



**COMILLAS**  
UNIVERSIDAD PONTIFICIA

ICAI

# MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIONES

TRABAJO FIN DE MÁSTER

## **Diseño y evaluación de un sistema de análisis de señales EEG para la detección de movimientos corporales**

Autor: Inés Saavedra Villafruela

Director: Antonio Muñoz San Roque

Co-director: José María Cogollor Delgado

2024/25

Madrid



Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título  
**Diseño y evaluación de un sistema de análisis de señales EEG para la detección de  
movimientos corporales**

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2024/25 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido

tomada de otros documentos está debidamente referenciada.

Fdo.: Inés Saavedra Villafruela

Fecha: 11/ 06/ 2025

Autorizada la entrega del proyecto

EL DIRECTOR Y EL CO-DIRECTOR DEL PROYECTO



Fdo.: *Antonio Muñoz San Roque* Fecha: 11/ 06/2025

**José**

Firmado

Fdo.:

**María**

digitalmente por Fecha: 11/ 06/ 2025

**Cogollor**

José María

**Delgado**

Cogollor Delgado

Fecha: 2025.06.13

14:23:35 +02'00'





**COMILLAS**  
UNIVERSIDAD PONTIFICIA

ICAI

# MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIONES

TRABAJO FIN DE MÁSTER

## **Diseño y evaluación de un sistema de análisis de señales EEG para la detección de movimientos corporales**

Autor: Inés Saavedra Villafruela

Director: Antonio Muñoz San Roque

Co-director: José María Cogollor Delgado

2024/25

Madrid



# DISEÑO Y EVALUACIÓN DE UN SISTEMA DE ANÁLISIS DE SEÑALES EEG PARA LA DETECCIÓN DE MOVIMIENTOS CORPORALES

**Autor: Saavedra Villafruela, Inés.**

Director: Muñoz San Roque, Antonio.

Codirector: José María Cogollor Delgado

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

## RESUMEN DEL PROYECTO

Este proyecto se centra en el diseño, desarrollo y evaluación un sistema BCI (Brain-Computer Interface) basado en señales EEG para detectar la intención de movimiento. Se utilizan dos fuentes de datos: un experimento propio con el dispositivo Emotiv EPOC X y la base de datos pública EEG Motor Movement/Imagery de PhysioNet. A partir de estas señales registradas se aplican técnicas de preprocesamiento, extracción de características y algoritmos de clasificación para detectar si el sujeto está en movimiento o no. El análisis de resultados se basa en la comparación de dos enfoques: modelos personalizados por sujeto y modelos generales, obteniéndose mejores resultados en los modelos individualizados, alcanzando precisiones cercanas al 63%.

**Palabras clave:** EEG, BCI, detección de movimiento, algoritmos de clasificación.

### 1. Introducción

Las interfaces cerebro-computadora (BCI) [1] permiten la comunicación directa entre cerebro humano y dispositivos externos. Se trata de una tecnología con alto potencial, debido a su naturaleza no invasiva, en campos como la rehabilitación neurológica y en control de prótesis o sillas de ruedas para personas con movilidad reducida. Este trabajo se centra en la detección de la intención de movimiento mediante señales EEG, analizando el rendimiento de distintos modelos de clasificación y estrategias de preprocesamiento para mejorar la robustez del sistema.

### 2. Definición del proyecto

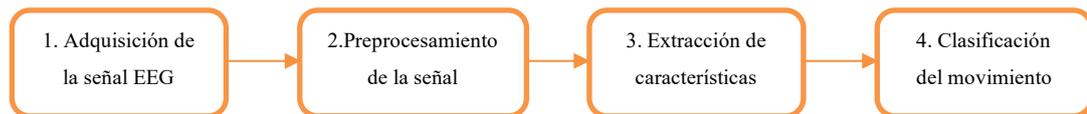
Este trabajo se estructura en torno a un objetivo principal y varios objetivos específicos que guían el diseño, implementación y evaluación del sistema BCI desarrollado. El objetivo principal es diseñar y evaluar un sistema BCI capaz de distinguir entre estados de reposo y actividad motora. Los objetivos específicos son:

- Realizar una revisión de la literatura científica para identificar metodologías más efectivas en sistemas BCI orientados a la detección de movimiento.
- Diseñar un experimento para la adquisición de datos con el dispositivo Emotiv EPOC X [2], en el que los pacientes responden a estímulos visuales representando intención de movimiento real.
- Utilizar como complemento la base de datos EEG Motor Movement/Imagery del repositorio público PhysioNet [3], que contiene registros de 109 sujetos realizando o imaginando tareas motoras, con el fin de enriquecer el análisis.
- Aplicar técnicas de preprocesamiento y extraer características en el dominio del tiempo y de la frecuencia.

- Entrenar y evaluar modelos de clasificación supervisada como Análisis Discriminante Lineal [4] y Random Forest [5], comparando su rendimiento.

### 3. Descripción del modelo/sistema/herramienta

La arquitectura del sistema BCI desarrollado en este proyecto sigue una estructura modular compuesta por las siguientes fases principales, como se muestra en la siguiente figura:



*Figura 1. Arquitectura del sistema BCI*

- Adquisición de la señal EEG: captación de datos mediante el dispositivo Emotiv EPOC X y mediante la base de datos de EEG Motor Movement/Imagery de PhysioNet.
- Preprocesamiento de la señal: es el paso más importante para asegurar la calidad de la señal. Entre los preprocesamientos más utilizados están el filtrado (paso banda y Laplacianos), la eliminación de artefactos mediante reducciones de dimensionalidad o la segmentación de la señal en ventanas temporales solapadas.
- Extracción de características: cálculo de medidas estadísticas (media, varianza, pendiente, etc.) o de características espectrales, tales como las potencias relativas en la diferentes bandas de frecuencia.
- Clasificación del movimiento: uso de modelos Linear Discriminant Analysis [4] y Random Forest [5] para evaluar la discriminación entre reposo y movimiento.

Estas etapas se han adaptado según los datos empleados en dos fases diferenciadas:

Fase 1: Experimento propio con Emotiv EPOC X

Se utiliza la diadema Emotiv EPOC X con 14 canales y una frecuencia de muestreo de 128Hz. Se diseña una aplicación interactiva en Python usando Pygame, en la que el usuario debe pulsar una tecla tras la aparición de una flecha en la pantalla. Se sincronizaron los eventos visuales con la señal EEG y se aplica un filtro laplaciano centrado en los canales AF3 y AF4. Aunque el diseño se vio limitado por fallos técnicos en un sensor, se pudo realizar un análisis exploratorio inicial.

Fase 2: Análisis con datos de PhysioNet

Debido a las limitaciones hardware de la fase 1, se complementa el estudio con la base de datos EEG Motor Movement/Imagery de PhysioNet, que incluye señales de 109 sujetos realizando tareas motoras. Se aplica un preprocesamiento y una extracción de características en el dominio del tiempo y en el de la frecuencia, para posteriormente entrenar un modelo de clasificación usando LDA y RF.

Para la etapa de clasificación, se implementaron dos estrategias de aprendizaje diferenciadas:

- Modelos individualizados: se entrena un modelo para cada sujeto y se valida con otro registro del mismo sujeto. Esta estrategia permite capturar las particularidades de cada individuo, mejorando la precisión en la detección de la intención de movimiento.
- Modelos generales: se construyen dos modelos (uno en el dominio de la frecuencia y otro en el dominio temporal) con datos de los 109 sujetos aplicando validación cruzada. Esta estrategia busca obtener un sistema más generalizable que funcione con nuevos usuarios sin necesidad de calibrar individualmente.

#### 4. Resultados

Los resultados experimentales obtenidos se muestran en la siguiente tabla:

*Tabla 1. Comparación de las precisiones obtenidas por modelo y dominio.*

<b>Dominio</b>	<b>Modelo</b>	<b>Precisión Entrenamiento</b>	<b>Precisión Validación</b>
<b>Tiempo (Modelo individualizado)</b>	LDA	66.6%	59.8%
<b>Tiempo (Modelo individualizado)</b>	Random Forest	95.6%	60.2%
<b>Frecuencia (Modelo individualizado)</b>	LDA	66.4%	63%
<b>Frecuencia (Modelo individualizado)</b>	Random Forest	93%	60%
<b>Tiempo (Modelo general)</b>	LDA + CV	51%	52%
<b>Frecuencia (Modelo general)</b>	LDA + CV	54.2%	53.9%

#### 5. Conclusiones

Los resultados muestran que es posible detectar la intención de movimiento mediante EEG utilizando modelos clásicos. Los modelos individualizados superan a los generales, lo que indica que la personalización mejora significativamente el rendimiento. El análisis en el dominio de la frecuencia resultó más eficaz que el del tiempo.

Se propone como líneas de mejora:

- Probar con otros modelos para mejorar la detección de patrones complejos, como por ejemplo redes neuronales profundas.
- Incrementar el tamaño de la muestra y diversidad de sujetos
- Evaluar el rendimiento con tareas de imaginación motora.

## 6. Referencias

- [1] «Interfaces Cerebro-Computador | Bitbrain». Accedido: 9 de septiembre de 2024. [En línea]. Disponible en: <https://www.bitbrain.com/es/aplicaciones/interfaces-cerebro-computador>
- [2] R. Ramele, A. J. Villar, y J. M. Santos, «EPOC Emotiv EEG Basics», 12 de octubre de 2022, *arXiv*: arXiv:2206.09051. Accedido: 8 de julio de 2024. [En línea]. Disponible en: <http://arxiv.org/abs/2206.09051>
- [3] «EEG Motor Movement/Imagery Dataset v1.0.0». Accedido: 20 de mayo de 2025. [En línea]. Disponible en: <https://physionet.org/content/eegmmidb/1.0.0/>
- [4] «Linear Discriminant Analysis». [En línea]. Disponible en: <https://www.ibm.com/think/topics/linear-discriminant-analysis>
- [5] «Random Forest: Bosque aleatorio. Definición y funcionamiento». Accedido: 23 de mayo de 2025. [En línea]. Disponible en: <https://datascientest.com/es/random-forest-bosque-aleatorio-definicion-y-funcionamiento>

# DESIGN AND EVALUATION OF AN EEG SIGNAL ANALYSIS SYSTEM FOR MOTOR MOVEMENT DETECTION

**Author: Saavedra Villafruela, Inés.**

Supervisor: Muñoz San Roque, Antonio.

Co-supervisor: José María Cogollor Delgado

Collaborating Entity: ICAI – Universidad Pontificia Comillas

## ABSTRACT

This project focuses on the design, development, and evaluation of a Brain-Computer Interface (BCI) system based on EEG signals to detect movement intention. Two data sources are used: a self-conducted experiment using the Emotiv EPOC X headset and the public EEG Motor Movement/Imagery dataset from PhysioNet. Preprocessing techniques, feature extraction, and classification algorithms are applied to determine whether the subject is at rest or moving. Two approaches are compared: personalized subject-specific models and general models. The best results were obtained using individualized models, achieving validation accuracies of up to 63%.

**Keywords:** EEG, BCI, Movement detection, classification algorithms.

## 1. Introduction

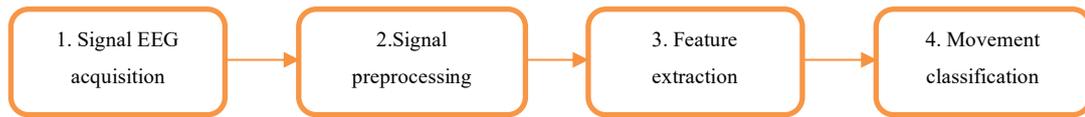
Brain-computer interfaces (BCIs) allow direct communication between the human brain and external devices. This non-invasive technology holds great potential in neurological rehabilitation and robotic prosthesis control for individuals with limited mobility. This work focuses on detecting movement intention through EEG signals and analyzes the performance of various preprocessing strategies and classification models to improve system robustness.

## 2. Project definition

This work is structured around a main objective and several specific objectives that guide the design, implementation and evaluation of the developed BCI system. The main objective is to design and evaluate a BCI system capable of distinguishing between resting states and motor activity. The specific objectives are:

- Perform a review of the scientific literature to identify more effective methodologies in BCI systems oriented to motion detection.
- To design an experiment for data acquisition with the Emotiv EPOC X device [2], in which patients respond to visual stimuli representing real movement intention.
- To use as a complement the EEG Motor Movement/Imagery database from the public repository PhysioNet [3], which contains records of 109 subjects performing or imagining motor tasks, in order to enrich the analysis.
- Apply preprocessing techniques and extract time and frequency domain features.
- Train and evaluate supervised classification models such as Linear Discriminant Analysis [4] and Random Forest [5], comparing their performance.

## 3. Description of the system



*Figura 2. BCI System architecture*

The architecture of the BCI system developed in this project follows a modular structure composed of the following main phases, as shown in the figure below:

- EEG signal acquisition: data acquisition using the Emotiv EPOC X device and using the PhysioNet EEG Motor Movement/Imagery EEG database.
- Signal preprocessing: this is the most important step to ensure signal quality. Among the most commonly used preprocessing are filters (bandpass and Laplacian), artifact removal by dimensionality reductions or segmentation of the signal into overlapping time windows.
- Feature extraction: calculation of statistical measures (mean, variance, slope...) or spectral features (relative powers in different frequency bands).
- Motion classification: use of Linear Discriminant Analysis [4] and Random Forest [5] models to evaluate the discrimination between rest and motion.

These stages have been adapted according to the data used in two different phases:

Phase 1: Own experiment with Emotiv EPOC X

The Emotiv EPOC X headset with 14 channels and a sampling frequency of 128Hz is used. An interactive application is designed in Python using Pygame, in which the user must press a key after the appearance of an arrow on the screen. Visual events were synchronized with the EEG signal and a Laplacian filter centered on channels AF3 and AF4 is applied. Although the design was limited by technical failures in one sensor, an initial exploratory analysis could be performed.

Phase 2: Analysis with data from PhysioNet

Due to the hardware limitations of phase 1, the study is supplemented with the PhysioNet EEG Motor Movement/Imagery database, which includes signals from 109 subjects performing motor tasks. A preprocessing and feature extraction in time and frequency domain is applied, to subsequently train a classification model using LDA and RF.

For the classification stage, two different learning strategies were implemented:

- Individualized models: a model is trained for each subject and validated with another recording of the same subject. This strategy allows capturing the particularities of everyone, improving accuracy in the detection of movement intention.
- General models: two models are built (one in the frequency domain and the other in the time domain) with data from the 109 subjects applying cross-validation.

This strategy seeks to obtain a more generalizable system that works with new users without the need for individual calibration.

#### 4. Results

The results obtained are summarized in the following table:

*Tabla 2. Comparison of accuracies by model and domain*

<b>Domain</b>	<b>Model</b>	<b>Train Accuracy</b>	<b>Validation Accuracy</b>
<b>Time (Individualized model)</b>	LDA	66.6%	59.8%
<b>Time (Individualized model)</b>	Random Forest	95.6%	60.2%
<b>Frequency (Individualized model)</b>	LDA	66.4%	63%
<b>Frequency (Individualized model)</b>	Random Forest	93%	60%
<b>Time (General model)</b>	LDA + CV	51%	52%
<b>Frequency (General model)</b>	LDA + CV	54.2%	53.9%

#### 5. Conclusions

The results show that it is possible to detect movement intention by EEG using classical models. Individualized models outperform general models, indicating that personalization significantly improves performance. Frequency domain analysis was found to be more effective than time domain analysis.

The following lines of improvement are proposed:

- Test with other models to improve the detection of complex patterns, such as deep neural networks.

- Increase the sample size and diversity of subjects.
- Evaluate performance with motor imagination tasks.

## 6. Bibliography

- [1] «Interfaces Cerebro-Computador | Bitbrain». [En línea]. Disponible en: <https://www.bitbrain.com/es/aplicaciones/interfaces-cerebro-computador>
- [2] R. Ramele, A. J. Villar, y J. M. Santos, «EPOC Emotiv EEG Basics», 12 de octubre de 2022, *arXiv*: arXiv:2206.09051. [En línea]. Disponible en: <http://arxiv.org/abs/2206.09051>
- [3] «EEG Motor Movement/Imagery Dataset v1.0.0». [En línea]. Disponible en: <https://physionet.org/content/eegmmidb/1.0.0/>
- [4] «Linear Discriminant Analysis». [En línea]. Disponible en: <https://www.ibm.com/think/topics/linear-discriminant-analysis>
- [5] «Random Forest: Bosque aleatorio. Definición y funcionamiento». [En línea]. Disponible en: <https://datascientest.com/es/random-forest-bosque-aleatorio-definicion-y-funcionamiento>

## Índice de la memoria

<b>Capítulo 1. Introducción .....</b>	<b>6</b>
<b>Capítulo 2. Estado de la Cuestión .....</b>	<b>9</b>
2.1 Adquisición de señales EEG .....	9
2.2 Preprocesamiento de señales EEG .....	12
2.2.1 Filtrado y eliminación de artefactos .....	12
2.2.2 Selección de los canales relevantes .....	12
2.2.3 Reducción de la dimensionalidad .....	13
2.2.4 Filtrado Laplaciano .....	13
2.2.5 Aumento de datos .....	14
2.3 Extracción de características .....	14
2.3.1 Transformada Rápida de Fourier (FFT) .....	14
2.3.2 Densidad espectral de potencia (PSD) .....	15
2.3.3 Patrones Espaciales Comunes (CSP) .....	16
2.3.4 Potenciales corticales .....	16
2.4 Modelos de clasificación.....	17
2.4.1 Análisis Discriminante Lineal (en inglés, Linear Discriminant Analysis, LDA) .....	18
2.4.2 Máquina de Soporte Vectorial (en inglés, Support Vector Machines (SVM)) .....	19
2.4.3 Redes Neuronales Artificiales (ANN).....	19
2.4.4 Redes neuronales profundas (CNN y BiLSTM).....	20
2.5 Matriz de revisión de casos de uso relevantes .....	21
<b>Capítulo 3. Metodología .....</b>	<b>24</b>
3.1 Fase 1: Diseño experimental con Emotiv EPOC X .....	24
3.2 Fase 2: Análisis con datos de PhysioNet .....	26
<b>Capítulo 4. Sistema Desarrollado .....</b>	<b>28</b>
4.1 Emotiv Epoc X.....	28
4.1.1 Adquisición de los datos.....	29
4.1.2 Preprocesamiento de la señal EEG .....	30
4.1.3 Extracción de Características.....	32
4.1.4 y modelo de clasificación.....	32

4.1.5	Limitaciones durante el experimento con la diadema Emotiv .....	33
4.2	PhysioNet EEG Motor Movement/Imagery.....	34
4.2.1	Introducción a la base de datos .....	34
4.2.2	Adquisición de los datos.....	37
4.2.3	Preprocesamiento en el dominio del tiempo.....	43
4.2.4	Características Extraídas en el dominio del tiempo .....	44
4.2.5	Modelo de Clasificación en el dominio del tiempo.....	48
4.2.6	Preprocesamiento en el dominio de la frecuencia.....	56
4.2.7	Extracción de características en el dominio de la frecuencia .....	56
4.2.8	Modelo de Clasificación.....	57
<b>Capítulo 5. Análisis de Resultados.....</b>		<b>63</b>
5.1	Resultados del experimento con Emotiv EPOC X.....	63
5.2	Resultados con la base de datos de PhysioNet.....	63
5.2.1	Dominio del tiempo .....	64
5.2.2	dominio de la frecuencia.....	64
5.2.3	Comparación entre dominios y modelos.....	64
<b>Capítulo 6. Conclusiones y trabajos futuros.....</b>		<b>67</b>
6.1	Conclusiones .....	67
6.2	Trabajos futuros .....	68
<b>Capítulo 7. Bibliografía.....</b>		<b>70</b>
<b>ANEXO A. Alineación con los Objetivos de Desarrollo Sostenible (ODS).....</b>		<b>76</b>
	ODS 3: Salud y Bienestar .....	76
	ODS 9: Industria, Innovación e Infraestructura.....	76
<b>Anexo A.2: Guía de uso de Emotiv EPOC X.....</b>		<b>77</b>

## *Índice de figuras*

Figura 1. Arquitectura del sistema BCI .....	8
Figura 2. BCI System architecture .....	12
Figura 3. Sistema Internacional 10-20 [17] .....	11
Figura 4. Ilustración de los componentes de detección de la intención de movimiento [36] .....	17
Figura 5. Características espaciales por eje en espacio tridimensional [8] .....	21
Figura 6. Arquitectura modular de un sistema BCI.....	24
Figura 7. Diadema Emotiv EPOC X[14].....	28
Figura 8. Flecha derecha e izquierda mostrada en la interfaz .....	29
Figura 9. Archivo CSV con los registros.....	30
Figura 10. Distribución de canales en Emotiv EPOC X de 14 electrodos [2].....	30
Figura 11. Señal EEG sincronizada con eventos en la izquierda .....	31
Figura 12. Señal EEG sincronizada con eventos en la derecha.....	32
Figura 13. Evolución de la probabilidad predicha.....	33
Figura 14. Adquisición de la base de datos de EEG Motor Movement/Imagery [50] .....	34
Figura 15. Registro de eventos de la librería MNE .....	38
Figura 16. Resumen de los metadatos de un archivo EDF .....	39
Figura 17. Distribución de los electrodos.....	42
Figura 18. Señal EEG del Sujeto 1 .....	42
Figura 19. Señal EEG después de la selección de los canales relevantes .....	44
Figura 20. Señal EEG de los canales seleccionados donde se observa pendiente negativa previa al inicio del movimiento .....	47
Figura 21. Evolución de la probabilidad de la clase movimiento del sujeto 4 .....	51
Figura 22. Evolución de la probabilidad de la clase movimiento del sujeto 4 .....	52
Figura 23. Espectrograma.....	55
Figura 24. Evolución de la probabilidad de estar en movimiento del sujeto 4.....	59

Figura 25. Evolución de la probabilidad de estar en movimiento del sujeto 4..... 61

## *Índice de tablas*

Tabla 1. Comparación de las precisiones obtenidas por modelo y dominio. ....	9
Tabla 2. Comparison of accuracies by model and domain.....	13
Tabla 3. Matriz de revisión de la literatura.....	22
Tabla 4. Tabla resumen del experimento de EEG Motor Movement/Imagery .....	35
Tabla 5. Descripción de las características de la grabación de un sujeto .....	39
Tabla 6. Precisión del modelo personalizado por sujeto en entrenamiento y validación....	49
Tabla 7. Resultados obtenidos en el dominio del tiempo para el modelo con 109 sujetos .	53
Tabla 8. Características extraídas en el dominio de la frecuencia.....	56
Tabla 9. Precisión del modelo LDA en el dominio de la frecuencia.....	58
Tabla 10. Precisión del modelo Random Forest en el dominio de la frecuencia .....	59
Tabla 11. Análisis de resultados .....	65
Tabla 12. Descripción del fichero .edf de Emotiv EPOC.....	80

## Capítulo 1. INTRODUCCIÓN

En las últimas décadas, la interacción directa entre el cerebro humano y dispositivos externos ha dejado de ser un concepto de ciencia ficción para convertirse en un ámbito real y en constante desarrollo por el potencial que presenta en rehabilitación neurológica. Esta interacción se materializa a través de interfaces cerebro-computadora (Brain-Computer Interfaces, BCI[1]), que son sistemas que permiten a los usuarios controlar dispositivos empleando su actividad cerebral. Entre las diferentes formas de registrar señales cerebrales, la técnica de electroencefalografía (EEG) se ha posicionado como una de las técnicas más utilizadas en el ámbito de las BCI, por su naturaleza no invasiva, su elevada resolución y su portabilidad [6].

