




UNIVERSIDAD DE BURGOS
ESCUELA POLITÉCNICA SUPERIOR
Grado en Ingeniería de la Salud



INGENIERÍA
DE LA SALUD

**TFG del Grado en Ingeniería de la
Salud**

**Preprocesado y procesado de
señales de
electroencefalograma (EEG)**

Presentado por Raúl Ortega Renuncio
en Universidad de Burgos

6 de febrero de 2026

Tutores: Dra. María Consuelo Saiz Manzanares –
Dr. Raúl Marticorena Sánchez

Resumen

El electroencefalograma (EEG) es una tecnología fundamental en neurociencia que permite registrar la actividad eléctrica cerebral de manera no invasiva. Sin embargo, el volumen masivo de datos generado por los sistemas de registro de EEG presenta desafíos significativos. El procesamiento eficaz de estos datos crudos requiere la implementación de *pipelines* robustos que integren preprocesamiento, procesamiento y análisis, junto con herramientas computacionales avanzadas y conocimientos en técnicas de análisis de datos que no siempre están disponibles en todos los contextos de investigación clínica. Además, la falta de estandarización en los procedimientos de preprocesamiento ha sido históricamente un obstáculo para la comparabilidad y replicabilidad de estudios.

Este Trabajo Fin de Grado se enfoca en el desarrollo de un *pipeline* integral de preprocesamiento y procesamiento de datos EEG crudos, recogidos en un estudio específico, con el objetivo de facilitar el análisis automatizado y reutilizable de estos datos. La solución se materializa en una aplicación interactiva que permitirá democratizar el acceso a estos análisis complejos, facilitando a investigadores sin conocimientos profundos en programación la visualización (cómo puede ser la topografía cerebral), procesamiento e interpretación de datos de EEG de forma intuitiva e integrada.

Se espera que este *pipeline* establezca una herramienta práctica y accesible para el análisis de EEG que combine rigor metodológico con usabilidad, proporcionando resultados reproducibles y permitiendo a profesionales e investigadores optimizar sus análisis según sus necesidades particulares.

Descriptores

Electroencefalograma (EEG), interfaz cerebro computador, *pipeline*, procesamiento de datos, análisis automatizado, reproducibilidad, visualización interactiva.

Abstract

The electroencephalogram (EEG) is a fundamental technology in neuroscience that enables non-invasive recording of brain electrical activity. However, the massive volume of data generated by EEG recording systems presents significant challenges. Effective processing of raw data requires the implementation of robust pipelines that integrate preprocessing, processing, and analysis, along with advanced computational tools and data analysis techniques not always available in all clinical research contexts. Furthermore, the historical lack of standardization in preprocessing procedures has been a barrier to study comparability and reproducibility.

This Final Degree Project focuses on developing a comprehensive pipeline for preprocessing and processing of raw EEG data collected in a specific study, with the aim of facilitating automated and reusable analysis of this data. The solution will be materialized in an interactive application that will democratize access to complex analyses, enabling researchers without deep programming knowledge to visualize (how brain topography can be), process, and interpret EEG data in an intuitive and integrated manner.

This pipeline is expected to establish a practical and accessible tool for EEG analysis that combines methodological rigor with usability, providing reproducible results and enabling professionals and researchers to optimize their analyses according to their particular needs.

Keywords

Electroencephalogram (EEG), brain computer interface, pipeline, data processing, automated analysis, reproducibility, interactive visualization.

