,8
Media	8,2	66,5	7,0	61,5
Relación	8,13		8,80	

Tabla 65. Resultados de diferentes selecciones de muestras para S7.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	16,0	68,6	15,3	60,8
2	7,5	36,0	8,3	46,9
3	4,6	31,3	5,8	42,2
4	2,5	18,8	2,6	32,9
5	0,5	7,9	0,3	14,0
Media	6,2	32,5	6,5	39,4
Relación	5,22		6,10	

Tabla 66. Resultados de diferentes selecciones de muestras para S8.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	22,7	53,8	18,9	52,3
2	10,5	21,5	7,7	30,8
3	5,2	15,4	5,1	16,9
4	2,1	4,6	2,5	7,7
5	0,7	1,5	1,0	4,6
Media	8,3	19,4	7,0	22,5
Relación	2,35		3,19	

Tabla 67. Resultados de diferentes selecciones de muestras para S9.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	21,2	83,0	12,6	50,9
2	8,6	90,9	5,0	95,4
3	5,9	73,7	3,4	96,9
4	4,4	56,8	2,9	96,9
5	3,4	38,4	2,4	89,2
Media	8,7	68,6	5,2	85,9
Relación	7,90		16,38	

Tabla 68. Resultados de diferentes selecciones de muestras para S10.

K	Muestra manual		Muestra automática	
	FP/min	TP(%)	FP/min	TP(%)
1	41,8	98,3	12,0	76,9
2	15,1	88,5	4,8	59,1
3	6,4	60,4	1,6	41,2
4	3,0	22,9	0,5	9,9
5	0,5	11,5	0,2	6,7
Media	13,4	56,3	3,8	38,7
Relación	4,22		10,13	

AI 1.5. Resultados para la configuración 5. Selección de electrodos

Tabla 69. Resultados tras selección de electrodos para S1.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	9,7	76,9	9,7	76,9
2	5,7	65,4	5,7	65,4
3	3,5	46,2	3,5	46,2
4	2,7	38,5	2,7	38,5
5	1,3	3,8	1,3	3,8
Media	4,6	46,2	4,6	46,2
Relación	10,02		10,02	

Tabla 70. Resultados tras selección de electrodos para S2.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	24,3	73,8	22,9	63,1
2	13,3	61,5	11,0	46,2
3	8,0	44,6	5,4	29,2
4	6,1	36,9	3,0	13,8
5	2,9	24,6	1,3	9,2
Media	10,9	48,3	8,7	32,3
Relación	4,43		3,71	

Tabla 71. Resultados tras selección de electrodos para S3.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	15,9	66,6	13,4	18,4
2	7,2	58,9	4,1	9,1
3	2,7	43,3	1,5	4,6
4	2,1	27,5	0,7	3,1
5	1,4	17,9	0,5	0,0
Media	5,9	42,8	4,0	7,0
Relación	7,32		1,74	

Tabla 72. Resultados tras selección de electrodos para S4.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	12,1	33,8	1,4	12,3
2	6,9	26,2	0,0	0,0
3	4,4	21,5	0,0	0,0
4	3,0	7,7	0,0	0,0
5	1,4	3,1	0,0	0,0
Media	5,6	18,5	0,3	2,5
Relación	3,31		8,88	

Tabla 73. Resultados tras selección de electrodos para S5.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	12,2	73,6	8,7	67,2
2	6,6	59,2	4,4	46,7
3	3,3	49,9	1,4	40,5
4	2,8	38,8	1,0	15,5
5	1,8	23,2	0,4	4,7
Media	5,3	48,9	3,2	34,9
Relación	9,17		11,01	

Tabla 74. Resultados tras selección de electrodos para S6.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	15,4	84,6	20,6	80,0
2	9,0	75,4	10,5	66,2
3	6,7	70,8	6,3	58,5
4	5,5	64,6	4,3	40,0
5	4,4	36,9	2,5	32,3
Media	8,2	66,5	8,8	55,4
Relación	8,13		6,26	

Tabla 75. Resultados tras selección de electrodos para S7.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	16,0	68,6	1,2	3,1
2	7,5	36,0	0,0	0,0
3	4,6	31,3	0,0	0,0
4	2,5	18,8	0,0	0,0
5	0,5	7,9	0,0	0,0
Media	6,2	32,5	0,2	0,6
Relación	5,22		2,56	

Tabla 76. Resultados tras selección de electrodos para S8.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	22,7	53,8	12,8	21,5
2	10,5	21,5	3,5	1,5
3	5,2	15,4	1,1	0,0
4	2,1	4,6	0,5	0,0
5	0,7	1,5	0,0	0,0
Media	8,3	19,4	3,6	4,6
Relación	2,35		1,29	

Tabla 77. Resultados tras selección de electrodos para S9.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	21,2	83,0	31,7	90,8
2	8,6	90,9	9,2	85,9
3	5,9	73,7	3,9	65,8
4	4,4	56,8	2,7	36,9
5	3,4	38,4	1,7	14,0
Media	8,7	68,6	9,8	58,7
Relación	7,90		5,97	

Tabla 78. Resultados tras selección de electrodos para S10.

K	Electrodos 1:22		occipital + parietal	
	FP/min	TP(%)	FP/min	TP(%)
1	41,8	98,3	30,3	83,6
2	15,1	88,5	10,1	60,5
3	6,4	60,4	3,4	26,3
4	3,0	22,9	1,1	6,7
5	0,5	11,5	0,2	1,7
Media	13,4	56,3	9,0	35,7
Relación	4,22		3,97	