Las interfaces BCI basadas en EEG se han aplicado en diversos campos como la rehabilitación neurológica [7] y el control de prótesis robóticas [8]. Uno de los paradigmas fundamentales en estas interfaces es la detección de la intención de movimiento, ya sea real o imaginario, a partir del análisis de las ondas cerebrales. La posibilidad de anticipar un movimiento antes de su ejecución es fundamental para la recuperación funcional en pacientes neurológicos.

La arquitectura de un sistema BCI basado en EEG se compone habitualmente de varias fases bien diferenciadas: adquisición de la señal, preprocesamiento, extracción de características y clasificación. Cada una de estas etapas es crucial para obtener un sistema robusto y preciso.

La actividad eléctrica del cerebro, registrada mediante EEG, puede representarse como oscilaciones que se distribuyen en distintas bandas de frecuencia: delta (1-4Hz), theta (4-8Hz), alpha (8-12Hz), beta (13-30 Hz) y gamma (>30Hz)[9]. Estas bandas reflejan diferentes procesos cognitivos y motores. Trabajar con estas señales conlleva importantes desafíos ya que se trata de una señal altamente susceptible a ruidos y artefactos, como los parpadeos (EoG), movimientos musculares, interferencias eléctricas o variaciones en la impedancia de

los electrodos. Por este motivo, el preprocesamiento de la señal EEG es de gran importancia para asegurar la calidad de los datos y mejorar el rendimiento del sistema.

La detección de la intención de movimiento a partir de EEG tiene aplicaciones clave en el desarrollo de prótesis robóticas controladas por el pensamiento, sillas de ruedas inteligentes, sistemas de comunicación alternativos para personas con parálisis y soluciones terapéuticas en neurorehabilitación.

Con este contexto, este trabajo se estructura en torno a un objetivo principal y cuatro objetivos secundarios.

El objetivo principal es desarrollar y evaluar un sistema BCI basado en señales EEG para la detección de la intención de realizar movimientos corporales, mediante el análisis de señales cerebrales EEG, su preprocesamiento, la extracción de características relevantes y la posterior clasificación utilizando técnicas de aprendizaje automático.

Los objetivos secundarios son:

1. Realizar una revisión de la literatura científica sobre las distintas metodologías utilizadas en sistemas BCI, con énfasis en la detección de intención de movimiento a través de señales EEG, incluyendo técnicas de preprocesamiento, extracción de características y modelos de clasificación más utilizados.
2. Diseñar y desarrollar un experimento para la captación de señales: el propósito es explorar cómo estas señales EEG pueden ser utilizadas para clasificar diferentes tipos de movimientos corporales. Para ello, el experimento se centrará en utilizar datos recogidos de sujetos realizando o imaginando movimientos específicos.
3. Preprocesamiento y extracción de las características: procesar las señales EEG mediante técnicas de filtrado y segmentación, entre otras, es un paso crucial y servirá para extraer características óptimas que aumenten el rendimiento del sistema.
4. Clasificación de movimientos: aplicar y comparar modelos de *Machine Learning* evaluando su rendimiento en la detección de la intención del movimiento real o imaginado a partir de las características extraídas.

5. Comparar el rendimiento de diferentes modelos de clasificación con el fin de determinar cuál ofrece mejor equilibrio entre precisión, generalización e interpretabilidad en el contexto de señales EEG.

## Capítulo 2. ESTADO DE LA CUESTIÓN

El uso de la técnica de electroencefalografía (EEG) para identificar movimientos corporales o su intención ha sido ampliamente estudiado en las últimas décadas, especialmente en el contexto de las interfaces cerebro-computadora. Estas tecnologías abren nuevas posibilidades en los campos de la neurorrehabilitación, el control de prótesis y la interacción hombre-máquina en personas con discapacidad motora. Este apartado recoge las investigaciones más relevantes sobre la adquisición de señales EEG destinadas a la detección de movimientos reales e imaginarios.

### *2.1 ADQUISICIÓN DE SEÑALES EEG*

Los sistemas BCI se pueden dividir en dos categorías: no invasivos e invasivos. Las técnicas invasivas, como la resonancia magnética funcional (fMRI), la magnetoencefalografía (MEG) o los electrocorticogramas (ECoG) [10] requieren la implantación de electrodos directamente sobre la superficie del cerebro, ofreciendo mayor resolución y menor ruido. Sin embargo, implican procedimientos quirúrgicos y riesgos asociados que limitan su aplicación. Por el contrario, las técnicas no invasivas, como la electroencefalografía, presentan una resolución espacial menor pero son ampliamente utilizadas debido a su facilidad de uso, bajo coste y fiabilidad en resultados clínicos y experimentales [6]. Según Chaddad et al., el registro EEG es actualmente el método no invasivo más extendido para estudios de detección de intención de movimiento gracias a su alta resolución temporal y adaptabilidad a contextos reales [6].

El EEG ha demostrado su capacidad para capturar las señales cerebrales en tiempo real, aunque con limitaciones de precisión debido a artefactos y la sensibilidad al ruido (SNR). Para mitigar estos efectos, se estudiarán las fases de preprocesamiento destinadas a mejorar la calidad de la señal antes del análisis y de la clasificación.

En los estudios revisados, la selección del dispositivo EEG que se utiliza condiciona la calidad de la señal y del experimento. Los sistemas biomédicos como g.tec [11], Biosemi ActiveTwo [12] o configuraciones multicanal en EEGLAB [13], utilizan numerosos electrodos (32, 64 o más canales) y consiguen así una excelente resolución. Sin embargo, su coste y complejidad limitan su aplicabilidad. Por este motivo, también se utilizan dispositivos más accesibles como Emotiv EPOC [14], Neurosky MindWave [15] o OpenBCI [16] que, aunque poseen menor resolución, ofrecen configuraciones rápidas y de bajo coste. Por ejemplo, en el artículo “*On the use of the Emotiv EPOC Neuroheadset as a low cost alternative for EEG signal acquisition*” [7] se ha utilizado la diadema Emotiv EPOC, para adquirir señales EEG y se propone un sistema de interpretación de parpadeos oculares. Utilizando Redes Neuronales Artificiales se demuestra una alta precisión en la clasificación de parpadeos que se pueden traducir en comandos útiles para la interacción humano-máquina de personas con discapacidad motora.

Para asegurar la compatibilidad entre estudios, la adquisición de EEG se realiza siguiendo estándares que definen posiciones fijas para los electrodos sobre el cuero cabelludo, como el estándar internacional 10-20 [4] que se muestra en la Figura 3. En función del objetivo de estudio y del dispositivo empleado, existen distintos tipos de electrodos entre los que se encuentran los húmedos, que requieren gel conductor y ofrecen mayor resolución de la señal; los semihúmedos, que equilibran precisión y comodidad y los secos, que no requieren preparación previa, pero pueden generar más artefactos [18]. La elección del tipo de electrodo afecta directamente a la calidad de la señal.

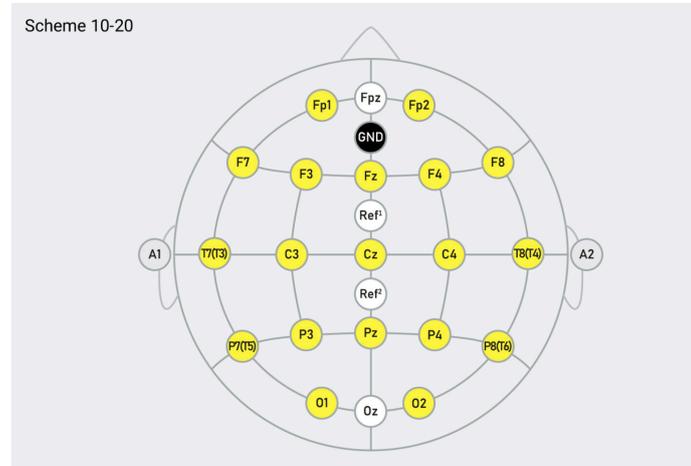


Figura 3. Sistema Internacional 10-20 [17]

Por último, es importante señalar una serie de limitaciones de la adquisición de las señales EEG que condicionan su análisis [10]:

1. Baja resolución espacial y SNR (relación señal-ruido), con altas sensibilidad a ruidos e interferencias.
2. Alta dimensionalidad, al registrar múltiples canales de forma simultánea.
3. No estacionariedad, ya que las propiedades de la señal cambian rápidamente con el tiempo. Se deberán aplicar técnicas para hacer la señal más estable y estacionaria.
4. Escasez de datos, la mayoría de los experimentos se realizan con pocos participantes, debido a la inversión de tiempo que supone la extracción de muestras y el análisis posterior.
5. Subjetividad: los datos específicos de cada usuario limitan la capacidad de generalización de los modelos entrenados.

Estas limitaciones refuerzan la necesidad de técnicas de preprocesamiento robustas que serán desarrolladas en el siguiente apartado.

## **2.2 PREPROCESAMIENTO DE SEÑALES EEG**

El preprocesamiento de las señales EEG es fundamental, ya que la calidad de los datos afecta directamente al rendimiento y la precisión de los modelos de clasificación. La señal cruda de EEG, contiene artefactos como parpadeos, movimiento musculares y ruido ambiental. Esta sección recoge las principales estrategias de preprocesamiento empleadas en la literatura para preparar la señal EEG antes de la extracción de características.

### **2.2.1 FILTRADO Y ELIMINACIÓN DE ARTEFACTOS**

El paso inicial en la mayoría de los estudios es el filtrado de la señal para eliminar frecuencias irrelevantes. Normalmente, se emplea un filtro paso banda (por ejemplo entre 0.5 y 45Hz) para mantener las bandas cerebrales relevantes (Delta, Theta, Alpha, Beta y Gamma) [19]. Entre los filtros más utilizados se encuentra el filtro Butterworth [20][21] por su respuesta suave y sin ondulaciones en la banda de paso. Otro filtro utilizado es el filtro FIR [8], [22]. Estos filtros pueden diseñarse con fase lineal, es decir, que no distorsionan el momento en el que ocurre el evento. Además, son filtros estables, que evita que haya oscilaciones o inestabilidad en la señal.

La eliminación de artefactos como los generados por el parpadeo (EOG) o movimientos musculares se realiza a menudo mediante Análisis de las Componentes Independientes (por sus siglas en inglés, ICA), que es una técnica que separa las fuentes independientes de señal y permite identificar y eliminar componentes no significativas [23].

### **2.2.2 SELECCIÓN DE LOS CANALES RELEVANTES**

Dado que no todos los canales EEG contienen información útil para detectar movimientos, muchos trabajos realizan una selección previa de canales con el objetivo de reducir ruido y complejidad en el sistema. Por ejemplo, en el artículo de Blankertz [24] se hace una selección de los canales más relevantes para aplicar Patrones Espaciales Comunes (*Common Spatial Patterns, CSP*), que es una técnica de filtrado espacial que hace una transformación de los

datos de manera que se maximice la varianza de una clase y se minimice la de otra, en este caso, para discriminar entre la mano derecha e izquierda.

### **2.2.3 REDUCCIÓN DE LA DIMENSIONALIDAD**

La alta dimensionalidad de los datos EEG, debido a los múltiples canales y la frecuencia de muestreo, puede dificultar el análisis y aumentar el riesgo de sobre ajuste. Algunas de las técnicas recogidas en la literatura son: (1)Análisis de Componentes Principales (PCA), que proyecta los datos en un espacio de menor dimensión teniendo en cuenta la varianza. Esta técnica aparece en propuestas de preprocesamiento previo al uso de redes neuronales convolucionales [19], [25]. (2)Análisis de Componentes Independientes (ICA), que como se ha mencionado anteriormente, se puede utilizar también para disminuir el número de canales relevantes [26].

### **2.2.4 FILTRADO LAPLACIANO**

El filtrado laplaciano es una técnica de referencia espacial empleada en EEG, especialmente en actividades motoras. Consiste en restar al valor de un canal central, la media de sus canales vecinos, como indica la siguiente ecuación. Esta técnica permite realzar la actividad local y ayuda a reducir el ruido de los electrodos [27].

$$V_{laplaciano}(C) = V(C) - \frac{1}{n} \sum_{i=1}^n V(C_i)$$

donde  $V(C)$  es el voltaje del canal central y  $V(\text{vecinos})$  el voltaje de los canales circundantes. Esta técnica es útil como paso previo a CSP o para detectar patrones corticales o el movimiento relacionado con potenciales, que se detallan en el siguiente apartado. En el estudio de Kamavuako et al. [28], se aplica un filtro Laplaciano amplio sobre un conjunto de 9 canales, obteniendo un canal derivado único (que se denomina en inglés *surrogate channel*). Esta señal combinada conserva la información relevante y reduce el ruido, permitiendo aplicar técnicas de extracción de características sobre una única señal

optimizada. Este canal se utiliza posteriormente para entrenar un clasificador basado en Análisis Discriminatorio Lineal (Linear Discriminant Analysis, LDA) [4].

### **2.2.5 AUMENTO DE DATOS**

Dado que los conjuntos de datos EEG son frecuentemente pequeños, diversos trabajos exploran técnicas de aumento de datos, como añadir ruido gaussiano, generar muestras sintéticas mediante GANs (Redes Generativas Antagónicas o en inglés, *Generative Adversarial Networks*) o utilizar ventanas deslizantes [10]. El enfoque de las ventanas deslizantes es el más utilizado por su sencillez, ya que consiste en segmentar la señal en ventanas temporales de tamaño fijo con o sin solapamiento entre ellas. Esta técnica es especialmente útil cuando hay escasez de datos [29]. Por otro lado, las técnicas para generar datos sintéticos mediante GANs se han utilizado recientemente en sistemas basados en Deep Learning [25] y modelos más complejos.

## **2.3 EXTRACCIÓN DE CARACTERÍSTICAS**

Una vez procesadas las señales EEG, el siguiente paso es la extracción de características representativas que permitan diferenciar distintos estados cerebrales para detectar movimientos. Estas características son la entrada a los algoritmos de clasificación.

La extracción puede realizarse en el dominios temporal o frecuencial. En esta sección se describen las principales técnicas empleadas en la literatura recogida para representar las señales EEG.

### **2.3.1 TRANSFORMADA RÁPIDA DE FOURIER (FFT)**

La Transformada Rápida de Fourier (FFT) [30] permite transformar la señal del dominio temporal al dominio de la frecuencia, facilitando el análisis de las componentes

frecuenciales. En EEG, se utiliza para identificar qué frecuencias predominan en la actividad cerebral y cómo se relacionan con las tareas motoras específicas.

Dada una señal EEG  $x(t)$ , la FFT genera un espectro de frecuencias  $X(f)$  que muestra cuánta energía está presente en cada frecuencia. Esto permite descomponer la señal EEG en oscilaciones de diferentes frecuencias. Aunque la señal EEG es no estacionaria, la FFT suele ser útil cuando se aplican ventanas temporales cortas, por ejemplo de 1 segundo, donde la señal se considera suficientemente estable. Esto permite estimar la energía en bandas específicas como Mu (8-13Hz) o Beta (13-30Hz). En muchos trabajos se utiliza la FFT como paso previo al cálculo de la PDS (densidad espectral de potencia) o para extraer la frecuencia pico y la frecuencia máxima en distintas bandas. Por ejemplo, en el estudio de Mahmoodi et al. [25], se emplea la Transformada de Fourier de Tiempo Corto (STFT) – basada en FFT– para generar espectrogramas y visualizar puntos de energía en frecuencias bajas que corresponden con el Potencial de Preparación (*Readiness Potential, RP*) [31], que es el potencial justo antes del inicio de un movimiento voluntario. Finalmente, cabe mencionar que la FFT aparece indirectamente en el método Welch, que se basa en una aplicación promediada de la transformada para estimar PSD, tal y como se observa en estudios como Nguyen y Chung [32] y Benítez et al. [7].

### **2.3.2 DENSIDAD ESPECTRAL DE POTENCIA (PSD)**

La densidad espectral de potencia de una señal es la cantidad de potencia presente en cada componente de frecuencia de esa señal. Es decir, la potencia total de una señal se puede descomponer como la suma de potencias asociadas a cada frecuencia. Al examinar la densidad espectral, se pueden identificar frecuencias y patrones que no son evidentes en el dominio del tiempo. Hay dos tipos principales de densidad espectral: la densidad espectral de potencia (PSD) y la densidad espectral de energía (ESD).. En el trabajo de Nguyen y Chung [29], se utiliza PSD para comparar las potencias en las bandas Alpha y Beta mientras se frena intencionadamente en un simulador de conducción. De forma similar, Benítez et al. [7], emplean PSD sobre señales adquiridas con la diadema Emotiv EPOC como entrada para

redes neuronales, demostrando que esta técnica también es válida en dispositivos de bajo coste.

### **2.3.3 PATRONES ESPACIALES COMUNES (CSP)**

CSP es una técnica de filtrado espacial supervisado utilizado ampliamente en tareas de detección de intención de movimiento (*motor imagery*) [33]. Su objetivo es encontrar una transformación espacial de los datos EEG que maximice la varianza de una clase (por ejemplo, la imaginación del movimiento de la mano derecha), mientras minimiza la varianza de la otra (imaginación del movimiento de la mano izquierda), facilitando la separación de clases. En el artículo “*EEG Wave Identification in Human Brain with Emotiv EPOC for Motor Imagery*” [34], se utiliza el dispositivo Emotiv EPOC y el entorno de desarrollo OpenVibe [35]. En este caso se discrimina entre el movimiento imaginario de mover la mano izquierda y el pie derecho. Gracias a CSP se consigue separar claramente los patrones asociados a cada movimiento y junto con otras características se utilizan como entrada para un clasificador de Máquina de Vectores de Soporte (*Support Vector Machines, SVM*).

### **2.3.4 POTENCIALES CORTICALES**

Para la detección de la intención de movimiento, una de las características más utilizadas son los potenciales corticales lentos, especialmente el Potencial de Preparación (también llamado *Bereitschaftspotential (BP)* o *Readiness Potential (RP)*), y los Potenciales Corticales relacionados con el movimiento (en inglés, *Movement-Related Cortical Potentials (MRCP)*). Estos componentes se manifiestan en la pendiente negativa de la componente baja de frecuencia de las señales EEG. Aparece hasta 2 segundos antes del inicio del movimiento voluntario, y reflejan la actividad preparatoria en la corteza motora.

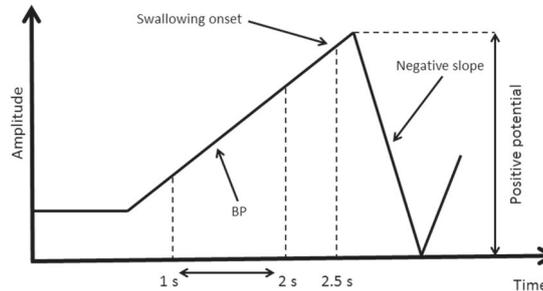


Figura 4. Ilustración de los componentes de detección de la intención de movimiento [36]

En el trabajo de Lew et al. [37], se detalla que el BP presenta dos fases: una componente temprana de desarrollo lento ( $\sim 1,5$ s antes del movimiento) y otra tardía ( $\sim 400$  ms antes), ambas con máxima expresión en los electrodos centrales.