Índice general

Índice general	iii
Índice de figuras	v
Índice de tablas	vi
Introducción	1
Objetivos	3
Conceptos teóricos	5
3.1. Electroencefalografía (EEG)	5
3.2. Componentes clave del <i>hardware</i>	7
3.3. Ventajas y desventajas del EEG	13
3.4. Usos y aplicaciones del EEG	15
3.5. Estado del arte y trabajos relacionados	15
Metodología	19
4.1. Descripción de los datos	19
4.2. Herramientas <i>hardware</i> y <i>software</i>	20
4.3. Técnicas metodológicas de programación	24
4.4. Entornos y aplicaciones	28
4.5. Procesamiento de la señal EEG	30
Resultados	39
5.1. Resumen de resultados	39
5.2. Discusión	42

Conclusiones	45
6.1. Aspectos relevantes	46
Lineas de trabajo futuras	49
Bibliografía	53

Índice de figuras

3.1. Representación gráfica de los distintos tipos de ondas cerebrales (delta, theta, alpha, beta y gamma) [Shure and Mínguez, 2024a].	6
3.2. Sistemas de montaje de electrodos: 10-20, 10-10 y 10-05 [Marino and Mantini, 2026].	8
3.3. Tipos de electrodos de EEG [Ortiz, 2020c].	9
3.4. Representación del ancho de banda [Ortiz, 2020b].	11
3.5. Representación de resolución con 3 bits y 16 bits [Ortiz, 2020b].	11
3.6. Representación de la saturación de la señal [Ortiz, 2020b].	12
3.7. Diagrama explicativo del concepto CMRR [Ortiz, 2020b].	12
3.8. Características de los diferentes tipos de conexión [Ortiz, 2020a].	14
4.1. <i>Diadem de Bitbrain</i> [Bitbrain, sfa].	20
4.2. Disposición de los electrodos conforme al montaje estándar internacional 10/10 [Bitbrain, sfa].	21
4.3. Pantalla principal <i>Sennslab</i> [Bitbrain, 2023].	23
4.4. Comparación de señales extraídas por ICA en registros EEG [Hramov et al., 2021].	33
4.5. Representación conceptual del funcionamiento de la Transformada de Fourier [Ollé, sf].	36
4.6. Oscilaciones neuronales en el registro de EEG [Marino and Mantini, 2026].	37
5.1. Comparativa raw vs preprocesado. Fuente propia	39
5.2. Comparativa raw vs preprocesado contaminado. Fuente propia	40
5.3. Gráfico Densidad Espectral de Potencia (PSD). Fuente propia	41
5.4. Mapas topográficos potencia espectral. Fuente propia	41
5.5. Gráfico de barras por electrodo y banda. Fuente propia	42
5.6. Interfaz de la aplicación desarrollada en modo Participante Individual. Fuente propia	43

Índice de tablas

5.1. Potencia espectral (μV^2) por banda de frecuencia y electrodo.	
Fuente propia	41
5.2. Electrodo con máxima potencia espectral por banda. Fuente propia	42

Introducción

El Electroencefalograma (EEG) es una técnica no invasiva de registro de la actividad eléctrica cerebral en tiempo real. Hans Berger acuñó este término en 1929 para describir las fluctuaciones eléctricas del cerebro captadas por electrodos en el cuero cabelludo [[Ramos-Argüelles et al., 2009](#)].

Esta herramienta relativamente antigua sigue siendo de gran utilidad clínica, por ejemplo, en epilepsia, encefalopatías o alteraciones de la conciencia [[Ramos-Argüelles et al., 2009](#)], y en la actualidad sus aplicaciones se extienden a la investigación cognitiva, educativa y clínica. En las últimas décadas se ha empleado para estudiar procesos de aprendizaje, atención, carga cognitiva y memoria de trabajo [[Barbey et al., 2022](#), [García-Monge et al., 2023](#)]. Asimismo, ha empezado a explorarse su uso en metacognición, es decir, el monitoreo y control de los propios procesos cognitivos, a través de estudios de neurociencia educativa que sugieren evidencias cerebrales con el rendimiento académico [[Fleur et al., 2021](#)].

