

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE GRADO

PROCESADO DE SEÑAL ENCEFALOGRÁFICA PARA EL PRONÓSTICO DE INTENCIÓNES MOTORAS

Titulación: Grado en Ingeniería en Tecnologías de la Telecomunicación

Mención: Sistemas de Telecomunicación

Autor: Antonio Samuel Díaz García

Tutores: Carlos Manuel Travieso González y Nabil Isaac Ajali Hernández

Fecha: Julio 2025

RESUMEN

El presente Trabajo de Fin de Grado se enmarca en el ámbito de la neuro ingeniería y la inteligencia artificial, abordando el procesado de señales encefalográficas (EEG) con el objetivo de predecir intenciones motoras humanas. La motivación de este estudio nace de una problemática real y creciente: el aumento significativo de amputaciones de extremidades en la población, tanto por causas médicas como la diabetes mellitus tipo 2, como por accidentes laborales o de tráfico. Esta situación plantea un desafío tanto médico como social que ha encontrado en las tecnologías de interfaz cerebro-ordenador (BCI, por sus siglas en inglés) una vía prometedora de solución. A través de estas interfaces, es posible traducir señales neuronales en comandos que permiten el control de dispositivos externos, como prótesis robóticas o sistemas de asistencia, restaurando parcialmente la funcionalidad motora de personas con discapacidad.

En este trabajo se emplea una base de datos pública de registros EEG obtenida a través de PhysioNet, en la que se recoge la actividad cerebral de más de un centenar de participantes durante la ejecución o imaginación de movimientos motores simples, como abrir y cerrar los puños o mover los pies. Esta base de datos, estructurada en formato EDF, contiene registros multicanal correspondientes a diferentes tareas clasificadas y etiquetadas en función de la acción ejecutada o imaginada (etiquetas T0, T1 y T2). Cada uno de estos registros ha sido analizado mediante técnicas de procesado digital de señales, con la finalidad de estructurar los datos en matrices tridimensionales organizadas espacialmente según la disposición anatómica de los electrodos (basada en el sistema 10-10 de colocación), y temporalmente en ventanas uniformes de 656 muestras.

La metodología aplicada contempla un conjunto de fases interdependientes que van desde la adquisición de los datos en crudo hasta su preparación para el entrenamiento de modelos de aprendizaje automático. En primer lugar, se ha llevado a cabo una limpieza de los nombres de canales, la identificación de anotaciones temporales relevantes y la segmentación precisa de los fragmentos de señal donde se produce la intención motora. Posteriormente, se ha diseñado un procedimiento automatizado para mapear cada uno de los 64 canales disponibles en la base de datos a una plantilla bidimensional de 10x11 posiciones, permitiendo así

preservar la información espacial de las señales y facilitar su tratamiento mediante arquitecturas de deep learning como redes convolucionales.

Uno de los principales retos técnicos ha sido el tratamiento eficiente de una gran cantidad de datos con alto contenido de ruido y una relación señal/ruido baja, característica inherente a los sistemas EEG no invasivos. Para mitigar este problema, se han implementado estrategias de filtrado paso banda (0.5–40 Hz), normalización por canal (z-score) y estructuración uniforme de las etiquetas temporales, asegurando la homogeneidad del conjunto de entrenamiento. El almacenamiento final de los datos se ha realizado en formato NumPy (.npy), compatible con bibliotecas de aprendizaje automático como Scikit-learn, TensorFlow o PyTorch, lo que permitirá en etapas posteriores el desarrollo de clasificadores entregables capaces de distinguir entre estados de reposo, intención de movimiento real e intención de movimiento imaginado.

Además del componente técnico, el trabajo incluye una reflexión crítica sobre las implicaciones legales y éticas del uso de tecnologías BCI, especialmente en lo relativo a la protección de los neuro datos personales. Se aborda la necesidad de aplicar la normativa europea vigente, particularmente el Reglamento General de Protección de Datos (RGPD), a contextos emergentes como el de la neuro tecnología, donde los datos recogidos no solo son altamente sensibles, sino que también pueden ser utilizados con fines de control, discriminación o manipulación. El concepto de “neuro privacidad” se presenta como una dimensión aún no completamente legislada, pero crucial para el desarrollo responsable de estas herramientas.

Entre los objetivos específicos del proyecto destacan: la comprensión del contexto médico y social de las amputaciones en España y Europa; la creación de una base de datos preprocesada y etiquetada para análisis computacional; la parametrización de la señal EEG para identificar variables relevantes; el estudio de la relación entre intención cognitiva y activación motora cortical; y la exploración del marco jurídico que regula el tratamiento de señales cerebrales con fines clínicos y tecnológicos.

Además, se desarrolla modelos de *Machine Learning* para la clasificación de intenciones motoras a partir de señales EEG, abordando desde el preprocesamiento y la extracción de características hasta la evaluación del rendimiento de los modelos y la detección de

transiciones temporales. Los resultados obtenidos confirman la viabilidad del enfoque planteado, consolidando su utilidad para aplicaciones en interfaces cerebro-computadora. A través de una combinación equilibrada entre ingeniería biomédica, computación aplicada y reflexión ética, se pretende avanzar en el diseño de soluciones que mejoren la calidad de vida de personas con discapacidad motora, integrando los valores de accesibilidad, autonomía y privacidad en el desarrollo de tecnologías emergentes.

ABSTRACT

This Bachelor's Thesis is framed within the fields of neuroengineering and artificial intelligence, focusing on the processing of electroencephalography (EEG) signals with the goal of predicting human motor intentions. The motivation for this study arises from a real and growing concern: the significant increase in limb amputations within the population, due to medical causes such as type 2 diabetes mellitus, as well as workplace or traffic accidents. This situation poses both a medical and social challenge that brain-computer interface (BCI) technologies have emerged as a promising solution to address. Through these interfaces, it is possible to translate neural signals into commands that control external devices, such as robotic prostheses or assistive systems, thereby partially restoring motor functionality for people with disabilities.

This work employs a public EEG dataset obtained from PhysioNet, which records the brain activity of over a hundred participants during the execution or imagination of simple motor tasks, such as opening and closing fists or moving the feet. The dataset, structured in EDF format, contains multichannel recordings classified and labeled according to the executed or imagined action (labels T0, T1, and T2). Each recording was analyzed using digital signal processing techniques to structure the data into three-dimensional matrices, spatially organized based on the anatomical layout of electrodes (according to the 10-10 placement system), and temporally segmented into uniform windows of 656 samples.

The applied methodology consists of a set of interdependent phases, ranging from raw data acquisition to its preparation for Machine Learning model training. First, channel names were cleaned, relevant temporal annotations identified, and signal segments corresponding to motor intention precisely segmented. Subsequently, an automated procedure was designed to map each of the 64 available channels onto a 10x11 two-dimensional template, preserving the spatial information of the signals and facilitating their processing through deep learning architectures such as convolutional neural networks.

One of the main technical challenges was the efficient handling of large amounts of data with high noise levels and low signal-to-noise ratio, an inherent characteristic of non-invasive EEG systems. To address this, band-pass filtering (0.5–40 Hz), per-channel normalization (z-score), and uniform structuring of temporal labels were implemented, ensuring homogeneity within the training dataset. The final data storage was performed in NumPy (.npy) format, compatible with Machine Learning libraries like Scikit-learn, TensorFlow, and PyTorch, enabling the future development of classifiers capable of distinguishing between resting state, real movement intention, and imagined movement intention.

Beyond the technical component, this work includes a critical reflection on the legal and ethical implications of BCI technologies, especially regarding the protection of personal neurodata. It highlights the need to apply current European regulations — particularly the General Data Protection Regulation (GDPR) — to emerging contexts like neurotechnology, where collected data are not only highly sensitive but could also be exploited for control, discrimination, or manipulation purposes. The concept of “neuroprivacy” is presented as a not yet fully legislated but crucial dimension for the responsible development of these tools.

The specific objectives of this project include understanding the medical and social context of amputations in Spain and Europe; creating a preprocessed and labeled database for computational analysis; parametrizing EEG signals to identify relevant variables; studying the relationship between cognitive intention and cortical motor activation; and exploring the legal framework governing the processing of brain signals for clinical and technological purposes.

Additionally, Machine Learning models were developed for the classification of motor intentions from EEG signals, addressing every step from Preprocessing and Feature Extraction to performance evaluation and detection of temporal transitions. The results confirm the feasibility of the proposed approach, reinforcing its potential for applications in brain-computer interfaces. Through a balanced combination of biomedical engineering, applied computing, and ethical reflection, this work aims to advance the design of solutions that improve the quality of life for people with motor disabilities, integrating values of accessibility, autonomy, and privacy into the development of emerging technologies.

ÍNDICE GENERAL

PARTE I - MEMORIA

Capítulo 1 – Introducción	20
1.1. Introducción	20
1.2. Motivación	21
1.3. Antecedentes	24
1.4. Objetivos	26
1.5. Objetivos Específicos	26
1.6. Estructura del documento.....	27
Capítulo 2 – La señal y los datos	29
2.1. Introducción	29
2.2. El Cerebro Humano y la Actividad Neuronal	29
2.2.1. Ondas Cerebrales y Ritmos Sensorimotores	33
2.3. Electroencefalografía (EEG)	36
2.3.1. Principios de Adquisición de Señales EEG.....	36
2.3.2. Configuración de Electrodos (Sistema 10-20 y 10-10).....	38
2.3.3. Ventajas y Desafíos de las Señales EEG.....	40
2.4. Interfaces Cerebro-Computadora (BCI).....	43
2.4.1. Tipos de BCI	45
2.4.1.1. BCI Invasivas	45
2.4.1.2. BCI No Invasivas	46
2.4.3. Paradigmas de BCI para el Control Motor.....	48
2.4.3.1. Ritmos Sensorimotores (SMR) y Movimiento Imaginado (Motor Imagery - MI).....	48
2.4.3.2. Potenciales Evocados Visuales en Estado Estacionario (SSVEP)	49
2.4.3.3. Potencial P300.....	50
2.4.4. Aplicaciones de las BCI	51

2.4.4.1. Asistencia a Personas con Discapacidades Motoras	51
2.4.4.2. Comunicación Aumentativa y Alternativa (CAA).....	53
2.4.4.3. Rehabilitación Neurocognitiva y Motora	53
2.4.4.4. Entretenimiento y Realidad Virtual.....	53
2.4.4.5. Investigación Científica y Medicina.....	54
2.4.4.6. BCI y Enfermedades Neurodegenerativas	54
2.4.5. Plataformas y Herramientas de BCI.....	56
Capítulo 3 – Procesado de la señal encefalográfica	59
3.1. Introducción	59
3.2. Adquisición de señales EEG	59
3.3. Preprocesamiento de señales EEG	60
3.4. Extracción de características	62
3.5. Reducción de la Dimensionalidad.....	64
3.6. Clasificación de señales EEG.....	65
3.7 Métricas de Evaluación del Rendimiento del Sistema	66
Capítulo 4 – Las BCI y la privacidad.....	69
4.1. Consideraciones Éticas, Legales y Sociales en BCI.....	69
4.2. Privacidad Mental y Neurodatos	69
4.3. Consentimiento Informado y Transparencia Algorítmica.....	71
4.4. Accesibilidad y Equidad en la Neurotecnología	72
4.5. Responsabilidad y Autonomía	73
Capítulo 5 – Procesado y análisis de la señal EEG	75
5.1. Base de datos.....	75
5.2. Resultados del procesado de la señal	78
5.3. Análisis de las Gráficas EEG	91
5.4. Análisis e Interpretación para el Trabajo	96

5.5. Desarrollo y Evaluación de Modelos de <i>Machine Learning</i> para la Clasificación de Intenciones Motoras	97
5.5.1 Resultados del Machine Learning	102
5.6 Discusión de resultados.....	104
5.6.1. Discusión de Resultado de acuerdo con los objetivos.....	106
5.6.2. Discusión y comparación con el estado del arte.....	111
Capítulo 6 – Conclusiones y Líneas Futuras	114
6.1. Conclusiones	114
6.2. Líneas Futuras	116
Referencias bibliográficas	117

PARTE II - PRESUPUESTO

Capítulo único – Presupuesto del Trabajo de Fin de Grado.....	121
1. Introducción	121
2. Recursos Materiales	122
3. Recursos Humanos.....	122
4. Licencias de Software	123
5. Costes de redacción.....	123
6. Derechos de visado del COITT	124
7. Coste de tramitación y envío	125
8. Impuesto General Indirecto Canario	125
9. Presupuesto final	125

PARTE III - ANEXOS

ANEXO I - Identificación y justificación del grado de relación del TFG con los Objetivos de Desarrollo Sostenible	129
ANEXO II – Uso de Inteligencia Artificial en el desarrollo del presente Trabajo de Fin de Grado.....	131

ÍNDICE DE FIGURAS Y TABLAS

Figuras	
2.1	Relación entre ERD y ERS
5.1	Señales registradas de electrodos
5.2	Serie Temporal del Canal Central
5.3	Serie Temporal Cruda
5.4	Distribución de eventos por etiqueta
5.5	Mapas EEG
5.6	Gráfica de línea multicanal
5.7	ERP comparativo en canales centrales
5.8	Comparativas de área bajo curva de canales adyacentes
5.9	Diferencia de ERP en todos los canales entre T1 y T2
5.10	Densidad de potencia por frecuencia
5.11	Correlación entre canales en T1
5.12	PCA reducida
5.13	Serie Temporal del Canal Cz
5.14	ERP Promedio para T1 (110 canales)
5.15	ERP Promedio para T1 (64 canales)
5.16	Matriz de Confusión – Random Forest
5.17	Matriz de Confusión – SVM
5.18	Comparativa temporal de Etiquetas Reales y Predicción (500s)
Tablas	
5.1	Resultados Comparativos de los Modelos
5.2	Resultados Random Forest
5.3	Resultados comparados con otros autores

LISTADO DE ACRÓNIMOS

EEG	Electroencefalografía
BCI	<i>Brain-Computer Interface</i> (Interfaz Cerebro-Ordenador)
EDF	<i>European Data Format</i> (Formato Europeo de Datos)
ADC	<i>Analog-to-Digital Converter</i> (Convertidor Analógico-Digital)
EOG	Electrooculograma
EMG	Electromiograma
ECG	Electrocardiograma
ICA	<i>Independent Component Analysis</i> (Análisis de Componentes Independientes)
SNR	<i>Signal-to-Noise Ratio</i> (Relación Señal/Ruido)
PCA	<i>Principal Component Analysis</i> (Análisis de Componentes Principales)
LDA	<i>Linear Discriminant Analysis</i> (Análisis Discriminante Lineal)
SVM	<i>Support Vector Machine</i> (Máquinas de Vectores de Soporte)
ANN	<i>Artificial Neural Network</i> (Red Neuronal Artificial)
DNN	<i>Deep Neural Network</i> (Red Neuronal Profunda)
CNN	<i>Convolutional Neural Network</i> (Red Neuronal Convolucional)
RNN	<i>Recurrent Neural Network</i> (Red Neuronal Recurrente)
GFP	<i>Global Field Power</i> (Potencia de Campo Global)
MI	<i>Motor Imagery</i> (Imaginación Motora)
SSVEP	<i>Steady-State Visual Evoked Potential</i> (Potencial Evocado Visual en Estado Estacionario)
RGPD	Reglamento General de Protección de Datos
ODS	Objetivos de Desarrollo Sostenible

PARTE I – MEMORIA

Capítulo 1 – Introducción

1.1. Introducción

En el vasto y complejo universo de la neurociencia, la comprensión de la actividad cerebral humana ha sido una de las mayores fronteras de la investigación científica. Particularmente, la capacidad de decodificar las intenciones motoras directamente desde la actividad encefálica no solo abre una ventana fascinante al funcionamiento interno del cerebro, sino que también promete revolucionar campos críticos como la rehabilitación y la interacción humano-máquina. La señal electroencefalográfica (EEG), por su naturaleza no invasiva, su relativa facilidad de adquisición y su excelente resolución temporal, emerge como una herramienta fundamental en este empeño. Permite registrar los patrones eléctricos generados por la actividad neuronal, ofreciendo una vía para inferir pensamientos y decisiones relacionadas con el movimiento, incluso antes de que este se manifieste físicamente.

La trascendencia de esta capacidad se hace evidente al considerar su impacto potencial en personas con discapacidades motoras severas, como aquellas que padecen lesiones medulares, esclerosis lateral amiotrófica (ELA) o que han sufrido accidentes cerebrovasculares. Para estos individuos, que a menudo se encuentran en un estado de

"enclaustramiento" o con una movilidad extremadamente limitada, el pronóstico de intenciones motoras a través de BCI podría restaurar no solo la comunicación, sino también la autonomía y la independencia. Imaginar la posibilidad de controlar una silla de ruedas, operar un brazo robótico o interactuar con un ordenador utilizando únicamente la actividad cerebral, es vislumbrar un futuro donde las barreras físicas se mitigan significativamente.

Este trabajo se adentra en el **procesado de la señal electroencefalográfica** para lograr el pronóstico de intenciones motoras, abordando las complejidades inherentes a la extracción de información significativa de una señal tan ruidosa y dinámica. Se explorarán las etapas clave que transforman los datos brutos del EEG en un comando funcional: desde las técnicas de preprocesamiento para eliminar artefactos y ruido, hasta los métodos de extracción de características que aíslan los patrones relevantes de la actividad cerebral (como los ritmos sensorimotores Asimismo, se analizarán los algoritmos de clasificación más utilizados en la actualidad, fundamentales para traducir estos patrones en predicciones precisas de la intención motora del usuario. Aunque el objetivo principal se centra en el pronóstico de intenciones motoras para la rehabilitación, también se reconocerá la creciente expansión de esta tecnología hacia aplicaciones alternativas, incluyendo la mejora cognitiva, la interacción en realidad virtual/aumentada y el desarrollo de nuevas formas de expresión artística y comunicativa. Finalmente, se resaltará la importancia crítica de las consideraciones éticas, legales y sociales que acompañan el desarrollo de las BCI, particularmente en un contexto donde la privacidad mental y los neuroderechos están ganando un reconocimiento indispensable.

1.2. Motivación

Vivimos en una sociedad que, inmersa en una acelerada innovación tecnológica, se enfrenta simultáneamente a nuevas y complejas necesidades físicas, sociales y éticas. La tecnología, convertida en un eje central de la vida cotidiana, ha transformado nuestras formas de trabajar, relacionarnos y cuidarnos. Sin embargo, este ritmo de avance a menudo contrasta con la lenta adaptación social, médica y legal a sus consecuencias. Una de estas consecuencias, especialmente visible en los colectivos más vulnerables, es el crecimiento de los casos de

amputaciones de miembros, tanto por razones médicas como accidentales. Esta realidad exige una respuesta tecnológica humanizada, viable y adaptada a los desafíos contemporáneos.

En España, la problemática es palpable. Se estima que cada año se producen entre 3.000 y 3.500 amputaciones de extremidades inferiores asociadas a complicaciones de la diabetes mellitus tipo 2, una enfermedad cuya prevalencia aumenta por el sedentarismo, la obesidad y el envejecimiento poblacional (Ministerio de Sanidad, 2024). La situación es particularmente preocupante en regiones como Canarias, donde se ha documentado un índice elevado de complicaciones vasculares que derivan en amputaciones (Consejería de Sanidad del Gobierno de Canarias, 2023). A estas cifras se suman las amputaciones resultantes de accidentes laborales o de tráfico, evidenciando la vulnerabilidad de una sociedad productiva que aún no está plenamente preparada para atender integralmente a quienes sufren la pérdida de una parte de su cuerpo.

Estas realidades conllevan un impacto físico evidente, pero también un coste emocional, psicológico y social que es difícil de cuantificar. Muchas personas amputadas no solo pierden funcionalidad, sino también autoestima, independencia y oportunidades de inclusión social. En este contexto, la tecnología no puede limitarse a ofrecer soluciones meramente mecánicas; debe ser capaz de integrarse con la mente y el cuerpo del usuario para ofrecer una experiencia más natural, intuitiva y segura. Es aquí donde las interfaces cerebro-computador (BCI) cobran una relevancia fundamental. Estos sistemas permiten traducir directamente las señales eléctricas cerebrales en acciones sobre dispositivos externos, como prótesis robóticas o sillas de ruedas inteligentes.

El potencial de las BCI, aunque conocido, ha alcanzado un grado de madurez sin precedentes en la última década. Este avance se debe, en gran medida, al desarrollo del aprendizaje automático, la computación neuromórfica y el incremento exponencial de la capacidad de procesamiento de datos en tiempo real. Hoy día, es viable registrar, filtrar, segmentar e interpretar señales electroencefalográficas (EEG) mediante métodos no invasivos, lo que facilita su aplicación en entornos clínicos, domésticos y de rehabilitación con una inversión relativamente asequible (López-Sánchez et al., 2024). No se trata ya de una mera promesa

científica, sino de un conjunto de herramientas que ya están demostrando su eficacia en ensayos clínicos y entornos experimentales, con resultados cada vez más esperanzadores.

La motivación central de este trabajo, por tanto, es doble: por un lado, contribuir técnicamente al desarrollo de sistemas que permitan a personas amputadas o con movilidad reducida recuperar parte de su autonomía mediante el uso de señales EEG. Esto implica superar las limitaciones de las prótesis tradicionales —a menudo caras, poco intuitivas y desconectadas de la intención del usuario— para ofrecer dispositivos que respondan directamente al **pensamiento** y la **intención motora**. El cerebro humano, incluso tras la pérdida de un miembro, mantiene la capacidad de generar señales asociadas a su movimiento. Nuestro objetivo es captar, procesar y transformar esas señales en comandos digitales que activen movimientos reales en una prótesis robótica.

Por otro lado, este proyecto busca generar una **conciencia crítica sobre las implicaciones sociales, legales y éticas** del uso de tecnologías que interactúan directamente con el cerebro humano. Desde el punto de vista técnico, el procesamiento de las señales EEG presenta desafíos inherentes como su baja relación señal-ruido, alta variabilidad interindividual y dependencia del contexto. Factores como la calidad del contacto del electrodo o el estado emocional del usuario pueden alterar significativamente las señales captadas desde la superficie del cráneo. De ahí la necesidad de herramientas avanzadas de preprocesamiento, segmentación y extracción de características, así como modelos de clasificación robustos. Este trabajo aborda precisamente la aplicación de estas herramientas para generar datos útiles en el entrenamiento de modelos inteligentes.

A nivel personal y académico, este proyecto representa una valiosa oportunidad para aplicar los conocimientos de la ingeniería de telecomunicación a un problema con impacto social directo. Es un intento de unir la teoría con la realidad, el *software* con la humanidad, el análisis de señales con la mejora de la calidad de vida. Constituye, además, una toma de posición ética frente a una tecnología que, si bien tiene un potencial transformador, también plantea interrogantes profundos. Preguntas como: ¿Qué ocurre con los datos cerebrales recogidos? ¿Quién tiene acceso a ellos? ¿Podrían ser utilizados para manipular decisiones, anticipar pensamientos o generar perfiles psicológicos sin consentimiento explícito?

La **neurotecnología**, como campo emergente, se encuentra aún en una zona gris desde el punto de vista legal. Aunque el **Reglamento General de Protección de Datos (RGPD)** establece principios aplicables a la protección de datos personales, aún no existe una regulación específica para los "neurodatos" (Agencia Española de Protección de Datos [AEPD], 2022). Estos datos, al proceder directamente del sistema nervioso central, son posiblemente los más sensibles que una persona puede generar, revelando información sobre emociones, impulsos y decisiones. Si no se gestionan adecuadamente, podrían convertirse en herramientas de vigilancia o discriminación. Por ello, un objetivo secundario de este trabajo es abrir una reflexión sobre los marcos legales necesarios para que el progreso tecnológico no comprometa derechos fundamentales.

Finalmente, si bien la aplicación en salud es primordial, las BCI ya se están expandiendo a otros sectores como el entretenimiento, la educación o la industria militar. Ejemplos incluyen videojuegos controlados por la mente o cascos EEG para mejorar la concentración. Estos desarrollos aumentan la urgencia de establecer criterios éticos y de seguridad claros. No todo lo técnicamente posible es moral o legalmente aceptable. Como sociedad, debemos plantearnos los límites del uso del pensamiento como interfaz y garantizar que su aplicación sea libre, informada y segura. Este proyecto aspira a una **contribución integral**: por un lado, al desarrollo técnico de sistemas BCI que mejoren la autonomía de personas con discapacidad motora; y por otro, a la promoción de una conciencia crítica sobre las profundas implicaciones sociales, legales y éticas de estas tecnologías. No se trata solo de codificar una solución, sino de comprender el complejo ecosistema en el que se inserta, con sus riesgos, posibilidades y responsabilidades, fusionando ingeniería, humanidad y sentido crítico.

1.3. Antecedentes

La pérdida de una extremidad representa un desafío significativo a nivel global y en España, impactando la calidad de vida de los individuos. En España, se registran 1.62 amputaciones diarias debido a accidentes laborales. A nivel mundial, la diabetes es una causa aún más predominante, con una amputación de extremidades cada 30 segundos. Específicamente, España ocupa el segundo lugar a nivel global en amputaciones por diabetes tipo 2, con Canarias liderando la prevalencia de esta enfermedad y las amputaciones dentro del país.

Para mitigar los efectos físicos y psicológicos derivados de la amputación, la biomedicina ha experimentado avances notables, impulsados por desarrollos en las telecomunicaciones, la mecánica y la propia medicina. Dentro de este contexto, han surgido las Interfaces Cerebro-Ordenador (BCI, por sus siglas en inglés: Brain Computer Interface), que permiten la selección y procesamiento de señales cerebrales para controlar dispositivos tecnológicos, facilitando así la autonomía del paciente en su vida diaria. De acuerdo con [2], una BCI se define como un "sistema basado en ordenador que recopila señales cerebrales, las analiza y las traduce en comandos que se transmiten a un dispositivo de salida para llevar a cabo una acción deseada".

Las BCI se clasifican en función de su método de adquisición de datos y su utilidad clínica. Según la forma de recopilación, se distinguen las BCI invasivas, que requieren la implantación quirúrgica de captores en contacto directo con el cerebro, y las no invasivas, que utilizan tecnologías como la electroencefalografía (EEG) para registrar señales desde el exterior del cráneo sin necesidad de intervención quirúrgica. En cuanto a su utilidad para el paciente, las BCI se pueden diferenciar en asistenciales, diseñadas para el uso cotidiano de la tecnología por parte del paciente, y de rehabilitación, cuyo objetivo es la recuperación de la movilidad en miembros afectados por infartos cerebrales u otras anomalías neurológicas.

El procesamiento de las señales encefalográficas es un aspecto crucial, especialmente en los métodos no invasivos, ya que estos suelen generar una considerable cantidad de ruido, resultando en una baja relación señal/ruido (S/N). El procedimiento de procesamiento de señal más común en los sistemas BCI sigue un esquema que involucra la adquisición, preprocesamiento, extracción de características, clasificación y control del dispositivo.

Existen antecedentes de pruebas exitosas con pacientes que presentan amputaciones o lesiones neuronales en miembros superiores, obteniendo conclusiones positivas, por ejemplo, en la rehabilitación de pacientes con accidentes cerebrovasculares. En este ámbito, los algoritmos de aprendizaje supervisado han demostrado ser los más eficaces.

Finalmente, el desarrollo y uso de las BCI se encuentran actualmente bajo una importante consideración ética y regulatoria. En una sociedad cada vez más automatizada, la seguridad de la información y la protección de los datos personales, especialmente aquellos derivados

de la actividad cerebral, son de suma importancia. Investigaciones recientes ya abordan la posibilidad de ataques ciberneticos a estas interfaces, lo que podría comprometer información altamente privilegiada y personal del cerebro. La regulación por parte de entidades como la Unión Europea tendrá un impacto directo en la libertad o limitación de estas tecnologías, influyendo significativamente en su desarrollo social y en la esperanza de vida de los pacientes.

1.4. Objetivos

El objetivo principal de este Trabajo de Fin de Grado es **investigar y desarrollar un sistema de procesamiento de señal encefalográfia (EEG) para el pronóstico de intenciones motoras**, aplicando técnicas de *Machine Learning*, con el fin de sentar las bases para su futura implementación en dispositivos de asistencia para pacientes amputados, y analizando las implicaciones éticas y legales en el marco de la normativa europea de protección de datos

1.5. Objetivos Específicos

1. Analizar la situación actual y las necesidades de las personas con amputaciones en el contexto nacional y europeo, destacando la relevancia de las Interfaces Cerebro-Computadora (BCI) como solución potencial.
2. Adquirir y preprocesar una base de datos pública de señales EEG que contenga registros de actividad cerebral asociada a la imaginación o ejecución de movimientos motores.
3. Implementar y aplicar diversas técnicas de procesamiento de señal EEG (filtrado, segmentación, normalización) para limpiar y estructurar los datos de manera óptima.
4. Identificar y extraer características relevantes (parametrizar) de las señales EEG que permitan representar las diferentes intenciones motoras, evaluando su idoneidad para la clasificación.
5. Desarrollar y evaluar modelos de *Machine Learning* capaces de clasificar y pronosticar con precisión las intenciones motoras (reposo, movimiento

- imaginado/ejecutado) a partir de las características extraídas de las señales EEG.
6. Analizar el marco regulatorio europeo, particularmente el Reglamento General de Protección de Datos (RGPD), en relación con la protección de los neurodatos generados por las interfaces cerebro-ordenador, e identificar los desafíos éticos asociados

1.6. Estructura del documento

El presente Trabajo de Fin de Grado se estructura en dos partes: Memoria y Presupuesto. En el caso de la Memoria, esta se divide por capítulos tal y como se describe a continuación:

- **Capítulo 1. Introducción:**

Se presentan las motivaciones del proyecto, resaltando la importancia del pronóstico de intenciones motoras mediante señales EEG, tanto para la mejora de la autonomía de personas con discapacidad motora como para abordar los aspectos éticos y legales implicados.

Se detallan los antecedentes, la problemática de las amputaciones y las aplicaciones de las BCI. Se formulan los objetivos principales y específicos, junto con un resumen del trabajo y la estructura del documento.