En su estudio, Mahmoodi et al. [25] destacan que el BP puede considerarse una onda lenta en la banda delta (0–4 Hz), generada por neuronas de la corteza motora y observable en electrodos centrales como Cz. También subrayan su presencia tanto en movimientos reales como imaginados (RMI e IMI), lo que lo convierte en un marcador robusto para aplicaciones BCI de bajo coste [25].

En el estudio de Kamavuako et al. [28], se exploraron características temporales y espectrales de los MRCP en sujetos sanos y pacientes con ictus. Encontraron que las características espectrales (frecuencias entre 0–45 Hz) eran más eficaces para diferenciar entre intención de movimiento y ruido que otras que se habían utilizado en otros estudios [28]. También se destaca su importancia en neurorrehabilitación: predecir el movimiento antes de su ejecución permite mejorar la conexión entre el cerebro y el músculo.

## 2.4 MODELOS DE CLASIFICACIÓN

Una vez que la señal está preprocesada y se han extraído las características óptimas, es necesario introducir esas características en modelo de clasificación. A lo largo de la investigación, se han propuesto diferentes modelos, desde los modelos clásicos supervisados

hasta redes neuronales profundas, cada uno con sus ventajas e inconvenientes según el tipo de experimento, tipo de señal, número de canales y la complejidad permitida. A continuación se resumen los principales modelos utilizados en los estudios revisados.

### **2.4.1 ANÁLISIS DISCRIMINANTE LINEAL (EN INGLÉS, *LINEAR DISCRIMINANT ANALYSIS, LDA*)**

LDA es un clasificador lineal supervisado que proyecta los datos en un espacio de menor dimensión maximizando la separabilidad entre clases [4]. Es especialmente útil en tareas binarias (por ejemplo, mano derecha vs mano izquierda), donde se busca una línea de decisión simple. A continuación se mencionan algunos estudios que utilizaron este modelo.

Kamavuako et al. [28] aplican LDA para detectar la intención de alcanzar un objeto. Se compara la diferencia de utilizar características espectrales y características temporales, así como comparar la diferencia entre movimientos reales e imaginarios. Las características se proyectan a un espacio de menor dimensión utilizando la proyección de Fisher (que es una técnica similar a LDA) y se conservan las direcciones más diferentes. El modelo, se entrena sobre un canal laplaciano derivado de 9 electrodos y tiene un rendimiento muy alto especialmente con características espectrales en situaciones de movimiento real e imaginario. Los resultados rondan precisiones muy altas en pacientes sanos y también en pacientes que han sufrido un ictus.

Lew et al.[37] utiliza LDA para clasificar la intención de movimiento a partir de señales EEG registradas en tareas de alcanzar un objeto de manera voluntaria. En este caso, LDA se utiliza como un clasificador binario para distinguir entre ventanas EEG que preceden a un movimiento y ventanas sin actividad, basándose en diferencias de amplitud en los electrodos seleccionados. Se usan ventanas de 500 ms para capturar la pendiente negativa característica que ocurre 400 ms antes del movimiento (BP o RP). Además, para reducir la dimensionalidad, se hace un submuestreo a 8 Hz y se utilizan 6 canales, por lo que la entrada al modelo es de 24 características por ventana. Este diseño de LDA es muy eficiente y aprovecha la alta resolución temporal del EEG.

## **2.4.2 MÁQUINA DE SOPORTE VECTORIAL (EN INGLÉS, *SUPPORT VECTOR MACHINES (SVM)*)**

SVM busca encontrar el hiperplano que mejor separa las clases en un espacio multidimensional, maximizando el margen entre los ejemplo de cada clase (vectores de soporte) [38]. SVM se utiliza mucho en EEG por su capacidad de adaptarse a espacios de características no lineales, en este caso ruido y complejidad de la señal EEG, mediante funciones kernel.

En la competición BCI 2003 [39] se evaluaron distintos algoritmos de clasificación para discriminar tareas de señales EEG. Uno de los equipos utilizó SVM sobre unos datos preprocesados y optimizados y obtuvieron errores por debajo del 12%, muy competitivos frente a los equipos que usaron LDA.

En el estudio de Nguyen y Chang [40], reconocen que SVM es un referente en la clasificación de EEG y prueban en este caso redes neuronales para estudiar si se alcanzan mejores precisiones que con los métodos clásicos.

## **2.4.3 REDES NEURONALES ARTIFICIALES (ANN)**

Una red neuronal artificial es un conjunto de capas de neuronas conectadas, que aprenden patrones complejos mediante entrenamiento supervisado. Las ANN básicas son adecuadas para tareas de clasificación si los datos están bien procesados.

En el estudio de Benítez et al. [7] se desarrolla un sistema de interpretación automática de parpadeos oculares a partir de señales EEG adquiridas con la diadema Emotiv EPOC. Se clasifican los parpadeos en derecha, izquierda, neutro. Utilizaron directamente los datos crudos del EEG para evaluar el rendimiento del modelo. Las características que se extrajeron fueron 6 canales, y por cada canal la densidad espectral de potencial (PSD) en las bandas Delta, Theta, Alpha y Beta. Se aplica una ventana de Hamming [41] y *zero padding* [42] para mejorar la resolución espectral, es decir 24 características (6 canales x 4 bandas).

Para evaluar el rendimiento de ANN, utilizan dos técnicas, primero un perceptrón multicapa (MLP) que clasifica basándose en la distancia lineal entre el vector de entrada y los pesos y por otro lado una red multicapa (ANN) con 3 neuronas en la capa de salida. Ambas redes lograron precisiones muy altas en la clasificación, 94% y 90% respectivamente.

#### **2.4.4 REDES NEURONALES PROFUNDAS (CNN Y BiLSTM)**

Las Redes Neuronales Convoluciones (CNN) [43] extraen automáticamente características espaciales, por ejemplo, entre canales EEG. BiLSTM [44] son variantes de redes neuronales recurrentes (RNN) que modelan secuencias temporales, capturando dependencias largas en el tiempo. Son útiles en EEG siempre y cuando se tengan altos volúmenes de datos y más potencial computacional.

En el estudio de Jeon et al.[8] se proponen un sistema para controlar un brazo de robot con el cerebro utilizando un marco denominado CNN-BiLSTM para decodificar la intención de movimiento en múltiples direcciones espaciales a través de señales EEG. El modelo se estructura en dos etapas:

1. Preentrenamiento con CNN: se entrenan redes convolucionales separadas para cada eje del espacio tridimensional (x,y,z) utilizando perfiles de velocidad de referencia del movimiento robótico. Estas CNN aprenden características espaciales de la señal EEG por eje.

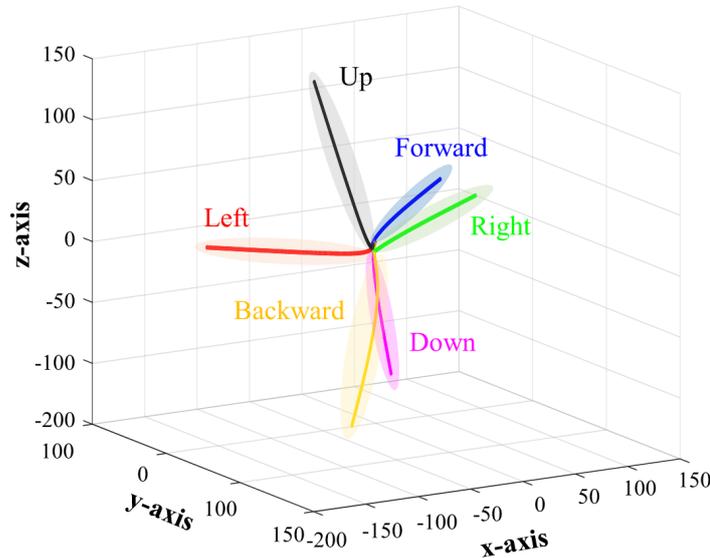


Figura 5. Características espaciales por eje en espacio tridimensional [8]

2. Entrenamiento BiLSTM: las características extraídas por las CNN se introducen en redes BiLSTM, que capturan relaciones dependientes entre los tres ejes. Esta red explora las dependencias en el espacio tridimensional. Su salida se conecta con una capa de activación ReLU seguida de una capa de regresión para predecir perfiles de velocidad.

Este enfoque permite personalizar el entrenamiento y lograr precisión en escenarios en tiempo real pero requiere una computación muy elevada y se trata de un modelo muy complejo.

## 2.5 MATRIZ DE REVISIÓN DE CASOS DE USO RELEVANTES

Una vez analizados los principales pasos que se han de seguir para el análisis de la detección del movimiento o la intención de éste con señales EEG – desde la adquisición y preprocesamiento, hasta la extracción de características relevantes y la aplicación de modelos de clasificación –, se presenta a continuación una síntesis de los estudios revisados en forma de tabla. En la tabla se han seleccionado aquellos trabajos que incluyen un experimento completo, desde la adquisición de datos hasta la evaluación del modelo, y que

pueden considerarse referencias clave. Esta muestra permite observar cómo han evolucionado las estrategias metodológicas en los últimos años y sirve como base para justificar las decisiones tomadas en este trabajo.

Tabla 3. Matriz de revisión de la literatura

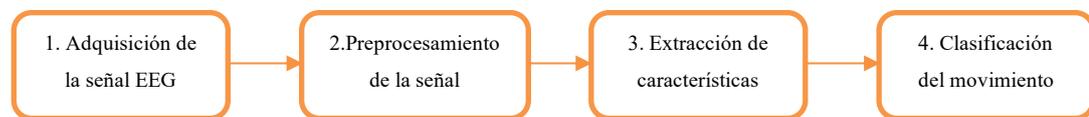
Artículo	Tarea	Adquisición de los datos	Preprocesamiento	Extracción de características	Modelo de clasificación	Precisión obtenida
<b>Singh et al.</b>	Estudios de Imaginación Motora (mano izquierda/derecha, pie, lengua, etc.)	EEG no invasivo con sistema 10-20, Sampling típico de 128-256 Hz	Filtros band-pass (8-30Hz), filtro espacial CAR o Laplaciano, eliminación de artefactos (ICA, EOG Filtering)	CSP, PDS, Wavelets, EMD, AR, Entropía, Deep CNN	LDA, SVM, MLP, CNN, R-SVM	-
<b>Bai et al.</b>	Movimientos de extensión de muñeca sin señales (self-paced)	27 electrodos	Bandpass 8-30Hz, derivación Laplaciana, reducción a 14 electrodos	Event-Related Desynchronization (ERD) alfa/beta.	Clasificador Lineal Multivariable	Detección 62 segundos antes del movimiento con un 90% de precisión
<b>Benítez et al.</b>	Parpadeo ocular voluntario	Emotiv EPOC	Filtrado básico, segmentación por eventos, uso de los canales AF3, F7, AF3, FC5	PSD en canales frontales	ANN (Red Neuronal Artificial)	87%
<b>Blankertz et al.</b>	Imaginación de movimientos (mano derecha vs mano izquierda)	BCI Competition 2003	Filtrado band-pass, normalización, selección de canales motores, CSP	CSP + potencias en bandas de frecuencia	LDA/SVM	70%
<b>Kamavuako et al.</b>	Predicción de la intención de movimiento con sujetos sanos y sujetos que han sufrido un ictus	EEG multicanal con 24 sujetos sanos y 6 enfermos	Filtro Butterworth 0.05-10Hz, filtro espacial Laplaciano	Temporales y espectrales (MRCP y bandas de frecuencia)	SVM	84%
<b>Nguyen &amp; Chang</b>	Detección de la intención de frenado durante la	EEG de 8 canales con	Filtro paso banda 0.5-45 Hz,	PSD en bandas Alpha y beta, análisis espectral	SVM	67%

	conducción simulada	simulador de conducción	eliminación de artefactos con ICA			
<b>Mahmoodi et al.</b>	Detección rápida y precisa del potencial de preparación (BP)	EEG multicanal desde Cz	Filtro paso banda 1-30 Hz, eliminación de transitorios con TVD	Teager-Kaiser Energy Operator, análisis morfológico BP	Detección por umbral de tiempo	Detección del movimiento con 384.9ms de antelación
<b>Lew et al.</b>	Detección de la intención de alcanzar un objeto de forma auto iniciada	EEG de 27 canales	Filtros específicos y normalización para extracción de BP y MRCP	Características espectrales y temporales	LDA	70%

## Capítulo 3. METODOLOGÍA

Este capítulo describe el enfoque adoptado para el desarrollo de un sistema de análisis de señales EEG para detectar movimientos corporales. La propuesta se estructura en torno a la arquitectura más habitual de las interfaces BCI, y se llevarán a cabo dos experimentos: un experimento propio con la diadema Emotiv EPOC X [45] y una segunda fase con datos públicos del repositorio de PhysioNet [46]. El objetivo es diseñar, implementar y evaluar un sistema capaz de distinguir entre distintos tipos de movimientos o su intención a partir de señales cerebrales.

El enfoque general se basa en una arquitectura modular que sigue las etapas fundamentales de la mayoría de sistemas EEG revisados [10].



*Figura 6. Arquitectura modular de un sistema BCI*

Cada uno de estos módulos se adapta según el tipo de datos y herramientas disponibles.

### ***3.1 FASE 1: DISEÑO EXPERIMENTAL CON EMOTIV EPOC X***

Para la primera fase se utiliza la diadema Emotiv EPOC X de 14 canales y frecuencia de muestreo de 128 Hz [14]. El objetivo es detectar el movimiento y distinguir si se trata de la derecha o de la izquierda. Para ello, se diseña una aplicación con Pygame [47] en la que aparecen dos flechas, de distintos colores y en la parte derecha o izquierda de la pantalla y el usuario debe tocar las teclas “P”, con la mano derecha, si aparece la flecha en la parte derecha o “Q”, con la mano izquierda, si aparece la flecha en la parte izquierda. Hasta que no se pulse la tecla no se mostrará la siguiente flecha.

El evento visual y la acción motora se sincronizarán y se registrará el tiempo que pasa entre que aparece la flecha y el usuario ejerce la acción. Debido a que se trata de un prototipo, solo participará un único sujeto.

Con estos datos se evaluará la posibilidad de detectar actividad cerebral diferencial entre hemisferio izquierdo y derecho.

### ***Preprocesamiento previsto***

- Aplicación de un filtro laplaciano centrado en los canales AF3 y AF4 para tener una señal para el hemisferio derecho y otra para el izquierdo
- Sincronización de los eventos registrados (estimulo y pulsación) con la señal EEG

### ***Extracción de características***

Se prevé trabajar con ventanas deslizantes de 1 segundo de duración centradas alrededor de cada estímulo para analizar la variación de la señal en esos momentos. El análisis principal será en el dominio del tiempo y se utilizarán las características:

1. Media: representa el valor promedio de la señal EEG en la ventana. Puede capturar potenciales lentos asociados a la preparación motora (BP).
2. Desviación típica: mide la dispersión de la señal, reflejando la variabilidad en el tiempo.
3. Energía: es la suma de los cuadrados de los valores de la señal EEG en cada ventana. Esta métrica capta la potencia total del canal
4. Amplitud pico-pico: diferencia entre el valor máximo y mínimo de la señal en una ventana para detectar potenciales o cambios bruscos.

### ***Modelo de clasificación***

Una vez extraídas las características relevantes de la señal EEG, se evalúa su capacidad de clasificación mediante un modelo lineal LDA, especialmente adecuado cuando la muestra es pequeña.

## ***3.2 FASE 2: ANÁLISIS CON DATOS DE PHYSIONET***

Debido a las limitaciones técnicas en el dispositivo Emotiv Epoc X, se complementa el estudio con un segundo bloque de análisis utilizando el dataset EEG Motor Movement/Imagery [3] del repositorio público PhysioNet. Este conjunto de datos incluye registros EEG multicanal de 109 sujetos realizando o imaginando movimientos de manos y pies. El formato de los archivos es .edf con marcas temporales de los eventos para su sincronización.

El objetivo de esta fase es entrenar modelos de clasificación supervisada que sean capaces de distinguir entre los estados de reposo (T0) y movimiento (T1/T2), basándose en ventanas EEG etiquetadas a partir de las anotaciones de eventos del archivo.

### ***Preprocesamiento previsto***

- Selección de canales motores relevantes
- Aplicación de un filtro paso banda adoptado al dominio de análisis:
  - o Dominio del tiempo: 0.1-5Hz para capturar potenciales lentos (BP)
  - o Dominio de la frecuencia: 2-60Hz para preservar las bandas mu, beta y gamma
- Segmentación en ventanas deslizantes de 1 segundo con solapamiento del 50%.

### ***Extracción de características***

Se aplican dos enfoques:

- Dominio del tiempo: se calcularán estadísticas como media, desviación estándar, energía, skewness, kurtosis y pendiente por canal.
- Dominio de la frecuencia: se extraerán potencias relativas en las bandas mu y beta, junto con la frecuencia de pico de cada banda.

### ***Modelado y validación***

Se contemplan dos estrategias:

- Modelos individualizados, entrenados con grabaciones específicas de un sujeto y validados con otra sesión del mismo sujeto.
- Modelo general, entrenando con múltiples sujetos y validado con registros independientes

Se evaluarán dos algoritmos de clasificación:

- Análisis Discriminante Lineal (LDA), por su sencillez y robustez
- Random Forest, por su capacidad para modelar relaciones no lineales entre variables.

Las métricas de rendimiento incluirán la precisión y la evolución temporal de la probabilidad de movimiento.

## Capítulo 4. SISTEMA DESARROLLADO

### 4.1 *EMOTIV EPOC X*

Con el objetivo de diseñar un sistema que permita predecir la intención de movimiento mediante señales EEG, se desarrolla una aplicación experimental personalizada utilizando la diadema Emotiv Epoc X. Esta diadema cuenta con 14 electrodos semihúmedos y permite registrar señales cerebrales en tiempo real con una alta resolución temporal, siendo una herramienta muy utilizada para estudios BCI de bajo coste [45].



*Figura 7. Diadema Emotiv Epoc X[14]*

Se diseña un experimento interactivo en el que se muestran al sujeto flechas visuales en pantalla (izquierda o derecha), debiendo responder con una pulsación de teclado correspondiente (tecla “Q” para izquierda y “P” para derecha). La aplicación registra en un archivo los timestamps exactos de del estímulo y de la pulsación para permitir su alineación con los datos de la diadema.



*Figura 8. Flecha derecha e izquierda mostrada en la interfaz*

#### **4.1.1 ADQUISICIÓN DE LOS DATOS**

La aplicación interactiva desarrollada en Python con Pygame [47] muestra 10 estímulos visuales (5 a la izquierda y 5 a la derecha, en orden aleatorio). La interfaz espera la pulsación del usuario y registra automáticamente:

- La dirección del estímulo (derecha/izquierda)
- Timestamp del estímulo
- Timestamp de la pulsación
- Tiempo de reacción

Los datos se quedan almacenados en un fichero CSV que permite sincronizarlos posteriormente con los datos registrados con la diadema Emotiv EPOC.

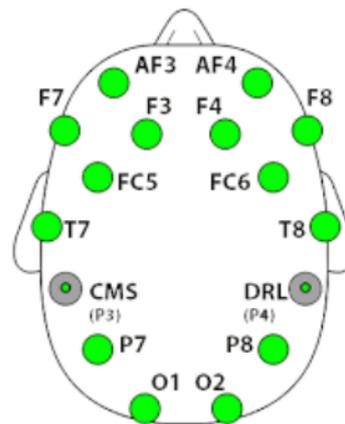
	timestamp_estimulo	direccion	timestamp_pulsacion	tiempo_reaccion	offset_seconds
0	2025-02-01 17:25:30.972147	izquierda	2025-02-01 17:25:33.366904	2.394757	21.972147
1	2025-02-01 17:25:38.434866	derecha	2025-02-01 17:25:41.170169	2.735303	29.434866
2	2025-02-01 17:25:50.996698	derecha	2025-02-01 17:25:54.603301	3.606603	41.996698
3	2025-02-01 17:26:02.278432	izquierda	2025-02-01 17:26:06.075884	3.797452	53.278432
4	2025-02-01 17:26:16.011261	derecha	2025-02-01 17:26:20.295305	4.284044	67.011261
5	2025-02-01 17:26:25.469988	derecha	2025-02-01 17:26:28.937343	3.467355	76.469988
6	2025-02-01 17:26:37.454006	derecha	2025-02-01 17:26:40.364054	2.910048	88.454006
7	2025-02-01 17:26:48.466075	derecha	2025-02-01 17:26:51.380728	2.914653	99.466075
8	2025-02-01 17:27:00.649545	derecha	2025-02-01 17:27:03.472230	2.822685	111.649545
9	2025-02-01 17:27:09.820816	izquierda	2025-02-01 17:27:13.299005	3.478189	120.820816

*Figura 9. Archivo CSV con los registros*

#### 4.1.2 PREPROCESAMIENTO DE LA SEÑAL EEG

Los datos EEG se graban en formato .edf y se procesan en Python mediante la biblioteca MNE [48]. El preprocesamiento incluye los siguientes pasos:

- Selección de canales relevantes: se seleccionan todos los canales: AF3, AF4, F3, F4, F7, F8, FC5, FC6, T7, T8, P7, P8, O1, O2.