Sin embargo, pese a su utilidad, el EEG presenta una elevada susceptibilidad a diversas señales fisiológicas, como la electrooculografía (EOG), la electromiografía (EMG) y la electrocardiografía (ECG), y señales no fisiológicas como el ruido electromagnético espacial. Esta contaminación frecuente genera ruido en los registros, complicando significativamente tanto la adquisición de datos como su posterior análisis e interpretación [[Jiang et al., 2025](#), [Sun et al., 2020](#)].

Es por esto por lo que el trabajo actual se centra en el preprocesamiento de las señales EEG crudas registradas a través de un dispositivo de diadema que integra 12 sensores secos para obtener señales limpias de ruidos y artefactos sobre las que realizar el procesamiento para la obtención de medidas que permitan llevar a cabo el análisis y su interpretación. Para ello,

en el procesamiento se busca una representación de las medidas que sirva para comprender mejor la actividad cerebral.

Gracias a este estudio, se podrá trabajar con la señal de EEG ya limpia para su procesamiento. Permitiendo de esta manera centrarse más en los análisis que se vayan a realizar, así como en su interpretación.

Para una comprensión más profunda de la investigación, toda la información técnica relacionada con el estudio está disponible en el [repositorio de *GitHub*](#). En él se detalla toda la información relacionada con los datos recolectados mediante la tecnología EEG, las herramientas de software utilizadas para su visualización y análisis, los resultados obtenidos, y el fundamento teórico que sustenta este trabajo fin de grado.

Objetivos

Este trabajo surge tras observar las dificultades que presenta analizar los datos obtenidos de la realización del Electroencefalograma. Estos deben pasar por un preprocesamiento para la obtención de señal de buena calidad, y posteriormente se debe trabajar sobre estos para realizar un análisis que permita su interpretación. Además, la accesibilidad a estas herramientas de análisis complejo presenta desafíos significativos para investigadores sin conocimientos avanzados en programación, lo que motiva el desarrollo de una solución interactiva y amigable.

Durante la realización de este trabajo, se ha buscado abordar una serie de objetivos correctamente definidos, que se pueden clasificar en diferentes áreas:

Los objetivos marcados por los requisitos del software a desarrollar:

1. Implementar un flujo de preprocesamiento para los datos EEG crudos que incluya:
 - Carga e importación de datos en formato CSV.
 - Aplicación de técnicas de filtrado y eliminación de artefactos.
 - Extracción y segmentación de eventos de interés.
 - Análisis espectral para la caracterización de la actividad cerebral.
2. Facilitar el acceso al análisis complejo de EEG mediante una aplicación interactiva que permita la visualización de resultados, sin requerir experiencia en programación.
3. Generar visualizaciones comprensibles que permitan la interpretación de los datos procesados.

Los objetivos de aprendizaje fijados en este trabajo son:

1. Analizar los fundamentos teóricos y metodológicos del electroencefalograma como herramienta de estudio de la actividad cerebral, explorando su relevancia, aplicaciones y desafíos en el contexto de la neurociencia contemporánea.
2. Dominar las técnicas computacionales necesarias para:
 - Manejo y manipulación de datos de EEG en contextos de investigación.
 - Implementación de algoritmos de preprocesamiento de señales.
 - Obtención de medidas para el análisis de los datos.
3. Diseñar soluciones accesibles que democratizen el análisis de EEG combinando rigor metodológico con usabilidad para investigadores sin experiencia en procesamiento de señales.
4. Desarrollar competencias en desarrollo de software enfocado en aplicaciones científicas y análisis de datos.

Conceptos teóricos

Como preámbulo a los detalles técnicos del trabajo, conviene introducir los conceptos teóricos clave que sustentan la comprensión de la tecnología de la Electroencefalografía (EEG).