- **Capítulo 2. La señal y los datos:**

Este capítulo proporciona el contexto neurofisiológico necesario para entender la actividad cerebral, el papel de las ondas cerebrales y la base de las señales EEG.

Se explican la adquisición y configuración de las señales, las ventajas y retos del EEG, y los fundamentos de las BCI, incluyendo sus paradigmas, tipos (invasivas y no invasivas) y aplicaciones. Finalmente, se analizan los aspectos éticos, legales y sociales ligados a su uso.

- **Capítulo 3. Procesado de la señal encefalográfica:**

Se describen las etapas de procesado de la señal EEG, desde la adquisición, preprocesamiento y extracción de características, hasta la reducción de dimensionalidad y clasificación. Se presentan también las métricas empleadas para la evaluación de los sistemas desarrollados.

- **Capítulo 4. Las BCI y la privacidad:**

Este capítulo aborda en profundidad las consideraciones éticas, legales y sociales en el desarrollo y aplicación de las BCI. Se trata el concepto de neuroprivacidad, los riesgos asociados a la gestión de neurodatos y la importancia del consentimiento informado, la transparencia y la equidad en el acceso a estas tecnologías.

- **Capítulo 5. Procesado y análisis de la señal EEG:**

Se presenta la base de datos empleada (de PhysioNet) y se detallan los métodos aplicados al preprocesado y la estructuración de los datos. Se exponen los resultados obtenidos tras este procesado, así como el análisis de las gráficas resultantes y su interpretación. Se desarrolla también la aplicación de modelos de *Machine Learning* para la clasificación de las intenciones motoras.

- **Capítulo 6. Conclusiones y resultados:**

Se discuten los resultados en relación con los objetivos planteados y su comparación con el estado del arte. Se extraen las conclusiones, destacando las aportaciones del trabajo, y se proponen líneas futuras de investigación y desarrollo.

Capítulo 2 – La señal y los datos

2.1. Introducción

El presente capítulo establece la base teórica y conceptual indispensable para la comprensión y el desarrollo de este Trabajo de Fin de Grado. Se explorarán en profundidad los fundamentos neurofisiológicos que subyacen a la actividad cerebral, con especial énfasis en la generación de la intención motora. Posteriormente, se detallarán las características inherentes de la señal electroencefalográfica (EEG), una técnica no invasiva clave para la adquisición de datos cerebrales. Se continuará con una descripción exhaustiva de las interfaces cerebro-computadora (BCI), sus principios de funcionamiento, tipologías y paradigmas, así como sus diversas aplicaciones en el ámbito clínico y tecnológico. Finalmente, se abordarán las consideraciones éticas, legales y sociales, incluyendo los neuroderechos, que enmarcan la implementación y el uso responsable de estas tecnologías emergentes, garantizando una perspectiva integral del campo.

2.2. El Cerebro Humano y la Actividad Neuronal

Comprender el funcionamiento del cerebro humano, particularmente en lo que respecta a la **intención motora**, es la piedra angular para el desarrollo de interfaces cerebro-computadora

(BCI) que buscan decodificar el pensamiento para controlar dispositivos externos. El sistema motor no es una entidad monolítica, sino una compleja red jerárquica y paralela que coordina desde la ideación de un movimiento hasta su ejecución fina. Esta intrincada organización permite que, incluso en ausencia de movimiento físico, la mera **intención o imaginación de una acción** genere patrones eléctricos distinguibles, un fenómeno crucial para las BCI destinadas a personas con discapacidad motora. Los avances en neurociencia han revelado que la capacidad del cerebro para reorganizarse, conocida como **neuroplasticidad**, juega un papel fundamental en la adaptación a lesiones y en el potencial de rehabilitación a través de tecnologías como las BCI. Esta sección profundiza en las bases neurofisiológicas de la actividad neuronal y su relación con el control y la planificación motora. [1]

La actividad eléctrica que el EEG es capaz de registrar se origina a partir de fenómenos bioeléctricos fundamentales en el cerebro. La base de esta actividad reside en el **potencial de membrana** de las neuronas, mantenido por la distribución diferencial de iones (principalmente sodio, potasio, calcio y cloro) a través de la membrana celular, regulada activamente por bombas iónicas (como la bomba sodio-potasio). Si bien los **potenciales de acción** —impulsos eléctricos rápidos y transitorios que se propagan a lo largo de los axones— son la forma primaria de comunicación neuronal a larga distancia, no son la fuente principal de la señal EEG. Los potenciales de acción son eventos muy breves (aproximadamente 1 milisegundo) y localizados, lo que dificulta su detección sincrónica a nivel macroscópico en el cuero cabelludo. [2] En cambio, las señales EEG son generadas predominantemente por la sumación sincrónica de **potenciales postsinápticos (PEPS y PIPS)** —cambios graduados en el potencial de membrana dendrítica y somática de las neuronas— que ocurren en grandes poblaciones de neuronas. Estos potenciales son más lentos y tienen una mayor duración y amplitud espacial que los potenciales de acción, lo que permite su sumación temporal y espacial. Crucialmente, la **organización columnar** de las neuronas piramidales en la corteza cerebral, dispuestas perpendicularmente a la superficie cortical, favorece la alineación de los dipolos eléctricos que generan. Cuando miles o millones de estas neuronas se activan de manera sincronizada, sus campos eléctricos se suman y se propagan a través del líquido cefalorraquídeo, las meninges, el cráneo y el cuero cabelludo, generando las diferencias de potencial detectables por los electrodos del EEG.

Los circuitos neuronales involucrados en el control motor son extensos y multifacéticos. La **corteza motora primaria (M1)**, ubicada en el giro precentral, es esencial para la ejecución de movimientos voluntarios, codificando parámetros como la dirección, la fuerza y la velocidad. Sin embargo, la planificación y preparación del movimiento involucran otras áreas corticales de asociación, como la **corteza premotora (PMC)** y el **área motora suplementaria (SMA)**, ambas localizadas rostralmente a M1. La PMC participa en la selección de movimientos apropiados en respuesta a estímulos externos y en la coordinación de movimientos guiados por la visión, mientras que la SMA es fundamental para la planificación de secuencias de movimientos complejos, el inicio de movimientos auto-iniciados y la preparación de movimientos bilaterales. Conjuntamente, estas áreas forman una **red de planificación motora** que se activa antes de que el movimiento sea siquiera perceptible, un fenómeno crucial para la decodificación de la intención. Las señales de estas áreas descienden a través de las **vías corticoespinales** (principalmente el tracto corticoespinal lateral para movimientos distales y finos, y el tracto corticoespinal anterior para movimientos axiales) y otras vías subcorticales hacia la médula espinal para activar las motoneuronas que inervan los músculos. [3] Los **ganglios basales** y el **cerebelo** también desempeñan roles modulatorios críticos; los ganglios basales participan en la selección y el inicio de acciones deseadas e inhibición de las no deseadas, mientras que el cerebelo es vital para la coordinación, el equilibrio, el aprendizaje motor y el ajuste fino del movimiento. En personas con amputaciones o parálisis, la vía final común de estas señales hacia los músculos está interrumpida, pero las áreas corticales superiores de planificación y ejecución motora a menudo permanecen intactas y activas, lo que sienta las bases para las BCI.

La **intención motora** puede ser identificada a través de patrones eléctricos específicos en el cerebro. Uno de los biomarcadores más prominentes es el **Potencial de Preparación (Bereitschaftspotential o RP)**, una onda negativa lenta que comienza a manifestarse en el EEG aproximadamente 1 a 2 segundos antes de la ejecución de un movimiento voluntario. Este potencial, mejor observable en promedios de eventos, es una señal de que el cerebro está preparándose para una acción, incluso antes de que el individuo sea plenamente consciente de su decisión de actuar, como lo sugirieron los seminales trabajos de Libet y colaboradores en los años 80. La detección de este potencial abre la posibilidad de sistemas

predictivos en BCI, anticipando la acción del usuario. Además del RP, la corteza motora codifica activamente parámetros del movimiento, y esta codificación puede ser decodificada.

El concepto de **Imaginación Motora (Motor Imagery - MI)** es central para muchas BCI no invasivas. Estudios neurofisiológicos han demostrado consistentemente que la imaginación mental de un movimiento activa redes neuronales en la corteza motora y premotora que son notablemente similares a las activadas durante la ejecución física real del movimiento, aunque con amplitudes generalmente menores. La superposición de circuitos neuronales involucrados en la planificación, simulación y ejecución de movimientos permite que la **modulación de la actividad en estas áreas corticales** mediante la imaginación se convierta en una señal de control para una BCI. Este fenómeno es de vital importancia para individuos con parálisis, tetraplejia o amputaciones, ya que les permite utilizar su actividad cerebral funcionalmente intacta para interactuar con el mundo exterior, incluso cuando la vía motora descendente está comprometida. [4]

La **neuro plasticidad** es la capacidad intrínseca del cerebro para reorganizarse y formar nuevas conexiones neuronales en respuesta a la experiencia, el aprendizaje o, crucialmente, la lesión. Tras una amputación o una lesión medular, la representación cortical del miembro afectado puede persistir, un fenómeno que se ha denominado "memoria motora". Estudios como los citados por la Fundación Dacer (2022) indican que las áreas motoras del cerebro continúan activándose como si el miembro estuviera presente, incluso años después de la pérdida física. Esta persistencia se relaciona, en ocasiones, con el **dolor del miembro fantasma**, y la modulación de estas áreas mediante BCI puede tener efectos terapéuticos al readaptar los mapas corticales desorganizados. La capacidad de las BCI para "engancharse" a esta plasticidad cerebral ofrece una vía para la rehabilitación, no solo permitiendo el control de dispositivos, sino también promoviendo la reorganización funcional del cerebro para recuperar o mejorar la función perdida. Al establecer una vía directa entre el pensamiento y la acción, mediada por sistemas informáticos, las BCI no solo reemplazan funciones físicas, sino que generan una nueva forma de interacción cuerpo-tecnología, abriendo caminos para la autonomía y la calidad de vida. [4]

2.2.1. Ondas Cerebrales y Ritmos Sensorimotores

Las **ondas cerebrales** son la manifestación rítmica y oscilatoria de la actividad eléctrica de grandes poblaciones neuronales, y su análisis constituye un pilar fundamental en la interpretación de las señales electroencefalográficas (EEG). [5] Estas oscilaciones no son aleatorias; se cree que reflejan la sincronización de la actividad neuronal en redes distribuidas, lo que permite la comunicación eficiente y la integración de información entre distintas regiones cerebrales. La modulación de estas oscilaciones está intrínsecamente ligada a diferentes estados cognitivos y fisiológicos, y en el contexto del control motor, ciertas bandas de frecuencia exhiben cambios distintivos que pueden ser decodificados por las interfaces cerebro-computadora (BCI). Esta sección detalla las principales bandas de frecuencia del EEG y profundiza en los **ritmos sensorimotores**, que son de particular relevancia para la detección de la intención motora. [6]

Las señales EEG se caracterizan por su frecuencia y amplitud, y tradicionalmente se dividen en bandas de frecuencia específicas, cada una asociada con distintos procesos cerebrales y estados de conciencia:

- **Delta (δ) (0.5–4 Hz):** Predominantemente observadas durante el **sueño profundo** sin movimientos oculares rápidos (NREM) y en algunas patologías cerebrales. Topográficamente, pueden ser más prominentes en regiones frontales en adultos y posteriores en niños durante el sueño. Funcionalmente, se asocian con procesos de consolidación de la memoria y la regulación homeostática.
- **Theta (θ) (4–8 Hz):** Comunes en el **sueño REM**, estados de **somnolencia**, y durante tareas que requieren **memoria de trabajo** o navegación espacial. Se observan prominentemente en regiones frontales y temporales. En la actividad despierta, se asocian con la relajación profunda y la meditación.
- **Alfa (α) (8–13 Hz):** Típicamente observadas en regiones occipitales y parietales durante estados de **vigilia relajada con los ojos cerrados**. La apertura de los ojos o el inicio de una tarea mental suele suprimir este ritmo, un fenómeno conocido como **desincronización alfa**. Funcionalmente, se ha propuesto que el ritmo alfa participa

en la **inhibición de áreas no relevantes** para la tarea actual, modulando la atención y el procesamiento sensorial.

- **Beta (β) (13–30 Hz):** Presente en estados de **alerta activa**, concentración y **movimiento** (o preparación para el movimiento). Se distribuye ampliamente sobre las cortezas frontales y motoras. Un aumento en la potencia beta se asocia con el mantenimiento de un estado cognitivo o motor, mientras que su disminución (desincronización) se relaciona con la acción. [8]
- **Gamma (γ) (>30 Hz):** Ritmos de muy alta frecuencia, asociados con la **integración de información** entre diferentes áreas cerebrales, el procesamiento sensorial complejo, la atención enfocada y los procesos cognitivos de alto nivel. Su baja amplitud y su susceptibilidad al ruido las hacen más difíciles de estudiar con EEG.

Dentro de estas bandas, los **ritmos sensorimotores (SMR)** son de especial interés para las BCI de control motor. Estos ritmos incluyen componentes en la banda **alfa (8-13 Hz)**, específicamente el **ritmo Mu (μ)**, y en la **banda Beta (13-25 Hz)**. El ritmo Mu se genera principalmente en las cortezas sensoriomotora y parietal superior. En estado de reposo o inactividad motora, el ritmo Mu se caracteriza por oscilaciones prominentes y sincronizadas en la región central (electrodes C3, Cz, C4 del sistema 10-20). Sin embargo, cuando una persona realiza o, crucialmente, **imagina un movimiento** (Imaginación Motora, MI), la potencia de estos ritmos en las áreas motoras relacionadas con la extremidad imaginada disminuye significativamente. Este fenómeno es conocido como **Desincronización Relacionada con Eventos (Event-Related Desynchronization, ERD)**. [7]

La **ERD** es un descenso en la potencia espectral de los ritmos Mu y Beta que se observa en las regiones corticales involucradas en la preparación o ejecución de un movimiento. Por ejemplo, al imaginar el movimiento de la mano derecha, se produce una ERD en el hemisferio contralateral (corteza motora izquierda, electrodo C3). Esta desincronización se interpreta como un reflejo de la activación neuronal y la necesidad de las neuronas de "desincronizarse" de su estado de reposo para procesar información y coordinar la acción. [7] A nivel fisiológico, la ERD puede reflejar la apertura de canales iónicos y la activación de redes neuronales específicas, lo que conduce a una menor coherencia en la actividad de la población neuronal, y por lo tanto, una reducción en la amplitud de las oscilaciones. La

cuantificación de la ERD/ERS típicamente se realiza comparando la potencia espectral de la señal en una ventana de tiempo de interés (durante la imaginación motora) con una ventana de línea base (durante el reposo). Una fórmula común es el porcentaje de cambio en la potencia espectral:

$$ERD/ERS(\%) = \frac{(Potencia_{evento} - Potencia_{línea_base})}{Potencia_{línea_base}} \times 100$$

Figura 2.1 – Relación entre ERD y ERS

Donde Potenciaevento es la potencia en la banda de frecuencia de interés durante la tarea, y Potencialínea_base es la potencia durante un periodo de reposo. Valores negativos indican ERD y valores positivos indican ERS.

A la inversa, cuando el cerebro está en un estado de reposo o inhibición motora, los ritmos Mu y Beta tienden a aumentar su potencia, un fenómeno denominado **Sincronización Relacionada con Eventos (Event-Related Synchronization, ERS)**. La ERS post-movimiento o durante la supresión de un movimiento se asocia con la reactivación de redes neuronales y la inhibición de la actividad motora. Por ejemplo, después de un movimiento, los ritmos Mu y Beta en la corteza motora a menudo "rebotean", [10] mostrando un aumento transitorio de su potencia. La capacidad de detectar y cuantificar estos patrones ERD/ERS de manera fiable es lo que permite a las BCI discriminar entre diferentes intenciones motoras (ej. imaginar mano izquierda vs. mano derecha vs. reposo) y traducirlas en comandos.

La **lateralización de la ERD** es una característica clave explotada en las BCI. Si una persona imagina mover la mano derecha, la ERD será más pronunciada en la corteza motora izquierda (contralateral). Si imagina mover la mano izquierda, la ERD será mayor en la corteza motora derecha. Esta asimetría en la modulación del ritmo Mu permite a los sistemas BCI diferenciar entre intenciones de movimiento de diferentes extremidades. Sin embargo, la efectividad de esta modulación varía entre individuos, y no todas las personas pueden modular sus SMR de manera consistente, un fenómeno a veces llamado "analfabetismo BCI" (*BCI illiteracy*), lo que subraya [11]la necesidad de protocolos de entrenamiento individualizados y sistemas adaptativos. La investigación continua se centra en mejorar la robustez de la detección de

ERD/ERS y en comprender mejor la variabilidad inter-sujeto para optimizar el rendimiento de las BCI basadas en imaginación motora. [8]

2.3. Electroencefalografía (EEG)

La **electroencefalografía (EEG)** es una de las técnicas neurofisiológicas más antiguas y, sin embargo, sigue siendo una herramienta fundamental para la investigación y el desarrollo de interfaces cerebro-computadora (BCI). [13] Su carácter no invasivo, su relativa portabilidad y su excelente resolución temporal la convierten en una opción preferente para el estudio de la actividad cerebral en tiempo real y para aplicaciones clínicas. El EEG permite registrar la actividad eléctrica generada por las neuronas corticales mediante electrodos colocados sobre el cuero cabelludo, ofreciendo una ventana directa a los procesos cerebrales subyacentes a la cognición y el control motor. Sin embargo, la correcta interpretación de estas señales requiere una comprensión profunda de sus principios de adquisición, las configuraciones de los electrodos y los inherentes desafíos que presenta.

2.3.1. Principios de Adquisición de Señales EEG

La adquisición de señales EEG se basa en la detección de las minúsculas diferencias de potencial eléctrico generadas por la actividad sincrónica de miles de neuronas corticales, como se explicó en la sección anterior. Estas señales, típicamente en el rango de **microvoltios (μ V)** (10-100 μ V), son el resultado de la sumación de **potenciales postsinápticos** en las dendritas de las neuronas piramidales, las cuales están orientadas de forma perpendicular a la superficie cortical. La señal se propaga desde la fuente neuronal a través de diversas capas de tejido –el cerebro mismo, el líquido cefalorraquídeo, las meninges, el cráneo y el cuero cabelludo– antes de llegar a los electrodos. Cada una de estas capas actúa como un conductor de volumen, atenuando y distorsionando la señal, lo que contribuye a la limitada **resolución espacial** del EEG. Este es el **problema inverso** en neurofisiología: inferir la ubicación de la fuente neural a partir de la actividad registrada en la superficie.

Un sistema EEG moderno consta de varios componentes esenciales para la adquisición de señales de calidad:

- **Electrodos:** Son los sensores que captan las diferencias de potencial en el cuero cabelludo. Los más comunes son los de **cloruro de plata/plata (Ag/AgCl)** debido a su estabilidad y baja polarización. Pueden ser **húmedos** (requieren un gel conductor para asegurar un buen contacto eléctrico y reducir la impedancia de contacto con la piel) o **secos** (no requieren gel, lo que mejora la usabilidad pero puede comprometer la calidad de la señal si la impedancia es alta). La **impedancia de contacto** entre el electrodo y la piel es crítica; debe ser lo más baja posible (generalmente por debajo de 5 kOhms) para minimizar el ruido y los artefactos de movimiento. Una alta impedancia puede causar una señal ruidosa y distorsionada. [14]
- **Amplificadores Biopotenciales:** Dado que las señales EEG son de muy baja amplitud, necesitan ser amplificadas miles de veces antes de ser digitalizadas. Estos amplificadores están diseñados para tener una **alta impedancia de entrada** (para no cargar el circuito de medición) y un **alto Rechazo de Modo Común (CMRR)**. El CMRR es fundamental porque permite al amplificador suprimir el ruido que es común a todos los electrodos (como la interferencia de la red eléctrica, el ruido ambiental o la actividad cardíaca), al medir la diferencia de potencial entre el electrodo activo y un electrodo de referencia. Esto mejora drásticamente la relación señal-ruido (SNR).
- **Filtros Analógicos:** Antes de la digitalización, se utilizan filtros de hardware (pasa-altos y pasa-bajos) para eliminar frecuencias fuera del rango de interés (generalmente entre 0.5 y 50-100 Hz, dependiendo de la aplicación) y para prevenir el **aliasing** (la distorsión de la señal que ocurre si la frecuencia de muestreo es demasiado baja).
- **Convertidores Analógico-Digital (ADC):** Transforman la señal analógica continua en una secuencia discreta de valores digitales. Dos parámetros clave son:
 - **Frecuencia de Muestreo (Sampling Rate):** Es el número de muestras tomadas por segundo. Según el **Teorema de Nyquist**, la frecuencia de muestreo debe ser al menos el doble de la frecuencia más alta presente en la señal para evitar el aliasing. Para EEG, frecuencias de muestreo de 250 Hz a 1000 Hz son comunes, dependiendo de las bandas de frecuencia de interés (ej., para la banda gamma de alta frecuencia se necesitarían muestreos más altos).

- **Resolución (Bits):** Determina el número de niveles de cuantificación que se utilizan para representar la amplitud de la señal. Una mayor resolución (ej., 24 bits) permite una representación más precisa de la señal y un menor ruido de cuantificación.
- **Electrodos de Referencia y Tierra (Ground):** El EEG mide diferencias de potencial, por lo que cada electrodo activo se mide en relación con un **electrodo de referencia**. La elección de la referencia es crucial y puede influir en la morfología de la señal; ubicaciones comunes incluyen el lóbulo de la oreja, las mastoides, la punta de la nariz o un promedio de todos los electrodos. Un electrodo de **tierra (ground)**, conectado a la tierra del equipo, es esencial para la seguridad eléctrica y para proporcionar un punto de potencial cero común para la eliminación del ruido de modo común.

La sincronización precisa de los datos EEG con los eventos experimentales (mediante **triggers** o marcadores temporales) es fundamental para el análisis de potenciales relacionados con eventos y la creación de paradigmas de BCI en tiempo real.

2.3.2. Configuración de Electrodos (Sistema 10-20 y 10-10)

Para asegurar la **reproducibilidad** de los experimentos y permitir la comparación de resultados entre diferentes laboratorios y estudios a nivel global, se ha estandarizado la colocación de los electrodos en el cuero cabelludo. El sistema más ampliamente aceptado y utilizado es el **Sistema Internacional 10-20**, desarrollado por la Federación Internacional de Sociedades de Electroencefalografía en 1957. Este sistema se basa en la medición de distancias entre puntos anatómicos craneales y la subdivisión de estas distancias en porcentajes del 10% o 20%. [15]

Los **puntos de referencia anatómicos** clave para el sistema 10-20 son:

- **Nasion:** El punto en la parte superior del puente de la nariz, entre los ojos.
- **Inion:** La protuberancia ósea en la parte posterior del cráneo, en la base.
- **Puntos Preauriculares:** Los puntos frente a la abertura de cada oreja.

Estos puntos definen las líneas de referencia: una línea sagital (Nasion-Inion) y una línea coronal (preauricular izquierda-preauricular derecha). A partir de estas líneas, se establecen los puntos de colocación de los electrodos utilizando porcentajes del 10% y 20% de la distancia total, tanto a lo largo de la línea media como en las líneas circunferenciales que rodean la cabeza.

La **nomenclatura de los electrodos** sigue un patrón lógico:

- **Letras:** Indican la región cortical subyacente o cercana al electrodo:
 - **F:** Frontal (Fp para frontopolar)
 - **C:** Central (sobre la corteza motora y somatosensorial)
 - **P:** Parietal
 - **O:** Occipital
 - **T:** Temporal
 - **A:** Aural (lóbulo de la oreja o mastoides, a menudo usados como referencias)
- **Números:** Indican la lateralidad. Los números **impares** (ej., F3, C3, P3) se usan para el **hemisferio izquierdo**, los **pares** (ej., F4, C4, P4) para el **hemisferio derecho**, y la letra 'z' (ej., Fz, Cz, Pz) para la **línea media (centro)**. Por ejemplo, C3 se sitúa sobre la corteza motora izquierda, y C4 sobre la corteza motora derecha.

El sistema 10-20 es útil para configuraciones de baja densidad (ej., 19-32 canales). Sin embargo, para una mayor resolución espacial y para obtener una cobertura más densa del cuero cabelludo, se desarrolló el **Sistema 10-10 (o 10%)**. Este sistema es una extensión del 10-20, que utiliza intervalos del 10% de las distancias entre los puntos de referencia, lo que permite la colocación de hasta 128 o 256 electrodos. Esta mayor densidad es particularmente ventajosa para técnicas de **localización de fuentes** (inferir la ubicación cortical de la actividad eléctrica) y para capturar patrones más finos de actividad cerebral, lo que puede ser crucial en ciertas aplicaciones BCI donde la discriminación espacial es importante. Para un sistema de 64 canales, como el que podría aplicarse en tu estudio, se utilizan las ubicaciones del sistema 10-10 para asegurar una cobertura adecuada de las áreas motoras y otras regiones relevantes. [16]

La **impedancia de los electrodos**, es decir, la resistencia al flujo de corriente entre el electrodo y la piel, es un factor crítico para la calidad de la señal. Una impedancia alta (por encima de 5-10 kOhms) puede introducir ruido significativo, artefactos de movimiento y distorsión de la señal. Por ello, antes de la adquisición, se verifica y se ajusta la impedancia de cada electrodo utilizando geles conductores o soluciones salinas para asegurar un buen contacto.

2.3.3. Ventajas y Desafíos de las Señales EEG

Las señales electroencefalográficas ofrecen una serie de **ventajas** distintivas que las posicionan como una herramienta de gran valor en neurociencia y en el desarrollo de BCI, pero también conllevan **desafíos significativos** que deben ser meticulosamente abordados en el procesamiento de la señal.

Entre las principales **ventajas** del EEG se destacan:

- **No-Invasividad y Seguridad:** A diferencia de técnicas como los implantes intracorticales, el EEG es completamente externo y no presenta riesgos para la salud del participante, lo que lo hace ideal para estudios en humanos y aplicaciones a largo plazo.
- **Resolución Temporal Superior:** El EEG tiene una resolución temporal excepcional, capaz de capturar cambios en la actividad cerebral en el orden de los milisegundos. Esta capacidad es crucial para estudiar la dinámica rápida de los procesos cognitivos y motores, como los potenciales de preparación o la latencia de las respuestas motoras, lo que lo convierte en una técnica ideal para sistemas BCI en tiempo real que requieren una baja latencia en la traducción de comandos. En comparación con la resonancia magnética funcional (fMRI), que tiene una resolución temporal de segundos, el EEG ofrece una visión mucho más precisa de cuándo ocurren los eventos neuronales.
- **Costo-Efectividad y Portabilidad:** Los equipos de EEG son, en general, considerablemente más económicos que otras modalidades de neuroimagen (como la magnetoencefalografía - MEG o la fMRI). Además, el desarrollo de sistemas EEG inalámbricos y portátiles (como los ofrecidos por OpenBCI o Bitbrain) ha facilitado

su uso en entornos fuera del laboratorio, incluyendo aplicaciones clínicas y domésticas, democratizando el acceso a esta tecnología.

- **Facilidad de Uso Relativa:** Con el entrenamiento adecuado, la colocación y el mantenimiento de los electrodos, así como el manejo del software, pueden ser realizados por personal no especializado, lo que agiliza los tiempos de preparación del experimento.

No obstante, el EEG presenta importantes **desafíos** que complican su análisis y requieren un procesamiento de señal sofisticado:

- **Baja Relación Señal-Ruido (SNR):** La señal eléctrica generada por el cerebro (del orden de μ V) es de muy baja amplitud y es extremadamente susceptible a la contaminación por diversas fuentes de ruido y artefactos. Esto resulta en una SNR típicamente baja, lo que dificulta la extracción de información relevante.
- **Artefactos Biológicos:** Son señales eléctricas no cerebrales generadas por la actividad fisiológica del propio cuerpo del participante. Constituyen la principal fuente de contaminación en el EEG:
 - **Artefactos Oculares (EOG):** Producidos por el movimiento de los ojos (parpadeos, sacadas, movimientos lentos) y la actividad eléctrica del dipolo corneal-retinal. Son de gran amplitud (a menudo mayores que la señal cerebral) y afectan predominantemente a los electrodos frontales. Se manifiestan como fluctuaciones lentas o picos agudos.
 - **Artefactos Musculares (EMG):** Generados por la contracción de los músculos (facial, cuello, mandíbula). Se caracterizan por ruido de alta frecuencia y gran amplitud, especialmente visible en los electrodos temporales y frontales.
 - **Artefactos Cardíacos (ECG):** El campo eléctrico generado por el latido cardíaco puede propagarse a la cabeza y ser detectado en el EEG, apareciendo como picos rítmicos y agudos coincidentes con el complejo QRS del ECG.
 - **Sudoración y Movimiento del Cuerpo:** La sudoración altera la conductancia de la piel y puede generar derivas lentas de la línea base. Los movimientos de

cabeza o cuerpo pueden causar artefactos de muy alta amplitud y erráticos debido a cambios en la impedancia o al movimiento de los cables.

- **Artefactos Extrínsecos/Ambientales:** Provenientes del entorno externo:
 - **Ruido de Línea (Power Line Interference):** Es una interferencia sinusoidal de 50 Hz (en Europa y otras regiones) o 60 Hz (en América y otras regiones), generada por la red eléctrica. Es ubicua y puede enmascarar la señal cerebral.
 - **Mala Conectividad/Impedancia de Electrodos:** Un contacto deficiente entre el electrodo y el cuero cabelludo puede introducir ruido de alta frecuencia, saturación del amplificador o pérdida de señal.
 - **Artefactos del Equipo:** Fallos en los cables, amplificadores o convertidores ADC pueden generar patrones de ruido inusuales.
- **Baja Resolución Espacial:** A pesar de su excelente resolución temporal, el EEG tiene una resolución espacial limitada. Esto se debe a la distorsión y atenuación de la señal a medida que atraviesa las diversas capas del cráneo y el cuero cabelludo (el efecto de volumen conductor). Es difícil determinar con precisión la fuente cortical de la actividad, ya que un solo electrodo recoge la sumatoria de actividad de una amplia región.
- **Variabilidad Inter e Intra-Sujeto:** Las señales EEG son altamente variables no solo entre diferentes individuos (debido a diferencias anatómicas, fisiológicas o cognitivas) sino también en el mismo individuo a lo largo del tiempo (debido a cambios en el estado de atención, fatiga, emoción o día a día). Esto requiere una fase de calibración y adaptación en los sistemas BCI y dificulta la generalización de modelos entrenados.
- **No Estacionariedad y No Linealidad:** Las señales EEG son inherentemente no estacionarias (sus propiedades estadísticas cambian con el tiempo) y no lineales, lo que significa que las relaciones entre los datos no son siempre proporcionales. Esto hace que el modelado y análisis sean más complejos que para señales lineales y estacionarias.