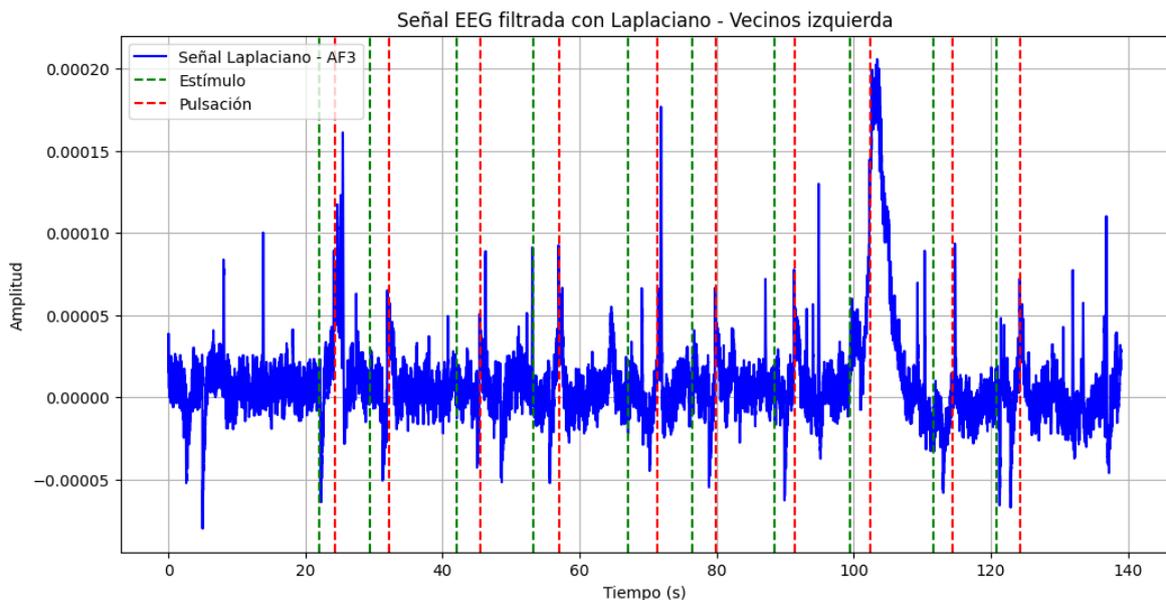
*Figura 10. Distribución de canales en Emotiv EPOC X de 14 electrodos [2]*

- Filtro Laplaciano avanzado: se aplica un filtro Laplaciano centrado en AF3 (hemisferio izquierdo) y AF4 (hemisferio derecho). Este filtro calcula la diferencia entre la señal de un canal central y la media de sus canales vecinos más cercanos, eliminando componentes comunes. Se definen manualmente

los vecinos de cada canal en base a la distribución estándar 10-20. La implementación permite obtener una señal más localizada, útil en tareas de clasificación del movimiento en cada lateral como se llevó a cabo en el estudio de Tobing et al. [21].

- Filtro paso banda: se aplica un filtro paso banda de 0.5-30Hz para eliminar los artefactos de muy baja frecuencia y los de alta frecuencia.
- Sincronización con los eventos: se alinearon los eventos de estímulo, pulsación y la señal EEG de la grabación.

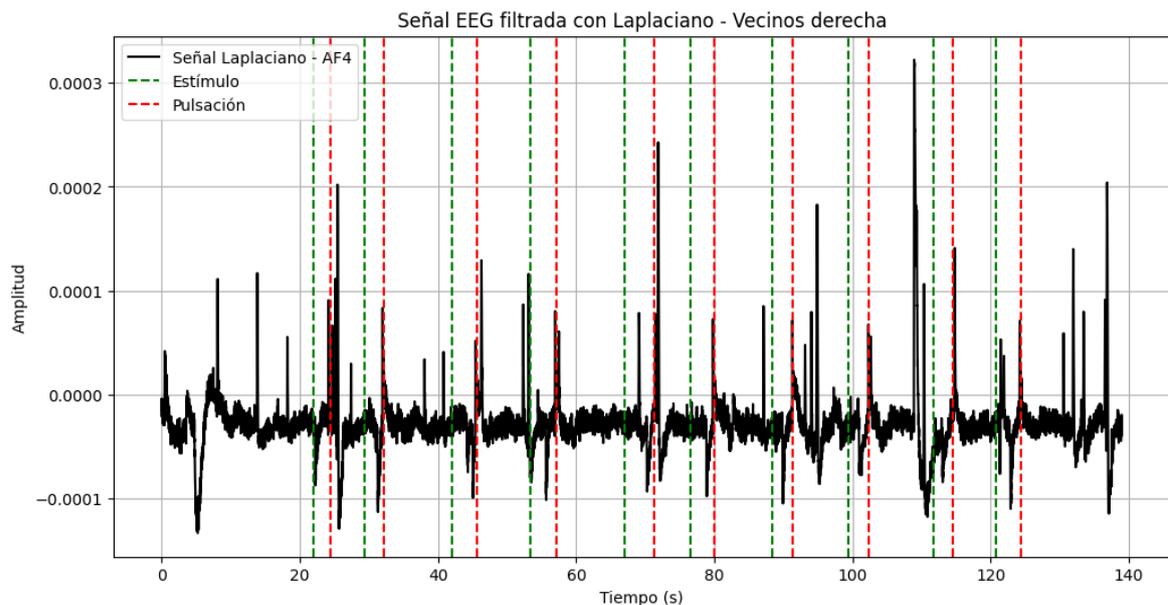
Se visualizan las señales sincronizadas, añadiendo marcas verticales en las gráficas para indicar los momentos de estímulo y los momentos en los que el sujeto pulsa las teclas. Este paso es un análisis visual, que es útil para evaluar la respuesta cerebral ante los eventos.



*Figura 11. Señal EEG sincronizada con eventos en la izquierda*

En la figura se muestra la señal EEG registrada en el canal AF3, tras aplicar un filtro laplaciano utilizando sus canales vecinos izquierdos (F3, F7). En la misma figura se representan los momentos de estímulo en líneas verdes discontinuas, que indican la aparición de una flecha en la pantalla solicitando un movimiento hacia la izquierda, y las pulsaciones del participante (líneas rojas), que reflejan la respuesta del sujeto mediante la pulsación de

una tecla. Se observa una variación de la amplitud en torno a algunos estímulos, lo que podría reflejar una preparación del movimiento. Existe una coherencia temporal entre los eventos y la señal EEG. A continuación se muestra una figura similar pero centrada en el canal AF4, con vecinos F4 y F8. De nuevo se muestra coherencia en la sincronización de eventos.



*Figura 12. Señal EEG sincronizada con eventos en la derecha*

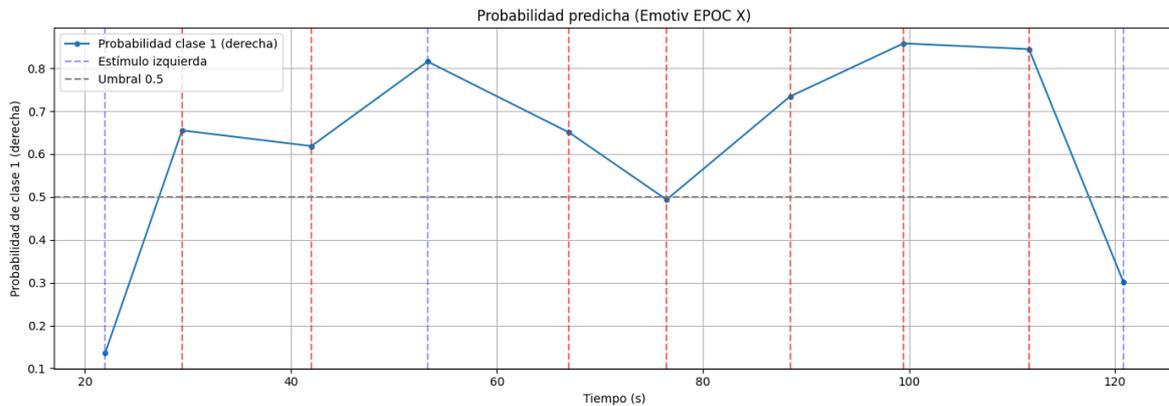
### 4.1.3 EXTRACCIÓN DE CARACTERÍSTICAS

A partir de la señal EEG preprocesada, se segmenta en ventanas de 1 segundo con un 50% de solapamiento. Para cada ventana se calculan las características en el dominio temporal (media, desviación, energía y amplitud pico-pico).

### 4.1.4 Y MODELO DE CLASIFICACIÓN

Con las características extraídas, se entrena un modelo LDA para clasificar la dirección del movimiento (siendo derecha = 1 e izquierda = 0). El conjunto de datos se divide en entrenamiento (70%) y test (30%). El LDA permite obtener una precisión del 66,6%, mostrando un rendimiento adecuado en la detección de diferencias. Sin embargo, al observar la evolución de la probabilidad a lo largo de la grabación, se observa en la figura 13 que

comete errores para predecir la izquierda, y que hay un mayor número de estímulos derechos que izquierdos.



*Figura 13. Evolución de la probabilidad predicha*

Debido a la falta de registros adicionales con esta configuración, no es posible realizar una validación del modelo, por lo que este análisis se complementa con el dataset EEG Motor Movement/Imagery de PhysioNet, que permite validar los enfoques propuestos en una muestra más amplia.

#### **4.1.5 LIMITACIONES DURANTE EL EXPERIMENTO CON LA DIADEMA EMOTIV**

Durante las siguientes sesiones de adquisición de datos, la diadema presentó problemas técnicos en varios sensores, en especial el canal F3, que dejó de registrar señal de forma persistente. A pesar de los intentos de corrección mediante rehidratación y reposicionamiento, el fallo persistió. Finalmente se determinó que el sensor presentaba un daño físico, lo cual imposibilitó continuar con la recogida de nuevos datos de forma fiable y simétrica en ambos hemisferios.

Debido a esta incidencia técnica, se optó por completar el estudio utilizando la base de datos publica EEG Motor Movement/Imagery Dataset [3], la cual incluye múltiples sujetos con registros completos y validados de movimientos reales e imaginados. Esta decisión asegura que exista consistencia en los datos utilizados para el desarrollo, entrenamiento y evaluación de los modelos de clasificación.

## 4.2 *PHYSIONET EEG MOTOR MOVEMENT/IMAGERY*

### 4.2.1 INTRODUCCIÓN A LA BASE DE DATOS

Para este estudio se ha utilizado la base de datos *EEG Motor Movement/Imagery Dataset* [3], que se encuentra en el repositorio público de PhysioNet [46]. Esta base consta de más de 1500 grabaciones EEG en formato EDF+, obtenidas de 109 sujetos voluntarios. Las grabaciones EEG se realizaron con 64 canales utilizando el sistema BCI2000 [49].

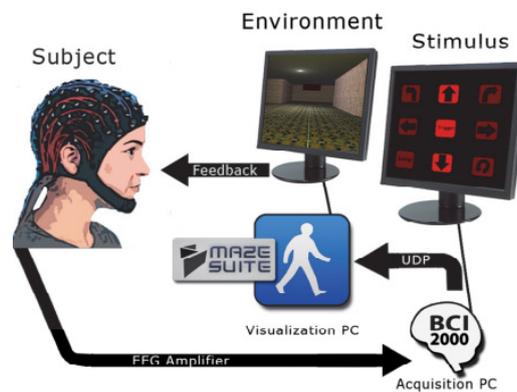


Figura 14. Adquisición de la base de datos de EEG Motor Movement/Imagery [50]

Cada sujeto realizó un total de 14 tareas experimentales divididas en:

- 2 tareas base (reposo con los ojos cerrados y abiertos)
- 6 tareas de movimiento real que incluyen:
  - Movimiento del puño izquierdo (T1)
  - Movimiento del puño derecho (T2)
  - Movimiento de ambos puños o ambos pies
- 6 tareas de imaginación motora, con los mismo movimientos.

La secuencia de tareas es la siguiente: primero el sujeto está 2 minutos en reposo (*baseline*) con los ojos abiertos, y 2 minutos en reposo con los ojos cerrados. Después, hace 3 rondas de dos minutos de cada una de las siguientes tareas:

1. Movimiento real de un puño (derecho o izquierdo): aparece un objeto a la izquierda o a la derecha de la pantalla. El sujeto abre y cierra el puño correspondiente hasta que el objeto desaparece, y luego se relaja.
2. Imaginación del movimiento del puño: aparece un objeto a la derecha o a la izquierda. El sujeto se imagina que abre y cierra el puño correspondiente hasta que el objeto desaparece, y luego se relaja.
3. Movimiento real de ambos puños o pies: aparece un objeto en la parte superior o inferior de la pantalla. Si está arriba, el sujeto mueve ambos puños; si está abajo, el sujeto mueve ambos pies. Al desaparecer el estímulo, el sujeto se relaja.
4. Imaginación del movimiento de ambos puños o pies: igual que el anterior pero el sujeto se imagina los movimientos hasta que desaparece el estímulo.

Cada grabación tiene un archivo *.event* que incluye marcas temporales con los siguientes códigos:

- T0: periodo de reposo
- T1: inicio del movimiento (real o imaginado) de:
  - Puño izquierdo en sesiones 3,4,7,8,11,12
  - Ambos puños en sesiones 5,6,9,10,13,14
- T2: inicio del movimiento (real o imaginado) de:
  - Puño derecho en sesiones 3,4,7,8,11,12
  - Ambos pies en sesiones: 5,6,9,10,13,14

A continuación se muestra una tabla resumen del experimento que se realizó para 109 sujetos.

*Tabla 4. Tabla resumen del experimento de EEG Motor Movement/Imagery*

Nº tarea	Tipo de tarea	Movimiento	Real/Imaginado
R01	Baseline (ojos abiertos)	Ninguno (T0)	-

R02	Baseline (ojos cerrados)	Ninguno (T0)	-
R03	Movimiento de abrir y cerrar el puño derecho o izquierdo	Izquierdo (T1) / Derecho (T2)	Real
R04	Movimiento de abrir y cerrar el puño derecho o izquierdo	Izquierdo (T1) / Derecho (T2)	Imaginado
R05	Movimiento de abrir o cerrar ambos puños o ambos pies	Ambos puños(T1) /Ambos pies (T2)	Real
R06	Movimiento de abrir o cerrar ambos puños o ambos pies	Ambos puños(T1) /Ambos pies (T2)	Imaginado
R07	Movimiento de abrir y cerrar el puño derecho o izquierdo	Izquierdo (T1) / Derecho (T2)	Real
R08	Movimiento de abrir y cerrar el puño derecho o izquierdo	Izquierdo (T1) / Derecho (T2)	Imaginado
R09	Movimiento de abrir o cerrar ambos puños o ambos pies	Ambos puños(T1) /Ambos pies (T2)	Real
R10	Movimiento de abrir o cerrar ambos puños o ambos pies	Ambos puños(T1) /Ambos pies (T2)	Imaginado
R11	Movimiento de abrir y cerrar el puño derecho o izquierdo	Izquierdo (T1) / Derecho (T2)	Real
R12	Movimiento de abrir y cerrar el puño derecho o izquierdo	Izquierdo (T1) / Derecho (T2)	Imaginado

---

R13	Movimiento de abrir o cerrar ambos puños o ambos pies	Ambos puños(T1) /Ambos pies (T2)	Real
R14	Movimiento de abrir o cerrar ambos puños o ambos pies	Ambos puños(T1) /Ambos pies (T2)	Imaginado

---

#### 4.2.2 ADQUISICIÓN DE LOS DATOS

Para desarrollar un sistema capaz de detectar movimientos corporales o la intención de realizarlos, el análisis se va a centrar en la detección de la etiqueta T0 (clase 0, correspondiente al reposo) y a la etiqueta T1/T2 (clase 1, correspondiente al movimiento). Para garantizar la clasificación, se utilizarán únicamente las tareas reales de abrir y cerrar el puño (R03, R07, R011). Como sujetos se utilizará el Sujeto 1 para entrenar y el Sujeto 2 para validar el resultado del modelo.

Cada archivo *.edf* incluye un canal con anotaciones que indican el inicio y final de los eventos mediante los códigos T0, T1 y T2. La librería MNE – Python [48], permite acceder fácilmente a estas anotaciones a través del objeto *raw.annotations*, que contiene la descripción, el tiempo de inicio y la duración de cada evento en segundos como se puede apreciar en la siguiente figura. Este objeto simplifica la segmentación de la señales en ventanas temporales y la etiquetación de cada una de esas ventanas.

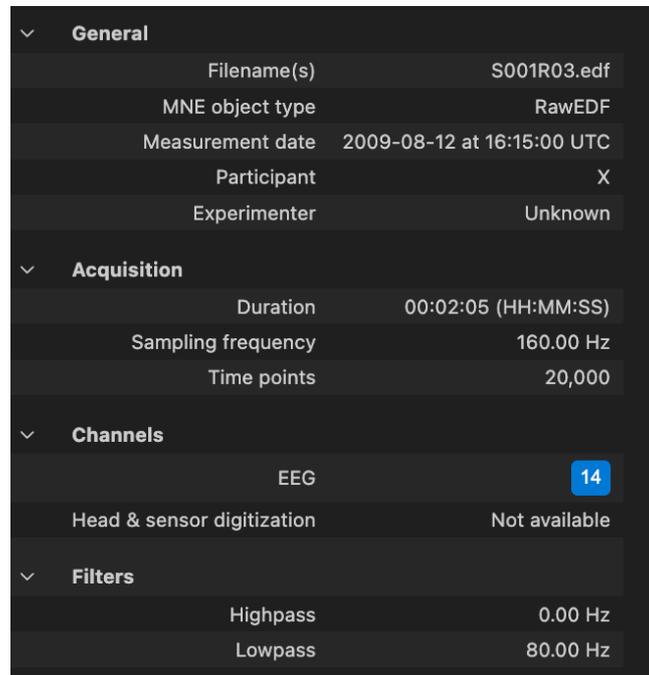
```

01. Evento T0: empieza en 0.00s (0), dura 4.20s → 672 muestras
02. Evento T2: empieza en 4.20s (672), dura 4.10s → 656 muestras
03. Evento T0: empieza en 8.30s (1328), dura 4.20s → 672 muestras
04. Evento T1: empieza en 12.50s (2000), dura 4.10s → 656 muestras
05. Evento T0: empieza en 16.60s (2656), dura 4.20s → 672 muestras
06. Evento T1: empieza en 20.80s (3328), dura 4.10s → 656 muestras
07. Evento T0: empieza en 24.90s (3984), dura 4.20s → 672 muestras
08. Evento T2: empieza en 29.10s (4656), dura 4.10s → 656 muestras
09. Evento T0: empieza en 33.20s (5312), dura 4.20s → 672 muestras
10. Evento T2: empieza en 37.40s (5984), dura 4.10s → 656 muestras
11. Evento T0: empieza en 41.50s (6640), dura 4.20s → 672 muestras
12. Evento T1: empieza en 45.70s (7312), dura 4.10s → 656 muestras
13. Evento T0: empieza en 49.80s (7968), dura 4.20s → 672 muestras
14. Evento T1: empieza en 54.00s (8640), dura 4.10s → 656 muestras
15. Evento T0: empieza en 58.10s (9296), dura 4.20s → 672 muestras
16. Evento T2: empieza en 62.30s (9968), dura 4.10s → 656 muestras
17. Evento T0: empieza en 66.40s (10624), dura 4.20s → 672 muestras
18. Evento T1: empieza en 70.60s (11296), dura 4.10s → 656 muestras
19. Evento T0: empieza en 74.70s (11952), dura 4.20s → 672 muestras
20. Evento T2: empieza en 78.90s (12624), dura 4.10s → 656 muestras
21. Evento T0: empieza en 83.00s (13280), dura 4.20s → 672 muestras
22. Evento T2: empieza en 87.20s (13952), dura 4.10s → 656 muestras
23. Evento T0: empieza en 91.30s (14608), dura 4.20s → 672 muestras
24. Evento T1: empieza en 95.50s (15280), dura 4.10s → 656 muestras
25. Evento T0: empieza en 99.60s (15936), dura 4.20s → 672 muestras
...
27. Evento T0: empieza en 107.90s (17264), dura 4.20s → 672 muestras
28. Evento T2: empieza en 112.10s (17936), dura 4.10s → 656 muestras
29. Evento T0: empieza en 116.20s (18592), dura 4.20s → 672 muestras
30. Evento T1: empieza en 120.40s (19264), dura 4.10s → 656 muestras

```

*Figura 15. Registro de eventos de la librería MNE*

A continuación se muestran los metadatos de la grabación del Sujeto 1 que participa en el experimento a modo de ejemplo para explicar de manera detallada los distintos campos en la Tabla 3.



General	
Filename(s)	S001R03.edf
MNE object type	RawEDF
Measurement date	2009-08-12 at 16:15:00 UTC
Participant	X
Experimenter	Unknown
Acquisition	
Duration	00:02:05 (HH:MM:SS)
Sampling frequency	160.00 Hz
Time points	20,000
Channels	
EEG	14
Head & sensor digitization	Not available
Filters	
Highpass	0.00 Hz
Lowpass	80.00 Hz

Figura 16. Resumen de los metadatos de un archivo EDF

Tabla 5. Descripción de las características de la grabación de un sujeto

Columnas	Descripción	Ejemplo
Filename	Nombre del archivo de grabación	S001R03.edf
MNE Object Type	Tipo de objeto reconocido por MNE, que indica cómo se representarán los datos	RawEDF
Measurement Date	Fecha y hora en la que se realizó la grabación	2009-08-12 at 16:15:00 UTC
Duration	Duración total de la grabación en horas, minutos y segundos	00:02:05
Sampling frequency	Frecuencia de muestreo utilizada para los datos, medida en Hertz (HZ)	160 Hz
Time points	Número total de puntos de datos registrados en la grabación	20.000

Channels	Número total de canales EEG utilizados en la grabación	14
	Highpass: filtro paso-alto aplicado a los datos, elimina frecuencias por debajo del valor indicado	Highpass: 0.00Hz
Filtros	Lowpass: filtro paso-bajo aplicado a los datos, elimina frecuencias por encima del valor indicado	Lowpass: 80.00Hz

Como se ha estudiado en el Capítulo 2, el análisis de EEG se puede abordar desde distintos dominios. En este caso, se han aplicado dos enfoques complementarios: el dominio del tiempo y el dominio de la frecuencia.