3.1. Electroencefalografía (EEG)

El Electroencefalograma (EEG) es una técnica no invasiva de registro de la actividad eléctrica cerebral. El origen de la señal eléctrica radica en las neuronas piramidales de la corteza cerebral, que constituyen dipolos eléctricos, cuya polaridad varía según la naturaleza inhibitoria o excitatoria de los impulsos. Para adquirir la señal de actividad eléctrica se colocan electrodos en la superficie craneal, cada par mide la diferencia de potencial eléctrico entre ellos [Ramos-Argüelles et al., 2009]. La señal del EEG es compleja y difícil de interpretar. Esto se debe a que es una señal no lineal, lo que significa que su comportamiento no sigue una proporción fija, y no estacionaria, es decir, sus características cambian con el tiempo. Además, como ya se ha comentado en la introducción, el EEG es muy susceptible a las interferencias. Por lo tanto, un registro de EEG no solo capta la actividad eléctrica del cerebro, sino también otras señales electrofisiológicas del cuerpo humano y señales no fisiológicas [Jiang et al., 2025].

Ondas cerebrales

Una onda cerebral es una oscilación rítmica observable en la actividad eléctrica del cerebro, registrada mediante un EEG. Estas oscilaciones surgen cuando grupos de neuronas se activan de manera sincronizada, generando fluctuaciones en el voltaje que los electrodos colocados sobre el cráneo

pueden capturar. En un EEG típico, estas variaciones se manifiestan como crestas y valles, y se miden en hercios (ciclos por segundo), clasificándose según su frecuencia en diferentes tipos de ondas (delta, theta, alpha, beta y gamma), cada una asociada a diversos estados cognitivos o fisiológicos [Shure and Mínguez, 2024a]. En la figura 3.1 se representan gráficamente los tipos de ondas cerebrales, donde puede observarse la diferencia en su morfología y frecuencia característica. En el eje X se representa el tiempo en segundos y en el eje Y se representa la amplitud de la señal.

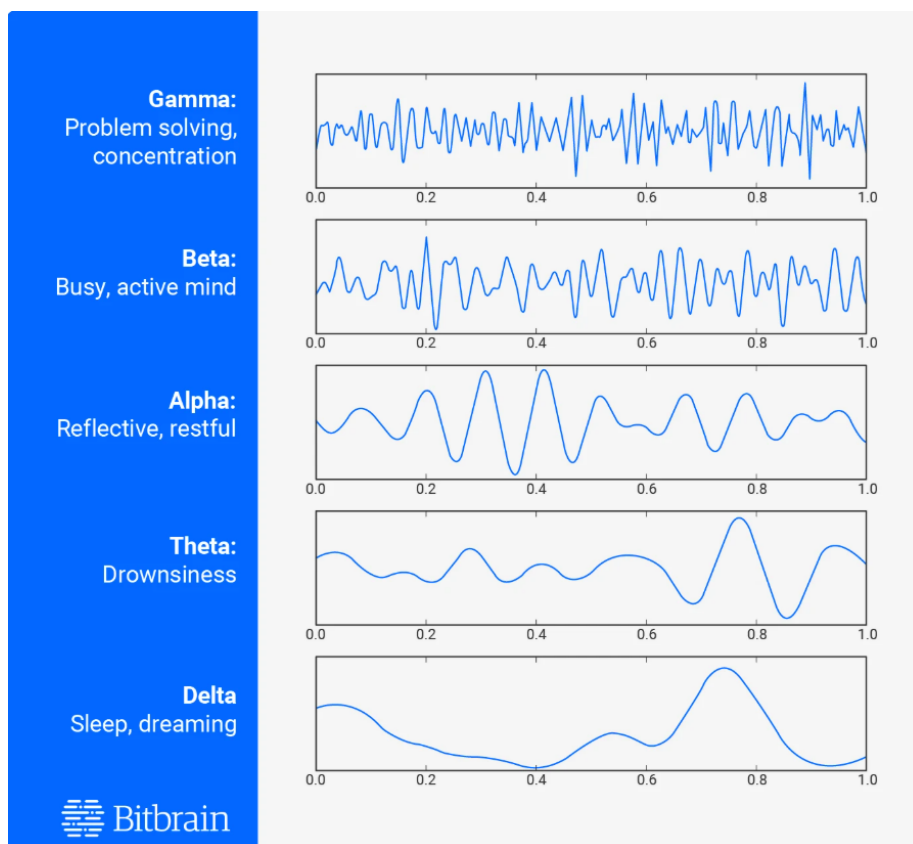


Figura 3.1: Representación gráfica de los distintos tipos de ondas cerebrales (delta, theta, alpha, beta y gamma) [Shure and Mínguez, 2024a].