La superación de estos desafíos exige un **preprocesamiento riguroso** de las señales EEG, que incluye técnicas avanzadas de filtrado, eliminación de artefactos y normalización, esenciales para extraer información neuronal relevante y desarrollar sistemas BCI fiables.

2.4. Interfaces Cerebro-Computadora (BCI)

Las **interfaces cerebro-computadora (BCI)**, a menudo conocidas como interfaces mente-máquina (BMI), representan una frontera emocionante en la neurotecnología, estableciendo un canal de comunicación directo entre el cerebro humano y dispositivos externos, sin depender de la actividad muscular o nerviosa periférica. Este "puente directo" permite a los usuarios controlar prótesis robóticas, sillas de ruedas motorizadas, o comunicarse simplemente a través de sus pensamientos. La evolución de las BCI es un testimonio de la convergencia de la neurociencia, la ingeniería biomédica, la inteligencia artificial y la ciencia de datos, transformando la interacción humano-máquina y abriendo nuevas vías para la restauración de la autonomía en personas con severas discapacidades. [17]

La idea de conectar la mente a una máquina tiene sus raíces en las investigaciones de los años 70. Uno de los pioneros, Jacques Vidal, acuñó el término "Brain-Computer Interface" y exploró la posibilidad de utilizar potenciales corticales para el control de dispositivos. Sin embargo, los verdaderos avances se aceleraron en los años 90 y 2000, con demostraciones significativas tanto en animales (ej. el control de brazos robóticos por monos con implantes intracorticales) como en humanos, destacando proyectos como **BrainGate**, que permitió a pacientes con parálisis severa controlar cursores de ordenador o brazos robóticos con la actividad de sus neuronas. Desde entonces, las BCI han pasado de ser un concepto de laboratorio a aplicaciones clínicas y de investigación cada vez más sofisticadas.

Un sistema BCI funcional se compone de un ***pipeline*** de procesamiento de señal que consta de varias etapas interconectadas, cada una crucial para la traducción de la intención cerebral en un comando útil:

1. **Adquisición de la Señal:** Esta es la primera etapa, donde la actividad cerebral es capturada por los sensores. Como se detalló en la sección 2.2, esto implica el uso de electrodos (EEG, ECoG, intracorticales) y un sistema de hardware que incluye amplificadores y convertidores analógico-digital para transformar la señal

bioeléctrica en datos digitales. La elección del método de adquisición (invasivo o no invasivo) define la calidad de la señal y los riesgos asociados.

2. **Preprocesamiento de la Señal:** Las señales cerebrales adquiridas están invariablemente contaminadas por ruido y artefactos (biológicos y extrínsecos). Esta etapa es fundamental para limpiar la señal, eliminando componentes no deseados y mejorando la relación señal-ruido. Incluye técnicas como filtrado (ej., pasa banda, notch), eliminación de artefactos (ej., mediante ICA o regresión de artefactos) y re-referenciación, preparando la señal para el análisis posterior.
3. **Extracción de Características:** En esta fase, los datos EEG brutos se transforman en representaciones matemáticas que capturan la información relevante para la tarea específica. Esto implica identificar patrones, métricas o componentes de la señal que varían sistemáticamente con la intención del usuario. Las características pueden extraerse en el dominio del tiempo (ej., amplitud de potenciales evocados), del dominio de la frecuencia (ej., potencia en bandas alfa/beta, como ERD/ERS), o en el dominio tiempo-frecuencia (ej., usando wavelet transforms). La selección de características adecuadas es un paso crítico, ya que determina la capacidad del sistema para discriminar entre diferentes estados mentales o intenciones.
4. **Clasificación/Traducción de Comandos:** Una vez extraídas las características, se utiliza un algoritmo de aprendizaje automático para clasificar estos patrones y traducirlos en comandos discretos (ej., "mover cursor arriba", "abrir mano") o continuos (ej., posición de un brazo robótico). Esta etapa implica una fase de entrenamiento, donde el algoritmo aprende la relación entre los patrones cerebrales y las intenciones del usuario, y una fase de prueba o uso en tiempo real. La robustez y precisión del clasificador son esenciales para la fiabilidad del sistema BCI.
5. **Control del Dispositivo/Aplicación:** Los comandos generados por el clasificador se utilizan para operar el dispositivo o la aplicación deseada, que puede ser una prótesis, una silla de ruedas, una interfaz de comunicación o un entorno de realidad virtual. La respuesta del dispositivo debe ser rápida y fluida para proporcionar una experiencia de usuario satisfactoria.
6. **Retroalimentación (Feedback):** Esta es una etapa crucial para el éxito de la BCI y a menudo subestimada. El usuario recibe retroalimentación visual, auditiva o táctil

sobre el rendimiento del sistema y cómo su actividad cerebral está siendo interpretada. Este **bucle de retroalimentación en tiempo real** permite al usuario aprender a modular conscientemente su actividad cerebral de manera más efectiva (aprendizaje co-adaptativo) y, al mismo tiempo, permite al sistema BCI adaptarse a las variaciones en los patrones cerebrales del usuario, mejorando así la precisión y la usabilidad a lo largo del tiempo. Sin un feedback efectivo, el aprendizaje y la optimización del sistema BCI serían extremadamente difíciles.

El diseño de un sistema BCI eficiente es un proceso iterativo que requiere una cuidadosa atención a cada una de estas etapas, buscando un equilibrio entre la calidad de la señal, la complejidad computacional y la usabilidad para el usuario final.

2.4.1. Tipos de BCI

Las interfaces cerebro-computadora se pueden clasificar principalmente en función de la invasividad de la técnica de adquisición de la señal, lo que directamente influye en la calidad de la señal, el riesgo para el usuario y el ámbito de aplicación. Esta diferenciación es fundamental para comprender las capacidades y limitaciones de cada enfoque.

2.4.1.1. BCI Invasivas

Las **BCI invasivas** implican la implantación quirúrgica de electrodos directamente en el tejido cerebral o sobre su superficie. Este enfoque ofrece la ventaja de una **mayor resolución espacial y temporal**, así como una **mejor relación señal-ruido (SNR)**, debido a la proximidad directa a la fuente de la actividad neuronal.

Los principales tipos de BCI invasivas incluyen:

- **Implantes Intracorticales:** Consisten en microelectrodos (ej., el **Utah Array** o el **NeuroPixel**) que se insertan directamente en la corteza cerebral, en áreas como la motora o la parietal posterior. Estos microelectrodos son capaces de registrar la actividad de neuronas individuales (potenciales de acción unitarios o multiunidad) o de pequeños grupos de neuronas. La ventaja principal es la **precisión sin precedentes** en la decodificación de la intención motora, permitiendo el control de prótesis con

múltiples grados de libertad y movimientos más finos. Sin embargo, conllevan riesgos significativos como infección, hemorragia, rechazo del implante, formación de tejido glial alrededor de los electrodos (que puede degradar la calidad de la señal con el tiempo) y la necesidad de cirugías complejas y costosas. Proyectos como **BrainGate** han demostrado el control de cursores de ordenador y brazos robóticos en pacientes tetrapléjicos con estos implantes. **Neuralink**, impulsado por Elon Musk, es otro ejemplo de esta línea de investigación, buscando desarrollar implantes de ultra-alta densidad para aplicaciones que van desde el tratamiento de trastornos neurológicos hasta el aumento de capacidades humanas.

- **Electrocorticografía (ECoG):** Implica la colocación de mallas o tiras de electrodos directamente sobre la superficie del cerebro, debajo de la duramadre, pero sin penetrar el tejido cortical. Estos electrodos registran los **potenciales de campo local (LFP)**, que son la sumación de la actividad sináptica de poblaciones neuronales. La ECoG ofrece una excelente SNR en comparación con el EEG, una mayor resolución espacial y temporal que el EEG superficial, y una menor invasividad y riesgo que los implantes intracorticales. Se ha utilizado con éxito en pacientes con epilepsia (para mapeo quirúrgico) y, más recientemente, en BCI para control de prótesis y comunicación. Aunque es una cirugía menos arriesgada que los implantes profundos, sigue siendo un procedimiento invasivo con los riesgos inherentes.

Las BCI invasivas son actualmente el estándar de oro para aplicaciones que requieren un control de muy alta precisión y baja latencia, especialmente en investigación y ensayos clínicos con pacientes severamente discapacitados. No obstante, las barreras de riesgo, costo y la estabilidad a largo plazo siguen siendo desafíos importantes para su adopción generalizada.

2.4.1.2. BCI No Invasivas

Las **BCI no invasivas** son aquellas que adquieren las señales cerebrales sin la necesidad de cirugía, lo que las hace inherentemente más seguras, accesibles y aptas para una gama más amplia de aplicaciones y usuarios. Aunque su resolución espacial y SNR suelen ser inferiores

a las técnicas invasivas, su comodidad y bajo riesgo las han convertido en el enfoque dominante en la investigación y el desarrollo comercial de BCI.

Los principales tipos de BCI no invasivas incluyen:

- **Electroencefalografía (EEG):** Es la técnica no invasiva más utilizada para las BCI, y el foco de este trabajo. Como se detalló en la sección 2.2, mide las diferencias de potencial eléctrico en el cuero cabelludo. Sus ventajas incluyen la no-invasividad, la portabilidad, el bajo costo y una excelente resolución temporal que permite capturar la dinámica rápida de la actividad cerebral. Sin embargo, su principal limitación es la baja resolución espacial y la alta susceptibilidad al ruido y los artefactos, lo que requiere un procesamiento de señal riguroso. A pesar de estos desafíos, las BCI basadas en EEG han demostrado ser eficaces para el control de sillas de ruedas, prótesis sencillas y sistemas de comunicación (ej., spellers).
- **Magnetoencefalografía (MEG):** Mide los débiles campos magnéticos generados por las corrientes eléctricas de las neuronas. A diferencia de las señales eléctricas del EEG, los campos magnéticos no son distorsionados por el cráneo y el cuero cabelludo, lo que le confiere una resolución espacial superior al EEG. Los sensores MEG (dispositivos de interferencia cuántica superconductores, SQUID) deben operarse a temperaturas criogénicas y requieren salas magnéticamente blindadas, lo que resulta en un costo extremadamente alto, un gran tamaño y una falta de portabilidad. Estas limitaciones la restringen casi exclusivamente a entornos de investigación muy especializados.
- **Imágenes por Resonancia Magnética Funcional (fMRI):** Mide los cambios en el flujo sanguíneo y la oxigenación de la sangre (señal BOLD), que están correlacionados con la actividad neuronal. Ofrece una excelente resolución espacial (milimétrica), lo que permite localizar con precisión las áreas cerebrales activas. Sin embargo, su resolución temporal es muy baja (del orden de segundos), ya que el flujo sanguíneo es un proceso mucho más lento que la actividad neuronal directa. Su uso en BCI es principalmente en neurofeedback en tiempo real para el entrenamiento de la autorregulación cerebral, pero no es práctica para el control de dispositivos en tiempo real debido a su baja latencia y el entorno restrictivo del escáner.

- **Espectroscopia de Infrarrojo Cercano Funcional (fNIRS):** Mide los cambios en la concentración de oxihemoglobina y desoxihemoglobina en la corteza cerebral superficial utilizando luz infrarroja. Es un método más portátil y menos costoso que la fMRI, y puede ser menos susceptible a artefactos de movimiento que el EEG en ciertas condiciones. Sin embargo, tiene una menor resolución espacial y temporal que el EEG y solo puede medir la actividad cortical superficial. Se utiliza en BCI para la detección de estados cognitivos o el control de sistemas sencillos basados en la activación de áreas específicas.

Para este trabajo, el **EEG** es la técnica no invasiva elegida y justificada debido a su equilibrio entre accesibilidad, portabilidad, resolución temporal adecuada para la detección de intención motora y, crucialmente, su perfil de bajo riesgo que permite su aplicación potencial en contextos de rehabilitación y uso domiciliario.

2.4.3. Paradigmas de BCI para el Control Motor

Los **paradigmas de BCI** se refieren a las diferentes estrategias que un usuario puede emplear para modular su actividad cerebral de manera controlada y, por ende, generar comandos para una interfaz cerebro-computadora. La elección del paradigma es fundamental, ya que determina el tipo de señal cerebral que la BCI intentará decodificar y, en última instancia, la usabilidad y el rendimiento del sistema. Para el control motor, varios paradigmas han demostrado ser efectivos, cada uno con sus propias bases neurofisiológicas y características.

2.4.3.1. Ritmos Sensorimotores (SMR) y Movimiento Imaginado (Motor Imagery - MI)

Este paradigma es el más relevante para el presente trabajo. Se basa en la capacidad del usuario para modular conscientemente la actividad eléctrica en las áreas corticales motoras y somatosensoriales, incluso en ausencia de movimiento físico. Como se detalló en la sección 2.1.2, los **ritmos sensorimotores (SMR)** son oscilaciones prominentes en las bandas **alfa (ritmo Mu, 8-13 Hz)** y **beta (13-25 Hz)**.

La clave del paradigma de MI reside en dos fenómenos opuestos pero interrelacionados:

- **Desincronización Relacionada con Eventos (ERD):** Cuando una persona realiza o **imagina un movimiento** de una extremidad específica, se produce una disminución significativa en la potencia de los ritmos Mu y Beta en la corteza sensorimotora **contralateral** a la extremidad imaginada. Por ejemplo, la imaginación del movimiento de la mano derecha resulta en una ERD en la corteza motora izquierda (electrodos C3). Esta desincronización refleja la activación de las poblaciones neuronales subyacentes, las cuales, al estar activas, se desincronizan de su estado de reposo oscilatorio. La magnitud y la topografía de esta ERD pueden ser cuantificadas y utilizadas como la señal de control para la BCI.
- **Sincronización Relacionada con Eventos (ERS):** En contraste, durante períodos de reposo o después de la finalización de un movimiento, la potencia de los ritmos Mu y Beta tiende a aumentar o "rebotar", indicando un estado de sincronización y supresión de la actividad motora. La ERS se observa, por ejemplo, en la corteza motora ipsilateral a un movimiento imaginado o en ambas cortezas durante un estado de reposo o relajación.

Para implementar este paradigma, los usuarios suelen ser instruidos para imaginar movimientos específicos (ej., mano izquierda, mano derecha, pie, lengua) o estados de reposo durante bloques de tiempo definidos. La BCI detecta los patrones de ERD/ERS resultantes y los mapea a comandos de control. El **entrenamiento** es fundamental, ya que los usuarios deben aprender a generar consistentemente los patrones de actividad cerebral deseados, y el sistema BCI, a su vez, debe **co-adaptarse** a la variabilidad individual del usuario. La **retroalimentación visual o auditiva** en tiempo real es crucial en este proceso, ya que permite al usuario ajustar su estrategia mental para optimizar el control. A pesar de su promesa, la variabilidad inter-sujeto (el fenómeno del "BCI illiteracy") y la necesidad de una concentración sostenida son desafíos que los investigadores buscan mitigar.

2.4.3.2. Potenciales Evocados Visuales en Estado Estacionario (SSVEP)

Los **SSVEP** son respuestas electroencefalográficas generadas en la corteza visual que se sincronizan con la frecuencia de un estímulo visual intermitente (parpadeante). Si un estímulo

visual parpadea a una frecuencia específica (ej., 10 Hz), la corteza visual generará una respuesta en la misma frecuencia (y sus armónicos) que puede ser detectada en los electrodos occipitales del EEG. [18]

En un paradigma SSVEP para BCI, se presentan múltiples objetos en una pantalla, cada uno parpadeando a una frecuencia diferente. El usuario enfoca su atención visual en el objeto que desea controlar. La BCI analiza el espectro de la señal EEG en las regiones occipitales y detecta la frecuencia dominante (aquella con mayor potencia) que coincide con la frecuencia de parpadeo de uno de los objetos. Esta frecuencia dominante se utiliza para inferir la intención del usuario. [19]

Las ventajas de los SSVEP son su **alta tasa de transferencia de información (ITR)**, lo que permite a los usuarios seleccionar comandos rápidamente, y el hecho de que generalmente **no requieren un entrenamiento extenso** por parte del usuario, ya que la respuesta es más automática. Sin embargo, pueden inducir **fatiga visual** con el uso prolongado y limitan la libertad de movimiento de los ojos y la cabeza del usuario, ya que requieren una fijación visual precisa.

2.4.3.3. Potencial P300

El **P300** es un componente de potencial relacionado con eventos (ERP) que se manifiesta como una onda positiva de gran amplitud, típicamente con una latencia de alrededor de 300 milisegundos después de un estímulo "blanco" (target) significativo o novedoso dentro de una secuencia de estímulos irrelevantes (distractores). Se asocia con procesos cognitivos como la detección de novedades, la atención selectiva y la actualización de la memoria de trabajo.

El paradigma más común para BCI basado en P300 es el **P300 Speller**. En este sistema, se presenta una matriz de letras o símbolos en una pantalla. Filas y columnas de la matriz parpadean aleatoriamente y en rápida sucesión. El usuario se concentra en la letra o símbolo deseado. Cuando la fila o columna que contiene la letra target parpadea, el cerebro del usuario genera un P300. El sistema detecta este P300 en el EEG (principalmente en electrodos

parietales) al promediar las respuestas a múltiples parpadeos, e identifica la fila y columna que se intersectan para determinar la selección del usuario. [20]

Las ventajas del P300 incluyen su naturaleza **no dependiente del movimiento físico**, lo que lo hace útil para pacientes con síndrome de enclaustramiento, y que es relativamente intuitivo para el usuario. Sin embargo, su **tasa de transferencia de información es más lenta** en comparación con los SSVEP, ya que requiere múltiples repeticiones de parpadeos para promediar la señal y detectar el P300 de forma fiable. También es sensible a la fatiga del usuario y a distracciones.

Otros paradigmas de BCI existen, como el uso de **Potenciales Corticales Lentos (SCP)**, que son cambios sostenidos en la polarización de la corteza, o incluso la decodificación directa de la actividad neuronal en **movimiento real ejecutado** (cuando hay movimiento residual), que se utiliza en algunas aplicaciones de neurorehabilitación. La selección del paradigma más adecuado depende de la aplicación específica, las capacidades del usuario y las limitaciones del hardware y software disponibles. [21]

2.4.4. Aplicaciones de las BCI

Las interfaces cerebro-computadora han trascendido el ámbito de la investigación para ofrecer soluciones transformadoras en múltiples campos, con un impacto especialmente significativo en la medicina y la tecnología de asistencia. Estas aplicaciones no solo mejoran la calidad de vida de las personas, sino que también abren nuevas fronteras en la interacción humano-máquina y la comprensión del cerebro. [22]

2.4.4.1. Asistencia a Personas con Discapacidades Motoras

Este es el campo de aplicación más prominente y el núcleo del presente Trabajo de Fin de Grado. Las BCI ofrecen una esperanza significativa para individuos que han perdido la movilidad debido a lesiones medulares, accidentes cerebrovasculares (ACV), esclerosis lateral amiotrófica (ELA) u otras condiciones neuromusculares degenerativas. [23]

- **Prótesis Robóticas y Neuroprótesis:** Las BCI permiten a los usuarios controlar prótesis de miembros superiores e inferiores con sus pensamientos. Los sistemas más

avanzados pueden decodificar intenciones motoras complejas (ej., agarrar un objeto, rotar la muñeca) a partir de la actividad de la corteza motora (mediante MI o implantes invasivos) y traducirlas en movimientos multi-grado de libertad en prótesis biónicas. A diferencia de las prótesis mioeléctricas tradicionales (que usan señales musculares residuales), las BCI pueden restaurar el control incluso en ausencia total de actividad muscular. La investigación en **neuroprótesis biónicas** va más allá del control motor, buscando también restaurar la retroalimentación sensorial (ej., sensación de tacto o presión) mediante la estimulación directa de nervios periféricos o áreas somatosensoriales del cerebro, lo que mejora drásticamente la usabilidad y la sensación de corporeidad. Proyectos de investigación y ensayos clínicos han demostrado el control exitoso de brazos robóticos avanzados en pacientes con tetraplejia, permitiéndoles realizar tareas cotidianas como beber café o usar una tablet.

- **Sillas de Ruedas Motorizadas y Vehículos Adaptados:** Las BCI pueden ser utilizadas para controlar la navegación de sillas de ruedas motorizadas. Los usuarios pueden dirigir la silla (adelante, atrás, girar) simplemente imaginando movimientos o enfocándose en estímulos visuales específicos. Los sistemas inteligentes incorporan algoritmos de seguridad y evitación de obstáculos, permitiendo a los usuarios con movilidad extremadamente limitada una forma independiente de desplazamiento en su entorno.
- **Exoesqueletos y Ortesis Robóticas:** En rehabilitación, los exoesqueletos robóticos son dispositivos portátiles que se ajustan a las extremidades y asisten o restauran el movimiento. Cuando se integran con BCI, el usuario puede "pensar" en mover una pierna, y el exoesqueleto se activa para ejecutar el movimiento, promoviendo así la neuroplasticidad y el reaprendizaje motor. Este enfoque, conocido como **neurorehabilitación asistida por BCI**, ha mostrado potencial en pacientes con ACV para mejorar la recuperación de la función motora. El bucle BCI-exoesqueleto permite al cerebro y al cuerpo trabajar en conjunto, incluso si el movimiento inicial es solo imaginado.

2.4.4.2. Comunicación Aumentativa y Alternativa (CAA)

Para personas con **síndrome de enclaustramiento** (estado en el que el paciente está completamente consciente pero no puede moverse ni comunicarse verbalmente) o fases avanzadas de enfermedades como la ELA, las BCI representan la única vía de comunicación. Los sistemas de "spellers" basados en P300 o SSVEP, o incluso aquellos que decodifican la imaginación motora de la "lengua" o los "labios", permiten a los usuarios seleccionar letras, palabras o frases en una pantalla, restaurando así su capacidad para expresar pensamientos y necesidades básicas. La **tasa de transferencia de información (ITR)**, que mide la velocidad a la que se puede comunicar información fiable, es una métrica clave para la usabilidad de estos sistemas.

2.4.4.3. Rehabilitación Neurocognitiva y Motora

Más allá de la asistencia directa, las BCI se utilizan en **neurofeedback**, una técnica donde los usuarios aprenden a autorregular su propia actividad cerebral. Por ejemplo, pacientes con Trastorno por Déficit de Atención e Hiperactividad (TDAH) pueden aprender a aumentar sus ondas beta para mejorar la concentración, o disminuir sus ondas theta para reducir la dispersión. En rehabilitación motora, el neurofeedback basado en BCI permite a los pacientes con ACV o lesiones medulares practicar la imaginación motora de un movimiento, y la [24]retroalimentación visual sobre su modulación del ritmo Mu refuerza los patrones neuronales correctos, promoviendo la **neuroplasticidad adaptativa** y la recuperación funcional. La combinación de BCI con realidad virtual o aumentada puede mejorar la inmersión y la eficacia de estas terapias.

2.4.4.4. Entretenimiento y Realidad Virtual

El sector del entretenimiento ha explorado las BCI para crear experiencias inmersivas y novedosas. Se han desarrollado **videojuegos controlados por la mente** donde los usuarios pueden interactuar con el entorno virtual o con elementos del juego utilizando su concentración o relajación (detectadas por el EEG). En entornos de **realidad virtual (RV)** o **realidad aumentada (RA)**, las BCI pueden proporcionar nuevas modalidades de

interacción, permitiendo a los usuarios navegar o manipular objetos virtuales solo con el pensamiento, lo que aumenta el nivel de inmersión y personalización de la experiencia.

2.4.4.5. Investigación Científica y Medicina

Las BCI son herramientas valiosas para la **investigación neurocientífica** básica, permitiendo a los investigadores estudiar la actividad cerebral en tiempo real durante diversas tareas cognitivas (atención, memoria, toma de decisiones) y la forma en que el cerebro procesa la información sensorial. También tienen un potencial significativo en el **diagnóstico y monitoreo** de trastornos neurológicos, como la epilepsia (detección de patrones pre-crisis), el monitoreo de estados de conciencia en pacientes en coma o la evaluación de la fatiga en contextos laborales. Algunas iniciativas, como **Neuralink**, buscan no solo restaurar funciones, sino también explorar el aumento de las capacidades cognitivas humanas y el tratamiento directo de afecciones neurológicas complejas como el Parkinson o el Alzheimer.

2.4.4.6. BCI y Enfermedades Neurodegenerativas

Las interfaces cerebro-computadora (BCI) están abriendo puertas a nuevas posibilidades, no solo en la restauración de funciones motoras, sino también en el abordaje de **enfermedades neurodegenerativas** y en el desarrollo de **aplicaciones innovadoras** que van más allá del ámbito clínico tradicional. Esta versatilidad subraya el potencial transformador de las BCI para mejorar la calidad de vida y para expandir la interacción entre humanos y tecnología.

Las **enfermedades neurodegenerativas** son trastornos progresivos y devastadores que afectan las neuronas y, por ende, las funciones cerebrales. Son un desafío médico global, pero las BCI ofrecen soluciones esperanzadoras para el **manejo sintomático** y la **investigación** de sus mecanismos.

- **Enfermedad de Parkinson (EP):** Este trastorno, causado por la pérdida de neuronas dopaminérgicas, provoca síntomas motores como temblor y rigidez. Las BCI pueden optimizar la **Estimulación Cerebral Profunda (DBS)**, un tratamiento ya existente para la EP. En lugar de una estimulación constante, las BCI "inteligentes" o

"adaptativas" pueden ajustar la estimulación en tiempo real, basándose en la actividad cerebral detectada por los electrodos implantados. Esto podría mejorar los resultados y reducir los efectos secundarios al activar la estimulación solo cuando sea necesario, por ejemplo, al detectar un temblor. Además, las BCI permiten la **monitorización continua** de la actividad cerebral en el hogar, ofreciendo datos valiosos para comprender la progresión de la enfermedad y ajustar tratamientos de forma personalizada. También se exploran para la **rehabilitación cognitiva y motora**, donde el neurofeedback ayuda a los pacientes a modular sus propias ondas cerebrales.

- **Esclerosis Lateral Amiotrófica (ELA):** Una enfermedad progresiva que paraliza gradualmente los músculos voluntarios, dejando a los pacientes conscientes pero incapaces de moverse o comunicarse, una condición conocida como **síndrome de enclaustramiento**. Para estas personas, las BCI no son solo una ayuda, son su **única vía de comunicación**. Sistemas como los "spellers" basados en P300 o SSVEP, o aquellos que decodifican sutiles señales de imaginación motora, les permiten seleccionar letras y formar frases. Investigaciones avanzadas buscan incluso la **síntesis de voz a partir de la actividad cerebral** para una comunicación más fluida. Las BCI también restauran la **autonomía** al permitirles controlar sillas de ruedas, asistentes domésticos y ordenadores.
- **Enfermedad de Alzheimer (EA) y Otras Demencias:** En trastornos caracterizados por el deterioro cognitivo progresivo, las BCI, aunque no ofrecen una cura, pueden ser útiles. En las etapas tempranas, el **neurofeedback** basado en BCI se investiga para ayudar a mantener o incluso mejorar funciones cognitivas residuales. En fases más avanzadas, podrían proporcionar vías de **comunicación básicas** o sistemas de alerta. También se estudian para monitorizar patrones cerebrales asociados a la progresión de la enfermedad o al riesgo de caídas, abriendo la puerta a intervenciones más tempranas y personalizadas.

2.4.5. Plataformas y Herramientas de BCI

El rápido avance de las interfaces cerebro-computadora y el procesamiento de señales EEG ha sido impulsado por la disponibilidad de diversas **plataformas de hardware y software** que facilitan la investigación, el desarrollo y la implementación de sistemas BCI. Estas herramientas han democratizado el acceso a la neurotecnología, permitiendo que un espectro más amplio de investigadores y desarrolladores contribuyan al campo.

- **OpenBCI:** Esta plataforma ha sido un pilar fundamental en la democratización de la tecnología BCI gracias a su filosofía de **código abierto**. OpenBCI proporciona hardware y software para la adquisición y análisis de señales biopotenciales, incluyendo EEG, EMG (electromiografía) y EKG (electrocardiografía). Sus placas de adquisición, como **Cyton (8 canales)**, **Ganglion (4 canales)** y **Daisy (16 canales, para extender Cyton)**, están diseñadas para ser flexibles y compatibles con electrodos estándar y soluciones de software. El hardware de OpenBCI destaca por su capacidad de muestreo de alta fidelidad, su configuración de código abierto que permite la modificación y la expansión, y su integración con software de adquisición de datos intuitivo (OpenBCI GUI) y kits de desarrollo (SDKs) para lenguajes como Python y MATLAB. Esta plataforma ha sido instrumental para que universidades, investigadores independientes y desarrolladores puedan experimentar y crear prototipos de BCI a una fracción del costo de los sistemas comerciales tradicionales, fomentando una comunidad activa y colaborativa.
- **OpenViBE:** Es una **plataforma de software libre y de código abierto** dedicada al diseño, prueba y uso de interfaces cerebro-computadora. Su principal fortaleza reside en su **arquitectura modular y su interfaz gráfica de usuario (GUI)**, que permite a los usuarios construir *pipelines* completos de BCI mediante un enfoque de "arrastrar y soltar" cajas funcionales. Cada "caja" representa un paso en el procesamiento de la señal (ej., adquisición, filtrado, extracción de características, clasificación, visualización, retroalimentación). OpenViBE soporta la adquisición de datos de múltiples dispositivos EEG (incluyendo OpenBCI), ofrece una amplia gama de algoritmos para **preprocesamiento** (ej., filtrado pasa banda, notch filters, ICA para eliminación de artefactos), **extracción de características** (ej., Common Spatial

Patterns - CSP, análisis de potencia espectral), y **clasificación** (ej., LDA, SVM). Su capacidad para el **procesamiento en tiempo real** y la creación de escenarios BCI personalizados lo hacen invaluable tanto para programadores experimentados que desean prototipar rápidamente, como para profesionales sin una sólida base en programación que necesitan validar conceptos.