- El análisis temporal permite capturar componentes lentos como el Potencial de Preparación (BP), que se manifiesta como una pendiente negativa previa al inicio del movimiento.
- El análisis frecuencial permite evaluar la actividad en diferentes bandas de frecuencia utilizando técnicas como la Transformada de Fourier o el método de Welch.

A continuación se presenta en detalle cada uno de los enfoques aplicados sobre los datos de PhysioNet, incluyendo el preprocesamiento, la extracción de características y la evaluación del modelo de clasificación.

## ***PROCESO DE APRENDIZAJE***

El proceso de aprendizaje automático consiste en entrenar un modelo que sea capaz de distinguir entre dos clases: reposo (T0) y movimiento (T1/T2). Este aprendizaje se basa en transformar la señal EEG en un conjunto de ventanas etiquetadas, de las que se extraen características representativas, tanto en el dominio del tiempo como en el de la frecuencia.

Con el objetivo de evaluar la capacidad de los modelos para adaptarse a diferentes contextos, se desarrollan dos estrategias de aprendizaje:

1. Modelos individuales por sujeto

Se seleccionan 5 sujetos y, para cada uno, se entrena un modelo personalizado utilizando las grabaciones de movimiento real del puño derecho o izquierdo (R03 y R07) y se valida con la grabación R11, que también es el movimiento real del puño derecho o izquierdo. Este enfoque busca estudiar la capacidad del modelo para aprender patrones específicos de cada persona y evaluar su estabilidad frente a nuevas registros del mismo individuo.

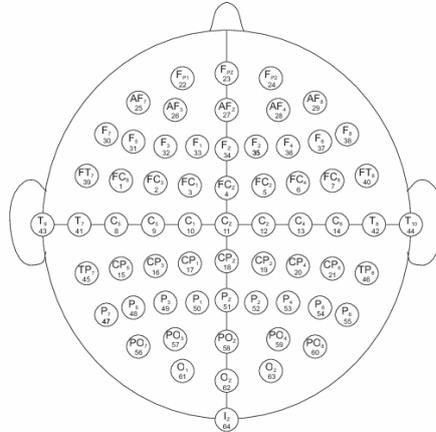
2. Modelo general con múltiples sujetos

Paralelamente, se entrena un único modelo utilizando datos combinados de los 109 sujetos disponibles en la base de datos de PhysioNet. Este modelo tiene como objetivo aprender patrones generales y transferibles que sean comunes a distintos usuarios, sin necesidad de recalibrar para cada individuo. El rendimiento de este modelo se evalúa con nuevos registros de los 109 sujetos para comprobar su capacidad de generalización inter-sujeto.

Ambas estrategias se aplican en el análisis temporal como en el frecuencial, empleando dos clasificadores: LDA, por su sencillez e interpretabilidad, y Random Forest, por su capacidad de capturar relaciones no lineales entre características.

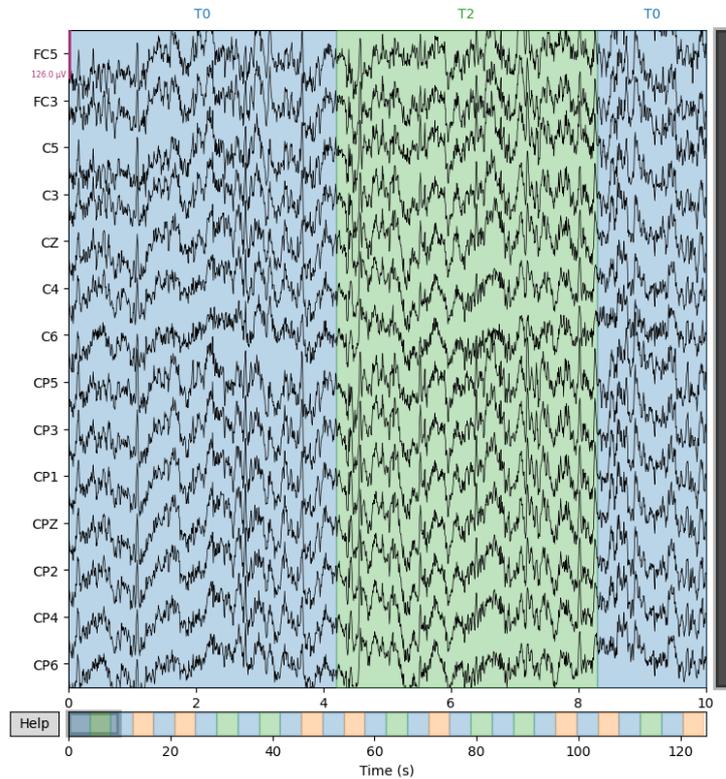
## ***ANÁLISIS EN EL DOMINIO DEL TIEMPO***

Inicialmente se trabaja con una selección de 14 canales ubicados en las áreas motoras y premotoras, distribuidos simétricamente en ambos hemisferios. Los canales son: FC5, FC3, C5, C3, CZ, C4, C6, CP5, CP3, CP1, CPZ, CP2, CP4, CP6, y se muestran en la siguiente figura.



*Figura 17. Distribución de los electrodos*

La siguiente figura muestra la señal en crudo antes del preprocesamiento en el dominio del tiempo.

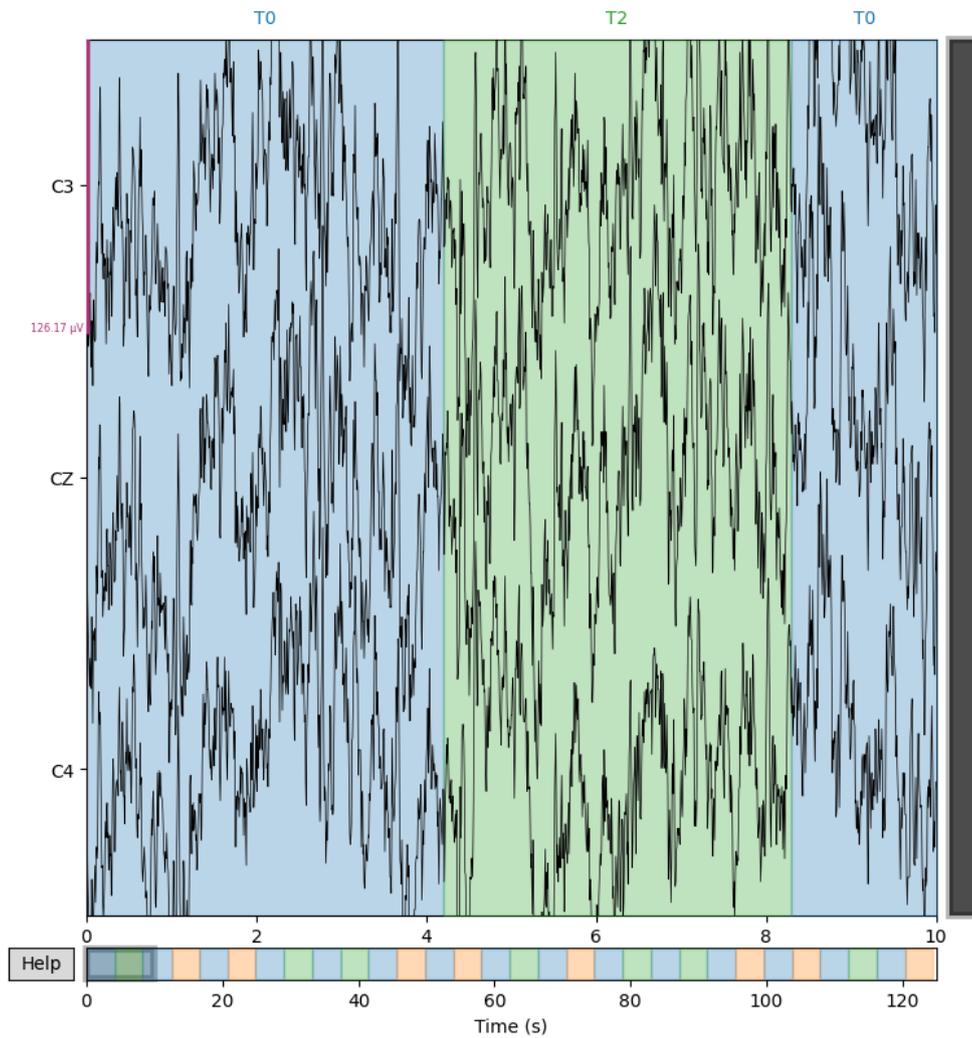


*Figura 18. Señal EEG del Sujeto 1*

### **4.2.3 PREPROCESAMIENTO EN EL DOMINIO DEL TIEMPO**

El preprocesamiento es una de las partes esenciales del análisis de señales EEG. Los 14 canales que se han mencionado anteriormente se utilizaron en una primera prueba en todo el pipeline de preprocesamiento, extracción de características y modelo de clasificación, y se observó que los canales más relevantes eran C3, Cz y C4, y el resto, solo aportaban ruido. Por lo tanto, el primer paso fue la selección de canales relevantes, en este caso C3, Cz y C4.

Puesto que el objetivo es detectar la intención de movimiento y siguiendo algunos artículos mencionados previamente como Benítez et al. [7] y Kamavuako et al. [28], se aplica un filtro paso banda Butterworth [20] entre 0.1-5 Hz para obtener las componentes lentas asociadas al Potencial de Preparación (BP) y a los Potenciales Corticales Relacionados con el Movimiento (MRCP), que se manifiestan en la actividad de baja frecuencia previa al inicio del movimiento voluntario.



*Figura 19. Señal EEG después de la selección de los canales relevantes*

#### **4.2.4 CARACTERÍSTICAS EXTRAÍDAS EN EL DOMINIO DEL TIEMPO**

Para transformar la señal continua en un conjunto de muestras etiquetadas, se aplicó una segmentación en ventanas deslizantes de 1 segundo con un 50% de solapamiento, siguiendo con la metodología empleada en estudios previos [19]. Para cada ventana se extraen un total

de 7 características, que permiten describir el comportamiento de la señal sin necesidad de transformarla al dominio de la frecuencia. Las características son las siguientes:

<b>Característica</b>	<b>Descripción técnica</b>	<b>Interpretación relevante</b>
Media	Promedio de los valores de la señal	Refleja el nivel medio de activación
Desviación estándar	Dispersión de la señal respecto a la media	Mayor durante el movimiento; menor en reposo
Varianza	Promedio de las desviaciones cuadradas respecto a la media	Similar a la desviación estándar
Energía(*)	Suma de los cuadrados de los valores temporales	Representa la intensidad total de la señal
Asimetría ( <i>Skewness</i> )	Asimetría de la distribución de valores	Detecta si una señal tiene una forma inclinada hacia los valores positivos o negativos
Curtosis (Kurtosis)	Medida de la concentración de valores alrededor de la media	Identifica señales con picos o planas
Pendiente (**)	Coefficiente de regresión lineal ajustada a la señal	Una pendiente negativa indica una disminución progresiva en el tiempo que es muy útil para identificar el BP.

(\*)La energía se calcula como la suma de los cuadrados de los valores de la señal en una ventana dada, es decir:

$$Energía = \sum_{i=1}^N x_i^2$$

Donde  $x_i$  son los valores de la señal EEG en microvoltios. Esta medida cuantifica la magnitud total de la actividad cerebral en ese intervalo. Durante eventos motores, la energía suele ser mayor.

(\*\*)La pendiente se calcula ajustando una regresión lineal sobre los puntos de la señal dentro de cada ventana. Esta característica tiene un gran valor en el contexto de la detección de la intención de movimiento, ya que el Potencial de Preparación (BP) suele manifestarse como una pendiente negativa en la señal EEG segundos antes del inicio del movimiento voluntarios. Por tanto, una pendiente negativa puede ser indicativa de preparación para el movimiento. A continuación, se muestra una figura de la señal EEG de los sensores que se está estudiando 2 segundos antes del inicio de un movimiento. Se puede apreciar una pendiente negativa que significa la preparación motora.

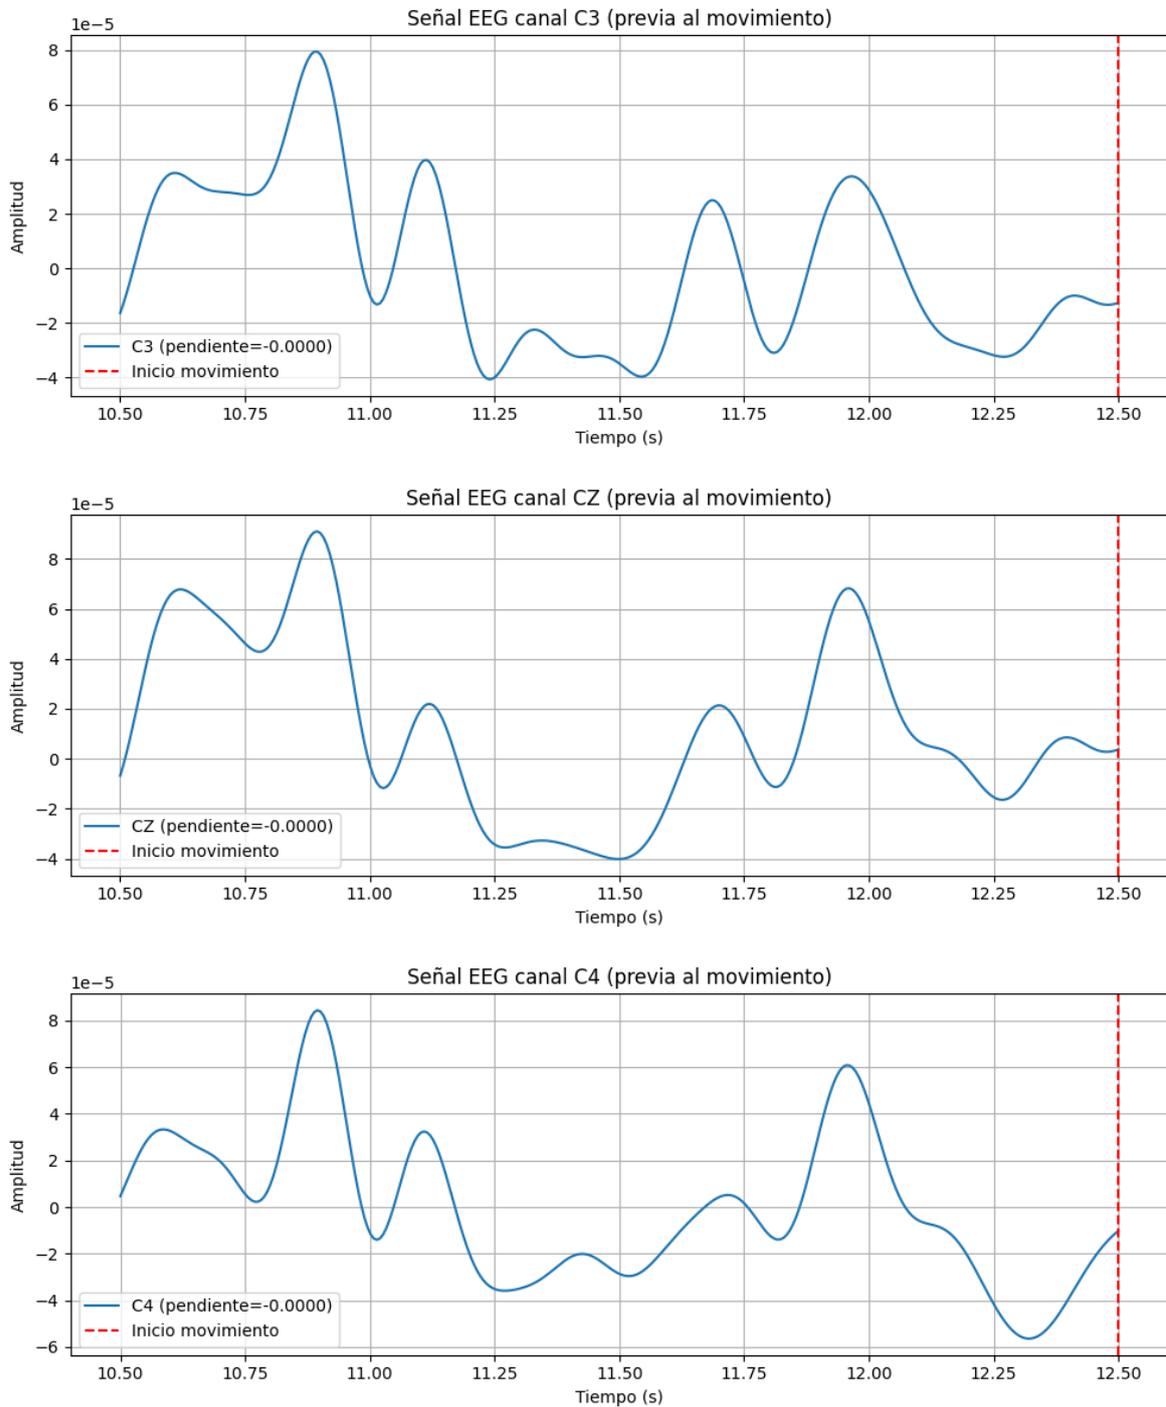


Figura 20. Señal EEG de los canales seleccionados donde se observa pendiente negativa previa al inicio del movimiento

Al tener 3 canales, se obtienen 21 características por ventana (3 canales x 7 características), que serán las entradas del modelo de clasificación.

#### **4.2.5 MODELO DE CLASIFICACIÓN EN EL DOMINIO DEL TIEMPO**

Una vez preprocesada y segmentada la señal EEG, y extraídas las 7 características por canal, se entrena un modelo supervisado para identificar cada ventana como reposo (T0) o movimiento (T1/T2). El objetivo es identificar de forma automática la intención de movimiento a partir de la actividad cerebral siguiendo dos estrategias complementarias de aprendizaje:

1. Modelos personalizados por sujeto, en los que se entrena un clasificador individual utilizando los datos de un único sujeto y se valida con una grabación independiente del mismo sujeto
2. Modelo general, entrenado con datos combinados de los 109 sujetos de la base de datos, para analizar la posibilidad de generalización sin calibrar individualmente.

Ambas estrategias se aplican en el dominio del tiempo, utilizando como entrada las 7 características extraídas de ventanas deslizantes de la señal EEG. En concreto, se utilizarán dos clasificadores supervisados: Análisis Discriminante Lineal (LDA) [4], como modelo base, lineal y fácilmente interpretable; y Random Forest (RF) [5], como modelo no lineal, robusto y capaz de capturar interacciones complejas entre variables.

El modelo Análisis Discriminante Lineal (LDA) [4], es un modelo supervisado lineal que busca proyectar datos en un espacio de dimensión menor donde la separación de las clases sea la máxima posible. LDA funciona identificando la combinación lineal entre las diferentes características que puedan separar en dos clases diferentes, en este caso reposo o movimiento.

Muchos artículos revisados [24], [28], [37], [51] utilizan este modelo de clasificación porque requiere pocos parámetros y funciona bien con conjuntos de datos pequeños. Su estructura simple facilita la interpretación de resultados.

Por otro lado, Random Forest (RF) [5] es un modelo no lineal basado en conjuntos (*ensembles*) de árboles de decisión. Cada árbol se entrena con una submuestra aleatoria de los datos y selecciona aleatoriamente un subconjunto de características en cada nodo, lo que permite capturar interacciones complejas y relaciones no lineales entre variables. Aunque este modelo no aparece con frecuencia en los artículos revisados, se ha demostrado en otros contextos como una técnica robusta frente al ruido [52]. Por ello, se ha incluido en este estudio con el objetivo de evaluar si puede aportar ventajas en la detección de la intención de movimiento a partir de señales EEG reales.