Artefactos

Los artefactos se definen como señales eléctricas que, aunque se registran simultáneamente con la actividad cerebral, no derivan de esta. Su presencia en los registros de EEG puede enmascarar la actividad neural de interés

y, en consecuencia, comprometer la validez del análisis. Se distinguen dos categorías principales de artefactos:

- Artefactos de origen fisiológico: son generados por la actividad de estructuras biológicas distintas al cerebro, como los movimientos oculares (incluyendo parpadeos), la actividad muscular (electromiografía, EMG), la actividad cardíaca (electrocardiograma, ECG), la transpiración y la respiración.
- Artefactos de origen no fisiológico: provienen de fuentes externas al sujeto, tales como el ruido de la red eléctrica, el movimiento de los electrodos y los cables, la colocación incorrecta de la referencia y movimientos corporales [Team, 2020].

3.2. Componentes clave del *hardware*

Un sistema de EEG suele dividirse en tres áreas principales: la capa de sensores (casco y electrodos), el amplificador (circuitos analógicos y digitales) y características complementarias como la conectividad, la transmisión de datos y la alimentación. A continuación, se describen estas partes, su funcionamiento y cómo influyen en la calidad de la señal EEG [Bitbrain, 2020].

Capa sensora de EEG (casco y electrodos)

La función de la capa sensora de EEG es establecer la conexión entre el cuerpo del sujeto y el sistema de adquisición, permitiendo el transporte de la señal biológica al amplificador [Ortiz, 2020c]. Los electrodos son los sensores que recogen las señales eléctricas cerebrales en el cuero cabelludo. Sus características determinan en gran medida la calidad de la señal registrada. Algunos aspectos clave son:

- Tipo de electrodo: por convención se emplea un electrodo de referencia fijo (común a todos los canales) y un electrodo de tierra. Así, un sistema de EEG típico incluye tres tipos de electrodos: de registro (situados en las zonas de interés cerebral), de referencia (cuyo potencial se sustrae de cada registro) y de tierra (asegura el mismo potencial entre amplificador y cuerpo, reduciendo interferencias de modo común, que serán explicadas más adelante).
- Número de electrodos: el número de electrodos determina la resolución espacial de la medición. Los sistemas comunes usan entre 8 y 128




Figura 3.2: Sistemas de montaje de electrodos: 10-20, 10-10 y 10-05 [Marino and Mantini, 2026].

electrodos (más uno de referencia y uno de tierra). Más electrodos permiten registrar actividad cerebral más detallada (varias áreas del cerebro), pero aumentan el costo, la complejidad del montaje y el procesamiento de datos. Por ejemplo, gorros de investigación pueden tener 32, 64 o más electrodos, mientras que dispositivos portátiles suelen usar menos para favorecer la comodidad.

- Colocación de electrodos: sigue estándares como el sistema internacional 10-20 (posición proporcional sobre la cabeza). Los sistemas pueden tener posiciones fijas (electrodos integrados en lugares predefinidos) o intercambiables (electrodos móviles). Los de disposición intercambiable ofrecen mayor flexibilidad experimental (útiles en investigación), pues permiten cubrir zonas del cerebro según necesidad. Los de posiciones fijas suelen ser más ergonómicos, sencillos de colocar y económicos. Aunque limitan el cambio de ubicaciones puede ser preferible para estudios donde la ubicación de los electrodos es siempre la misma, priorizando así la usabilidad y la comodidad. En la figura 3.2 se muestran ejemplos de sistemas estándar de montaje de electrodos, específicamente los sistemas 10-20, 10-10, 10-05.
- Contacto del electrodo: según la sustancia conductora entre el electrodo y la piel se diferencian dos grandes familias como se puede observar en la figura 3.3: electrodos secos y húmedos. Los electrodos húmedos requieren un gel o solución salina entre el metal y la piel, por lo que ofrecen menor impedancia de contacto, proporcionando mejor relación señal/ruido. Esto significa que facilitan la transmisión de la señal cerebral al amplificador con menor contaminación por ruido. Sin embargo, requieren preparación (aplicar gel, limpieza), pueden