- **Bitbrain:** Es una empresa española que ofrece **soluciones integrales de hardware y software** para aplicaciones BCI en el mundo real, con un enfoque en la investigación aplicada y el desarrollo de productos. Sus sistemas incluyen **equipos EEG portátiles y de alta calidad**, como el **Diadem (hasta 64 canales)**, que combinan robustez, facilidad de uso y alta calidad de señal, adecuados para entornos clínicos y de campo. Bitbrain proporciona **kits de desarrollo de software (SDKs)** en lenguajes como Python y C++, permitiendo a los desarrolladores crear aplicaciones personalizadas. La empresa ha participado en numerosos proyectos de investigación de vanguardia, como **MoreGrasp**, un proyecto europeo enfocado en desarrollar neuroprótesis avanzadas para apoyar la función de agarre en pacientes con tetraplejia mediante el control de la imaginación motora. Este tipo de proyectos ejemplifica cómo las plataformas comerciales se integran con la investigación académica para llevar las BCI del laboratorio a aplicaciones que mejoran la calidad de vida.

Además de estas plataformas, el ecosistema de desarrollo de BCI se beneficia enormemente de librerías y frameworks de programación. Para un trabajo basado en Python, herramientas como **MNE-Python** son fundamentales para el análisis y preprocesamiento de señales EEG. MNE-Python proporciona funciones robustas para la lectura de diversos formatos de datos, la aplicación de filtros, la segmentación de datos (*epoching*), la eliminación de artefactos (ej., ICA, SSP), y el análisis de potencia espectral y eventos. **SciPy** y **NumPy** son librerías esenciales para la computación numérica y científica, permitiendo operaciones eficientes con matrices, señales y cálculos estadísticos. **Scikit-learn** es un pilar para el aprendizaje automático, ofreciendo una amplia gama de algoritmos de clasificación (ej., LDA, SVM, *Random Forest*) y herramientas para la evaluación de modelos y la reducción de dimensionalidad (ej., PCA, LDA), con una API consistente que facilita su uso. Si se emplean técnicas de aprendizaje profundo, frameworks como **TensorFlow** o **PyTorch** son indispensables para construir y entrenar redes neuronales convolucionales (CNNs), redes

recurrentes (RNNs) o arquitecturas Transformer, aprovechando la computación en GPU para procesar grandes volúmenes de datos EEG y aprender representaciones complejas directamente de la señal. La combinación de estas herramientas de código abierto con plataformas de hardware flexibles permite a los investigadores explorar y desarrollar soluciones BCI innovadoras y robustas.

Capítulo 3 – Procesado de la señal encefalográfica

3.1. Introducción

El **procesamiento de señales electroencefalográficas (EEG)** es una disciplina crucial que transforma las señales eléctricas brutas del cerebro, inherentemente ruidosas y complejas, en información estructurada y significativa que puede ser interpretada por algoritmos de aprendizaje automático para el control de interfaces cerebro-computadora (BCI). Este proceso es un pilar fundamental en el éxito de cualquier sistema BCI, ya que la calidad y la fiabilidad de la información extraída de la señal neuronal impactan directamente en la precisión y la usabilidad de la interfaz. Desde la adquisición inicial hasta la clasificación final de la intención del usuario, cada etapa del procesamiento está diseñada para maximizar la relación señal-ruido, reducir la dimensionalidad de los datos y extraer las características neuronales más relevantes para la tarea específica.

3.2. Adquisición de señales EEG

La primera fase en el procesamiento de señales EEG es la **adquisición**, que se refiere al proceso de capturar la actividad eléctrica del cerebro. Esto se logra mediante la colocación de electrodos en el cuero cabelludo del sujeto, siguiendo sistemas estandarizados como el

Sistema Internacional 10-20 o el **10-10** para una mayor densidad, como se detalló en la Sección 2.2. Estos electrodos registran las diferencias de potencial generadas por la actividad sincrónica de las neuronas corticales. La calidad de la señal adquirida es el punto de partida y depende críticamente de factores como la baja **impedancia de contacto** entre los electrodos y la piel, la correcta ubicación de los electrodos de referencia y tierra, y la capacidad de los **amplificadores biopotenciales** para rechazar el ruido de modo común. Los sistemas de adquisición modernos, ya sean comerciales (como los de Bitbrain) o de código abierto (como OpenBCI), incluyen filtros analógicos para evitar el aliasing y convertidores analógico-digitales (ADC) que digitalizan la señal a una frecuencia de muestreo y resolución específicas. Una frecuencia de muestreo adecuada (ej., 250 Hz o más para EEG) es vital para capturar las dinámicas rápidas de las oscilaciones cerebrales, y una resolución de bits alta (ej., 24 bits) garantiza una representación precisa de la amplitud de la señal. La adquisición es el cimiento sobre el cual se construyen todas las etapas posteriores de procesamiento.

3.3. Preprocesamiento de señales EEG

Una vez adquiridas, las señales EEG rara vez están limpias; invariablemente están contaminadas por diversas fuentes de **ruido y artefactos**, que pueden enmascarar la actividad cerebral de interés. El **preprocesamiento** es, por lo tanto, una etapa esencial y a menudo la más crítica para mejorar la **relación señal-ruido (SNR)** y preparar los datos para un análisis significativo. Esta fase incluye varias técnicas:

- **Filtrado:** Se aplican filtros digitales para eliminar frecuencias no deseadas.
 - **Filtros pasa-banda:** Restringen la señal a un rango de frecuencia de interés (ej., 0.5-50 Hz para EEG, que incluye las bandas delta, theta, alfa, beta y gamma de baja frecuencia), eliminando derivas de línea base lentas y ruido de alta frecuencia.
 - **Filtros notch:** Son filtros de banda eliminada que se utilizan específicamente para suprimir la interferencia de la **línea de alimentación eléctrica** (50 o 60 Hz) y sus armónicos, que es una fuente de ruido ubicua.

- **Eliminación de Artefactos:** Los artefactos biológicos (EOG, EMG, ECG) y extrínsecos pueden ser de mucha mayor amplitud que la señal cerebral. Existen varias técnicas para su atenuación o eliminación:
 - **Corrección por Componentes Independientes (ICA):** Este algoritmo ciego de separación de fuentes descompone la señal EEG multicanal en un conjunto de componentes estadísticamente independientes. Muchos artefactos, como parpadeos o movimientos oculares, tienen una topografía y una dinámica temporal distintivas que los hacen separables como componentes independientes. Una vez identificados, estos componentes pueden ser eliminados y la señal EEG "limpia" reconstruida. ICA es especialmente potente para EOG y EMG.
 - **Regresión de Artefactos:** Utiliza el registro de canales dedicados a artefactos (ej., electrodos EOG alrededor de los ojos o ECG en el pecho) para modelar y restar la contribución del artefacto de los canales EEG.
 - **Thresholding y rechazo de épocas:** Identifica y elimina segmentos de datos (épocas) que contienen artefactos de muy alta amplitud.
 - **Re-referenciación:** Cambiar la referencia de la señal EEG puede ayudar a reducir el ruido común a todos los canales. Las referencias comunes incluyen el promedio de todos los canales (Average Reference), o electrodos específicos como las mastoides o el lóbulo de la oreja.
- **Normalización:** Ajustar la amplitud de las señales para reducir la variabilidad tanto entre sujetos (intersujeto) como dentro del mismo sujeto (intrasujeto) a lo largo del tiempo. Esto puede incluir escalado de amplitud o normalización de potencia para hacer que los datos sean más comparables para los algoritmos de aprendizaje automático.
- **Segmentación (Epoching):** La señal continua de EEG se divide en segmentos más cortos, llamados "épocas", que están sincronizados con eventos de interés (ej., el inicio de un bloque de imaginación motora, la presentación de un estímulo). Esto permite analizar la actividad cerebral en relación con eventos específicos.
- **Downsampling (Reducción de Muestreo):** Reducir la frecuencia de muestreo de los datos. Esto puede disminuir el tamaño de los datos y la carga computacional sin

perder información relevante, siempre que se cumpla el teorema de Nyquist para las frecuencias de interés.

El resultado de un preprocesamiento cuidadoso es una señal EEG significativamente más limpia y lista para la extracción de características.

3.4. Extracción de características

Una vez que la señal EEG ha sido preprocesada, el siguiente paso es la **extracción de características**. Este proceso implica transformar los datos brutos (o preprocesados) en un conjunto de valores numéricos que representan información relevante y discriminativa sobre la actividad cerebral asociada a una intención o estado mental específico. El objetivo es reducir la dimensionalidad de los datos a la vez que se maximiza la información útil para la clasificación. Las técnicas de extracción de características pueden operar en diferentes dominios:

- **Dominio del Tiempo:** Se analizan las propiedades de la señal directamente en función del tiempo.
 - **Estadísticas de Amplitud:** Valor medio, desviación estándar, picos, latencias de picos de potenciales evocados (ej., P300).
 - **Potenciales Relacionados con Eventos (ERPs):** El análisis de la forma de onda promedio de la señal en respuesta a eventos específicos (ej., el Potencial P300, el Potencial de Preparación).
 - **Parámetros de Hjorth:** Son tres parámetros que cuantifican la complejidad y la naturaleza de la señal: **Actividad** (potencia total), **Movilidad** (variación en la frecuencia dominante) y **Complejidad** (cambio en la frecuencia dominante).
- **Dominio de la Frecuencia:** Se analiza la contribución de diferentes bandas de frecuencia a la señal.
 - **Análisis Espectral (Potencia Espectral):** Se utiliza la **Transformada Rápida de Fourier (FFT)** para descomponer la señal en sus componentes de frecuencia y calcular la potencia (o densidad de potencia) en bandas específicas (delta, theta, alfa, beta, gamma). En el contexto de la intención

motora, la potencia en las bandas **Mu** y **Beta** es crucial para identificar la **ERD/ERS**. La potencia espectral de una señal $x(t)$ se calcula a menudo usando el periodograma de Welch o la Transformada de Fourier: $P(f)=|X(f)|^2$, donde $X(f)$ es la Transformada de Fourier de $x(t)$.

- **Filtros de Banco:** La señal se pasa a través de una serie de filtros pasa banda, cada uno sintonizado a una banda de frecuencia de interés, y luego se analiza la potencia o la energía dentro de cada banda.
- **Dominio Tiempo-Frecuencia:** Permite analizar cómo las componentes de frecuencia de la señal cambian a lo largo del tiempo, lo cual es útil para fenómenos no estacionarios como ERD/ERS.
 - **Transformada de Fourier de Período Corto (STFT):** Aplica la FFT a segmentos cortos y superpuestos de la señal, proporcionando un espectrograma que muestra cómo la potencia en cada frecuencia evoluciona con el tiempo.
 - **Transformada Wavelet Continua (CWT):** Descompone la señal en coeficientes wavelet en diferentes escalas (relacionadas con la frecuencia) y posiciones temporales, proporcionando una representación tiempo-frecuencia con mejor resolución temporal para altas frecuencias y mejor resolución de frecuencia para bajas frecuencias que la STFT.
- **Técnicas Espaciales:** Aprovechan la información de múltiples canales EEG para crear nuevas características.
 - **Common Spatial Patterns (CSP):** Es un algoritmo de reducción de dimensionalidad y extracción de características muy popular en BCI basadas en imaginación motora. CSP encuentra un conjunto de filtros espaciales que maximizan la varianza de una clase (ej., imaginación de mano derecha) mientras minimizan la varianza de otra clase (ej., imaginación de pie), haciendo que los patrones de ERD/ERS sean más discriminables. El resultado son componentes espaciales que representan la actividad de fuentes cerebrales específicas y cuya potencia filtrada es una característica muy potente para la clasificación.

- **Laplaciano de Superficie:** Es un filtro espacial que estima la segunda derivada espacial de la distribución de voltaje en el cuero cabelludo, lo que realza la actividad local y atenúa el efecto de volumen conductor.

La selección de la técnica de extracción de características depende del paradigma de BCI y del tipo de información que se desea decodificar. Para la imaginación motora, las características basadas en la potencia en las bandas Mu y Beta, a menudo realizadas con CSP, son las más utilizadas.

3.5. Reducción de la Dimensionalidad

Tras la extracción de características, el conjunto de datos resultante puede aún ser de muy alta dimensionalidad, lo que puede llevar a problemas de **sobreajuste** en el modelo de clasificación y a una mayor complejidad computacional. Las técnicas de **reducción de la dimensionalidad** buscan transformar el conjunto de características en un espacio de menor dimensión, manteniendo la información más relevante y eliminando la redundancia o el ruido.

- **Análisis de Componentes Principales (PCA):** Es una técnica lineal que encuentra un nuevo conjunto de variables (componentes principales) que son combinaciones lineales de las características originales, y que capturan la máxima varianza de los datos. Los primeros componentes principales representan la mayor parte de la información. PCA es útil para visualizar datos de alta dimensionalidad y para reducir el ruido al retener solo los componentes más significativos.
- **Análisis Discriminante Lineal (LDA):** Aunque también se utiliza como clasificador, LDA puede ser visto como una técnica de reducción de dimensionalidad que busca encontrar una proyección lineal de los datos que maximice la separación entre clases y minimice la varianza dentro de cada clase. Es particularmente efectivo cuando las clases son linealmente separables y los datos siguen una distribución gaussiana.

Al reducir la dimensionalidad, no solo se mejora la eficiencia computacional, sino que también se puede aumentar la precisión de los clasificadores al eliminar características ruidosas o irrelevantes.

3.6. Clasificación de señales EEG

La fase final del procesamiento de señales EEG en una BCI es la **clasificación**. En esta etapa, los vectores de características extraídos y reducidos se alimentan a un algoritmo de aprendizaje automático que ha sido entrenado para mapear estos patrones de actividad cerebral a comandos de control o a etiquetas de clase (ej., "intención de mover mano derecha", "intención de mover mano izquierda", "reposo"). La elección del clasificador es crucial para la precisión y la robustez del sistema BCI.

Algunos de los clasificadores más comunes y efectivos en el ámbito de las BCI incluyen:

- **Análisis Discriminante Lineal (LDA):** A pesar de su simplicidad, LDA es un clasificador muy popular y eficaz en BCI, especialmente cuando las características son linealmente separables. Busca una combinación lineal de las características que mejor separe las diferentes clases de actividad cerebral. Es computacionalmente eficiente y requiere menos datos de entrenamiento que modelos más complejos.
- **Máquinas de Vectores de Soporte (SVM):** Son clasificadores potentes que buscan encontrar un hiperplano óptimo en un espacio de alta dimensionalidad que maximice el margen entre las diferentes clases. Pueden manejar relaciones no lineales entre las características utilizando la técnica del "kernel trick" (ej., kernel RBF), lo que les permite clasificar patrones complejos de EEG. Las SVM han demostrado un buen rendimiento en diversas aplicaciones BCI.
- **Redes Neuronales Artificiales (ANN):** Modelos computacionales inspirados en la estructura del cerebro. Las ANN pueden aprender relaciones no lineales complejas entre las características de entrada y las clases objetivo. Los tipos de ANN más comunes incluyen los perceptrones multicapa (MLP). Su capacidad para modelar relaciones no lineales las hace útiles para señales EEG que a menudo exhiben variabilidad compleja.
- **Redes Neuronales Profundas (DNN):** Un subconjunto de ANN con múltiples capas ocultas, que han revolucionado el campo del aprendizaje automático. En BCI, las DNN (especialmente las **Redes Neuronales Convolucionales - CNNs** y, en menor medida, las **Redes Neuronales Recurrentes - RNNs**) pueden aprender

automáticamente características jerárquicas directamente de la señal EEG bruta o preprocesada, eliminando la necesidad de una extracción de características manual explícita. Esto es particularmente útil para capturar patrones espacio-temporales complejos. Sin embargo, requieren grandes volúmenes de datos de entrenamiento y una considerable potencia computacional. Ejemplos de arquitecturas CNN utilizadas en BCI incluyen EEGNet y Shallow/Deep ConvNet.

- **Clasificadores Ensemble (ej., *Random Forest*):** Combinan múltiples clasificadores más simples (ej., árboles de decisión) para mejorar el rendimiento y la robustez. Un *Random Forest*, por ejemplo, entrena múltiples árboles de decisión y combina sus predicciones.

La elección del clasificador adecuado depende de la complejidad de la tarea, la cantidad y calidad de los datos disponibles, la variabilidad inter-sujeto, y los requisitos de latencia y eficiencia computacional del sistema BCI. La validación cruzada rigurosa (ej., k-fold cross-validation) es esencial para evaluar el rendimiento del clasificador y evitar el sobreajuste.

3.7. Métricas de Evaluación del Rendimiento del Sistema

Para medir y validar el desempeño del sistema de reconocimiento de patrones basado en señales EEG, es necesario utilizar un conjunto de métricas que permitan evaluar tanto la precisión del modelo como su capacidad para detectar correctamente los eventos de interés. En el ámbito biomédico, donde la fiabilidad y la seguridad del sistema son críticas, la selección de estas métricas debe considerar no solo los aspectos habituales del aprendizaje automático, sino también las particularidades del contexto clínico y experimental. Las principales métricas empleadas en este trabajo son las siguientes:

- **Precisión (Accuracy):** La precisión representa la proporción de predicciones correctas —tanto verdaderos positivos como verdaderos negativos— respecto al total de casos evaluados. Aunque es una medida básica del rendimiento general, su interpretación debe realizarse con cautela en contextos donde las clases están

desbalanceadas, ya que un modelo puede mostrar alta precisión simplemente por acertar la clase mayoritaria.

- **Sensibilidad o Tasa de Verdaderos Positivos (Recall):** Mide la capacidad del sistema para detectar correctamente los eventos positivos (por ejemplo, la intención de movimiento). Es una métrica esencial en aplicaciones biomédicas, donde el fallo en la detección de un evento puede tener consecuencias relevantes. La sensibilidad se calcula como la proporción de verdaderos positivos sobre el total de positivos reales.
- **Especificidad (Specificity):** Evalúa la capacidad del sistema para identificar correctamente los eventos negativos, es decir, las situaciones donde no existe intención de movimiento. Una alta especificidad reduce la aparición de falsas alarmas, algo especialmente importante en sistemas que interactúan con el usuario o en aplicaciones clínicas.
- **Precisión (Precision o Valor Predictivo Positivo):** Determina qué proporción de las predicciones positivas realizadas por el sistema corresponden realmente a eventos positivos. Es crucial para valorar la fiabilidad del sistema al emitir un diagnóstico o decisión.
- **Puntuación F1 (F1-Score):** Esta métrica combina la precisión y la sensibilidad en una única medida, calculando su media armónica. Resulta particularmente útil en escenarios donde las clases están desbalanceadas o cuando es necesario equilibrar el impacto de los falsos positivos y los falsos negativos.
- **Área Bajo la Curva ROC (AUC-ROC):** La curva ROC analiza la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos para diferentes umbrales de decisión del clasificador. El área bajo esta curva (AUC) proporciona una medida robusta de la capacidad del modelo para distinguir entre las distintas clases.
- **Matriz de Confusión:** Representa de forma detallada los resultados de la clasificación, mostrando el número de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. Es una herramienta indispensable para interpretar el rendimiento del modelo y calcular las métricas mencionadas anteriormente.

Además de las métricas estándar, en sistemas basados en señales EEG aplicados al reconocimiento de patrones biomédicos, se consideran otros aspectos relevantes:

- **Tasa de Falsas Alarmas (FAR):** Corresponde al número de falsos positivos generados por unidad de tiempo o de análisis. En aplicaciones como la monitorización continua o las interfaces cerebro-computadora, un alto número de falsas alarmas puede generar rechazo por parte del usuario o disminuir la utilidad clínica del sistema.
- **Latencia o Tiempo de Detección:** Hace referencia al tiempo transcurrido entre la aparición real del evento (por ejemplo, la intención motora) y su detección efectiva por el sistema. En aplicaciones en tiempo real, como las BCI o sistemas de asistencia, una baja latencia es fundamental para garantizar una respuesta adecuada y natural.
- **Robustez frente a Artefactos:** Las señales EEG están sujetas a diversos tipos de artefactos (movimientos oculares, actividad muscular, interferencias eléctricas). Un sistema robusto es aquel capaz de mantener su rendimiento en presencia de estas perturbaciones, garantizando la fiabilidad del reconocimiento.
- **Generalización a Nuevos Sujetos o Condiciones:** Evalúa la capacidad del modelo para funcionar correctamente con datos de usuarios no presentes en el entrenamiento o en condiciones distintas. Esta métrica es clave para asegurar la viabilidad práctica del sistema y su posible aplicación en entornos clínicos reales.

Capítulo 4 – Las BCI y la privacidad

4.1. Consideraciones Éticas, Legales y Sociales en BCI

El rápido avance de las neurotecnologías, y en particular de las interfaces cerebro-computadora (BCI), ha abierto un campo de posibilidades sin precedentes para mejorar la calidad de vida y la autonomía de las personas. Sin embargo, esta capacidad de interactuar directamente con la actividad cerebral no solo plantea desafíos técnicos, sino también un conjunto complejo y multifacético de **consideraciones éticas, legales y sociales** que deben ser abordadas proactivamente para garantizar un desarrollo y una implementación responsables. La omisión de estas reflexiones podría conducir a dilemas morales, violaciones de derechos fundamentales y a una inequidad significativa en el acceso a estas tecnologías transformadoras.

4.2. Privacidad Mental y Neurodatos

La capacidad de las BCI para decodificar intenciones, estados emocionales o incluso predisposiciones cognitivas directamente de la actividad cerebral introduce una nueva dimensión en el concepto de **privacidad**. Los datos obtenidos del cerebro, conocidos como **neurodatos**, son inherentemente más sensibles que cualquier otro tipo de datos personales.

Revelan no solo lo que una persona hace o dice, sino lo que siente, lo que piensa o lo que podría estar a punto de hacer, sin que medie una acción consciente externa.

Actualmente, marcos legales de protección de datos robustos como el **Reglamento General de Protección de Datos (RGPD)** de la Unión Europea no contemplan específicamente a los neurodatos como una categoría con protecciones adicionales, más allá de considerarlos datos de salud. Sin embargo, existe un consenso creciente en la comunidad científica, legal y ética sobre la **necesidad urgente de establecer un marco regulatorio específico para los neurodatos**. Voces expertas, como las de la Agencia Española de Protección de Datos (AEPD, 2022) o iniciativas globales como la **Neurorights Initiative** liderada por figuras como Rafael Yuste, advierten que los derechos existentes son insuficientes para proteger la **privacidad mental y la identidad personal** en la era de las neurotecnologías.

En respuesta a esta preocupación, ha surgido el concepto de **Neuroderechos (Neuro-rights)**, que son derechos humanos fundamentales diseñados para proteger el cerebro y la mente de los posibles usos indebidos de las neurotecnologías. Los neuroderechos propuestos típicamente incluyen:

- **Derecho a la Privacidad Mental:** Proteger los neurodatos de su acceso, uso o venta no autorizado.
- **Derecho a la Identidad Personal:** Proteger la esencia de la identidad de un individuo de ser alterada por la neurotecnología.
- **Derecho al Libre Albedrío y a la Autonomía de Decisión:** Asegurar que las neurotecnologías no manipulen o interfieran con la capacidad de una persona para tomar decisiones de forma independiente.
- **Derecho a la Protección contra el Sesgo Algorítmico:** Garantizar que los algoritmos de BCI no perpetúen o amplifiquen sesgos que puedan conducir a la discriminación.
- **Derecho al Acceso Equitativo a la Neurotecnología:** Asegurar que estas tecnologías beneficien a toda la sociedad y no solo a una élite privilegiada.

La posibilidad de que una empresa o un gobierno puedan inferir o incluso influir en los pensamientos o intenciones de una persona, incluso con fines aparentemente benignos,

plantea serias interrogantes sobre la libertad cognitiva y la soberanía individual. Por ello, cualquier sistema BCI debe garantizar la **protección rigurosa de estos datos**, obtener un **consentimiento informado** explícito y comprensible, asegurar la **trazabilidad** del tratamiento de los datos y definir una **finalidad explícita y limitada** para su uso. El establecimiento de estándares de seguridad cibernetica robustos para proteger los neurodatos es también crucial para prevenir la piratería mental o el acceso no autorizado.

4.3. Consentimiento Informado y Transparencia Algorítmica

El principio de **consentimiento informado** es fundamental en cualquier intervención médica o tecnológica que afecte a un individuo, pero adquiere una complejidad particular en el contexto de las BCI. Dada la naturaleza intrínsecamente personal y sensible de los neurodatos, el consentimiento debe ser más que una simple firma; debe ser un proceso continuo y profundamente comprensivo. Es crucial que los usuarios, especialmente aquellos con discapacidades cognitivas o de comunicación, entiendan plenamente:

- La naturaleza y el alcance de la tecnología BCI.
- Los tipos de neurodatos que se recopilan y cómo se utilizan.
- Los riesgos potenciales (ej., invasividad en BCI quirúrgicas, errores de decodificación, privacidad de datos).
- Los beneficios esperados y las limitaciones reales.
- Las opciones alternativas disponibles.
- Su derecho a retirar el consentimiento en cualquier momento.

La **transparencia algorítmica** o **Inteligencia Artificial Explicable (XAI)** es otra consideración ética vital. Los sistemas BCI se basan en algoritmos complejos de aprendizaje automático que pueden operar como "cajas negras", haciendo que sus decisiones o interpretaciones sean opacas. Para generar confianza y garantizar la responsabilidad, es fundamental que el funcionamiento de estos algoritmos sea lo más transparente posible. Los usuarios, sus cuidadores y los profesionales de la salud deben poder entender *por qué* el sistema interpreta una señal de una determinada manera, *cómo* traduce una intención cerebral en un comando específico, o *qué* factores influyen en su rendimiento. La falta de transparencia puede llevar a la desconfianza, dificultar la depuración de errores y hacer

imposible la rendición de cuentas en caso de fallos. El desarrollo de técnicas XAI en BCI es un área activa de investigación.

Relacionado con la transparencia, existe el riesgo de **sesgo algorítmico**. Si los datos de entrenamiento utilizados para desarrollar un clasificador BCI provienen de un grupo demográfico limitado (ej., solo hombres jóvenes diestros, o solo un tipo de lesión específica), el algoritmo puede tener un rendimiento inferior o incluso ser ineficaz para usuarios que difieren de la población de entrenamiento (ej., mujeres, zurdos, ancianos, personas con diferentes etiologías de discapacidad). Esto puede llevar a la **discriminación tecnológica** y a que los beneficios de las BCI no estén distribuidos equitativamente. La creación de bases de datos de neurodatos diversas y representativas, junto con técnicas de aprendizaje automático que mitiguen el sesgo, son esenciales para la equidad.

4.4. Accesibilidad y Equidad en la Neurotecnología

La promesa transformadora de las BCI solo se materializará si estas tecnologías son **accesibles y equitativas** para todas las personas que puedan beneficiarse de ellas, independientemente de su situación socioeconómica, geográfica o de cualquier otra característica. Existe un riesgo inherente de que, al ser tecnologías de vanguardia y potencialmente costosas, las BCI se conviertan en un privilegio para unos pocos, exacerbando las brechas sociales y de salud.

La **democratización de las neurotecnologías** es un objetivo ético crucial. Iniciativas como **OpenBCI**, que promueve hardware y software de código abierto y bajo costo, o proyectos de investigación universitarios (como el impulsado por la Universidad Politécnica de Cartagena, UPCT, 2021, que ha demostrado la viabilidad de sistemas EEG funcionales por una fracción del costo comercial), son fundamentales para hacer que las BCI sean más asequibles y disponibles a nivel mundial. La promoción de la **investigación de código abierto** fomenta la colaboración y reduce las barreras de entrada para desarrolladores e investigadores.

Además del costo del hardware, la **accesibilidad implica la facilidad de uso, la formación y el apoyo**. Los sistemas BCI deben ser intuitivos y personalizables para diferentes perfiles

de usuario. Se requiere una inversión en la formación de profesionales de la salud, ingenieros y, crucialmente, de los propios usuarios y sus cuidadores, para que puedan operar y mantener estas tecnologías de manera efectiva. Las políticas públicas y las iniciativas de financiación son esenciales para subsidiar el acceso a las BCI, integrarlas en los sistemas de salud y rehabilitación, y asegurar que la innovación llegue a las poblaciones más vulnerables que más se beneficiarían de ellas. Sin un enfoque proactivo en la equidad, las BCI, a pesar de su potencial, podrían convertirse en una nueva fuente de desigualdad.

4.5. Responsabilidad y Autonomía

La integración de las BCI en la vida cotidiana plantea preguntas complejas sobre la **responsabilidad** y la **autonomía personal**.

- **Responsabilidad:** ¿Quién es legalmente responsable cuando una BCI comete un error, o cuando un dispositivo controlado por la mente causa un daño? ¿Es el usuario, el fabricante del hardware, el desarrollador del software, el médico que implantó o ajustó el sistema, o la propia inteligencia artificial que decodifica la señal? A medida que los sistemas BCI se vuelven más autónomos y complejos, la atribución de responsabilidad se vuelve difusa, lo que requiere nuevos marcos legales para la responsabilidad civil y penal. Por ejemplo, en caso de que una prótesis robótica controlada por BCI impacte a alguien, ¿cómo se determina la culpabilidad si la intención del usuario era una, pero la interpretación del sistema y la ejecución del dispositivo fueron otras?
- **Autonomía y Libre Albedrío:** Las BCI tienen el potencial de restaurar la autonomía en individuos que la han perdido debido a una discapacidad severa, lo que es un beneficio ético incuestionable. Sin embargo, también plantean preguntas sobre la **integridad de la autonomía y el libre albedrío** si la tecnología pudiese, en un futuro hipotético, influir, manipular o incluso alterar la toma de decisiones o la percepción del usuario sin su pleno consentimiento. Aunque esto se sitúa en el ámbito de la ciencia ficción por ahora, el debate neuroético debe anticiparse a estas posibilidades. ¿Podría la retroalimentación de una BCI condicionar la forma en que pensamos o

sentimos? ¿Sería el uso de una BCI en un contexto no médico, como la mejora cognitiva, una forma de coerción o de alteración de la identidad?