### 1. Modelo personalizado por sujeto

El modelo se entrena utilizando LDA y las características extraídas del dominio del tiempo. Los datos de entrenamiento son R03 y R07 y se valida con el registro R011 de cada individuo. Estos registros son reposo (T0) y movimientos reales del puño derecho o izquierdo (T1/T2). Se observa que la precisión media en entrenamiento es de 66.6% y en validación de 59.8%. El mejor modelo es el del sujeto 4, que tiene una precisión en entrenamiento de 78% y una precisión en validación de 67%

*Tabla 6. Precisión del modelo personalizado por sujeto en entrenamiento y validación*

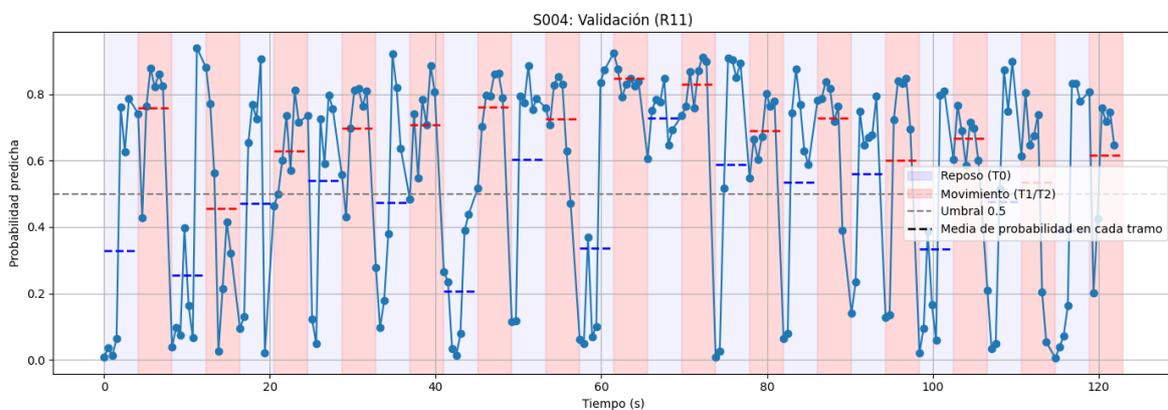
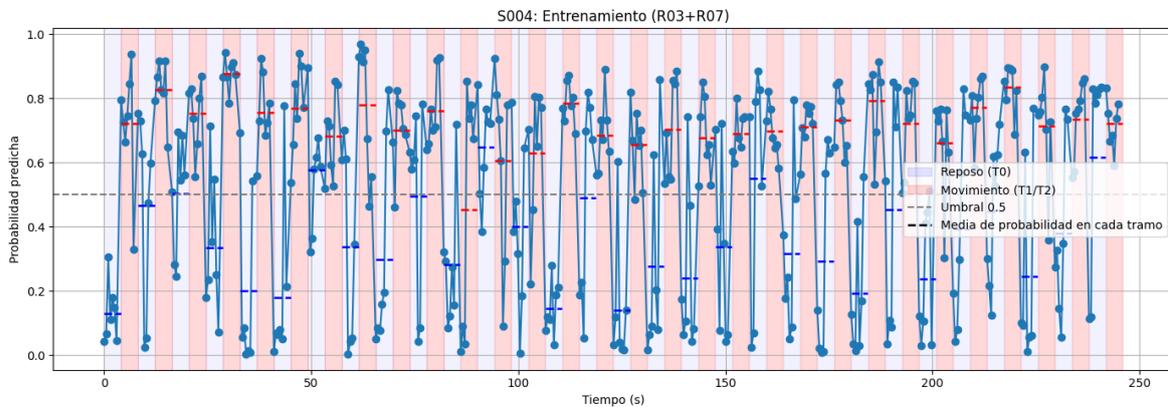
<b>Sujeto</b>	<b>Precisión Entrenamiento (R03 + R07)</b>	<b>Precisión Validación (R011)</b>
S001	66%	60%
S002	58%	51%
S003	67%	61%
S004	78%	67%
S005	64%	60%

**Media**

**66.6%**

**59.8%**

A continuación se puede observar la evolución de la probabilidad predicha por el modelo LDA para la clase “movimiento” (T1/T2) a lo largo del tiempo. Esta representación gráfica permite visualizar cómo responde el clasificador en cada momento del experimento. en la figura se muestra la probabilidad de movimiento estimada por el modelo para cada ventana (línea azul con marcadores), las zonas de reposo (T0) y movimiento (T1/T2) según las anotaciones del archivo edf, representada con franjas azules y rojas respectivamente, y una línea discontinua que marca el umbral de decisión en 0.5. Además se añaden líneas horizontales discontinuas en cada tramo de reposo o de movimiento, que representan la probabilidad media estimada por el modelo en ese intervalo. En concreto se muestran las gráficas del Sujeto 4.

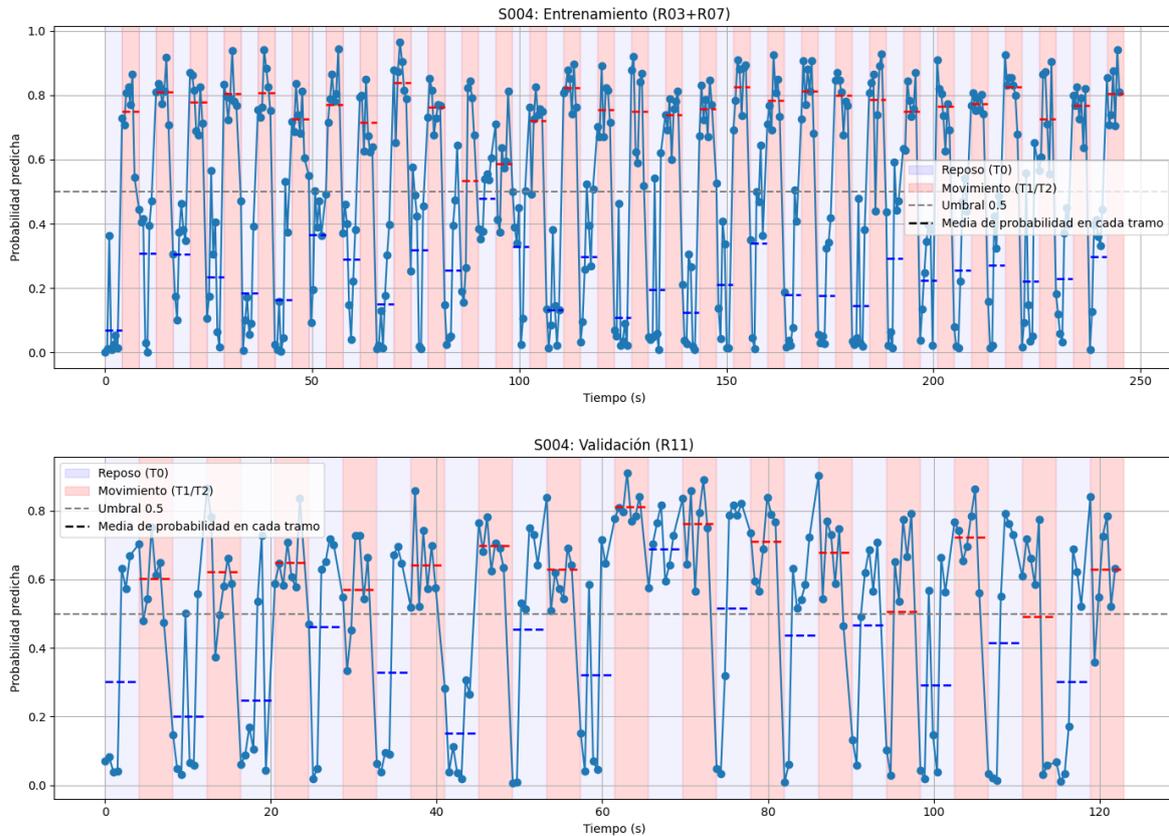


*Figura 21. Evolución de la probabilidad de la clase movimiento del sujeto 4*

Tras aplicar el modelo LDA, se entrena también un clasificador Random Forest (RF) utilizando las mismas características y particiones de entrenamiento y validación. La siguiente tabla presenta las precisiones obtenidas por RF en cada sujeto. Se aprecia una media en la precisión de entrenamiento de 95.6% y una media de precisión en validación de 60.2%. En este caso, el mejor sujeto en media vuelve a ser el sujeto 4, con una precisión en entrenamiento de 92% y en validación de 70%.

<b>Sujeto</b>	<b>Precisión Entrenamiento</b>	<b>Precisión Validación</b>
S001	96%	59%
S002	97%	56%
S003	98%	53%
S004	92%	70%
S005	95%	63%
<b>Media</b>	<b>95.6%</b>	<b>60.2%</b>

Se muestra de nuevo la evolución de la probabilidad para el sujeto 4 con los resultados obtenidos de entrenar el RF.



*Figura 22. Evolución de la probabilidad de la clase movimiento del sujeto 4*

Al comparar los resultados medios de los modelos LDA y RF, se observa una diferencia significativa en la precisión de entrenamiento. LDA alcanza un 66.6% y RF un 95.6%. La bajada de la precisión en validación de RF (60.2%) sugiere que Random Forest podría estar sobre ajustando los datos de entrenamiento. Es decir, RF logra aprender muy bien los patrones del conjunto de entrenamiento, pero pierde capacidad a la hora de generalizar cuando se trata de datos nuevos.

## 2. Modelo general

El modelo general se entrena utilizando LDA y las características extraídas del dominio del tiempo. Para ello, se combinan los registros R03 y R07 de los 109 sujetos, que incluyen ventanas etiquetadas como reposo (T0) y movimiento (T1/T2). El objetivo es evaluar si es posible detectar el movimiento de forma generalizada sin necesidad de calibración personal por sujeto.

Tras un preprocesamiento utilizando los canales C3, C4, Cz y un filtro paso banda entre 0.1Hz y 5Hz, se realiza una segmentación de la señal en ventanas de 1 segundo con solapamiento del 50%. Para validar el modelo se implementan dos estrategias:

(1) Validación con los registros R01: se entrena con los registros R03 y R07 de los 109 sujetos, y se valida utilizando los registros R011, correspondientes a nuevas grabaciones de los mismos sujetos. Este enfoque permite analizar la capacidad del modelo para generalizar a registros distintos.

(2) Validación cruzada (k-fold): se aplica validación cruzada estratificada con 10 particiones (k=10) sobre el conjunto combinado de R03 y R07. En cada iteración se entrena con el 90% de los datos y se valida con el 10% restante. Esta estrategia permite evaluar la robustez del modelo ante nuevas ventanas dentro del mismo conjunto de sujetos y registros.

Los resultados obtenidos se resumen en la siguiente tabla:

*Tabla 7. Resultados obtenidos en el dominio del tiempo para el modelo con 109 sujetos*

Enfoque	R011	R03 + R07	Evalúa la generalización de...	Precisión media en validación
<b>Modelo general + validación R011</b>	Validación	Entrenamiento	Otro registro de muchos sujetos	51%
<b>Modelo general + CV (k=10)</b>	-	Entrenamiento y validación	Nuevas ventanas del mismo conjunto de sujetos	52% (±0.0061)

Como puede observarse en la tabla, los resultados son muy similares en ambos casos, lo que sugiere que el modelo en general tiene un rendimiento moderado en tareas de clasificación del movimiento. Esta precisión cercana al 50% podría atribuirse a la gran variabilidad intersujeto presente en las señales EEG.

## ***ANÁLISIS EN EL DOMINIO DE LA FRECUENCIA***

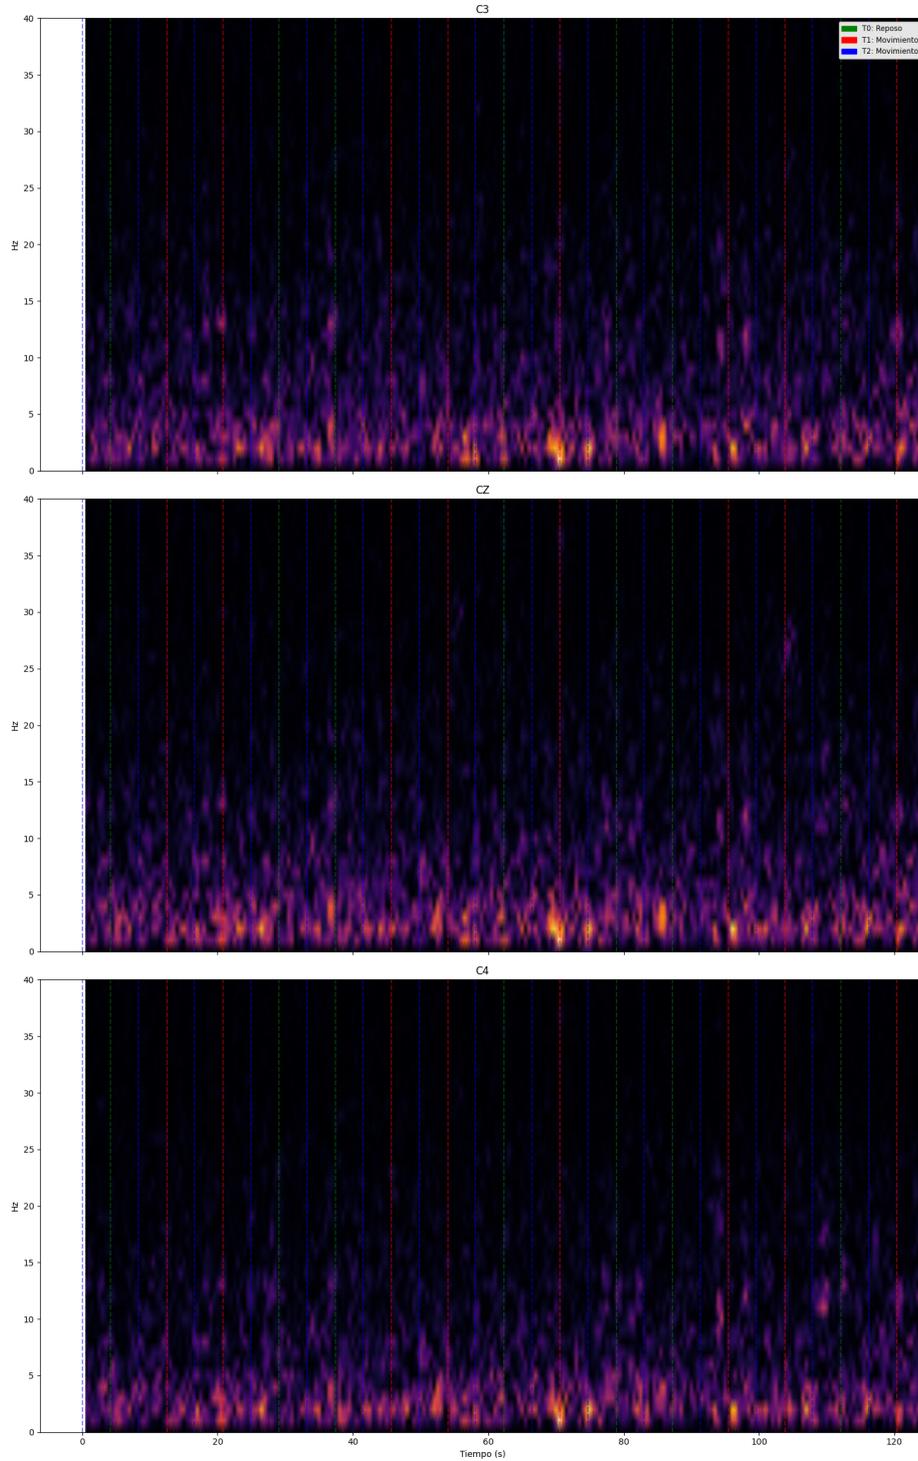
Tras el análisis en el dominio del tiempo, se aborda ahora un enfoque complementario basado en características espectrales.

A continuación se muestra primero los espectrogramas obtenidos para cada uno de los canales (C3, Cz y C4) utilizando la Transformada de Fourier de tiempo corto (STFT), junto con las marcas temporales de los eventos del archivo edf.

- T0: reposo (líneas azules)
- T1: inicio del movimiento del puño izquierdo (líneas verdes)
- T2: inicio del movimiento del puño derecho (líneas rojas)

Este espectrograma mostrado en la siguiente figura permite observar zonas de mayor densidad de energía en frecuencias bajas (especialmente mu y beta) coincidiendo con los periodos de actividad motora.

Espectrogramas con eventos (T0, T1, T2)



*Figura 23. Espectrograma*

#### 4.2.6 PREPROCESAMIENTO EN EL DOMINIO DE LA FRECUENCIA

Para el dominio de la frecuencia se ha mantenido la selección de canales más relevantes: C3, C4 y Cz. Estos electrodos están situados en la corteza central y son clave para detectar patrones de movimiento real.

Para el dominio de la frecuencia se aplica un filtro paso banda entre 2 y 60 Hz para preservar las bandas de interés (delta, mu, alpha, beta y gamma), que se han identificado como relevantes en las tareas de movimientos reales e imaginados [28]. Este filtro tiene como objetivo eliminar componentes de baja frecuencia (como artefactos de movimiento ocular) o muy alta frecuencia (como ruido muscular o eléctrico).

#### 4.2.7 EXTRACCIÓN DE CARACTERÍSTICAS EN EL DOMINIO DE LA FRECUENCIA

La señal se segmenta en ventanas deslizantes de 1 segundo con un 50% de solapamiento, como se recomienda en estudios como Nguyen et al. [32]. Siguiendo el estudio de Tobing et al. [21], se han seleccionado como características las potencias relativas en las bandas mu (8-13Hz) y beta (13-30Hz), ya que son las que experimentan una disminución significativa durante la ejecución de movimiento. Este fenómeno, que se denomina desincronización relacionada con eventos (ERD)[53], se localiza especialmente en la zona motora (canales C3, C4 y Cz). Además, se incluyen como características la frecuencia de pico en ambas bandas para capturar la concentración de frecuencia en cada ventana temporal.

*Tabla 8. Características extraídas en el dominio de la frecuencia*

Característica	Descripción técnica
MMR (Mu-band Ratio)	Potencia relativa de la banda mu respecto al total
MBR (Beta-band Ratio)	Potencia relativa en la banda beta respecto al total

---

Pico mu	Frecuencia dentro de la banda mu con mayor potencia
Pico beta	Frecuencia dentro de la banda beta con mayor potencia

---

Al tener 3 canales, se generan en total 12 características por ventana (3 canales x 4 características).

#### **4.2.8 MODELO DE CLASIFICACIÓN**

En el dominio de la frecuencia se van a llevar a cabo de nuevo las dos estrategias de modelo individual y modelo generalizado.

##### 1. Modelo individual por sujeto

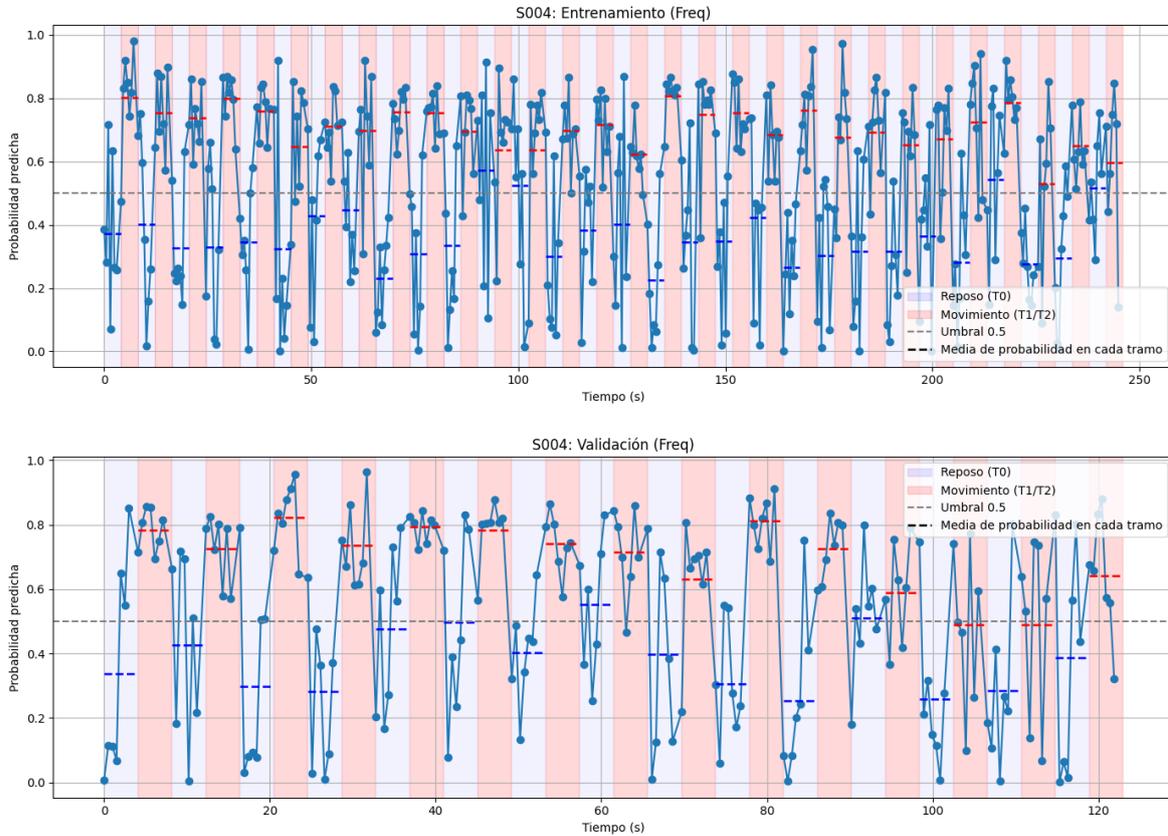
Para esta primera estrategia, al igual que en el dominio del tiempo, se cogen los registros R03 y R07 para entrenar y R011 para validar de los 5 primeros sujetos. Para este modelo se prueba LDA y Random Forest. El modelo se entrena con las características: MMR, MBR, frecuencia de pico en banda mu y frecuencia de pico en banda beta, calculadas sobre 3 canales motores.

Se dividen los datos en entrenamiento (R03 + R07) y validación (R011), y a continuación se muestra la tabla con la precisión en entrenamiento y validación para cada sujeto. Se observa que la precisión media en entrenamiento es de 66.4% y en validación de 63%. El mejor modelo es el del sujeto 4, que tiene una precisión en entrenamiento de 78% y una precisión en validación de 76%.