ser incómodos a largo plazo y necesitan mantenimiento (limpieza, jeringas, etc.). Los electrodos secos son más cómodos y rápidos de colocar, lo que los hace ideales para entornos de uso real o aplicaciones de consumo (*neurofeedback*, interfaces cerebrales de uso cotidiano). Su inconveniente es la alta impedancia de contacto, que degrada la relación señal/ruido. Para contrarrestar esto, tanto el electrodo como el amplificador deben diseñarse para tolerar el ruido extra. Entre ambos extremos existen los electrodos semisecos o a base de agua/salina, que usan solo agua o una solución salina en lugar de gel, centrándose en la integración de consideraciones ergonómicas y de rendimiento.

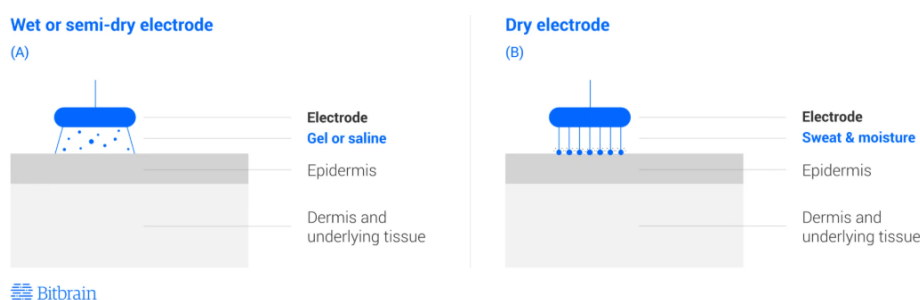


Figura 3.3: Tipos de electrodos de EEG [Ortiz, 2020c].

- Blindaje de EEG: el uso de blindaje en electrodos y cables mejora la calidad de la señal al minimizar los artefactos y el ruido. Los electrodos pueden ser activos o pasivos. Los electrodos activos incorporan un amplificador pequeño junto al electrodo. Este preamplificador local eleva la señal antes de conducirla por el cable, reduciendo la dependencia de la impedancia piel-cable y amortiguando en parte los artefactos de movimiento. En cambio, los electrodos pasivos carecen de preamplificador y conectan directamente el sensor con el cable de registro. Aunque los activos mejoran la inmunidad al ruido inducido por cable o movimiento, pueden introducir ruidos comunes si no se calibran correctamente. Dado que las señales EEG tienen amplitudes en rango de microvoltios, es crucial minimizar todo ruido adicional. Por ello se emplea blindaje (apantallado) en cables y electrodos: un recubrimiento conductor externo (jaula de Faraday) que aísla la señal interna de interferencias externas. El blindaje pasivo, conectado a un potencial fijo (generalmente tierra), ya reduce mucho el ruido, y el blindaje activo, donde existe el mismo potencial en el cable interno y externo, maximiza la atenuación de capacitancias parásitas. Un buen apantallado de cables y electrodos mejora notablemente la calidad de

la señal EEG, ya que elimina gran parte del ruido ambiental inducido [Bitbrain, 2020, Ortiz, 2020c].