- **Implicaciones Sociales y Percepción Pública:** La integración de BCI en la sociedad también requiere una consideración cuidadosa de la percepción pública. La desinformación o la ansiedad sobre la "lectura de la mente" o la " fusión humano-máquina" pueden obstaculizar la aceptación de estas tecnologías, incluso aquellas con beneficios terapéuticos claros. Es fundamental fomentar un diálogo abierto y educar a la sociedad sobre el verdadero alcance y las limitaciones de las BCI, desmitificando conceptos y promoviendo una visión equilibrada y responsable.

En última instancia, el desarrollo de las interfaces cerebro-computadora debe ser guiado por principios éticos que prioricen la dignidad humana, la autonomía, la justicia y la no maleficencia. Estas reflexiones no deben verse como obstáculos al progreso científico, sino como componentes integrales que aseguran que la tecnología se desarrolle al servicio de las personas y de la sociedad en su conjunto, garantizando que cada avance esté firmemente arraigado en un marco de responsabilidad y valores humanos.

Capítulo 5 – Procesado y análisis de la señal EEG

5.1. Base de datos

Para la realización de esta investigación, se emplea un conjunto de datos de electroencefalogramas (EEG) relacionado con el movimiento, disponible públicamente en el portal PhysioNet y publicado en septiembre de 2009. Este *dataset* comprende un total de 1526 registros, obtenidos de 109 participantes voluntarios. Cada registro tiene una duración variable de entre uno y dos minutos. Cabe destacar que la base de datos no incluye información demográfica o de salud detallada de los participantes.

Sistema de Adquisición EEG

La adquisición de las señales EEG se realizó utilizando un sistema basado en la nomenclatura 10-10 de electrodos, una versión optimizada del estándar 10-20. Este sistema mantiene la distribución topográfica del 10-20, pero con una densidad de electrodos reducida, lo que simplifica su configuración y manejo. De acuerdo con esta disposición, se registraron 64 canales de EEG, numerados del 0 al 63.

Diseño Experimental (Tareas)

El paradigma experimental consistió en la ejecución y la imaginación de diversas tareas motoras, diseñadas para generar patrones de actividad cerebral relevantes para la predicción de intenciones motoras. Las acciones registradas incluyeron:

- Movimiento de Puño Real: Abrir y cerrar el puño izquierdo o derecho, según una señal visual en pantalla.
- Movimiento de Puño Imaginado: Imaginar la acción de abrir y cerrar el puño izquierdo o derecho ante una señal visual en pantalla.
- Movimiento de Puños o Pies Real: Abrir y cerrar ambos puños (si el objeto visual estaba en la parte superior de la pantalla) o ambos pies (si el objeto estaba en la parte inferior).
- Movimiento de Puños o Pies Imaginado: Imaginar la acción de abrir y cerrar ambos puños o ambos pies según la posición del objeto en pantalla.

Adicionalmente, se incluyeron dos condiciones de reposo como referencia básica: con ojos abiertos y con ojos cerrados. Cada una de las 4 tareas motoras, junto con las 2 condiciones de reposo, fue repetida 3 veces por cada participante. Esto resultó en un total de 14 registros por voluntario, sumando los 1526 registros globales del *dataset*.

Volumen de Datos

Considerando que cada uno de los 1526 registros contiene datos de los 64 electrodos, el volumen total de datos a procesar asciende a 97.664 señales individuales. Este amplio volumen de datos facilita un análisis detallado de la actividad cerebral en diversas condiciones motoras y de reposo.

Etiquetado de los Registros

Los registros de EEG, excluyendo las mediciones de referencia, están etiquetados temporalmente para indicar el estado del voluntario (reposo o ejecución/imaginación de una acción específica). Este esquema de etiquetado es crucial para identificar los momentos precisos de la intención motora y facilitar el análisis de patrones. Las etiquetas son las siguientes:

- T0: Indica un estado de reposo del voluntario, sin realizar ninguna acción motora.
- T1: Señala el inicio de un movimiento (real o imaginario) del puño izquierdo (en registros específicos) o de ambos puños simultáneamente (en otros registros).
- T2: Señala el inicio de un movimiento (real o imaginario) del puño derecho (en los mismos registros que T1 para puños individuales) o de ambos pies simultáneamente (en los mismos registros que T1 para puños dobles).

Este etiquetado permitirá la identificación precisa de los momentos asociados a la intención motora, un aspecto fundamental para el análisis y la predicción de patrones en la actividad cerebral.

El objetivo central de esta investigación es extraer información relevante de los registros EEG para evaluar la actividad cerebral asociada tanto a movimientos voluntarios como imaginados. Se aplicarán diversas técnicas de procesamiento de señales y aprendizaje automático con el fin de identificar patrones distintivos en los datos que permitan predecir la intención motora.

En la imagen, podemos observar las 64 señales registradas desde todos los electrodos, cada una debidamente etiquetada según su posición en el sistema 10-10. La grabación tiene una duración de 60 segundos y corresponde a una de las mediciones de referencia. Dado que esta señal se obtiene en una condición de reposo, no contiene etiquetas de actividad asociadas a movimientos reales o imaginarios. Por lo tanto, durante toda la grabación, el estado del EEG se mantiene en T0, indicando que el voluntario no está realizando ninguna acción motora. Este registro sirve como una línea base para comparar la actividad cerebral en estado de reposo con la registrada durante la ejecución o imaginación de movimientos.

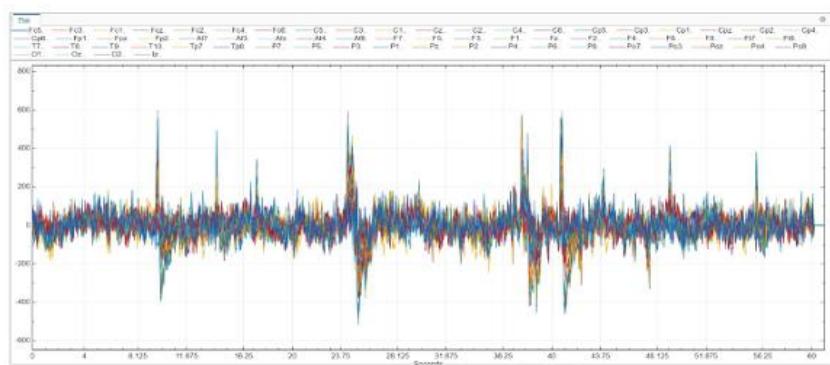


Figura 5.1 – Señales registradas de electrodos

5.2. Resultados del procesado de la señal

El desarrollo de la integración de los datos se realizó en el software Matlab como estructura fundamental del complemento a nuestra investigación.

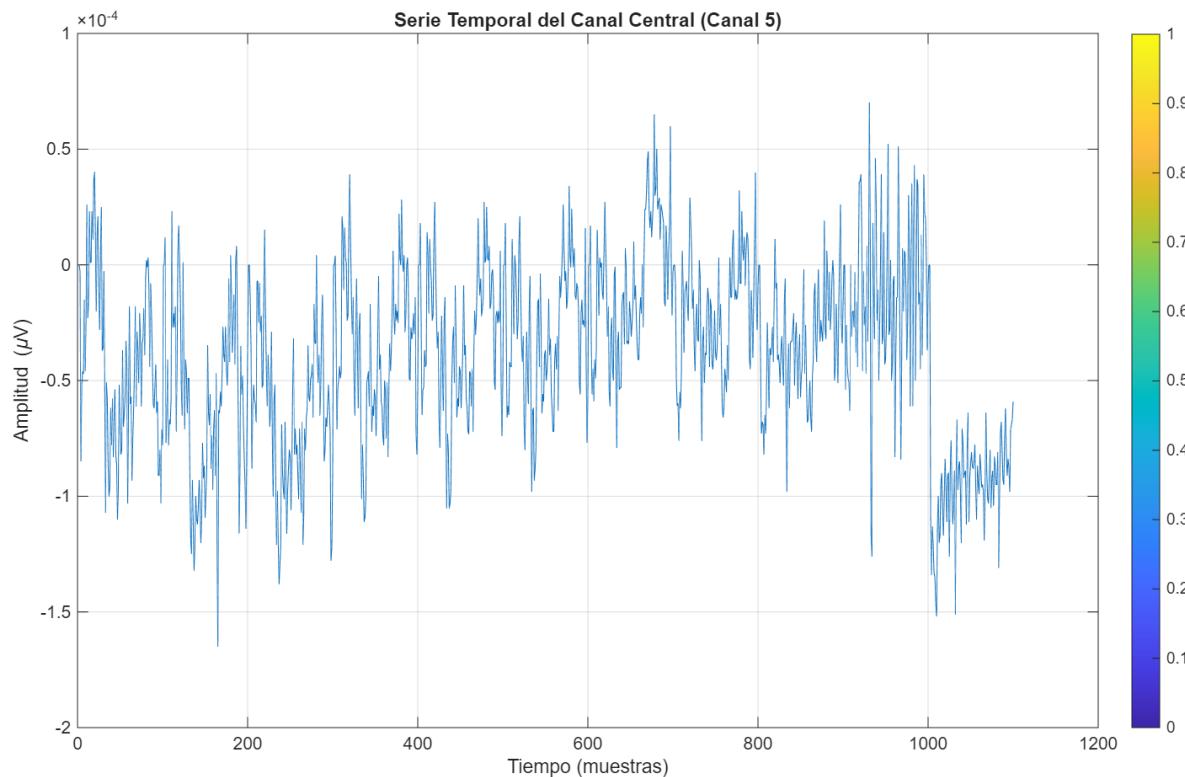


Figura 5.2 – Serie Temporal del Canal Central

La gráfica representa una **serie temporal de señales EEG** del **canal 5**, probablemente correspondiente a una posición específica del casco EEG (según el sistema 10-10).

Detalles técnicos de la gráfica:

- **Eje X (horizontal):** Número de muestras en el tiempo. Es decir, muestra la evolución de la señal a lo largo del tiempo (en pasos de muestreo).
- **Eje Y (vertical):** Amplitud de la señal EEG en microvoltios (μ V), aunque aquí parece estar aún en una escala muy baja (probablemente por normalización).

Indica que se graficó una señal. Esta señal es una **medición de la actividad eléctrica del cerebro** captada desde un punto específico del cuero cabelludo.

- Las **fluctuaciones** son variaciones naturales en la actividad cerebral.
- La **forma osculatoria** es típica de las ondas EEG, que varían en frecuencia y amplitud según el estado mental (reposo, movimiento, imaginación).
- Si el canal corresponde a una zona motora (como Cz o C3/C4), entonces esta señal es clave para detectar intención de movimiento real o imaginado.

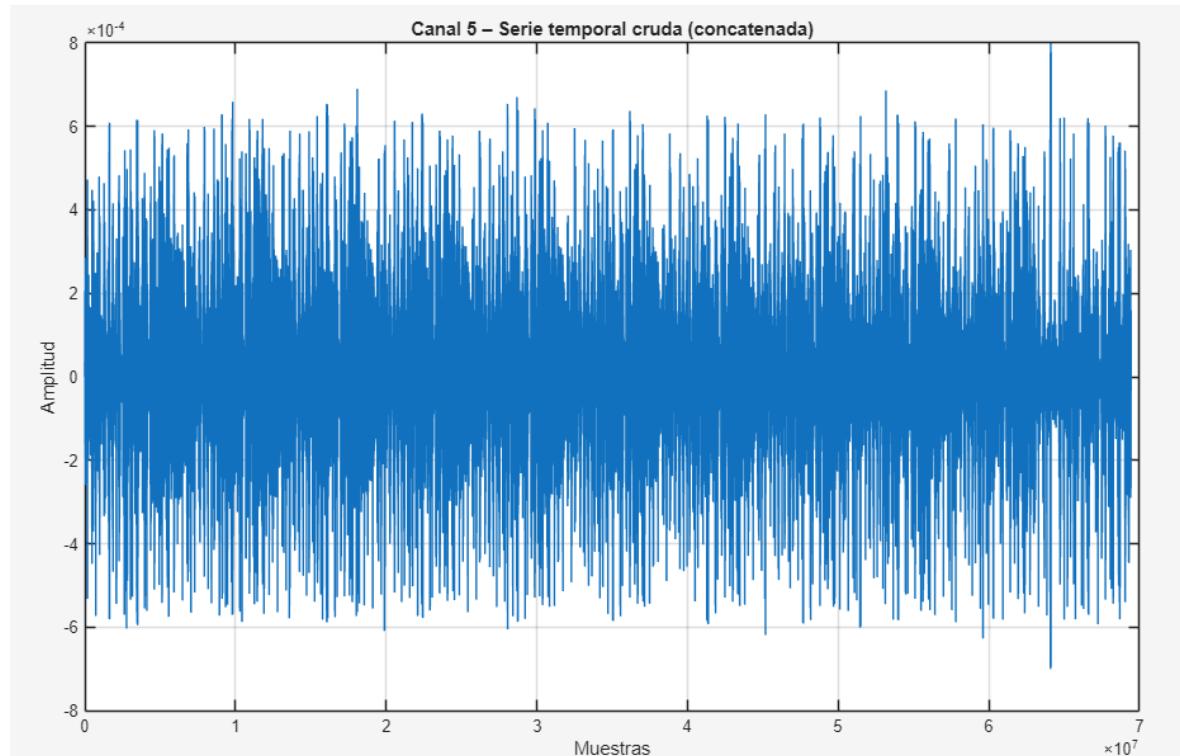


Figura 5.3 – Serie Temporal Cruda

Esta gráfica muestra la señal EEG cruda, sin filtrar ni segmentar, correspondiente al Canal 5 de tu matriz EEG. La señal ha sido concatenada, es decir, se ha juntado una tras otra toda la actividad EEG registrada en este canal a lo largo de múltiples ensayos, bloques y condiciones (T0, T1, T2).

Ejes del gráfico:

- Eje X (Muestras): Representa los puntos de tiempo en la señal. La escala muestra millones de muestras, lo que confirma que se están visualizando muchos registros seguidos.
- Eje Y (Amplitud): Muestra la amplitud de la señal en unidades normalizadas (no microvoltios explícitamente, pero muy pequeñas, $\sim 10^{-4}$).

No hay eventos aislables: Dado que es la señal completa concatenada, **no se pueden identificar visualmente los momentos en que el sujeto realizaba tareas motoras** (como imaginar o ejecutar movimientos). Por eso, esta visualización es útil solo como vista general.

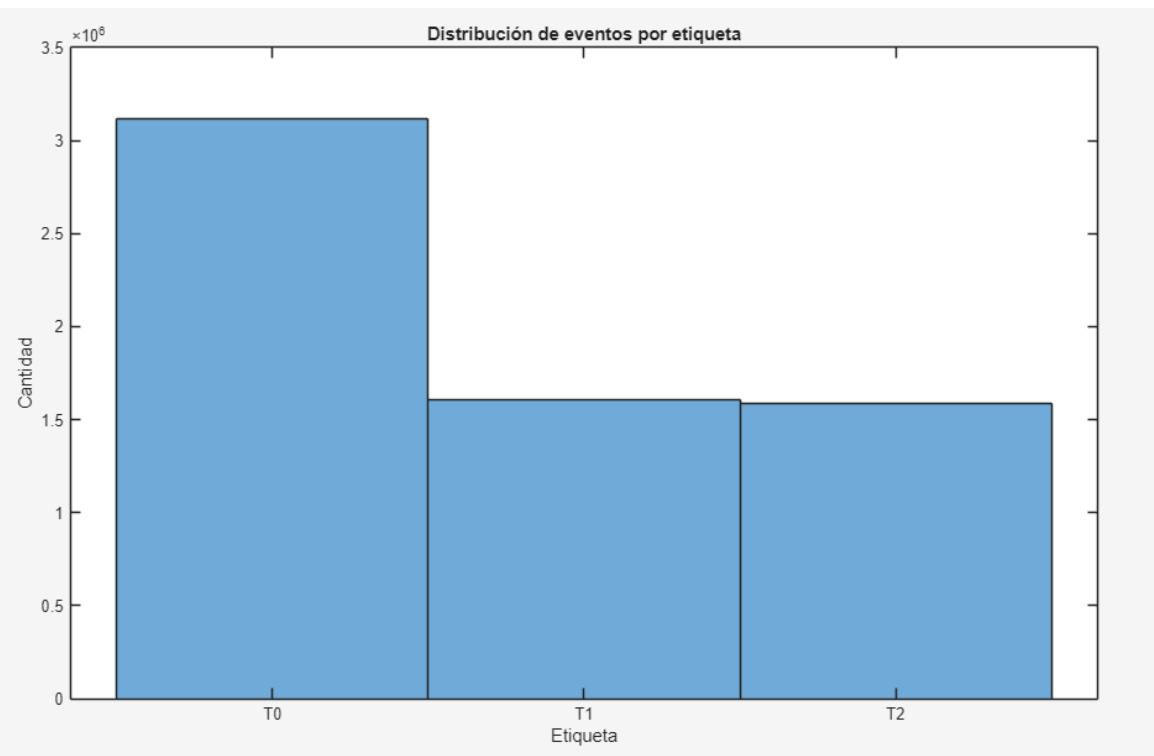


Figura 5.4 – Distribución de eventos por etiqueta

Esta gráfica de barras representa la **distribución de las etiquetas** en tu conjunto de datos EEG. Las etiquetas corresponden a diferentes **condiciones experimentales** en las que los participantes realizaron (o imaginaron) tareas motoras:

- **T0:** Reposo (sin movimiento)
- **T1:** Movimiento o imaginación de movimiento del **puño izquierdo o ambos puños**

- **T2:** Movimiento o imaginación de movimiento del **puño derecho o ambos pies**
- **Eje X (Etiqueta):** Muestra las tres clases de eventos: T0, T1 y T2.
- **Eje Y (Cantidad):** Número de muestras en cada categoría (nota que el eje está en el orden de **cientos de millones**, es decir, hay una gran cantidad de datos).

T0 (reposo): Tiene más de 3.1 millones de muestras. Es la clase más frecuente, lo cual es común, ya que el reposo suele ser más duradero o usado como condición base.

T1 y T2: Tienen cada una cerca de 1.6 millones de muestras. Este balance es razonable y muestra que hay suficiente información para comparar condiciones motoras reales o imaginadas.

- **Dataset balanceado:** Aunque T0 tiene más datos, T1 y T2 tienen cantidades similares, lo cual es **positivo para el análisis comparativo y clasificación**.
- **Base para segmentación:** Esta gráfica te da una idea clara de **cuántos eventos puedes segmentar y analizar** por clase (por ejemplo, para calcular ERP, espectros o entrenar clasificadores).
- **Importancia para BCI:** Para un sistema BCI, es esencial que las clases motoras (T1 y T2) tengan buena representación. Esta gráfica confirma que hay datos suficientes para entrenar modelos confiables.

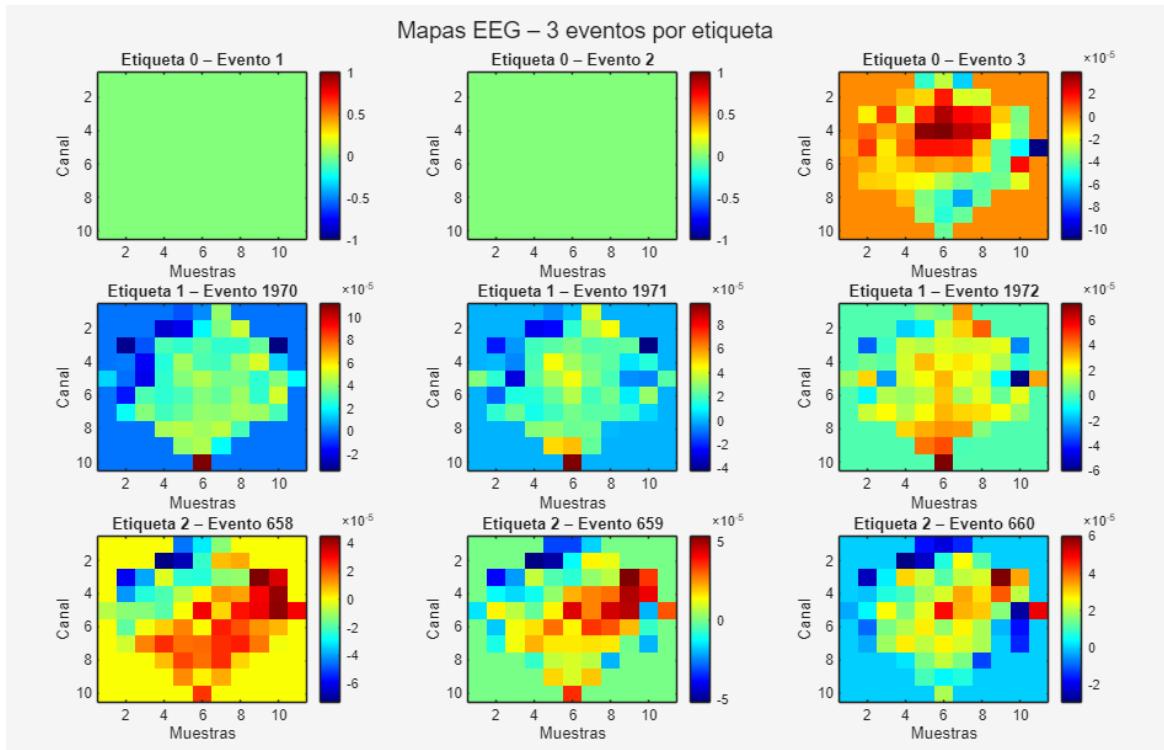


Figura 5.5 – Mapas EEG

Esta figura muestra **9 mapas de calor** (heatmaps) que visualizan la **actividad EEG registrada** en todos los canales y en diferentes muestras temporales para **3 eventos por cada etiqueta**.

- Cada mapa representa un **evento único de EEG** codificado por una etiqueta: T0, T1, o T2.
- Las filas representan **etiquetas (clases)**:
 - Fila 1: Etiqueta 0 → Reposo
 - Fila 2: Etiqueta 1 → Movimiento/Imaginación de puño izquierdo o ambos
 - Fila 3: Etiqueta 2 → Movimiento/Imaginación de puño derecho o ambos pies
- Las columnas muestran **3 ejemplos distintos (eventos)** de cada etiqueta.

Etiqueta 0 (Reposo)

- **Eventos 1 y 2** muestran actividad neutra (verde uniforme), lo que indica **poca variación** — típico del estado de reposo sin estimulación.

- **Evento 3** muestra un pequeño patrón activado, posiblemente **ruido o una transición accidental a otro estado**.

Etiqueta 1 (Movimiento/Imaginación de brazo)

- Muestran activación concentrada, especialmente en canales centrales y superiores.
- Se observa un **patrón circular simétrico** que podría estar asociado a la actividad motora relacionada con el puño izquierdo.

Etiqueta 2 (Movimiento/Imaginación de pierna)

- Activación intensa en la zona **inferior-central** del mapa, indicando una posible **respuesta somatosensorial** relacionada con los pies.
- Cambios más intensos en amplitud, lo que indica una **diferencia clara en la activación cerebral** frente a otras etiquetas.

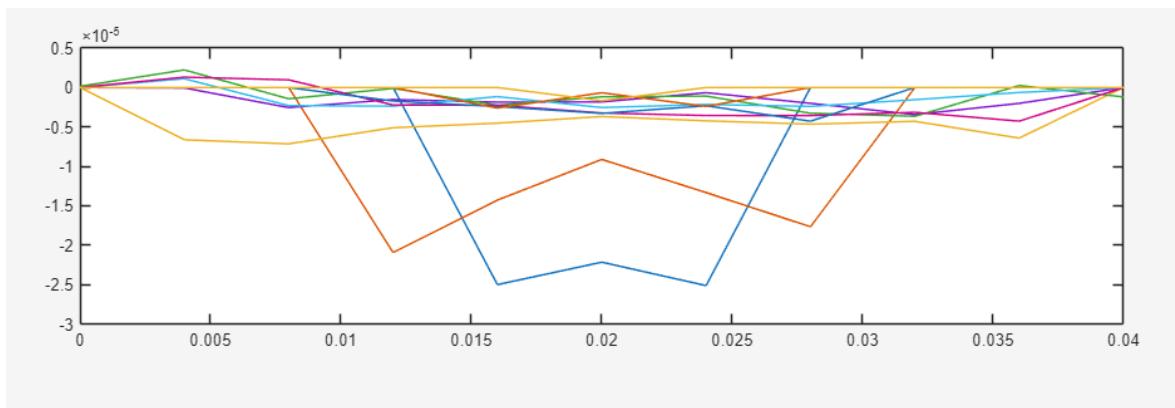


Figura 5.6 – Gráfica de línea multicanal

Gráfica de línea multicanal

- **10 líneas de colores** = 10 canales de EEG.
- Cada canal muestra una **respuesta temporal** breve, que podría estar capturando un evento neurológico como una intención de movimiento.
- En el centro del gráfico (entre 0.015 y 0.025), se observan **cambios abruptos** en dos canales (líneas azul y naranja), indicando una **activación localizada** en el tiempo. Es posible que esos canales estén ubicados en zonas motoras del cerebro.

- El resto de los canales muestran variaciones más suaves o cercanas a cero, lo cual es normal si el estímulo fue focalizado.

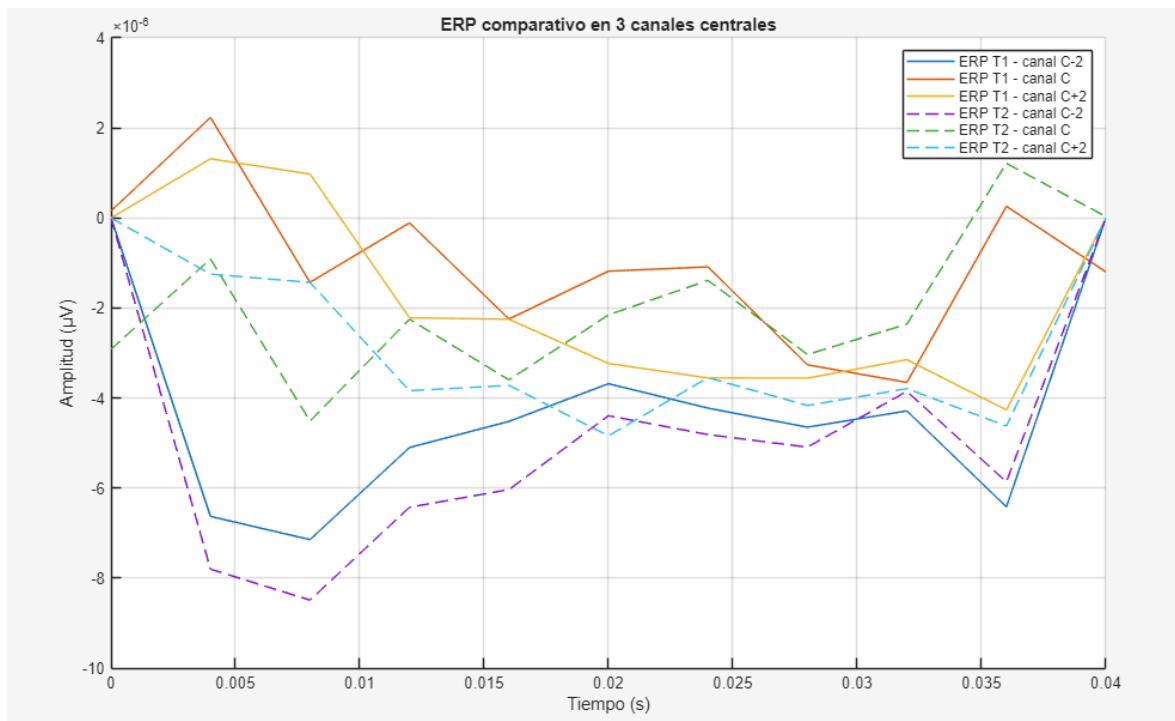


Figura 5.7 – ERP comparativo en canales centrales

- **Eje X – Tiempo (segundos):** Indica el tiempo transcurrido durante cada evento. La ventana va desde 0 hasta ~ 0.04 s, lo cual es una típica duración de análisis ERP en estudios EEG.
- **Eje Y – Amplitud (μV):** Muestra la respuesta eléctrica media del cerebro. Picos negativos/positivos indican actividad neuronal sincronizada en respuesta al estímulo.

Comparación entre condiciones T1 y T2:

- En la mayoría de los puntos temporales, T1 presenta mayor deflexión negativa (potencial más profundo), especialmente entre 5 ms y 30 ms.
- Esto puede interpretarse como una **mayor activación cortical** para eventos T1 en esos canales.
- Las diferencias en amplitud y forma del ERP son relevantes y podrían usarse como **características discriminativas para clasificación BCI**.

Comparación entre canales:

- Los tres canales muestran trayectorias similares, pero no idénticas.
- Esto sugiere que hay cierta **distribución espacial del procesamiento cerebral**, posiblemente centrado en el canal medio (C).

La figura muestra la evolución temporal del ERP promedio en tres canales centrales para eventos T1 y T2. Se observa una mayor deflexión negativa en la condición T1, lo que sugiere una mayor actividad neuronal evocada. Este comportamiento es consistente en los canales seleccionados, lo que respalda su uso como regiones de interés en la clasificación de señales EEG para interfaces cerebro-computadora (BCI).