Tabla 9. Precisión del modelo LDA en el dominio de la frecuencia

<b>Sujeto</b>	<b>Precisión Entrenamiento (R03+R07)</b>	<b>Precisión Validación (R011)</b>
S001	64%	57%
S002	58%	54%
S003	62%	59%
S004	78%	76%
S005	70%	69%
<b>Media</b>	<b>66.4%</b>	<b>63%</b>

A continuación se puede observar la evolución de la probabilidad predicha por el modelo LDA para la clase “movimiento” (T1/T2) a lo largo del tiempo. Esta representación gráfica permite visualizar cómo responde el clasificador en cada momento del experimento. en la figura se muestra la probabilidad de movimiento estimada por el modelo para cada ventana (línea azul con marcadores), las zonas de reposo (T0) y movimiento (T1/T2) según las anotaciones del archivo edf, representada con franjas azules y rojas respectivamente, y una línea discontinua que marca el umbral de decisión en 0.5. En concreto se muestra la del Sujeto 4.



*Figura 24. Evolución de la probabilidad de estar en movimiento del sujeto 4*

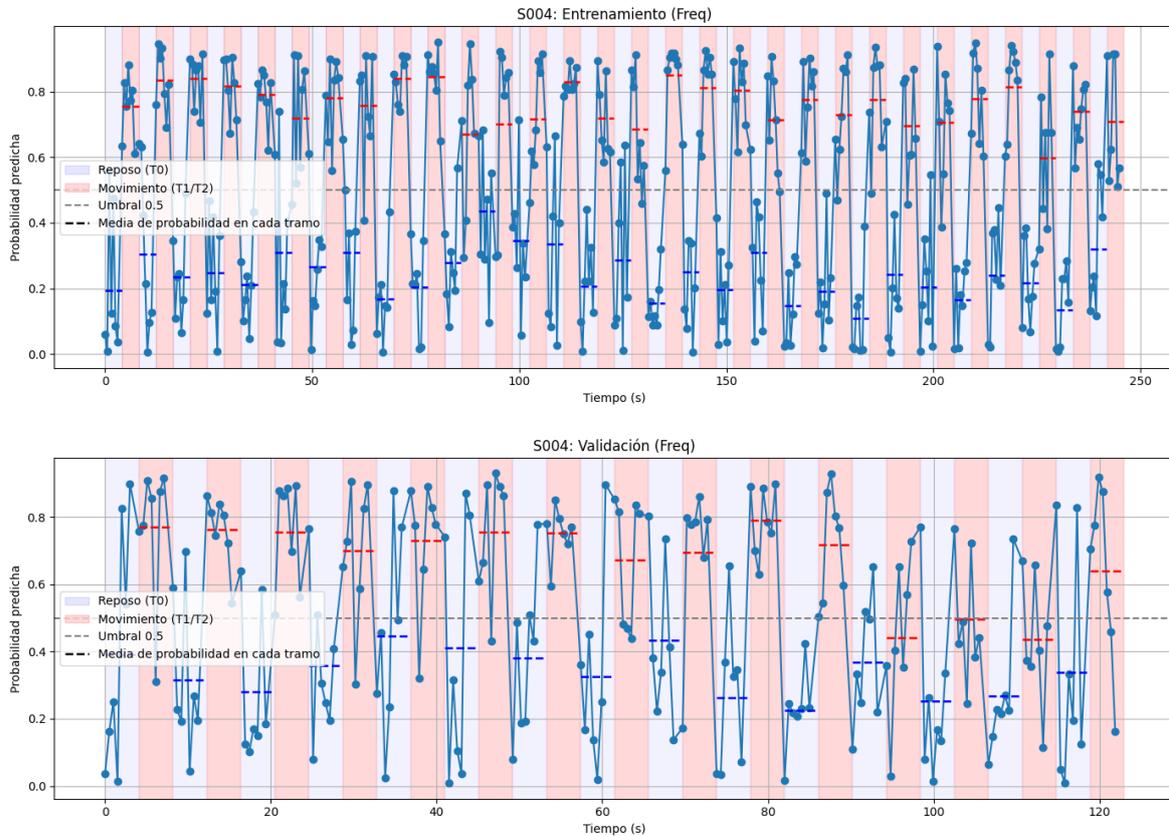
Se entrena un clasificador Random Forest (RF) utilizando las mismas características y particiones de entrenamiento y validación. La siguiente tabla presenta las precisiones obtenidas por RF en cada sujeto. Se aprecia una media en la precisión de entrenamiento de 93% y una media de precisión en validación de 60%. En este caso, el mejor sujeto en media vuelve a ser el sujeto 4, con una precisión en entrenamiento de 91% y en validación de 76%.

*Tabla 10. Precisión del modelo Random Forest en el dominio de la frecuencia*

Sujeto	Precisión Entrenamiento	Precisión Validación
S001	95%	50%

S002	94%	60%
S003	94%	50%
S004	91%	76%
S005	91%	64%
<b>Media</b>	<b>93%</b>	<b>60%</b>

A continuación se muestra la evolución de la probabilidad de este modelo para el sujeto 4 como se ha hecho anteriormente.



*Figura 25. Evolución de la probabilidad de estar en movimiento del sujeto 4*

Al analizar los resultados obtenidos en el dominio de la frecuencia, se observa un comportamiento similar al descrito en el dominio del tiempo. El modelo LDA alcanza una precisión media de 66.4% en entrenamiento y 63% en validación, lo que indica un rendimiento moderadamente estable, con una pérdida aceptable en la validación. Por otro lado, Random Forest vuelve a mostrar una precisión muy elevada en entrenamiento (93%), pero una caída más pronunciada en validación (60%). Esta diferencia entre fases refuerza que RF podría estar sobre ajustando los datos de entrenamiento. En conclusión, LDA ofrece mayor estabilidad y generalización media, mientras que RF destaca por su capacidad de aprendizaje profundo, con mayor riesgo de pérdida de generalización.

## 2. Modelo general

En este apartado se entrena un modelo único general utilizando LDA con las características extraídas del dominio de la frecuencia (MMR, MBR, mu-pico, beta-pico). El conjunto de

entrenamiento se compone de los registros R03 y R07 de los 109 sujetos, y la validación con el registro R011 de los sujetos. El preprocesamiento es el mismo que en el modelo individualizado.

El objetivo es evaluar si un modelo general, entrenado con sujetos diversos, es capaz de generalizar a nuevas grabaciones de esos mismos sujetos. El modelo alcanza una precisión media del 54.2%, ligeramente superior a la obtenida en el dominio del tiempo.

Además, se aplicó validación cruzada ( $k=10$ ) sobre todo el conjunto de entrenamiento. Esta técnica evalúa la robustez del modelo al dividir los datos en 10 particiones. Se obtiene una precisión 53.9% ( $\pm 1.7\%$ ).

## Capítulo 5. ANÁLISIS DE RESULTADOS

Este capítulo recopila los resultados obtenidos tras aplicar distintos modelos de clasificación a las señales EEG, tanto del experimento propio realizado con la diadema Emotiv EPOC X como del análisis sobre la base de datos pública EEG Motor Movement/Imagery de PhysioNet. Los resultados se han analizado en dos dominios: dominio del tiempo y dominio de la frecuencia, utilizando diferentes estrategias de modelos de clasificación (modelo individualizado y modelo general), con el fin de evaluar la capacidad del sistema para detectar la intención de movimiento.

### 5.1 RESULTADOS DEL EXPERIMENTO CON EMOTIV EPOC X

En el experimento realizado con la diadema Emotiv, se diseñó una aplicación para registrar la actividad cerebral de un sujeto mientras realizaba movimientos manuales (pulsaciones con la mano derecha y la mano izquierda) en respuesta a estímulos visuales. El diseño permitió una sincronización entre los eventos del estímulo y la señal EEG recogida de la diadema, se extrajeron características del dominio temporal y se entrenó un modelo de LDA para evaluar la posibilidad de distinguir entre estímulos derechos e izquierdos. El modelo alcanzó una precisión del 66% pero al observar la evolución de la probabilidad, el modelo no detectaba los movimientos izquierdos de manera confiable.

Debido a la limitación del tamaño muestral, que no pudo ser ampliado por un fallo técnico en el sensor F3, que dejó de registrar señal de forma permanente, se propuso complementar con el dataset público de PhysioNet.

### 5.2 RESULTADOS CON LA BASE DE DATOS DE PHYSIONET

Para superar las limitaciones del experimento con Emotiv, se utilizó una base de datos de PhysioNet, que permite analizar múltiples sujetos y tareas motoras. Los resultados se estructuran según el dominio del análisis y la estrategia de aprendizaje:

### **5.2.1 DOMINIO DEL TIEMPO**

En el análisis temporal se aplicó una segmentación de la señal EEG en ventanas de 1 segundo con solapamiento del 50%, y se extrajeron 7 características por canal. Las estrategias de aprendizaje fueron dos:

- 1- Modelo individualizado por sujeto: se toman 5 sujetos y se hace un modelo LDA y RF individualizado para cada uno de ellos con registros de entrenamiento (R03 y R07) y registros de validación (R011). Se obtiene una precisión para LDA de 66.6% en entrenamiento y 59.8% en validación, y para Random Forest un 95.6% en entrenamiento, pero mayor caída en la fase de validación (60.2%), lo que sugiere sobreajuste en el entrenamiento.
- 2- Modelo general entrenado con 109 sujetos, donde el rendimiento fue más bajo (51% de precisión media) validando con nuevos registros (R011) y 52% de precisión mediante validación cruzada. Esta pérdida de precisión puede deberse a la alta variabilidad intersujeto presente en señales EEG

### **5.2.2 DOMINIO DE LA FRECUENCIA**

En el dominio de la frecuencia, se extrajeron 4 características para cada una de las ventanas de 1 segundo solapadas 50%. De nuevo, se siguieron las mismas estrategias de aprendizaje:

- 1- Modelo individualizado por sujeto: en LDA se alcanzó una precisión media del 66.4% y en Random Forest 93%, con caída en validación (60%).
- 2- Modelo general: se logra una precisión del 54.2%, algo superior a la obtenida en el dominio del tiempo pero muy cerca del umbral del 50%. Este incremento puede deberse a que las características espectrales tienen mayor capacidad para capturar diferencias entre reposo y movimiento.

### **5.2.3 COMPARACIÓN ENTRE DOMINIOS Y MODELOS**

A continuación se muestra una tabla comparativa de lo que se ha mencionado en este capítulo.

Tabla 11. Análisis de resultados

<b>Dominio</b>	<b>Modelo</b>	<b>Precisión Entrenamiento</b>	<b>Precisión Validación</b>
<b>Tiempo (Modelo individualizado)</b>	LDA	66.6%	59.8%
<b>Tiempo (Modelo individualizado)</b>	Random Forest	95.6%	60.2%
<b>Frecuencia (Modelo individualizado)</b>	LDA	66.4%	63%
<b>Frecuencia (Modelo individualizado)</b>	Random Forest	93%	60%
<b>Tiempo (Modelo general)</b>	LDA + CV	51%	52%
<b>Frecuencia (Modelo general)</b>	LDA + CV	54.2%	53.9%

Los resultados obtenidos en este trabajo se alinean parcialmente con lo reportado en la matriz de la literatura revisada de la Tabla 3. Estudios como Kamavuako et al. [54] o Bai et al. [19] muestran altas precisiones (84% y 90%, respectivamente) en tareas de predicción de movimiento pero lo hacen bajo condiciones experimentales muy controladas, con múltiples electrodos y sujetos sanos. En cambio, estudios más cercanos a nuestro enfoque, como el de Benítez et al. [7], que utilizan el dispositivo Emotiv EPOC y un número reducido de canales, logran precisiones alrededor del 87% en tareas como la detección del parpadeo. El modelo general generado presenta dificultades para generalizar entre sujetos, lo que también ha sido observado por otros autores, mientras que los modelos entrenados de forma personalizada ofrecen mejores resultados, como es coherente con la literatura. Además, al comparar

clasificadores, se confirma que LDA tiende a ofrecer un rendimiento más robusto que otros modelos como Random Forest, probablemente debido a su simplicidad y eficacia con señales EEG procesadas, como también se evidencia en trabajos como el de Blankertz et al.[39] y Lew et al. [37].

Los resultados obtenidos indican que para la tarea de detección de movimiento a partir de EEG, los modelos personalizados son claramente superiores. Los modelos generales muestran limitaciones importantes en su capacidad de generalización. Además, el uso de LDA parece preferible frente a Random Forest en este contexto, ya que ofrece un mejor equilibrio entre aprendizaje y generalización.

## Capítulo 6. CONCLUSIONES Y TRABAJOS FUTUROS

### 6.1 CONCLUSIONES

Este trabajo ha tenido como objetivo principal el diseño, implementación y evaluación de un sistema BCI basado en señales EEG capaz de detectar la intención de movimiento. A través de un enfoque metodológico se cumplen todos los objetivos planteados en el Capítulo 1.

En primer lugar, la revisión de la literatura permitió identificar las técnicas más relevantes para cada una de las fases de un sistema BCI desde el preprocesamiento de la señal hasta la extracción de características y modelos de clasificación. Esta revisión sirvió como base para el diseño experimental posterior.

Se desarrolló un experimento propio utilizando la diadema Emotiv Epoc X con estimulación visual. Este experimento se vio limitado por un fallo técnico en el sensor F3, pero aun así, se realizó un análisis exploratorio de la señal y se sincronizaron los eventos de pulsación con la señal EEG.

Dado ese contratiempo, el análisis principal se realizó utilizando la base de datos publica EEG Motor Movement/Imagery de PhysioNet, que permitió trabajar con múltiples sujetos y condiciones motoras. se llevaron a cabo dos análisis:

- En el dominio del tiempo, se entrenaron los modelos LDA y Random Forest. Los modelos individualizados por sujeto ofrecieron mejores resultados(hasta 66% con LDA), mientras que los modelos generales presentaron un rendimiento cercano al azar (51%), evidenciando la dificultad de controlar la variabilidad entre sujetos.
- En el dominio del a frecuencia, utilizando características espectrales extraídas por bandas, se observaron precisiones ligeramente superiores. Este dominio mostró más capacidad de discriminación.

En general, se puede concluir que:

- La personalización del modelo por sujeto es clave en sistemas BCI basados en EEG
- Los modelos simples como LDA ofrecen un buen compromiso entre precisión y capacidad de generalizar frente a modelos no lineales como Random Forest.
- Las características espectrales extraídas en el dominio de la frecuencia resultan más efectivas que las temporales para esta tarea.
- Estos hallazgos están en línea con la literatura revisada, donde se ha observado que los modelos personalizados tienden a superar en rendimiento a los modelos generales, y que algoritmos lineales como LDA son fuertemente utilizados por su robustez en contextos con señales EEG y número de muestras limitado.

## **6.2 TRABAJOS FUTUROS**

A partir de las limitaciones detectadas y las oportunidades, se proponen varias líneas para continuar y mejorar este sistema:

### 1- Ampliación experimental y validación:

Se plantea repetir y ampliar el experimento una vez solucionado el problema técnico con la diadema Emotiv EPOC X. Esto incluiría la recopilación de señales EEG en una muestra más amplia de sujetos y de estímulos para evaluar la validez del sistema en un entorno realista, lo cual permite mejorar la robustez del modelo.

### 2- Avances en el procesamiento y modelado de señales EEG:

Se propone incorporar nuevas características relevantes como cocientes entre bandas (por ejemplo, beta/Alpha, beta/mu), entropía espectral o parámetros de Hjorth [55], así como explorar el uso de modelos de Deep Learning. Estos modelos, como se ha visto en la

literatura revisada, podrían mejorar la detección automática de patrones temporales sin necesidad de extraer las características manualmente, siempre y cuando se trate de una muestra amplia de datos.

### 3- Aplicación a BCI y sistemas en tiempo real:

Finalmente, se pretende extender el sistema a tareas de imaginación motora, especialmente relevantes en contextos de BCI para personas con movilidad reducida, y desarrollar una implementación en tiempo real que permita la integración con dispositivos de asistencia como prótesis o sillas de ruedas, validando así su utilidad en entornos aplicados.

Este trabajo supone un primer paso sólido hacia la detección de intención motora a partir de EEG, y sienta las bases para futuras aplicaciones y tecnologías en el campo de las interfaces cerebro-computadora.

## Capítulo 7. BIBLIOGRAFÍA

- [1] «Interfaces Cerebro-Computador | Bitbrain». [En línea]. Disponible en: <https://www.bitbrain.com/es/aplicaciones/interfaces-cerebro-computador>
- [2] R. Ramele, A. J. Villar, y J. M. Santos, «EPOC Emotiv EEG Basics», 12 de octubre de 2022, *arXiv*: arXiv:2206.09051. [En línea]. Disponible en: <http://arxiv.org/abs/2206.09051>
- [3] «EEG Motor Movement/Imagery Dataset v1.0.0». Accedido: 20 de mayo de 2025. [En línea]. Disponible en: <https://physionet.org/content/eegmmidb/1.0.0/>
- [4] «Linear Discriminant Analysis». [En línea]. Disponible en: <https://www.ibm.com/think/topics/linear-discriminant-analysis>
- [5] «Random Forest: Bosque aleatorio. Definición y funcionamiento». A [En línea]. Disponible en: <https://datascientest.com/es/random-forest-bosque-aleatorio-definicion-y-funcionamiento>
- [6] A. Chaddad, Y. Wu, R. Kateb, y A. Bouridane, «Electroencephalography Signal Processing: A Comprehensive Review and Analysis of Methods and Techniques», *Sensors*, vol. 23, n.º 14, p. 6434, jul. 2023, doi: 10.3390/s23146434.
- [7] D. S. Benitez, S. Toscano, y A. Silva, «On the use of the Emotiv EPOC neuroheadset as a low cost alternative for EEG signal acquisition», en *2016 IEEE Colombian Conference on Communications and Computing (COLCOM)*, Cartagena, Colombia: IEEE, abr. 2016, pp. 1-6. doi: 10.1109/ColComCon.2016.7516380.
- [8] J.-H. Jeong, K.-H. Shim, D.-J. Kim, y S.-W. Lee, «Brain-Controlled Robotic Arm System Based on Multi-Directional CNN-BiLSTM Network Using EEG Signals», *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 28, n.º 5, pp. 1226-1238, may 2020, doi: 10.1109/TNSRE.2020.2981659.

- [9] «Fisiología de la actividad eléctrica del cerebro: electroencefalografía | FISIOLÓGÍA». [En línea]. Disponible en: <https://fisiologia.facmed.unam.mx/index.php/fisiologia-de-la-actividad-electrica-del-cerebro-electroencefalografia/>
- [10] C. Sun y C. Mou, «Survey on the research direction of EEG-based signal processing», *Front. Neurosci.*, vol. 17, p. 1203059, jul. 2023, doi: 10.3389/fnins.2023.1203059.
- [11] «Home: g.tec Medical Engineering – Innovative Neurotechnology Solutions». [En línea]. Disponible en: [https://www.gtec.at/?srsltid=AfmBOopG9o7gf9a-91FFZw7j3MfgMugrMVe07gC1HRn15J6\\_XsdmADSe](https://www.gtec.at/?srsltid=AfmBOopG9o7gf9a-91FFZw7j3MfgMugrMVe07gC1HRn15J6_XsdmADSe)
- [12] «Biosemi EEG ECG EMG BSPM NEURO amplifier electrodes». Accedido: 9 de mayo de 2025. [En línea]. Disponible en: <https://www.biosemi.com/products.htm>
- [13] «EEGLAB». [En línea]. Disponible en: <https://sccn.ucsd.edu/eeglab/>
- [14] «EPOC X - 14 Channel Wireless EEG Headset – EMOTIV». A [En línea]. Disponible en: <https://www.emotiv.com/products/epoc-x>
- [15] «EEG Headsets | NeuroSky Store». [En línea]. Disponible en: <https://store.neurosky.com/>
- [16] «OpenBCI». [En línea]. Disponible en: <https://openbci.com/>
- [17] «10-20 Sistema de electrodos en electroencefalografía (EEG) - GVB geliMED GmbH». [En línea]. Disponible en: <https://gvb-gelimed.com/es/10-20-elektrodensystem-in-der-elektroenzephalografie-eeg/>
- [18] M. Saeidi *et al.*, «Neural Decoding of EEG Signals with Machine Learning: A Systematic Review», *Brain Sci.*, vol. 11, n.º 11, p. 1525, nov. 2021, doi: 10.3390/brainsci1111525.