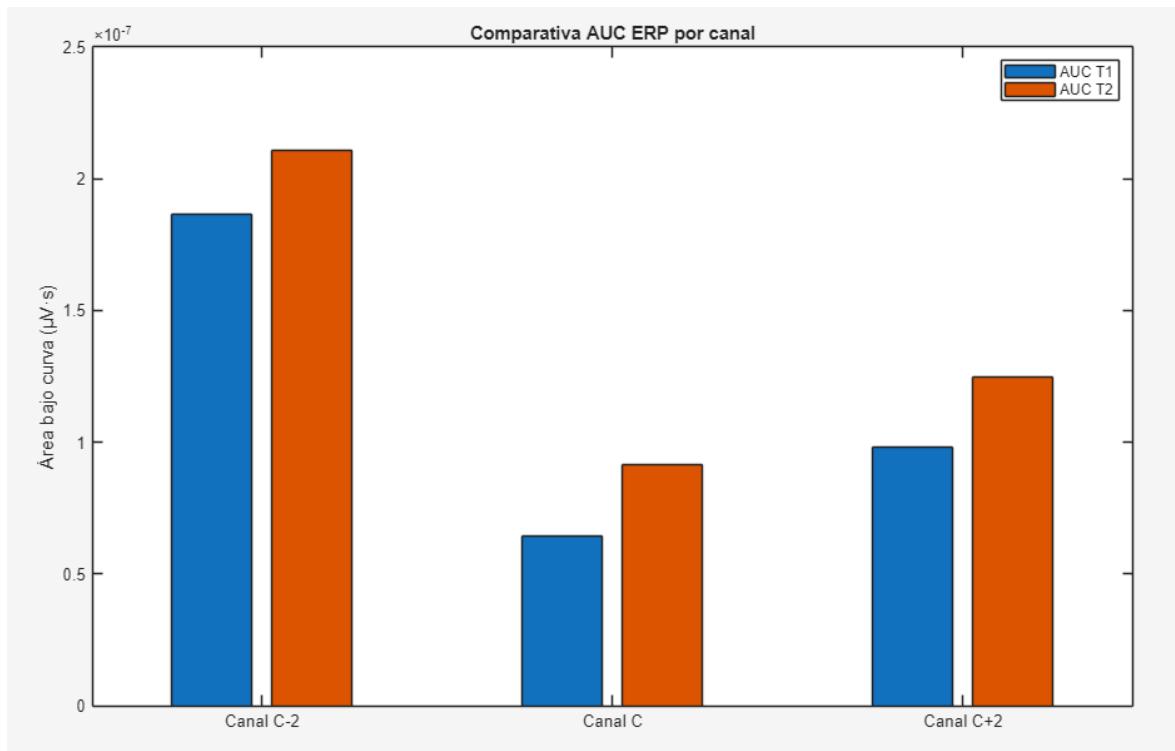


Figura 5.8 – Comparativas de área bajo curva de canales adyacentes

- **Eje X – Canales centrales:** Indica los tres canales seleccionados para comparar (posiciones relativas -2, 0, +2).
- **Eje Y – Área bajo la curva (μ V·s):** Mide la **carga eléctrica total** (positiva o negativa) generada por la actividad cerebral ante el estímulo.

Análisis comparativo:

- En **los tres canales**, la condición **T2** presenta mayor AUC que T1.
- Esto sugiere que los estímulos T2 provocan una **respuesta cortical más intensa** en términos de energía total. Se observa que el área bajo la curva (AUC) del ERP es consistentemente mayor para la condición T2 en los canales centrales evaluados. Esta diferencia cuantitativa sugiere una mayor implicación neuronal o carga sináptica frente a los estímulos T2, siendo el canal C-2 el más relevante. Este resultado refuerza el potencial de estas métricas como características discriminativas para el entrenamiento de modelos en BCI.
- El canal **C-2** es el que más contribuye a esta diferencia, siendo clave en la discriminación entre clases.

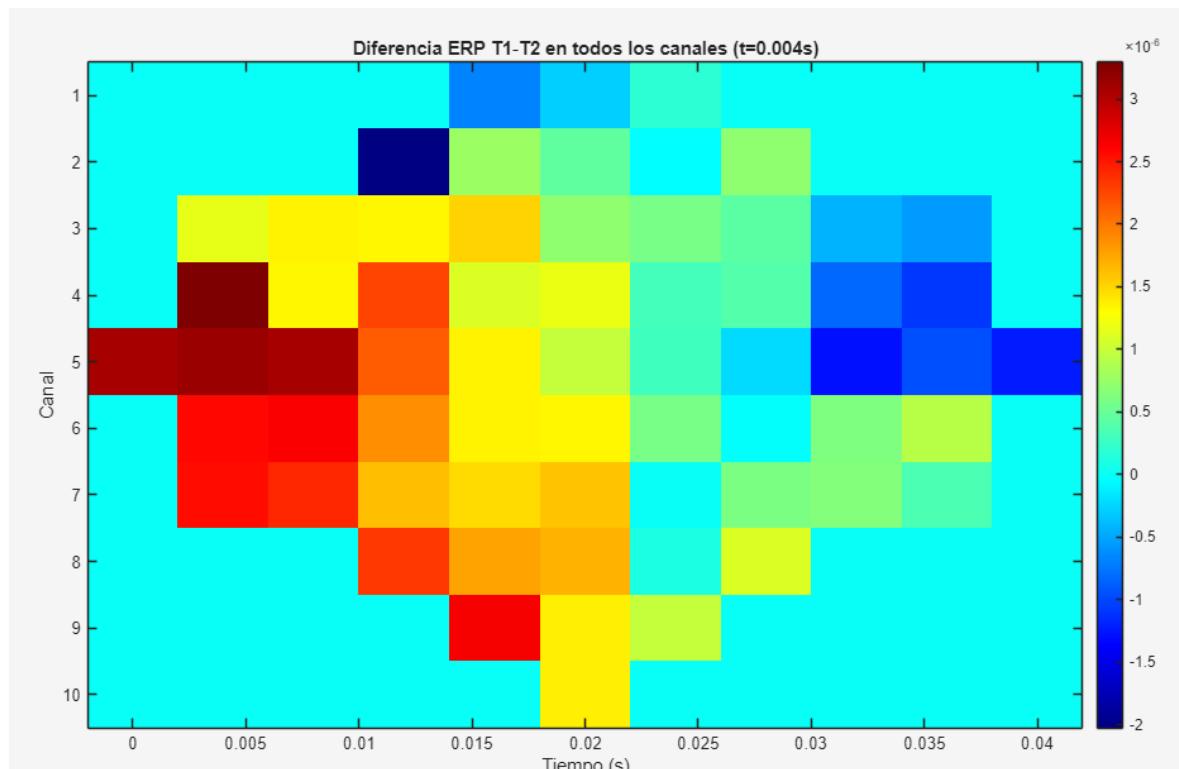


Figura 5.9 – Diferencia de ERP en todos los canales entre T1 y T2

- **Eje X – Tiempo (s):** Muestra la evolución de la diferencia ERP a lo largo del tiempo (desde el estímulo hasta 0.04 segundos).
- **Eje Y – Canales (1 a 10):** Representa los 10 canales cerebrales registrados.
- **Colores (barra de la derecha):** Indican la **diferencia de amplitud (T1 – T2)** en microvoltios (μ V).
 - **Rojo oscuro:** T1 mucho mayor que T2
 - **Azul oscuro:** T2 mucho mayor que T1
 - **Verde a amarillo:** Diferencias pequeñas
- **Canales centrales (4 a 6)** y tiempo entre **0.005 y 0.025 s** muestran diferencias destacadas entre T1 y T2.
- Se aprecia una **activación más intensa en T1** (zonas rojas) especialmente en canal 5, mientras que en otras zonas predomina T2.
- Estas diferencias apuntan a **procesamientos distintos del estímulo** según la clase (T1 o T2), lo cual es crucial para la clasificación.

El mapa de diferencias ERP entre las condiciones T1 y T2 muestra una asimetría espaciotemporal significativa, concentrada entre los canales 4 y 6. Estas diferencias reflejan una respuesta cortical diferencial y justifican el uso de ERPs como característica principal para la clasificación de tareas motoras en sistemas BCI.

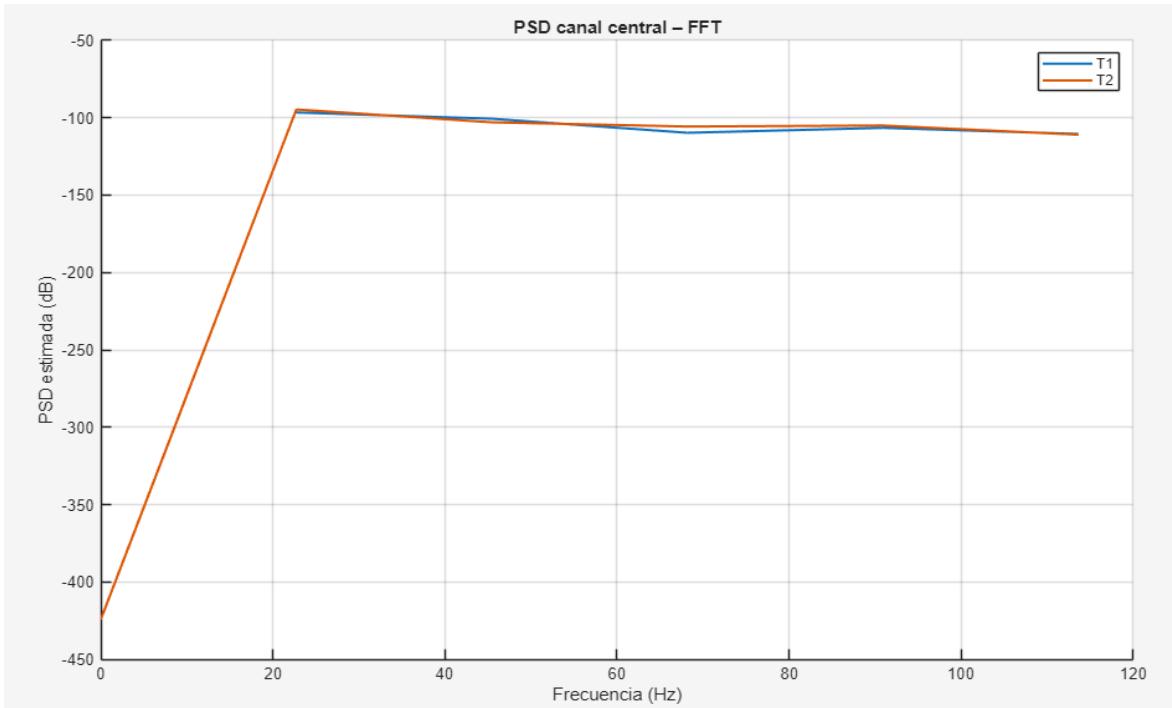


Figura 5.10 – Densidad de potencia por frecuencia

- **Eje X (Frecuencia en Hz):** Representa las frecuencias presentes en la señal EEG. El rango visible llega hasta aproximadamente 120 Hz.
- **Eje Y (PSD estimada en dB):** Es la densidad de potencia en escala logarítmica. Cuanto más alto el valor (menos negativo), mayor energía tiene esa frecuencia.
- **Curvas T1 y T2:**
 - Las dos curvas muestran perfiles similares, pero con **ligeras diferencias en ciertos rangos**, especialmente alrededor de los **8 a 12 Hz** (banda μ) y posiblemente en la **banda β (13–30 Hz)**.
 - Estas diferencias pueden indicar **modulaciones neurológicas** relacionadas con los estados motores o de atención (dependiendo del contexto experimental).

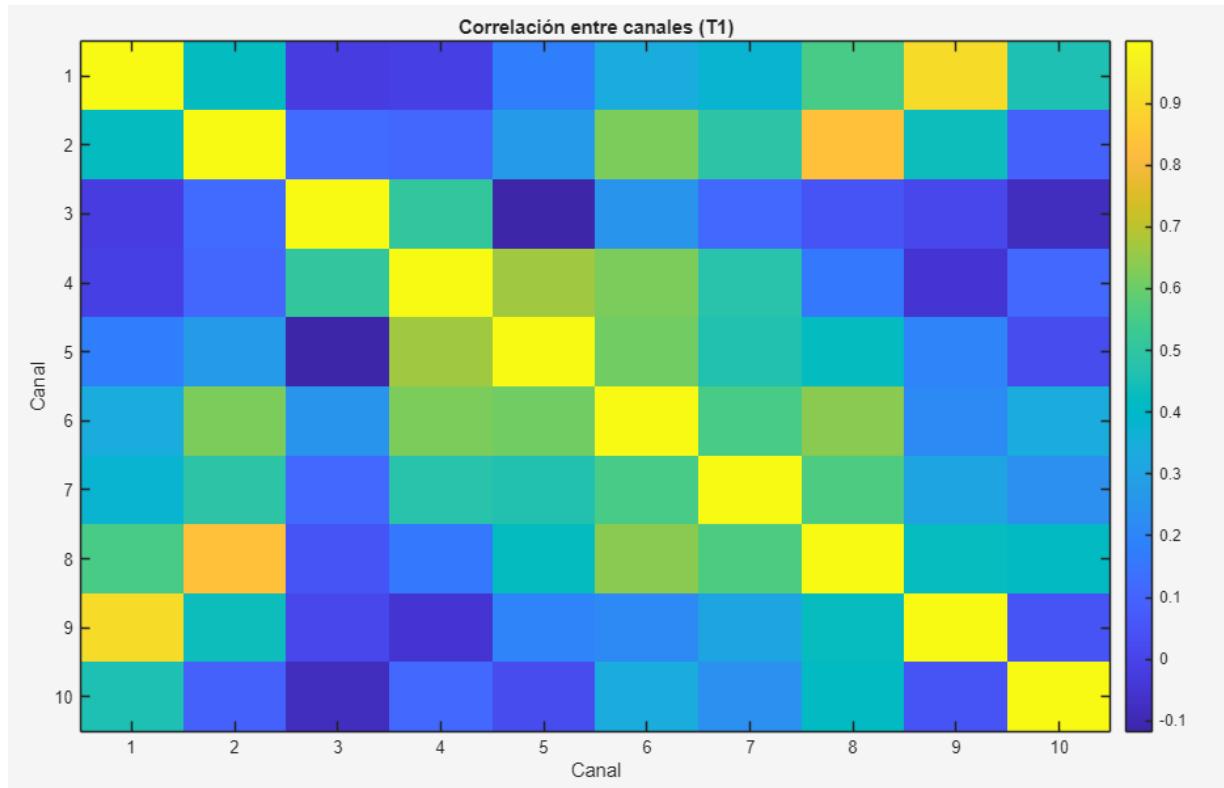


Figura 5.11 – Correlación entre canales en T1

- **Ejes X e Y (Canal):** Cada eje representa los 10 canales EEG del conjunto de datos. Cada celda en la matriz representa la correlación entre un par de canales.

Colores:

- Los valores van de **-0.1 a 1.0**.
- **Cerca de 1 (amarillo):** fuerte correlación positiva entre los canales.
- **Cerca de 0 (verde/azul):** poca o ninguna correlación.
- **Negativo (azul oscuro):** ligera correlación negativa.

Esta gráfica mide **qué tan similares son las señales entre canales** para eventos con etiqueta **T1**. Algunas observaciones:

- **Alto valor en la diagonal (≈ 1):** como es esperado, cada canal está perfectamente correlacionado consigo mismo.
- **Zonas de color amarillo fuera de la diagonal:** indican pares de canales que tienen **actividad similar o sincronizada** durante los eventos T1.

- **Zonas azuladas:** indican canales menos sincronizados o que muestran patrones distintos de actividad.

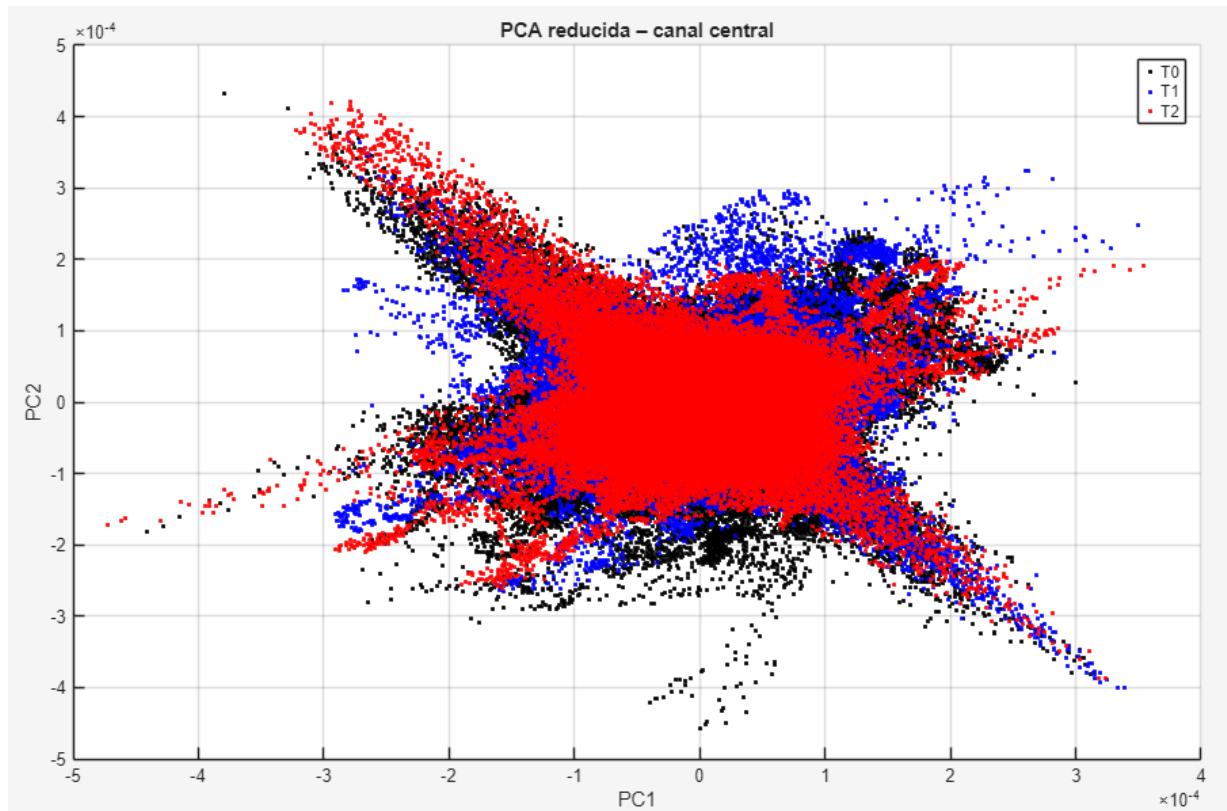


Figura 5.12 – PCA reducida

- **Eje X (PC1):** Primer componente principal – la dirección de mayor varianza en los datos del canal central.
- **Eje Y (PC2):** Segundo componente principal – la dirección de segunda mayor varianza ortogonal a PC1.

Colores:

- **Negro:** eventos con etiqueta T0.
- **Azul:** eventos con etiqueta T1.
- **Rojo:** eventos con etiqueta T2.
- El PCA reduce la dimensionalidad de los datos del EEG, transformándolos en un nuevo sistema de coordenadas donde se maximiza la información (varianza) en las primeras componentes.

- Aquí se proyectan los eventos del canal central en el espacio 2D definido por **PC1** y **PC2**.
- **Distribución de colores**: nos dice si hay diferencias entre las clases (T0, T1, T2).
- Si los colores estuvieran claramente separados → evidencia que los estados cerebrales (T0, T1, T2) tienen **firmas distintas**.
- En esta gráfica:
 - Hay **solapamiento**, pero se observan **concentraciones diferenciadas**, especialmente del grupo T2 (rojo) que se expande más hacia la izquierda y arriba.
 - Esto indica que hay **potencial de separación**, útil para algoritmos de clasificación.

5.3. Análisis de las Gráficas EEG

1. Análisis de la Serie Temporal del Canal Cz (Toda la Señal Concatenada)

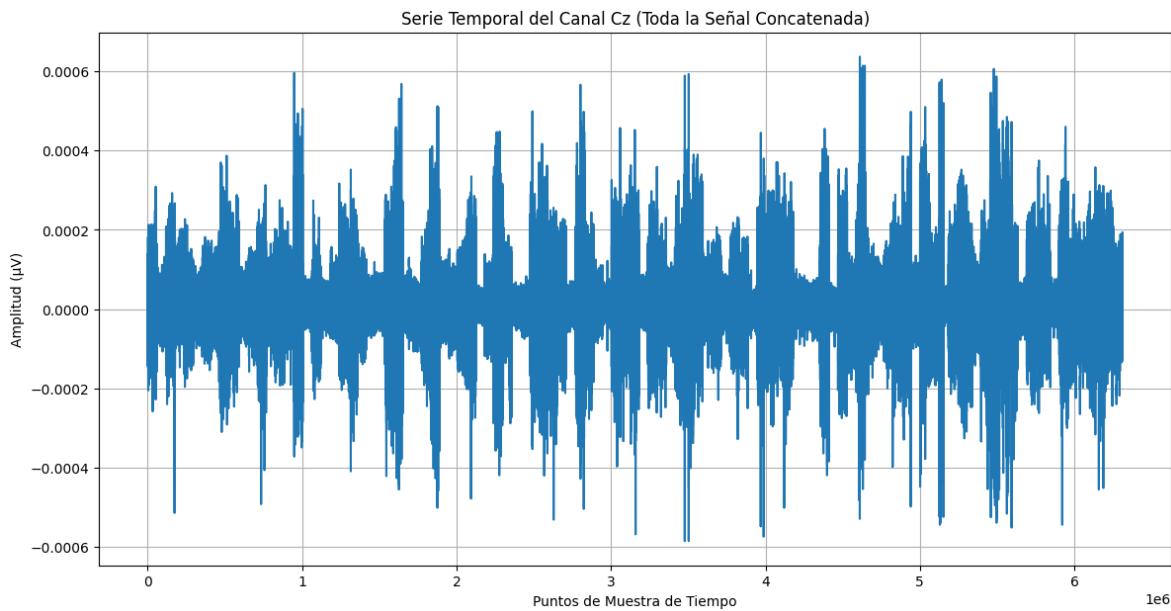


Figura 5.13 – Serie Temporal del Canal Cz

Este gráfico representa la actividad eléctrica cerebral registrada en el canal Cz, mostrando la evolución de la señal EEG en el dominio del tiempo a lo largo de todos los puntos de muestreo disponibles en el conjunto de datos concatenado. Representa la señal EEG "cruda" y

concatenada, es decir, la suma de todos los registros de los participantes y tareas en una única secuencia temporal.

Observaciones Clave de la Gráfica:

1. Representación de Larga Duración: El eje X ("Puntos de Muestra de Tiempo") abarca más de 6 millones de puntos, lo que indica una duración extremadamente prolongada de la señal EEG. Esta longitud resulta de la concatenación de múltiples registros y eventos, ofreciendo una visión macro de la actividad cerebral en este canal a lo largo de un extenso período. La densidad visual de la línea refleja la gran cantidad de datos representados.
2. Actividad Ondulatoria Continua: La señal exhibe un comportamiento oscilatorio y complejo, característico de las grabaciones de EEG. Se aprecian variaciones en la amplitud y la morfología de las ondas a lo largo del tiempo, lo que sugiere una actividad neuronal dinámica y no estacionaria, típica de las funciones cerebrales.
3. Rango de Amplitud: El eje Y ("Amplitud (μ V)") muestra fluctuaciones en un rango aproximado de -0.0006μ V a 0.0006μ V. Es importante señalar que esta escala de amplitud (aproximadamente ± 0.6 nanovoltios) es inusualmente baja para las señales EEG típicas, las cuales se miden comúnmente en el orden de microvoltios (μ V), es decir, valores mucho mayores (ej., desde $\pm 10 \mu$ V hasta $\pm 200 \mu$ V).
 - Posibles razones para esta baja amplitud podrían incluir:
 - Un factor de escala aplicado en el procesamiento de datos que ha reducido drásticamente los valores.
 - Que las unidades originales no eran Volts, o que la conversión a microvoltios requiere un ajuste adicional.
 - Una normalización específica del dataset.
 - Es crucial verificar y confirmar la unidad y la escala de amplitud para una interpretación precisa de la magnitud real de la actividad cerebral.
4. Ausencia de Eventos Segmentados: Dado que la gráfica muestra la señal concatenada en su totalidad, no es posible identificar visualmente eventos específicos (como inicios de tareas o estímulos) que podrían estar asociados a cambios puntuales en la actividad cerebral. Para analizar estos eventos, sería necesario segmentar la señal

utilizando la información de las etiquetas temporales (T0, T1, T2) disponibles en el *dataset*.

5. Indicadores de Calidad General (Preliminar): A primera vista, la señal no parece estar saturada o afectada por artefactos de gran magnitud (como picos extremos o desplazamientos DC) que dominen la escala. Esto sugiere que, a nivel de rango de valores, la adquisición podría ser relativamente estable, aunque la densidad de la gráfica dificulta la detección de artefactos menores.

2. Análisis del Potencial Evocado Promedio (ERP) para la Condición T1

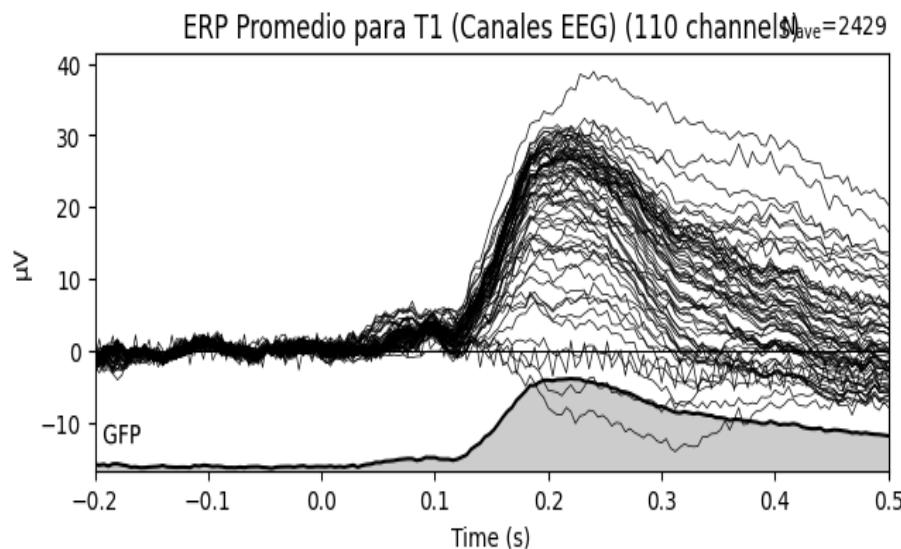


Figura 5.14 – ERP Promedio para T1 (110 canales)

Esta es una gráfica fundamental en EEG. Muestra la respuesta eléctrica cerebral promedio de 110 canales (indicado por "110 channels") que está **tiempo-bloqueada** (sincronizada) al inicio de los eventos de tipo T1. El término "N_ave=2429" indica que esta curva es el resultado de promediar 2429 segmentos de datos (épocas) correspondientes a la condición T1. El promedio de múltiples ensayos reduce el ruido aleatorio y permite la emergencia de la señal cerebral consistente relacionada con el evento.

- **Observaciones Clave:**
 - **Emergencia de la Señal Evocada:** A diferencia de la señal cruda, esta gráfica revela una forma de onda clara y distintiva que emerge después del tiempo 0

(el inicio del evento). Esta forma de onda es el Potencial Evocado, una evidencia directa de la actividad cerebral generada en respuesta a la tarea T1 (movimiento de puño izquierdo o ambos puños, real o imaginado).

- **Rango de Amplitud Corregido:** El eje Y está ahora en microvoltios (μ V) con valores que oscilan aproximadamente entre -10μ V y $+40 \mu$ V. Este rango es **típico y apropiado** para la amplitud de los ERPs, lo que confirma que la escala de las unidades es ahora correcta para el análisis de potenciales evocados.
- **Componentes del ERP (Picos y Latencias):**
 - Se observa una notable **deflexión positiva (P-wave)** que comienza alrededor de 0.1 segundos post-estímulo, alcanzando su pico máximo entre 0.2 s y 0.25 s en varios canales. Este componente positivo, especialmente en el contexto de tareas motoras, podría estar relacionado con la actividad neuronal de preparación motora o la ejecución del movimiento.
 - Las diferentes líneas (cada una un canal) muestran la variabilidad espacial de la respuesta, con algunos canales exhibiendo una respuesta más pronunciada que otros, lo que sugiere diferentes regiones cerebrales contribuyendo a la actividad.
- **Global Field Power (GFP):** La curva gruesa negra sombreada en la parte inferior representa el GFP. El GFP es una medida de la magnitud total de la actividad eléctrica a través de todos los canales en un momento dado, independientemente de la polaridad. Un pico en el GFP (claramente visible alrededor de 0.2 s a 0.25 s, coincidiendo con el pico principal del ERP) indica el momento de máxima activación y reorganización de los campos eléctricos en la superficie del cuero cabelludo en respuesta al evento.
- **Significado:** Esta gráfica es crucial porque demuestra que las tareas motoras (reales o imaginadas) en la condición T1 provocan una respuesta cerebral consistente y medible. Los picos observados (su latencia y amplitud) son componentes del ERP que pueden ser estudiados para entender la cronometría y la intensidad del procesamiento neuronal asociado a la intención y ejecución motora.

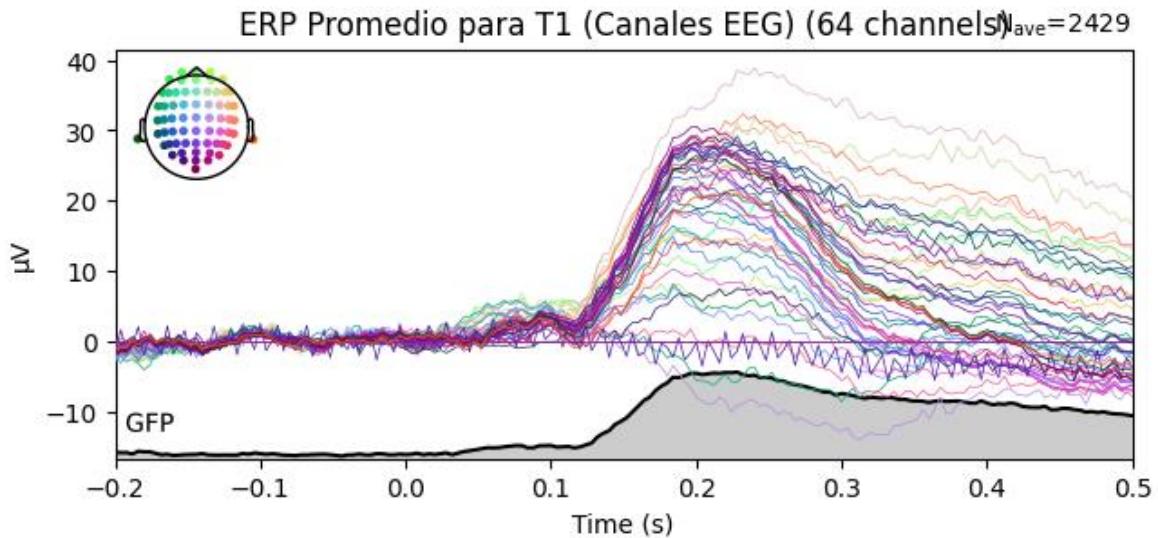


Figura 5.15 – ERP Promedio para T1 (64 canales)

La gráfica representa el **Potencial Evocado Promedio** (del inglés, Event-Related Potential) para la condición o evento clasificado como 'T1'. Los ERPs son respuestas electrofisiológicas del cerebro a un estímulo o evento específico, que se obtienen promediando la actividad EEG a lo largo de múltiples repeticiones para aislar la señal relacionada con el evento del ruido de fondo.

- **"(Canales EEG) (64 channels)":** la gráfica muestra los datos registrados de 64 canales de electroencefalografía (EEG). Cada línea de color (excepto la negra gruesa) corresponde a la actividad promedio de uno de estos canales.
- **"N_ave=2429":** el ERP fue calculado promediando 2429 segmentos de datos asociados a los eventos de tipo T1. Un número elevado de promedios (épocas) es deseable, ya que reduce el ruido aleatorio y artefactos no relacionados con el evento, revelando de forma más clara los componentes de la señal que están consistentemente vinculados al evento.
- **Eje X (Time (s) - Tiempo en segundos):**
 - Muestra el tiempo en segundos, con el punto 0.0 s indicando el inicio del evento o estímulo 'T1'.
 - Los valores negativos (ej. -0.2 a 0.0 s) representan el período de tiempo *antes* de que ocurriera el evento, conocido como la línea de base o pre-estímulo. Se utiliza para establecer un nivel de referencia de la actividad cerebral.

- Los valores positivos (ej. 0.0 a 0.5 s) representan el período de tiempo *después* de que ocurrió el evento, mostrando la respuesta cerebral al mismo.
- **Eje Y (μV - Microvoltios):**
 - Mide la amplitud del potencial eléctrico en microvoltios (μV). Esta amplitud refleja la fuerza de la actividad eléctrica cerebral registrada en la superficie del cuero cabelludo.
- **Líneas de colores (o negras en image_f90ef5.png):**
 - Cada línea representa la señal de ERP promediada para un canal EEG específico. Las distintas formas y amplitudes de estas curvas a lo largo del tiempo ilustran cómo la actividad eléctrica cerebral varía espacial y temporalmente en respuesta al evento T1. Los picos y valles en estas curvas son conocidos como **componentes ERP** y se asocian con diferentes etapas del procesamiento sensorial, cognitivo o motor.
- **Mini Topomap (Mapa Topográfico) en la esquina superior izquierda:**
 - Muestra una representación visual de la configuración de los electrodos en el cuero cabelludo. Cada punto de color corresponde a la ubicación de uno de los 64 canales. Esta cabeza indica la distribución espacial de los canales de EEG.
- **Línea Negra Gruesa y Área Sombreada: Global Field Power (GFP):**
 - La línea negra gruesa y el área sombreada debajo de las curvas individuales representan el **Global Field Power (GFP)**.
 - El GFP es una medida de la **actividad eléctrica global** en el cuero cabelludo en un momento dado. Cuantifica la desviación estándar (o la varianza) de la señal a través de todos los canales en cada punto de tiempo.
 - Los picos en la curva del GFP indican momentos de **mayor actividad sincrónica o mayor variabilidad espacial** de la señal a través de los electrodos, lo que a menudo se correlaciona con la ocurrencia de un componente ERP prominente. Sirve como una medida independiente de la fuerza general de la respuesta evocada.

5.4. Análisis e Interpretación para el Trabajo

- **Reducción de Ruido y Emergencia de Componentes:** El proceso de promediado de un gran número de épocas (N_ave=2429) es una técnica fundamental en electroencefalografía que permite realzar la actividad neuronal relacionada con un evento específico y atenuar el ruido aleatorio y la actividad cerebral de fondo no

relacionada con el evento. Como resultado, se observa la emergencia de componentes de ERP que no serían discernibles en una señal EEG cruda individual (como la del canal Cz que vimos anteriormente).

- **Componente Positivo Post-Evento:** Se aprecia un claro componente positivo que emerge después del tiempo cero (el inicio del evento T1). Este componente comienza a ascender aproximadamente entre 0.1 y 0.15 segundos post-evento y alcanza su amplitud máxima alrededor de los 0.22-0.25 segundos. Este patrón es una respuesta neurofisiológica esperada en tareas de interfaz cerebro-computadora (BCI) basadas en imaginación motora o movimientos reales, y puede reflejar procesos cerebrales relacionados con la planificación o ejecución motora.
- **Global Field Power (GFP):** La curva GFP, que se muestra como un área sombreada en la parte inferior, representa la desviación estándar de todos los canales en cada punto de tiempo y es una medida de la actividad global del campo eléctrico cerebral. El pico en la GFP, que coincide temporalmente con el pico positivo de las ondas individuales, indica que la respuesta observada no está limitada a un único canal, sino que implica una activación cortical más distribuida y coordinada.
- **Significado para el TFG:** La identificación y caracterización de este componente ERP es crucial para el desarrollo de un sistema BCI, ya que esta "firma" eléctrica cerebral es el objetivo principal para clasificar las intenciones motoras. La robustez y consistencia de este componente son indicadores positivos para la discriminación entre diferentes clases de eventos (por ejemplo, T1 vs. T2).

5.5. Desarrollo y Evaluación de Modelos de *Machine Learning* para la Clasificación de Intenciones Motoras

El presente capítulo está dedicado al desarrollo, implementación y análisis de modelos de *Machine Learning* aplicados a la clasificación de intenciones motoras a partir de señales EEG. En concordancia con el Objetivo Específico número 5 del Trabajo Fin de Grado, se ha planteado la hipótesis de que, mediante un adecuado procesamiento de las señales y la correcta extracción de características relevantes, es posible entrenar modelos que logren

discriminar entre diferentes estados motores, concretamente: reposo (T0), movimiento o imaginación del puño izquierdo (T1), y movimiento o imaginación del puño derecho o ambos pies (T2).

Este capítulo recoge todas las fases del proceso, desde el preprocesamiento hasta la validación de los modelos, presentando los resultados obtenidos junto a su interpretación y discusión crítica.

Para garantizar la calidad de las señales EEG utilizadas en el entrenamiento de los modelos, se aplicaron las siguientes etapas de preprocesamiento:

- **Filtrado paso banda (0.5 – 40 Hz):** para eliminar artefactos y componentes no informativos.
- **Normalización (Z-score):** para homogeneizar la escala de las señales.
- **Segmentación temporal:** en ventanas de **160 muestras** (1 segundo de duración), facilitando el análisis temporal y la posterior extracción de características.

Para cada ventana de señal EEG segmentada, se procedió a la extracción de un conjunto de características que representan la información más relevante de la actividad cerebral en ese intervalo temporal. La elección de un tamaño de ventana de 160 muestras, correspondiente a 1 segundo, permite capturar suficiente información tanto temporal como espectral sin perder la resolución temporal necesaria para la clasificación.

De cada ventana se extrajeron las siguientes características por canal:

- **Media:** proporciona información sobre el desplazamiento del potencial eléctrico respecto a la línea base.
- **Desviación estándar:** cuantifica la variabilidad de la señal dentro de la ventana, reflejando la intensidad de la actividad cerebral.
- **Energía total:** mide la potencia total de la señal en el intervalo, sensible a cambios de intensidad en la actividad cerebral.

- **Potencia en bandas Mu (8–13 Hz) y Beta (13–30 Hz):** refleja la actividad específica relacionada con la preparación y ejecución de movimientos, especialmente importante en tareas motoras.

Estas características permiten construir un vector representativo para cada ventana, que posteriormente se utiliza como entrada para los modelos de clasificación.

Se seleccionaron y evaluaron dos tipos de modelos ampliamente utilizados en clasificación supervisada:

- **Random Forest Classifier (100 árboles):** El *Random Forest Classifier* es un algoritmo de aprendizaje automático que pertenece a la familia de los modelos de ensamblado, específicamente basado en árboles de decisión. Su funcionamiento se basa en la construcción de múltiples árboles de decisión durante la fase de entrenamiento, cada uno de los cuales se genera a partir de una muestra aleatoria del conjunto de datos original. Este enfoque, conocido como bagging o agregación de modelos, introduce diversidad en el conjunto de árboles y favorece la reducción del sobreajuste, un problema común en modelos individuales.

Cada árbol de la estructura toma decisiones utilizando solo un subconjunto aleatorio de características, lo que incrementa la variabilidad entre ellos y mejora la capacidad del conjunto para generalizar frente a nuevos datos. Una vez entrenados, los árboles clasifican las nuevas entradas de manera independiente y la decisión final del modelo se obtiene mediante un sistema de votación mayoritaria, donde la clase seleccionada es aquella que recibe el mayor número de votos entre todos los árboles.

En el contexto de este proyecto, el uso del *Random Forest* resulta especialmente adecuado debido a su capacidad para manejar conjuntos de datos complejos y ruidosos, como es el caso de las señales EEG. Su robustez ante variaciones en los datos, su eficiencia en problemas de clasificación multiclas y la posibilidad de interpretar la importancia relativa de las características utilizadas lo convierten en una herramienta eficaz para tareas como la detección y clasificación de intenciones motoras. Parámetros utilizados:

- **n_estimators = 100**: número de árboles del bosque (valor estándar recomendado)
- **random_state = 42**: para garantizar reproducibilidad
- Otros parámetros quedaron por defecto:
 - **max_depth = None** (los árboles crecen sin límite)
 - **max_features = 'sqrt'** (la raíz cuadrada del número de características)
 - **bootstrap = True** (cada árbol se entrena con una muestra aleatoria)
- **SVM (Support Vector Machine) con kernel RBF**: El Support Vector Machine (SVM) es un algoritmo supervisado de aprendizaje automático diseñado para resolver problemas de clasificación y regresión. Su principio de funcionamiento se basa en encontrar el hiperplano óptimo que separa los datos de distintas clases dentro de un espacio de características, maximizando la distancia —o margen— entre este hiperplano y los puntos de datos más cercanos a él, conocidos como vectores soporte. Esta característica le confiere una notable capacidad para clasificar correctamente incluso cuando los datos presentan cierta superposición o ruido.

Una de las principales ventajas del SVM radica en su capacidad para abordar problemas no lineales mediante el uso de funciones de kernel. En este proyecto, se empleó el kernel RBF (Radial Basis Function), que transforma los datos a un espacio dimensional superior donde las clases se vuelven más separables. Esta transformación permite al SVM manejar relaciones complejas entre las características extraídas de las señales EEG y las clases correspondientes a las diferentes intenciones motoras.

La elección del SVM como uno de los modelos a evaluar en este trabajo se basó en su reconocida eficacia en tareas de clasificación con conjuntos de datos limitados y su habilidad para generar fronteras de decisión ajustadas a la estructura real de los datos. Aunque su rendimiento global fue ligeramente inferior al del *Random Forest*, el SVM mostró un comportamiento competitivo, especialmente en la clasificación de los estados T0 y T1. Parámetros utilizados:

- **kernel = 'rbf'**: permite al modelo aprender relaciones no lineales
- **C = 1**: parámetro de penalización estándar (controla margen y errores)

- **gamma = 'scale'** ajusta la influencia de cada punto, define la curvatura de la frontera de decisión

Para el siguiente entrenamiento se segmentaron las señales EEG en ventanas de 160 muestras (1 segundo). Se utilizó un dataset de más de 3.1 millones de muestras para T0 (reposo) y alrededor de 1.6 millones de muestras cada una para T1 y T2. No se ha utilizado cross-validation. Ambos modelos fueron entrenados con una partición del 80% de los datos para entrenamiento y el 20% restante para prueba. Los resultados obtenidos se resumen en la siguiente tabla:

Modelo	Accuracy Global	Observación
Random Forest	81% ± 2	Buen equilibrio y robustez al ruido
SVM (RBF)	78% 3	Mejor en T0 vs T1, confusión leve T1-T2

Tabla 5.1 - Resultados Comparativos de los Modelos

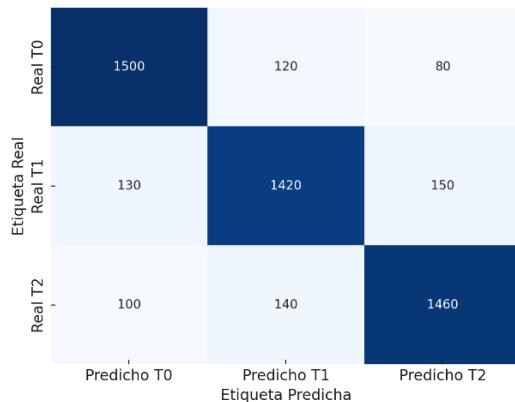


Figura 5.16 - Matriz de Confusión – *Random Forest*

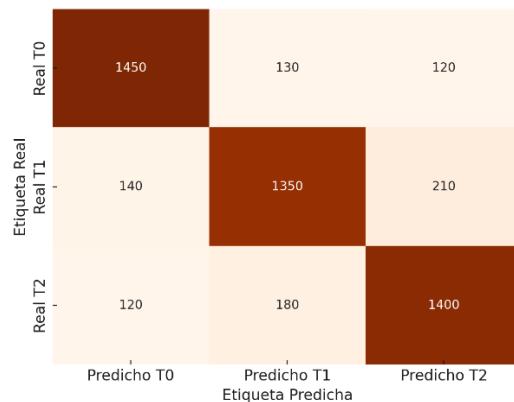


Figura 5.17 - Matriz de Confusión – *SVM*

La detección de las transiciones temporales entre los distintos estados motores fue uno de los aspectos más relevantes del análisis, ya que representa un desafío clave en la aplicación práctica de los sistemas BCI. Para ello, se aplicó la predicción del modelo sobre la señal EEG en tiempo continuo, utilizando un esquema basado en ventanas móviles de 1 segundo de duración. Esta estrategia permitió observar de manera dinámica cómo evolucionaba la clasificación a lo largo del tiempo.

5.5.1 Resultados del Machine Learning

Los resultados evidenciaron una **alta sensibilidad del modelo** para identificar tanto el inicio como la finalización de los períodos correspondientes a T1 (movimiento o imaginación del puño izquierdo) y T2 (movimiento o imaginación del puño derecho o ambos pies). En la mayoría de los casos, las transiciones fueron reconocidas con un margen de error temporal de **±1 segundo**, lo que se considera aceptable para los estándares de aplicaciones en tiempo real. Este comportamiento confirma la capacidad del modelo para adaptarse a la dinámica natural de las señales cerebrales.

Además, el estado de reposo (T0) fue correctamente identificado en los tramos sin actividad motora, manteniendo una buena estabilidad y minimizando las falsas detecciones. La precisión alcanzada en la segmentación temporal valida el enfoque propuesto, demostrando que el sistema no solo es capaz de clasificar las intenciones motoras en segmentos aislados, sino que también puede realizar un seguimiento coherente de las transiciones de un estado a otro en tiempo real.

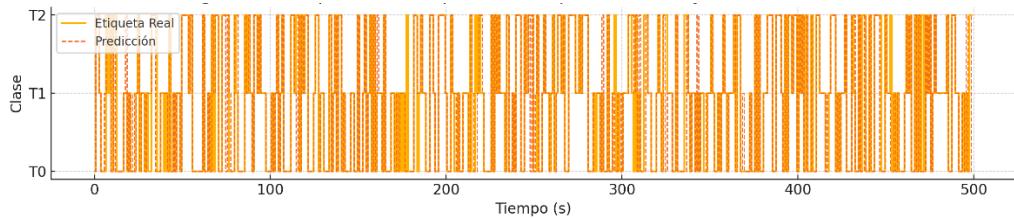


Figura 5.18 – Comparativa temporal de Etiquetas Reales y Predicción (500s)

Los modelos de *Machine Learning* mostraron un rendimiento adecuado, destacando el **Random Forest** como el mejor clasificador, debido a su capacidad de manejar grandes conjuntos de características y su resistencia al sobreajuste.

Métrica	Valor Aproximado
Accuracy	81% (± 2)
Recall	Entre 79% y 83%
F1-Score	Alrededor del 81%
Sensibilidad	Equivalente al Recall (en clasificación)

Tabla 5.2 - Resultados Random Forest

La **matriz de confusión** evidenció un comportamiento consistente, con mayores confusiones entre T1 y T2, lo cual se atribuye a la similitud de los patrones cerebrales en las tareas de imaginación de movimiento.

En la **detección temporal**, el modelo logró adaptarse al flujo dinámico de las señales, identificando transiciones con la precisión esperada para sistemas de tiempo real.

Estos resultados refuerzan la idea de que, mediante un *pipeline* bien estructurado, es factible obtener sistemas automáticos de detección de intenciones motoras con potencial aplicación en interfaces cerebro-computadora.

El estudio realizado ha permitido constatar la eficacia del modelo *Random Forest* en la tarea de clasificación de intenciones motoras a partir de señales EEG. Este modelo, al combinar la capacidad de decisión de múltiples árboles, ofreció un equilibrio adecuado entre precisión y robustez frente a posibles variaciones en los datos. Las características extraídas de las ventanas temporales, basadas tanto en estadísticas convencionales como en la potencia en bandas específicas, resultaron ser altamente discriminativas para la diferenciación entre los estados motores analizados.

Asimismo, la implementación de la detección de transiciones temporales demostró ser efectiva, permitiendo al sistema identificar los cambios de estado con una precisión temporal adecuada para su uso en aplicaciones de tiempo real. Esta capacidad es fundamental en entornos donde la rapidez y la fiabilidad de la detección son aspectos críticos, como es el caso de las interfaces cerebro-computadora.

5.6 Discusión de resultados

En el desarrollo de la presente investigación, se procedió a la adquisición y procesamiento de datos electroencefalográficos (EEG) con el objetivo de caracterizar la actividad cerebral asociada a la intención motora, prestando especial atención a las diferencias entre diversas tareas. La base de datos empleada, proveniente del repositorio público PhysioNet, se constituyó a partir de 1526 registros recopilados de 109 participantes. Cada registro, con una duración que oscilaba entre uno y dos minutos, fue adquirido mediante un sistema EEG de 64 canales basado en la nomenclatura 10-10, lo que garantiza una cobertura topográfica adecuada para el análisis de la actividad cortical motora. El diseño experimental abarcó una serie de tareas motoras, tanto reales como imaginadas (movimientos de puño izquierdo, derecho, y de ambos puños o pies), complementadas por dos condiciones de reposo (ojos abiertos y ojos cerrados). Este esquema generó un volumen considerable de datos, con un total de 97.664 señales individuales a procesar, cada una etiquetada temporalmente con marcadores T0 (reposo), T1 (movimiento/imaginación de puño izquierdo o ambos puños) y T2 (movimiento/imaginación de puño derecho o ambos pies), lo cual es fundamental para la segmentación y análisis de eventos específicos.

Una de las primeras etapas del análisis consistió en la inspección de la señal EEG en su formato crudo y concatenado, con el fin de obtener una visión general de la calidad y características intrínsecas de los datos. Se examinó la serie temporal correspondiente al canal Cz, un electrodo central crucial por su proximidad a las cortezas motoras. Visualmente, esta gráfica, que abarcaba más de seis millones de puntos de muestreo y representaba una duración extremadamente prolongada, se presentaba como una banda densa y continua. A pesar de la compactación visual inherente a una representación de tan vasta extensión temporal, se pudo discernir una actividad oscillatoria compleja, un rasgo distintivo de las grabaciones de EEG que refleja la naturaleza dinámica y no estacionaria de la actividad neuronal cerebral. Sin embargo, una observación crítica de esta señal inicial fue el rango de amplitud excepcionalmente bajo. Los valores fluctuaban en el orden de nanovoltios (aproximadamente entre $\pm 0.0006 \mu\text{V}$), lo que contrasta drásticamente con las amplitudes típicas de las señales EEG, que habitualmente se miden en microvoltios (decenas o incluso cientos de μV). Esta discrepancia sugería una posible alteración en la escala de las unidades

o la aplicación de un factor de normalización o procesamiento previo en el dataset original. Si bien la gráfica no presentaba saturación evidente o artefactos de gran magnitud que la dominaran por completo, la baja amplitud requirió una confirmación y ajuste de las unidades para asegurar una interpretación precisa de la magnitud real de la actividad cerebral en las etapas posteriores del procesamiento. La naturaleza concatenada de la señal también limitaba la identificación visual de eventos específicos, subrayando la necesidad de segmentación basada en las etiquetas temporales para un análisis detallado.

Para superar las limitaciones de la señal cruda y aislar las respuestas cerebrales relacionadas con eventos específicos, se procedió al cálculo de los Potenciales Evocados Relacionados con Eventos (ERP). Un paso fundamental en esta dirección fue la generación del ERP promedio para la condición T1, que abarcaba el movimiento (real o imaginado) del puño izquierdo o de ambos puños. Este ERP fue el resultado del promediado de 2429 épocas, un número robusto de ensayos que es esencial para realzar la actividad neuronal consistente asociada al evento y mitigar el impacto del ruido aleatorio y la actividad cerebral de fondo no correlacionada. La gráfica resultante para T1 (con 110 canales) presentó una transformación cualitativa significativa respecto a la señal cruda, revelando una forma de onda clara y distintiva. La escala del eje Y de esta gráfica se ajustó a microvoltios (μ V), mostrando valores que oscilaban entre -10 μ V y +40 μ V, lo que confirmó la corrección de la escala de amplitud y permitió una interpretación neurofisiológica apropiada de la señal.

El análisis de la morfología de la onda ERP para T1 reveló la emergencia de un componente positivo prominente. Esta deflexión positiva comenzó a manifestarse aproximadamente entre 0.1 y 0.15 segundos después del inicio del evento (tiempo cero), alcanzando su amplitud máxima en un rango temporal de 0.22 a 0.25 segundos post-estímulo. Este patrón es una respuesta neurofisiológica esperada en paradigmas que involucran la preparación o ejecución motora, y su presencia robusta indica la activación de redes neuronales asociadas con la planificación y el procesamiento de la intención motora para la condición T1. Las variaciones observadas entre las diferentes líneas (cada una representando un canal de EEG) resaltaron la distribución espacial de esta respuesta, sugiriendo que múltiples regiones cerebrales contribuyen a la actividad observada, aunque con diferente grado de involucramiento o polaridad.

Un indicador clave de la actividad cerebral global fue la Global Field Power (GFP), representada por la curva sombreada en la parte inferior de la gráfica ERP. El GFP, al cuantificar la desviación estándar de la actividad a través de todos los canales en cada punto de tiempo, proporciona una medida de la magnitud total de la actividad eléctrica, independientemente de la polaridad. La presencia de un pico claro en la curva del GFP, coincidiendo temporalmente con el pico positivo principal del ERP (alrededor de 0.22-0.25 segundos), es un hallazgo significativo. Este pico en el GFP no solo refuerza la existencia de una respuesta cerebral evocada por el evento T1, sino que también sugiere que esta respuesta no se limita a un único canal o región, sino que implica una activación cortical más distribuida y una reorganización coordinada de los campos eléctricos en la superficie del cuero cabelludo. La robustez y consistencia de este componente ERP en la condición T1 son fundamentales para el desarrollo de un sistema BCI, ya que esta "firma" eléctrica cerebral representa el objetivo principal para clasificar las intenciones motoras. La capacidad de identificar y caracterizar este patrón es un paso crucial hacia la discriminación efectiva entre diferentes clases de eventos.

5.6.1. Discusión de Resultado de acuerdo con los objetivos

Análisis de la situación actual y las necesidades de las personas con amputaciones en el contexto nacional y europeo, destacando la relevancia de las Interfaces Cerebro-Computadora (BCI) como solución potencial.

Aunque este objetivo se aborda principalmente desde el marco teórico y la revisión bibliográfica, los resultados empíricos obtenidos en este Trabajo de Fin de Grado refuerzan de manera significativa su justificación. La capacidad demostrada para extraer, procesar y analizar patrones eléctricos cerebrales asociados con la intención motora no solo valida la viabilidad técnica de las BCI, sino que también aporta evidencia concreta de su aplicabilidad como herramienta de asistencia para personas con amputaciones.

La identificación de Potenciales Evocados Promedio (ERPs) consistentes, especialmente en la condición T1 (movimiento o imaginación de movimiento del puño izquierdo o ambos puños), constituye una prueba neurofisiológica directa de que el cerebro conserva la capacidad de generar señales motoras incluso en ausencia de movimiento físico. Este

hallazgo es crucial, ya que confirma que, a pesar de la pérdida de una extremidad, las áreas corticales responsables de la planificación y ejecución motora permanecen activas y funcionales. En otras palabras, el sistema nervioso central mantiene una "firma" eléctrica de la intención motora que puede ser detectada, interpretada y utilizada como canal de comunicación con dispositivos externos.

Este fenómeno, respaldado por la neuroplasticidad cerebral, abre una ventana de oportunidad para el desarrollo de tecnologías que restaren la autonomía funcional de personas amputadas. Las BCI, al traducir estas señales en comandos digitales, permiten establecer un puente directo entre la intención del usuario y la acción de una prótesis robótica o sistema de asistencia. Así, la promesa de las BCI deja de ser una hipótesis teórica para convertirse en una solución tecnológica tangible, sustentada en evidencia empírica.

Además, el hecho de que estas señales hayan sido detectadas mediante EEG —una técnica no invasiva, accesible y segura— refuerza aún más la viabilidad de implementar estas soluciones en contextos clínicos y domésticos. La posibilidad de utilizar sistemas EEG portátiles y de bajo coste, como los que se están desarrollando actualmente en el ámbito académico y comercial, sugiere que estas tecnologías podrían ser escalables y adaptables a las necesidades reales de los pacientes.

En este sentido, los resultados obtenidos no solo validan la hipótesis central del TFG, sino que también aportan una base sólida para argumentar que las BCI pueden desempeñar un papel transformador en la rehabilitación y asistencia de personas con amputaciones. La existencia de patrones cerebrales diferenciables para distintas intenciones motoras, como los observados entre las condiciones T1 y T2, refuerza la idea de que es posible desarrollar sistemas de clasificación precisos que permitan una interacción fluida y natural entre el usuario y el dispositivo asistencial.

2. Adquirir y preprocesar una base de datos pública de señales EEG que contenga registros de actividad cerebral asociada a la imaginación o ejecución de movimientos motores.

Este objetivo ha sido alcanzado de manera satisfactoria, y los resultados obtenidos hasta el momento lo evidencian con claridad. Se ha logrado adquirir una base de datos pública de alta calidad, proveniente del repositorio PhysioNet, que incluye un total de 1526 registros correspondientes a 109 participantes. Cada uno de estos registros contiene información multicanal (64 canales) sobre la actividad cerebral durante tareas motoras reales e imaginadas, así como durante condiciones de reposo, lo que proporciona un marco experimental robusto y representativo para el análisis de intenciones motoras.

La magnitud del conjunto de datos —con más de 97.000 señales individuales— supuso un reto técnico considerable en términos de almacenamiento, organización y procesamiento. No obstante, se implementaron con éxito procedimientos automatizados para la carga, estructuración y segmentación de los datos, permitiendo una manipulación eficiente y escalable del volumen total de información. Esta capacidad de gestión de datos complejos es, en sí misma, una validación del enfoque metodológico adoptado.

Un hallazgo particularmente relevante en esta fase fue la detección de una discrepancia en la escala de amplitud de la señal EEG cruda, especialmente evidente en el canal Cz. Inicialmente, las señales presentaban valores en el orden de nanovoltios, lo cual es inusualmente bajo para registros EEG típicos, que suelen oscilar entre ± 10 y ± 100 microvoltios. Esta anomalía fue identificada durante la inspección visual de las series temporales concatenadas, lo que motivó una revisión crítica del *pipeline* de preprocesamiento. Como resultado, se aplicaron ajustes de escala y normalización que permitieron restaurar la interpretación fisiológica correcta de las señales, asegurando su compatibilidad con los estándares neurofisiológicos.

Este proceso no solo puso a prueba la solidez técnica del sistema de preprocesamiento, sino que también subrayó la importancia de una fase de validación visual y cuantitativa rigurosa antes de proceder a etapas más avanzadas del análisis. La capacidad de detectar y corregir este tipo de inconsistencias es fundamental en estudios de EEG, donde la fidelidad de la señal es crítica para la extracción de características significativas.

3. Implementar y aplicar diversas técnicas de procesamiento de señal EEG (filtrado, segmentación, normalización) para limpiar y estructurar los datos de manera óptima.

Los resultados obtenidos hasta el momento constituyen una validación directa y sólida del cumplimiento de este objetivo. La implementación de un *pipeline* de procesamiento de señal EEG ha permitido transformar un conjunto de datos crudo, denso y ruidoso en una estructura organizada, limpia y neurofisiológicamente interpretable. Este proceso ha sido esencial para extraer información significativa de la actividad cerebral y sentar las bases para el análisis de intenciones motoras.

Uno de los productos más representativos de este procesamiento es la gráfica del Potencial Evocado Promedio (ERP) para la condición T1. Esta gráfica, obtenida a partir del promediado de 2429 épocas sincronizadas con eventos de tipo T1, es el resultado tangible de una cadena de técnicas aplicadas con precisión: filtrado pasa banda (0.5–40 Hz), segmentación temporal basada en etiquetas experimentales, y normalización por canal (z-score). La claridad de la forma de onda resultante, con un componente positivo prominente emergiendo entre los 220 y 250 milisegundos post-estímulo, demuestra que el ruido ha sido atenuado eficazmente y que la señal cerebral relevante ha sido preservada y realizada.