- [19] O. Bai *et al.*, «Prediction of human voluntary movement before it occurs», *Clin. Neurophysiol.*, vol. 122, n.º 2, pp. 364-372, feb. 2011, doi: 10.1016/j.clinph.2010.07.010.
- [20] «Filtros Butterworth vs Chebyshev: una guía comparativa». [En línea]. Disponible en: <https://www.linkedin.com/advice/3/what-distinguishes-butterworth-filter-from-chebyshev-yczlc?lang=es&lang=es&originalSubdomain=es>
- [21] T. A. M. L. Tobing, Prawito, y S. K. Wijaya, «Classification of right-hand grasp movement based on EMOTIV Eporc+», presentado en INTERNATIONAL SYMPOSIUM ON CURRENT PROGRESS IN MATHEMATICS AND SCIENCES 2016 (ISCPMS 2016): Proceedings of the 2nd International Symposium on Current Progress in Mathematics and Sciences 2016, Depok, Jawa Barat, Indonesia, 2017, p. 030069. doi: 10.1063/1.4991173.
- [22] «Filtros FIR - Elipsis». [En línea]. Disponible en: <https://www.elipsisaudio.com.mx/filtros-fir.html>
- [23] A. Sinha, D. Chatterjee, R. Das, S. Datta, R. Gavas, y S. K. Saha, «Artifact Removal from EEG Signals Recorded Using Low Resolution Emotiv Device», en *2015 IEEE International Conference on Systems, Man, and Cybernetics*, Kowloon: IEEE, oct. 2015, pp. 1445-1451. doi: 10.1109/SMC.2015.256.
- [24] B. Blankertz *et al.*, «The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials», *IEEE Trans. Biomed. Eng.*, vol. 51, n.º 6, pp. 1044-1051, jun. 2004, doi: 10.1109/TBME.2004.826692.
- [25] M. Mahmoodi, B. Makkiabadi, M. Mahmoudi, y S. Sanei, «A new method for accurate detection of movement intention from single channel EEG for online BCI», *Comput. Methods Programs Biomed. Update*, vol. 1, p. 100027, 2021, doi: 10.1016/j.cmpbup.2021.100027.
- [26] B. Blankertz *et al.*, «The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials», *IEEE Trans. Biomed. Eng.*, vol. 51, n.º 6, Art. n.º 6, jun. 2004, doi: 10.1109/TBME.2004.826692.

- [27] «Apply Laplacian Filters». [En línea]. Disponible en: <https://www.nv5geospatialsoftware.com/docs/LaplacianFilters.html>
- [28] E. N. Kamavuako, M. Jochumsen, I. K. Niazi, y K. Dremstrup, «Comparison of Features for Movement Prediction from Single-Trial Movement-Related Cortical Potentials in Healthy Subjects and Stroke Patients», *Comput. Intell. Neurosci.*, vol. 2015, pp. 1-8, 2015, doi: 10.1155/2015/858015.
- [29] T.-H. Nguyen y W.-Y. Chung, «Detection of Driver Braking Intention Using EEG Signals During Simulated Driving», *Sensors*, vol. 19, n.º 13, Art. n.º 13, jun. 2019, doi: 10.3390/s19132863.
- [30] «FFT». Disponible en: <https://www.nti-audio.com/es/servicio/conocimientos/transformacion-rapida-de-fourier-fft>
- [31] «What Is the Readiness Potential? - ScienceDirect». [En línea]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1364661321000930>
- [32] T.-H. Nguyen y W.-Y. Chung, «Detection of Driver Braking Intention Using EEG Signals During Simulated Driving», *Sensors*, vol. 19, n.º 13, p. 2863, jun. 2019, doi: 10.3390/s19132863.
- [33] «Common Spatial Pattern - an overview | ScienceDirect Topics». [En línea]. Disponible en: <https://www.sciencedirect.com/topics/engineering/common-spatial-pattern>
- [34] M. N. Fakhruzzaman, E. Riksakomara, y H. Suryotrisongko, «EEG Wave Identification in Human Brain with Emotiv EPOC for Motor Imagery», *Procedia Comput. Sci.*, vol. 72, pp. 269-276, 2015, doi: 10.1016/j.procs.2015.12.140.
- [35] «OpenViBE | Software for Brain Computer Interfaces and Real Time Neurosciences». [En línea]. Disponible en: <https://openvibe.inria.fr/>
- [36] «An-illustrative-sample-of-MRCP-contains-two-components-bereishafths-potential-BP-which.jpg».

- [37] E. Lew, «Detection of self-paced reaching movement intention from EEG signals», *Front. Neuroengineering*, vol. 5, 2012, doi: 10.3389/fneng.2012.00013.
- [38] «SVM, RBF», [En línea]. Disponible en: <https://www.pycodemates.com/2022/10/the-rbf-kernel-in-svm-complete-guide.html>
- [39] B. Blankertz *et al.*, «The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials», *IEEE Trans. Biomed. Eng.*, vol. 51, n.º 6, pp. 1044-1051, jun. 2004, doi: 10.1109/TBME.2004.826692.
- [40] T.-H. Nguyen y W.-Y. Chung, «Detection of Driver Braking Intention Using EEG Signals During Simulated Driving», *Sensors*, vol. 19, n.º 13, p. 2863, jun. 2019, doi: 10.3390/s19132863.
- [41] «Comprender las FFT y las ventanas - NI». [En línea]. Disponible en: [https://www.ni.com/es/shop/data-acquisition/measurement-fundamentals/analog-fundamentals/understanding-ffts-and-windowing.html?srsId=AfmBOookmymSydOcBzqu3XaDvp7cGIUqGFuLBXF-omczSOM239BOS\\_ZX](https://www.ni.com/es/shop/data-acquisition/measurement-fundamentals/analog-fundamentals/understanding-ffts-and-windowing.html?srsId=AfmBOookmymSydOcBzqu3XaDvp7cGIUqGFuLBXF-omczSOM239BOS_ZX)
- [42] «FFT Zero Padding - BitWeenie | BitWeenie». [En línea]. Disponible en: <https://www.bitweenie.com/listings/fft-zero-padding/>
- [43] «Convolutional Neural Network: definición y funcionamiento». Disponible en: <https://datascientest.com/es/convolutional-neural-network-es>
- [44] «Bidirectional LSTM in NLP | GeeksforGeeks». [En línea]. Disponible en: <https://www.geeksforgeeks.org/bidirectional-lstm-in-nlp/>
- [45] R. Ramele, A. J. Villar, y J. M. Santos, «EPOC Emotiv EEG Basics», 12 de octubre de 2022, *arXiv*: arXiv:2206.09051. [En línea]. Disponible en: <http://arxiv.org/abs/2206.09051>
- [46] «PhysioNet». Disponible en: <https://physionet.org/>

- [47] «Client Challenge». [En línea]. Disponible en: <https://pypi.org/project/pygame/>
- [48] «MNE — MNE 1.9.0 documentation». [En línea]. Disponible en: <https://mne.tools/stable/index.html>
- [49] «BCI2000 Wiki». [En línea]. Disponible en: [https://www.bci2000.org/mediawiki/index.php/Main\\_Page](https://www.bci2000.org/mediawiki/index.php/Main_Page)
- [50] «MazeSuite BCI2000 Interfacing - MazeSuite». [En línea]. Disponible en: <https://mazesuite.com/gallery/app/mazesuite-bci2000-interfacing/>
- [51] A. Singh, A. A. Hussain, S. Lal, y H. W. Guesgen, «A Comprehensive Review on Critical Issues and Possible Solutions of Motor Imagery Based Electroencephalography Brain-Computer Interface», *Sensors*, vol. 21, n.º 6, p. 2173, mar. 2021, doi: 10.3390/s21062173.
- [52] «Bosque aleatorio: Una guía de aprendizaje automático | Ultralytics». [En línea]. Disponible en: <https://www.ultralytics.com/es/glossary/random-forest>
- [53] «Event-related desynchronization, ERD-mapping and hemispheric differences for words and numbers - PubMed». [En línea]. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/2338409/>
- [54] E. N. Kamavuako, M. Jochumsen, I. K. Niazi, y K. Dremstrup, «Comparison of Features for Movement Prediction from Single-Trial Movement-Related Cortical Potentials in Healthy Subjects and Stroke Patients», *Comput. Intell. Neurosci.*, vol. 2015, pp. 1-8, 2015, doi: 10.1155/2015/858015.
- [55] «Repositorio Institucional: Metodología basada en la transformada wavelet y los parámetros de Hjorth para la clasificación de Imaginación motora usando señales electroencefalográficas». En línea]. Disponible en: <https://ri-ng.uaq.mx/handle/123456789/9256>

## ANEXO A. ALINEACIÓN CON LOS OBJETIVOS DE DESARROLLO SOSTENIBLE (ODS)

Este trabajo contribuye de forma directa a los principios de sostenibilidad e inclusión definidos en la Agenda 2030, en concreto en los siguientes Objetivos de Desarrollo Sostenible:

### ***ODS 3: SALUD Y BIENESTAR***

Este proyecto promueve el desarrollo de tecnologías que pueden aplicarse en el ámbito de la rehabilitación neurológica y el apoyo a personas con movilidad reducida, facilitando el control de dispositivos mediante interfaces cerebro-computadora (BCI). La detección de la intención de movimiento a partir de EEG puede ser clave para mejorar la calidad de vida de personas afectadas por ictus, lesiones medulares o enfermedades neurodegenerativas.

### ***ODS 9: INDUSTRIA, INNOVACIÓN E INFRAESTRUCTURA***

El sistema desarrollado representa una solución tecnológica innovadora en el campo de las neurociencias aplicadas, combinando adquisición de datos EEG, preprocesamiento avanzado de señales y modelos de aprendizaje automático. Se fomenta la investigación aplicada y el diseño de prototipos funcionales con potencial tecnológico y futura escalabilidad.

## **ANEXO A.2: GUÍA DE USO DE EMOTIV EPOC X**

### ***CONTENIDO DEL DISPOSITIVO***

El paquete de la diadema Emotiv EPOC X incluye:

- Diadema EEG con 14 electrodos
- Solución salina para hidratar los sensores
- Cable USB-C de carga
- Cable de conexión Bluetooth
- Manual de usuario
- Código QR de acceso al software EmotivPRO (vía suscripción)

### ***CARACTERÍSTICAS TÉCNICAS***

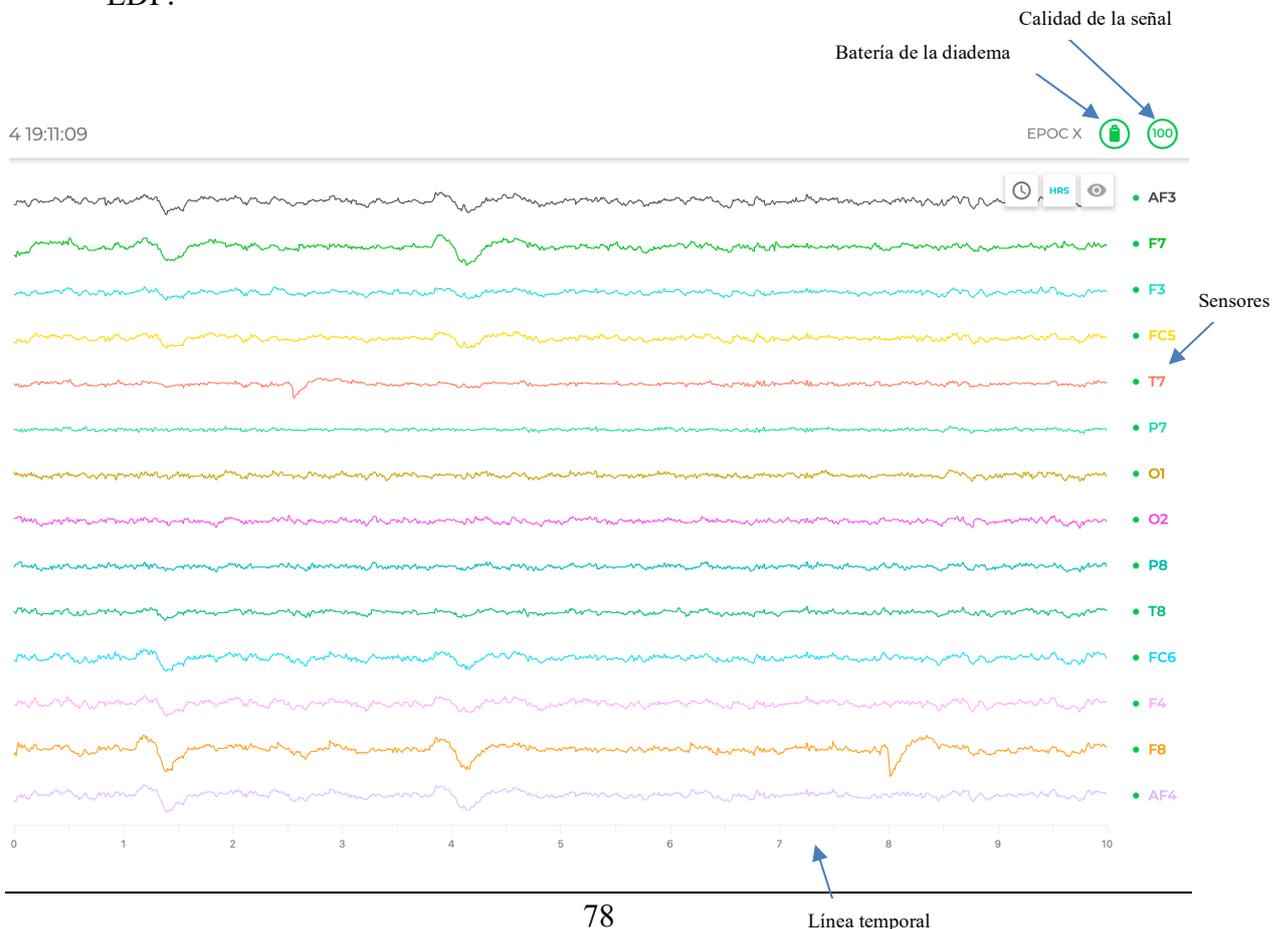
- Canales EEG 14 sensores (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) + 2 referencias (CMS/DRL).
- Frecuencia de muestreo: 128 Hz.
- Resolución: 14 bits.
- Comunicación: Bluetooth LE o receptor USB.
- Batería: Recargable, autonomía de ~6 horas.

### ***REQUISITOS PREVIOS ANTES DE REALIZAR EXPERIMENTO***

- Ordenador Windows o macOS
- Cuenta en Emotiv (Emotiv ID) y software instalado de EmotivPRO
- Acceso a internet en el ordenador para conectarse al software
- Sensores hidratados con la solución salina

## COLOCACIÓN Y PREPARACIÓN

1. Hidratar los sensores con la solución salina (sin exceso de líquido)
2. Encender la diadema y conectar el cable de conexión bluetooth al ordenador.
3. Abrir el software de EmotivPRO, iniciar sesión con el EmotivID y comprobar que se detecta la diadema.
4. Colocar la diadema como se muestra en la pantalla del software, asegurando que los sensores referencia están bien apoyados detrás de las orejas y que los sensores están pegados al cuero cabelludo. Si algún sensor aparece en gris puede ser porque le falte hidratación o porque no esté haciendo buen contacto con el cuero cabelludo.
5. Comprobar en el software que todos los sensores están en verde. En caso de recolocarse la diadema, esperar unos segundos para estabilizar el contacto.
6. Una vez se alcanza un 100% en la precisión, se puede comenzar a grabar.
7. Los datos se almacenan en el software y pueden ser exportados en formato CSV o EDF.



## ***EXPORTACIÓN DE LOS DATOS***

Una vez finalizada la grabación en el software EmotivPRO, los datos EEG pueden ser exportados para su análisis posterior. EL software permite guardar los registros en dos formatos principales:

- Formato CSV (.csv): cada columna representa un canal (AF3, F7, etc.) y las filas corresponden a las muestras temporales registradas con una frecuencia de muestreo de 128Hz. Este formato es útil para análisis rápidos en herramientas como Excel o MATLAB. También puede incluir una columna adicional con marcas de eventos si se activan durante la grabación.
- Formato EDF (.edf): es un formato estándar en el ámbito clínico y de neurociencia, compatible con softwares especializados como EEGLAB o la librería MNE de Python. Este formato conserva la estructura temporal y la resolución de los datos, permitiendo un análisis más profundo, especialmente en contextos donde se requiere una sincronización precisa.

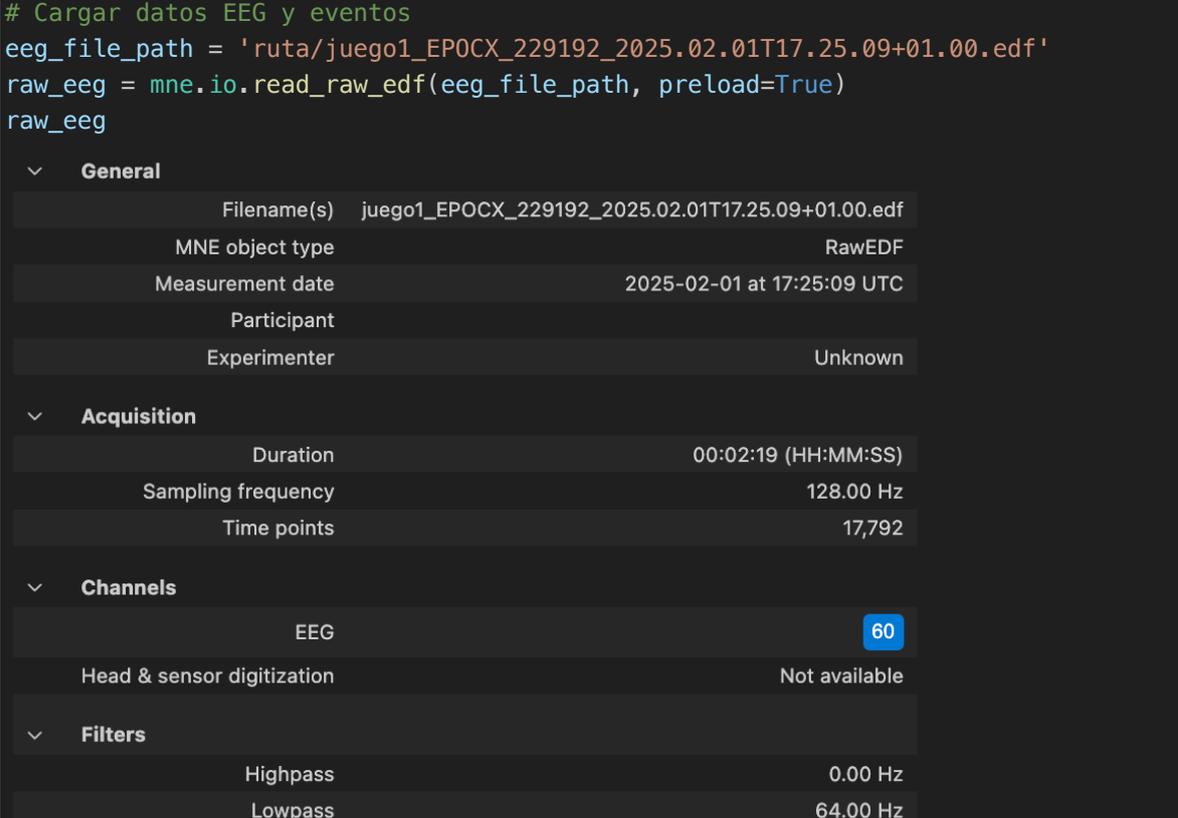
### **Procedimiento de exportación en EmotivPRO:**

1. Finalizar la sesión de grabación
2. Seleccionar el archivo desde la lista de sesiones guardadas
3. Hacer clic en “Exportar”
4. Elegir el formato deseado para exportar (.csv o .edf)
5. Seleccionar la ruta de guardado en el sistema local.

A continuación se muestra una descripción técnica de la estructura del archivo .edf exportado que es el que se ha utilizado para este trabajo junto con la librería MNE de Python.

Una vez exportado y guardado el archivo en la ruta deseada, se procede a leerlo utilizando la librería MNE de Python

```
# Cargar datos EEG y eventos
eeg_file_path = 'ruta/juego1_EPOCX_229192_2025.02.01T17.25.09+01.00.edf'
raw_eeg = mne.io.read_raw_edf(eeg_file_path, preload=True)
raw_eeg
```



The screenshot shows the metadata for an EDF file. It is organized into sections: General, Acquisition, Channels, and Filters. The General section includes filename, MNE object type (RawEDF), measurement date, participant, and experimenter. The Acquisition section includes duration, sampling frequency, and time points. The Channels section shows 60 EEG channels and that head & sensor digitization is not available. The Filters section shows highpass and lowpass filter settings.

Section	Property	Value
General	Filename(s)	juego1_EPOCX_229192_2025.02.01T17.25.09+01.00.edf
	MNE object type	RawEDF
	Measurement date	2025-02-01 at 17:25:09 UTC
	Participant	
	Experimenter	Unknown
Acquisition	Duration	00:02:19 (HH:MM:SS)
	Sampling frequency	128.00 Hz
	Time points	17,792
Channels	EEG	60
	Head & sensor digitization	Not available
Filters	Highpass	0.00 Hz
	Lowpass	64.00 Hz

Tabla 12. Descripción del fichero .edf de Emotiv EPOC

Columnas	Descripción
Filename	Nombre del archivo de grabación
MNE Object Type	Tipo de objeto reconocido por MNE, que indica cómo se representarán los datos
Measurement Date	Fecha y hora en la que se realizó la grabación
Duration	Duración total de la grabación en horas, minutos y segundos
Sampling frequency	Frecuencia de muestreo utilizada para los datos, medida en Hertz (HZ)

---

Time points	Número total de puntos de datos registrados en la grabación
Channels	Número total de canales EEG utilizados en la grabación
Filtros	Highpass: filtro paso-alto aplicado a los datos, elimina frecuencias por debajo del valor indicado  Lowpass: filtro paso-bajo aplicado a los datos, elimina frecuencias por encima del valor indicado

---

## ***RECOMENDACIONES DE USO***

- Evitar interferencias cercanas
- Usar en entornos con poco ruido
- Si algún canal falla:
  - Revisar que esté bien colocado
  - Rehidratar el sensor
  - Asegurarse de que hace buen contacto con la diadema
- Guía de uso del software: <https://www.emotiv.com/tools/knowledge-base/epoc-support/quick-start-guide-and-user-manual>