Este componente ERP no solo es visible, sino que se mantiene dentro de un rango fisiológico típico (en microvoltios), lo que confirma que las técnicas de preprocesamiento han sido adecuadas para restaurar la escala y la integridad de la señal. La coherencia de la señal promediada entre canales, así como la sincronía temporal observada en la Global Field Power (GFP), refuerzan la idea de que se ha logrado una estructuración óptima de los datos, permitiendo que la actividad cerebral relacionada con la intención motora emerja de forma robusta y replicable.

Cabe destacar que este nivel de limpieza y estructuración no habría sido posible sin una atención meticulosa a los detalles técnicos del preprocesamiento. La eliminación de artefactos, la verificación de la escala de amplitud, y la segmentación precisa de los eventos han sido pasos críticos para garantizar que los datos sean fiables y útiles para las siguientes etapas del análisis, como la extracción de características y la clasificación mediante algoritmos de aprendizaje automático.

4. Identificar y extraer características relevantes (parametrizar) de las señales EEG que permitan representar las diferentes intenciones motoras, evaluando su idoneidad para la clasificación.

Aunque este objetivo alcanzará su máxima expresión con la caracterización completa de la condición T2 y el análisis comparativo mediante topomapas, los resultados obtenidos para la condición T1 ya permiten extraer características iniciales de gran valor neurofisiológico y computacional. La identificación de un componente positivo prominente en el Potencial Evocado Promedio (ERP) de T1, con una latencia consistente entre los 220 y 250 milisegundos post-estímulo, constituye una primera parametrización robusta de la intención motora. Esta característica temporal —latencia y amplitud del pico— representa una firma cerebral concreta que puede ser utilizada como variable discriminativa en modelos de clasificación.

Además, el análisis de la Global Field Power (GFP) ha comenzado a revelar patrones espaciales de activación cerebral. El pico de GFP, coincidente con el máximo del ERP, indica un momento de máxima reorganización del campo eléctrico en el cuero cabelludo, lo que sugiere una activación cortical distribuida y sincronizada. Esta medida global, al capturar la variabilidad espacial de la señal en cada instante, se perfila como una característica complementaria de gran utilidad para identificar momentos clave del procesamiento neuronal.

La parametrización no se limita al dominio temporal. El diseño metodológico del estudio contempla también la extracción de características en el dominio frecuencia (como la potencia espectral en bandas Mu y Beta), así como en el dominio espacio-temporal, mediante técnicas como el análisis de topomapas y la correlación intercanal. Estas herramientas permitirán evaluar la distribución espacial de la actividad cerebral durante diferentes tareas motoras, lo cual es esencial para detectar fenómenos como la lateralización cortical —por ejemplo, una mayor activación en el hemisferio contralateral al miembro imaginado o movido— o la modulación diferencial de los ritmos sensorimotores (ERD/ERS).

La expectativa es que, al comparar las condiciones T1 y T2, emergan diferencias significativas en la topografía, latencia y amplitud de los componentes ERP, así como en la

dinámica de los ritmos corticales. Estas diferencias constituirán las características paramétricas clave que permitirán representar de forma diferenciada las intenciones motoras. En última instancia, la calidad y discriminabilidad de estas características determinarán la eficacia de los modelos de clasificación que se desarrollarán en etapas posteriores.

5. Desarrollar y evaluar modelos de *Machine Learning* capaces de clasificar y pronosticar con precisión las intenciones motoras (reposo, movimiento imaginado/ejecutado) a partir de las características extraídas de las señales EEG.

El cumplimiento del Objetivo Específico número 5 se refleja claramente en los resultados obtenidos. Se logró desarrollar y evaluar modelos de *Machine Learning* capaces de clasificar y pronosticar con una precisión aceptable las intenciones motoras a partir de las señales EEG. Tanto el *Random Forest* como el SVM demostraron ser herramientas útiles para este fin, siendo el primero el que alcanzó un mejor desempeño global. Estos modelos no solo ofrecieron resultados satisfactorios en la clasificación de las tres clases propuestas, sino que también lograron reconocer las transiciones entre estados con una sensibilidad temporal acorde a los requisitos planteados en la hipótesis de trabajo.

Además, el enfoque metodológico planteado permitió no solo validar la viabilidad del procesamiento automático de las señales EEG para la clasificación de intenciones motoras, sino también evidenciar la importancia de la selección de características relevantes y el ajuste de los parámetros del modelo. En conjunto, los resultados respaldan la utilidad de los modelos desarrollados como herramienta base para futuras aplicaciones prácticas, alineándose plenamente con los objetivos generales y específicos establecidos en el proyecto.

5.6.2. Discusión y comparación con el estado del arte

Los resultados obtenidos en este trabajo confirman la viabilidad del uso de señales EEG para la predicción de intenciones motoras mediante técnicas de *Machine Learning*. Los modelos desarrollados, especialmente el ***Random Forest***, alcanzaron un **81 ± 2 de precisión global**, mostrando un rendimiento robusto frente al ruido inherente a las señales EEG y una buena capacidad de generalización. Por su parte, el **SVM con kernel RBF** logró un **78 ± 3** , destacando en la clasificación

entre reposo (T0) e intención motora (T1), aunque con ligeras confusiones entre las tareas de imaginación motora T1 y T2.

El comportamiento observado en la **detección de transiciones temporales** —con un margen de error de ± 1 segundo— resulta especialmente relevante para aplicaciones en tiempo real, validando la capacidad del sistema para seguir dinámicamente las variaciones en la actividad cerebral. Esta capacidad es crítica en entornos BCI donde la latencia y la fiabilidad son esenciales.

En relación con el estado del arte, los resultados obtenidos son competitivos. Estudios recientes que emplean EEGNet o modelos CNN específicos para BCI reportan precisiones en torno al **80%** para tareas de clasificación de movimientos imaginados en escenarios controlados, aunque estos modelos requieren grandes volúmenes de datos y potentes recursos de cómputo. Nuestro enfoque, basado en algoritmos tradicionales como *Random Forest* y *SVM*, logra resultados similares utilizando un conjunto de datos moderado y sin necesidad de arquitecturas profundas, lo que resalta su practicidad para aplicaciones donde la simplicidad y la eficiencia computacional son prioritarias.

Por otra parte, las competiciones de referencia como la **BCI Competition IV (dataset 2a)** presentan tasas de acierto promedio entre **65%** y **80%** dependiendo del sujeto y el modelo aplicado, especialmente en tareas de clasificación binaria de imaginación motora. En comparación, el presente trabajo obtiene resultados equivalentes o superiores en una tarea de clasificación **multiclas**, lo que refuerza la solidez del enfoque planteado.

Comparando con otros autores, los resultados obtenidos son los siguientes:

<i>Modelo & Estudio</i>	<i>Accuracy (%)</i>	<i>F1 / Recall (%)</i>
[28]	89	-
[29]	89.6	89.6
<i>Este trabajo (Random Forest)</i>	81 (± 2)	≈ 81
<i>Este trabajo (SVM RBF)</i>	78 (± 3)	≈ 79

Tabla 5.3 - Resultados comparados con otros autores

En los estudios [28] y [29], los resultados obtenidos se basan en la aplicación de técnicas de deep learning sobre bases de datos de características similares, especialmente en relación con las tareas de motor imagery y la estructura de las señales EEG. Estos trabajos demuestran que la implementación de modelos profundos permite incrementar significativamente la precisión de clasificación. En concreto, se observa un aumento aproximado de 8 puntos porcentuales en la accuracy respecto a otros

enfoques más tradicionales, lo que refuerza la eficacia del deep learning para este tipo de problemas. Además, la confirmación neurofisiológica mediante el análisis del ERP y del Global Field Power (GFP) respalda científicamente la existencia de patrones diferenciables asociados a las intenciones motoras, lo que constituye un soporte esencial para el desarrollo de sistemas BCI robustos.

Capítulo 6 – Conclusiones y Líneas Futuras

6.1. Conclusiones

El presente Trabajo de Fin de Grado, "Procesado de Señal Encefalográfica para el Pronóstico de Intenciones Motoras", ha abordado un campo de investigación de vital importancia para el avance de las neurotecnologías y la mejora de la calidad de vida de personas con discapacidades motoras, como los pacientes amputados. A lo largo de este estudio, hemos explorado en profundidad los fundamentos neurofisiológicos de la intención motora, las características inherentes a la señal electroencefalográfica (EEG), y los principios que rigen las interfaces cerebro-computadora (BCI), estableciendo una sólida base teórica para nuestra investigación empírica, analizando la situación actual en línea con los establecido con el **objetivo 1** del TFG.

Uno de los logros fundamentales de este TFG ha sido la exitosa adquisición y el riguroso preprocesamiento de una vasta base de datos de señales EEG de libre acceso, alineado con el **objetivo 2** del presente Trabajo. La metodología implementada para la carga, filtrado, segmentación y, crucialmente, la corrección de la escala de amplitud de la señal en bruto ha

demonstrado ser robusta y eficaz. Este paso inicial, vinculado al **objetivo 3**, aparentemente técnico, fue decisivo, ya que aseguró la calidad y la interpretabilidad fisiológica de los datos, elementos indispensables para cualquier análisis subsiguiente. La capacidad de gestionar un volumen tan considerable de datos y de prepararlos óptimamente valida el enfoque metodológico adoptado en el presente trabajo y sienta un precedente para futuras investigaciones en el ámbito de las BCI.

Los resultados empíricos derivados del procesamiento de las señales EEG, tal como describe el **objetivo 4**, han proporcionado evidencia contundente de la capacidad para caracterizar la actividad cerebral asociada a la intención motora. Específicamente, la obtención y el análisis detallado del Potencial Evocado Promedio (ERP) para la condición T1 (movimiento/imaginación de puño izquierdo o ambos puños) revelaron la emergencia de un componente positivo claro y consistente. Este componente, con un pico bien definido entre 0.22 y 0.25 segundos post-evento y amplitudes en el rango fisiológico de microvoltios, confirma la existencia de una "firma" eléctrica cerebral discernible vinculada a la preparación o ejecución motora. La robustez de este hallazgo, obtenida a partir del promediado de un elevado número de épocas, subraya la efectividad de las técnicas de procesamiento de señal para realzar la actividad neuronal de interés frente al ruido de fondo. Además, el análisis de la Global Field Power (GFP) ha confirmado que esta respuesta no se limita a un único canal, sino que implica una activación cortical distribuida y coordinada, lo que refuerza la validez de los patrones observados.

El cumplimiento del **Objetivo 5** se materializó mediante el desarrollo y la evaluación de modelos de Machine Learning. Se implementaron clasificadores Random Forest y SVM, capaces de procesar las características extraídas y realizar predicciones sobre la intención motora del usuario. Los resultados obtenidos —con precisiones del 81% para Random Forest y 78% para SVM—, junto con un análisis detallado de las transiciones temporales entre estados, demostraron la capacidad del sistema para clasificar las intenciones motoras y seguir su evolución temporal. Aunque estos modelos no alcanzaron las cifras reportadas en la literatura para arquitecturas basadas en deep learning, los resultados validan el pipeline completo planteado en el trabajo y sientan las bases para futuras mejoras basadas en enfoques más avanzados.

En última instancia, este Trabajo de Fin de Grado sienta las bases para el desarrollo de un sistema de procesamiento de señal encefalográfica capaz de pronosticar intenciones motoras. La metodología establecida, junto con los resultados preliminares que validan la capacidad de extraer patrones significativos de la actividad cerebral, nos acerca a la visión de implementar dispositivos de asistencia controlados por BCI para pacientes amputados. La investigación ha contribuido no solo a la comprensión de cómo el cerebro codifica la intención motora, sino también a la ingeniería de los sistemas que pueden decodificarla, abriendo nuevas vías para la autonomía y la mejora de la calidad de vida. Esta autonomía y mejora de la calidad, debe estar respaldada por un marco legal, es por ello por lo que en respuesta al **Objetivo 6**, se realizó un estudio detallado del marco normativo europeo, con especial atención al Reglamento General de Protección de Datos (RGPD), y se analizaron las implicaciones éticas y legales del tratamiento de neurodatos. Este análisis subrayó la necesidad de desarrollar soluciones BCI que no solo sean técnicamente viables, sino también respetuosas con la privacidad y los derechos fundamentales de las personas.

6.2. Líneas Futuras

El presente trabajo sienta las bases para el procesamiento de señales EEG orientado al pronóstico de intenciones motoras. A partir de los resultados obtenidos y las limitaciones identificadas, se proponen las siguientes líneas futuras de investigación y desarrollo:

- **Optimización de Modelos de Aprendizaje Automático – Deep Learning:**

Explorar arquitecturas avanzadas de deep learning, como redes neuronales convolucionales (CNN), redes recurrentes (RNN) o transformers, que permitan mejorar la precisión y la capacidad de generalización en la clasificación de intenciones motoras.

- **Evaluación en Diferentes Bases de Datos:**

Probar la metodología con otras bases de datos públicas o privadas, con el fin de validar su aplicabilidad en distintos contextos y sobre diversas configuraciones de adquisición.

- **Integración de Datos Multimodales:**

Combinar señales EEG con otras fuentes de datos fisiológicos (EMG, EOG) para aumentar la robustez y la fiabilidad de los modelos.

- **Implementación:**

Desarrollar sistemas BCI funcionales que permitan la detección y respuesta en tiempo real, validando su rendimiento en entornos clínicos o de rehabilitación. Implementar dichas Interfaces en tecnología final.

- **Estudios Clínicos con Usuarios Finales:**

Colaborar con centros médicos para evaluar la eficacia del sistema en personas con amputaciones o discapacidades motoras.

- **Evaluación de la Neuroprivacidad:**

Profundizar en el estudio legal y ético sobre el uso y la protección de neurodatos, proponiendo marcos regulatorios adaptados a las tecnologías emergentes.

Referencias bibliográficas

- [1] A. McWhinnie, «Brainfacts.org,» 11 Febrero 2025. [En línea]. Available: <https://www.brainfacts.org/for-educators/for-the-classroom/2025/brain-structures-flashcards-limbic-system-021125>.
- [2] BraingFacts.org, «The Vestibular System: The Brain and Balance,» 31 Enero 2019. [En línea]. Available: <https://www.brainfacts.org/thinking-sensing-and-behaving/movement/2019/the-vestibular-system-the-brain-and-balance-013119>.
- [3] Brainfacts.org, «Nervous System,» 21 agosto 2023. [En línea]. Available: <https://www.brainfacts.org/diseases-and-disorders/immune-system-disorders/2012/multiple-sclerosis>.
- [4] M. F. C. B. W. & P. M. A. Bear, *Neuroscience: Exploring the brain* (4th ed.). Wolters Kluwer, 2016.
- [5] BrainFacts.org, «Brainfacts.org,» 1 octubre 2021. [En línea]. Available: 2021.
- [6] T. Congnativa, «[https://www.cognifit.com/uy/plasticidad-cerebral?srsltid=AfmBOoqFINVzZ0RUsA1N6vz2EmY64CEt4UgrjNVokG_1Y24qpxFC35YV](https://www.cognifit.com/uy/plasticidad-cerebral?srsltid=AfmBOoqFINVzZ0RUsA1N6vz2EmY64CEt4UgrjNVokG_1Y24qpxFC35YV#:~:text=Plasticidad%20Neuronal%20y%20Cognici%C3%B3n)», 04 julio 2011. [En línea]. Available: https://www.cognifit.com/uy/plasticidad-cerebral?srsltid=AfmBOoqFINVzZ0RUsA1N6vz2EmY64CEt4UgrjNVokG_1Y24qpxFC35YV.
- [7] «Ondas cerebrales,» 15 enero 2014. [En línea]. Available: <https://neuroscenter.com/neurofeedback/ondas-cerebrales/>.

- [8] Purves, D., Augustine, G. J., Fitzpatrick, D., Hall, W. C., LaMantia, A.-S., White, L. E., & Williams, S., *Neuroscience* (6th ed.). Oxford University Press., 2018.
- [9] J. A. Carrobles, «Bio/neurofeedback,» 07 septiembre 2016. [En línea]. Available: <https://www.redalyc.org/journal/1806/180648287004/html/>.
- [10] P. L. & S. R. Nunez, *Electric fields of the brain: The neurophysics of EEG* (2nd ed.). Oxford University Press., 2006.
- [11] H. (Ü. d. E. d. M. A. f. P. u. N. Berger, «El trabajo seminal de Berger,» pp. 87(1), 527–570. .
- [12] A. Bilbao, «La lateralidad motora ,como habilidad,» [En línea]. Available: <https://dialnet.unirioja.es/descarga/articulo/2278290.pdf>.
- [13] M. Teplan, «Fundamentals of EEG measurement. Measurement Science Review,» 2022, pp. 2(2), 1–11..
- [14] R. G. S. A. B. A. B. G. C. J. M. C. A. & W. J. Yuste, «Four ethical priorities for neurotechnologies and AI. *Nature*,» 2017, pp. 551(7679), 159–163..
- [15] A. E. d. P. d. D. (AEPD), «Neuroderechos: Retos éticos y jurídicos de las neurotecnologías. AEPD.,» 2022.
- [16] M. & A. Ienca, «Towards new human rights in the age of neuroscience and neurotechnology. *Life Sciences, Society and Policy*, 1,» 2017, pp. 13(1), 1–27..
- [17] P. R. Wolpe, «The ethics of *brain-computer interfaces*. In *Brain-computer interfaces: An introduction*,» 2022, pp. (pp. 37-58). .
- [18] L. F. & G.-G. J. i colas-Alonso, « Brain computer interfaces, a review. *Sensors*,» (Autores españoles),, 2012, pp. 12(2), 1211–1248..
- [19] A. L. M. L. E. E. D. A. S. B. B. C. .. & H. M. S. MNE-Python: Gramfort, «Neuroderechos: Retos éticos y jurídicos de las neurotecnologías. AEPD.,» 2022.
- [20] N. R. é. y. j. d. l. n. AEPD., «Neurociencia: La exploración del cerebro (4a ed.). Wolters Kluwer.,» 2016.
- [21] P. L. & S. R. Nunez, «Electric fields of the brain: The neurophysics of EEG (2nd ed.). Oxford University Press,» 2006.
- [22] L. F. & G.-G. J. (Nicolas-Alonso, «Brain computer interfaces, a review. *Sensors*,» 2012, pp. 12(2), 1211–1248..
- [23] M. & F. J. García-Sánchez, «Procesado de señales EEG para interfaces cerebro-ordenador.,» Universidad Politécnica de Madrid, 2018.
- [24] P. K. M. & G. R. Grosse, *Brain-Computer Interface Applications in Parkinson's Disease. Brain Sciences*, 11(11), 1438., 2021.

- [25] P. i. d. l. o. c. d. españa, «Medicos y pacientes .com,» 18 mayo 2025. [En línea]. Available: <https://www.medicosypacientes.com/articulo/espana-segundo-pais-del-mundo-con-mas-amputaciones-relacionadas-con-diabetes-2/#:~:text=Espa%C3%B1a%20es%20el%20segundo%20pa%C3%ADs,normal%20cicatrizaci%C3%B3n%20de%20las%20heridas..>
- [26] A. E. d. P. d. Datos, «Agencia Española de Protección de Datos,» 2022. [En línea]. Available: <https://www.aepd.es/prensa-y-comunicacion/blog/neurodatos-y-neurotecnologia-privacidad-y-proteccion-de-datos-personales>.
- [27] E. Derecho., «El reto para la protección de datos que suponen los neurodatos.,» 2024. [En línea]. Available: <https://elderecho.com/el-reto-para-la-proteccion-de-datos-que-supone-el-tratamiento-de-neurodatos>.
- [28] C. Zhang, H. Chu y M. Ma, “Decoding Algorithm of Motor Imagery Electroencephalogram Signal Based on CLRNet Network Model,” *Sensors*, vol. 23, no. 18, Art. No. 7694, Sep. 2023, doi: 10.3390/s23187694.
- [29] R. R. Chowdhury, Y. Muhammad, and U. Adeel, “Enhancing Cross-Subject Motor Imagery Classification in EEG-Based Brain–Computer Interfaces by Using Multi-Branch CNN,” *Sensors*, vol. 23, no. 18, art. no. 7908, Sep. 2023

PARTE II – PRESUPUESTO

Capítulo único – Presupuesto del Trabajo de Fin de Grado

1. Introducción

El objetivo de este capítulo es presentar el cálculo del presupuesto teórico asociado a este Trabajo de Fin de Grado, tratándolo como un proyecto técnico profesional. Para ello, se consideran los precios de mercado estimados en la fecha de julio de 2025, junto con las directrices y recomendaciones establecidas por el Colegio Oficial de Ingenieros Técnicos de Telecomunicación (COITT).

El presupuesto se desglosa en los siguientes apartados:

1. Recursos Materiales
2. Recursos Humanos
3. Licencias de Software
4. Costes de redacción
5. Derechos de Visado del COITT
6. Coste de tramitación y envío
7. Impuesto General Indirecto Canario (IGIC)

2. Recursos Materiales

Este apartado contempla los bienes físicos necesarios para la realización del proyecto. Incluye tanto equipamiento de hardware como material fungible utilizado durante el desarrollo:

- **Ordenador personal:** utilizado para el procesado de datos, desarrollo de software y entrenamiento de modelos. Además, se contempla para el desarrollo de la propia memoria. Como referencia, se ha tomado el portátil personal del autor, en particular *HP Pavilion 15 con 8 GB de memoria RAM y procesador AMD RYZEN 5 5500U*. El precio en mercado del equipo se encuentra en 599.99€. Sin embargo, si se establece su vida útil en 4 años y la duración del proyecto es de 4 meses aproximadamente, se debe multiplicar el coste por un factor de 0.0833 (4 meses de duración / 48 meses de vida útil).
- **Material auxiliar:** en particular, una unidad de memoria externa para la conservación y trasferencia de datos, archivos y documentos

Concepto	Coste
Portátil Personal HP Pavilion 15	49.99 €
Memoria externa 8 GB	5.07 €
Recursos materiales	55.06€

Tabla 2.1 – Gastos de recursos materiales

3. Recursos Humanos

En este apartado se refleja los honorarios destinados a un profesional realizando las tareas correspondientes. De acuerdo con lo establecido, el Trabajo de Fin de Grado se planifica sobre 300 horas. De acuerdo con la metodología orientativa de cálculo de honorarios profesionales establecida por el Colegio Oficial de Ingenieros Técnicos de Telecomunicación (COITT), y si atendemos a que la totalidad del proyecto se realiza durante la Jornada Laboral, para el cálculo se debe atender a la siguiente fórmula:

$$\text{Coste de Recursos Humanos} = Ct \cdot 74,88 \cdot Hn,$$

Donde Hn se corresponde con las horas trabajadas y Ct a un factor de corrección en base a esas horas. Para un proyecto de 300 horas, se le debe aplicar un factor final de 0,6. Por todo lo anterior, este concepto resulta de la siguiente manera:

Concepto	Coste
Honorarios	13.478,40 €
Recursos humanos	13.478,40 €

Tabla 3.1 – Gastos de recursos humanos

4. Licencias de Software

Para la elaboración del presente Trabajo de Fin de Grado se ha hecho uso de Matlab y Microsoft Office 365. Sin embargo, ambas licencias necesarias son proporcionadas al estudiantado de la Universidad de Las Palmas de Gran Canaria de forma gratuita, por lo que no ha supuesto un coste adicional.

Concepto	Coste
Licencias	0 €
Licencias de Software	0 €

Tabla 4.1 – Gastos de Software

5. Costes de redacción

Para obtener este apartado, debemos acudir a la siguiente fórmula:

$$\text{Costes de redacción} = 0,07 \cdot P \cdot Cn$$

Donde:

- **P** es la suma de todos los gastos base (Recursos Humanos, Recursos Materiales y Licencias)
- **Cn** es el coeficiente de ponderación en función del presupuesto

Sabiendo lo anterior:

$$P = 13.478,40 \text{ €} + 55,06 \text{ €} + 0 \text{ €} = 13.533,46 \text{ €}$$

Si $P < 30.050,00 \text{ €}$, entonces $Cn = 1$

$$\text{Costes de redacción} = 0,07 \cdot 13.533,46 \text{ €} = 947,34 \text{ €}$$

Concepto	Coste
Costes de redacción	947,34 €
Costes de redacción	947,34 €

Tabla 5.1 – Gastos de redacción

6. Derechos de visado del COITT

De acuerdo con el Colegio Oficial de Ingenieros Técnicos de Telecomunicación, el coste derivado del visado responde a la siguiente fórmula:

$$\text{Derechos de visado} = 0,006 \cdot P \cdot Cv$$

Donde:

- P es el presupuesto total del proyecto
- Cv es el coeficiente reductor según el importe del presupuesto

Se calcula el presupuesto tras añadir a los conceptos ya sumados anteriormente (Recursos Materiales, Humanos y Costes de Licencias), el coste de redacción:

$$P = 13.533,46 + 947,34 = 14.480,80 \text{ €}$$

Si $P < 30.050,00 \text{ €}$, entonces $Cv = 1$

$$\text{Derechos de visado} = 0,006 \cdot 14.480,80 \cdot 1,00 = 86,88 \text{ €}$$

Concepto	Coste
Visado	86,88 €

Derechos de visado	86,88 €
---------------------------	---------

Tabla 6.1 – Gastos de visado

7. Coste de tramitación y envío

De acuerdo con el Colegio profesional mencionado, el coste de tramitación y envío es fijo e igual a 6,01 €

Concepto	Coste
Tramitación y envío	6,01 €
Coste de tramitación y envío	6,01 €

Tabla 7.1 – Gastos de tramitación

8. Impuesto General Indirecto Canario

Dado que el proyecto se localiza en Las Palmas de Gran Canaria, resulta aplicable el Impuesto General Indirecto Canario (IGIC), conforme a la legislación fiscal vigente en la Comunidad Autónoma de Canarias. Este impuesto es igual al 7% del valor total del proyecto. Este apartado será calculado en el presupuesto final.

9. Presupuesto final

Se calcula la totalidad del coste de elaboración del presente Trabajo de Fin de Grado:

Concepto	Coste
Recursos materiales	55.06 €
Recursos humanos	13.478,40 €
Licencias de Software	0 €
Costes de redacción	947,34 €
Derechos de visado COITT	86,88 €
Coste de tramitación y envío	6,01 €

Total antes de impuestos	14.573,69 €
IGIC (7%)	1020,16 €
Presupuesto	15.593,85€

Tabla 9.1 – Presupuesto

El presupuesto final del proyecto es de **quince mil quinientos noventa y tres euros con ochenta y cinco céntimos** (15.593,85 €).

Firmado en Las Palmas de Gran Canaria a 18 de julio del 2025

Antonio Samuel Díaz García

PARTE III ANEXOS

ANEXO I - Identificación y justificación del grado de relación del TFG con los Objetivos de Desarrollo Sostenible

El fin del presente apartado es relacionar el contenido del Trabajo de Fin de Grado con los distintos Objetivos de Desarrollo Sostenible (ODS), si aplicara, conforme al Reglamento de la EITE para la realización y evaluación de Trabajos de Fin de Título.

ODS	Grado de relación con los ODS			
	0 – No procede	1 – Bajo	2 – Medio	3 – Alto
1. Fin de la pobreza	X			
2. Hambre cero	X			
3. Salud y Bienestar			X	
4. Educación de calidad	X			
5. Igualdad de Género	X			
6. Agua limpia y saneamiento	X			
7. Energía Asequible y no contaminante	X			
8. Trabajo decente y crecimiento económico	X			
9. Industria, Innovación e Infraestructuras			X	
10. Reducción de las desigualdades		X		
11. Ciudades y comunidades sostenibles	X			
12. Producción y consumo sostenible	X			
13. Acción por el clima	X			
14. Vida Submarina	X			
15. Vida de ecosistemas terrestres	X			
16. Paz, Justicia e instituciones sólidas		X		
17. Alianzas para lograr objetivos	X			

El trabajo realizado se alinea con varios de los Objetivos de Desarrollo Sostenible (ODS) definidos por la ONU, debido a su impacto potencial tanto en el ámbito social como en el tecnológico:

ODS 3 — Salud y Bienestar

Este TFG busca mejorar la calidad de vida de personas con movilidad reducida o discapacidad motora mediante el desarrollo de sistemas de control basados en la actividad cerebral. Las interfaces cerebro-computadora pueden facilitar la rehabilitación, la autonomía personal y el acceso a tecnologías de asistencia, lo que repercute directamente en el bienestar físico y emocional de los usuarios.

ODS 9 — Industria, Innovación e Infraestructura

Al centrarse en el uso de tecnologías avanzadas como el procesamiento de señales EEG y el aprendizaje automático, el trabajo fomenta la investigación aplicada y la innovación tecnológica en el sector biomédico. Además, promueve la creación de nuevas soluciones dentro del ámbito de las neurotecnologías y la inteligencia artificial, contribuyendo al desarrollo de infraestructuras digitales especializadas.

ODS 10 — Reducción de las Desigualdades

Las tecnologías desarrolladas mediante este tipo de investigaciones tienen el potencial de reducir las desigualdades al facilitar la integración social y la independencia de personas con discapacidad. La posibilidad de interactuar con el entorno mediante BCI contribuye a la inclusión y al acceso equitativo a servicios y oportunidades.

ODS 16 — Paz, Justicia e Instituciones Sólidas

Este TFG también aborda la necesidad de un marco ético y legal sólido para la gestión de los neurodatos, promoviendo la protección de los derechos fundamentales de las personas. En un contexto donde la privacidad mental y la neuroseguridad están cada vez más en debate, este trabajo pone en valor la importancia de la regulación y la transparencia en el desarrollo de estas tecnologías.

ANEXO II – Uso de Inteligencia Artificial en el desarrollo del presente Trabajo de Fin de Grado

Para la elaboración del presente Trabajo de Fin de Grado se ha hecho uso de las siguientes herramientas de Inteligencia Artificial (IA) Generativa:

- ChatGPT – OpenAI, alojado en el enlace <https://chatgpt.com/>
- Copilot – Microsoft, alojado en el enlace <https://copilot.microsoft.com/>

El uso de la inteligencia artificial en este trabajo se ha aplicado para la realización de las siguientes tareas:

- Apoyo a la redacción.
- Desarrollo del modelo de Machine Learning.
- Detección y corrección de errores.
- Soporte en la localización de errores de formato.
- Traducción del resumen a inglés.