Amplificador EEG

El amplificador es el dispositivo encargado de capturar, amplificar y digitalizar las señales analógicas del EEG [Ortiz, 2020b]. Su funcionamiento se caracteriza por las siguientes propiedades:

- Frecuencia de muestreo: determina el número de veces que se mide la señal por unidad de tiempo, expresada generalmente en hercios (Hz). Según el teorema de Nyquist, debe ser al menos el doble de la frecuencia máxima útil de la señal. Las bandas EEG van típicamente de 0.5 a 80 Hz, si bien una frecuencia de muestreo de 160 Hz sería suficiente, los amplificadores estándar suelen presentar una frecuencia de muestreo de 256 Hz. Frecuencias de muestreo superiores ofrecen mayor resolución, pero no información neurológica adicional.
- Ancho de banda: el ancho de banda define el rango de frecuencias dentro del cual un sistema de EEG puede capturar y procesar señales de forma fiable, tal como se muestra en la figura 3.4. Este parámetro está condicionado por la frecuencia de muestreo del sistema, como se ha comentado anteriormente y por los filtros pasa-banda internos del amplificador (filtro pasa-alto y filtro pasa-bajo).
- Resolución: cada muestra analógica se convierte a un valor digital con un Conversor Analógico-Digital (ADC) de n bits. El número de bits determina cuántos niveles discretos puede codificar. A mayor número de bits utilizados, mayor será la resolución de la señal digital registrada, como se puede observar en la figura 3.5. En EEG clínico/investigación de alta calidad la resolución estándar generalmente es de 24 bits o mayor.
- Rango de entrada: define la amplitud máxima de señal que el amplificador puede registrar sin saturarse. Este efecto de saturación se puede ver en la figura 3.6.
- Ruido interno: es el ruido eléctrico generado por los circuitos internos del amplificador. La baja amplitud de las señales de EEG (típicamente del orden de los microvoltios) requiere que el ruido de fondo sea de un valor inferior a $1 \mu V_{\text{rms}}$, con el fin de asegurar la calidad del registro. El valor μV_{rms} representa el voltaje efectivo de la señal, calculado




Figura 3.4: Representación del ancho de banda [Ortiz, 2020b].

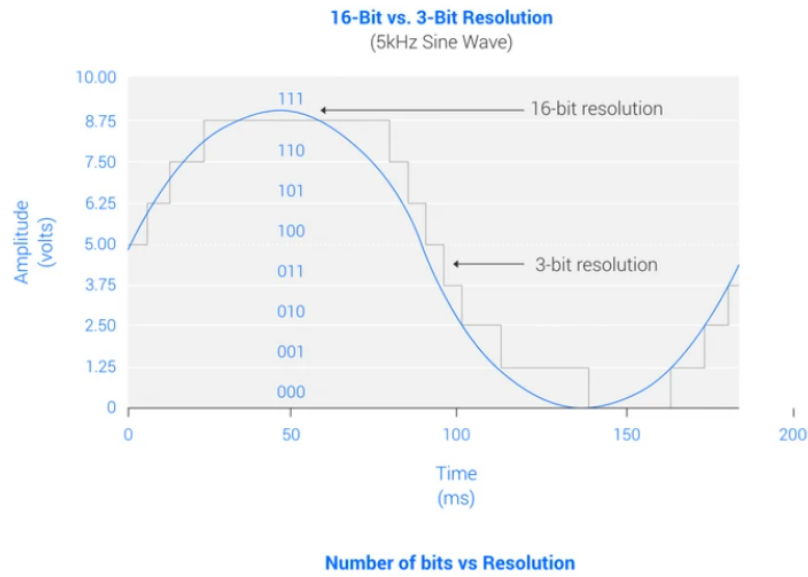


Figura 3.5: Representación de resolución con 3 bits y 16 bits [Ortiz, 2020b].

como la raíz cuadrada de la media aritmética de los valores de voltaje al cuadrado, es decir, mediante la raíz de la media cuadrática (*Root Mean Square*, RMS) [Wikipedia, 2024c].

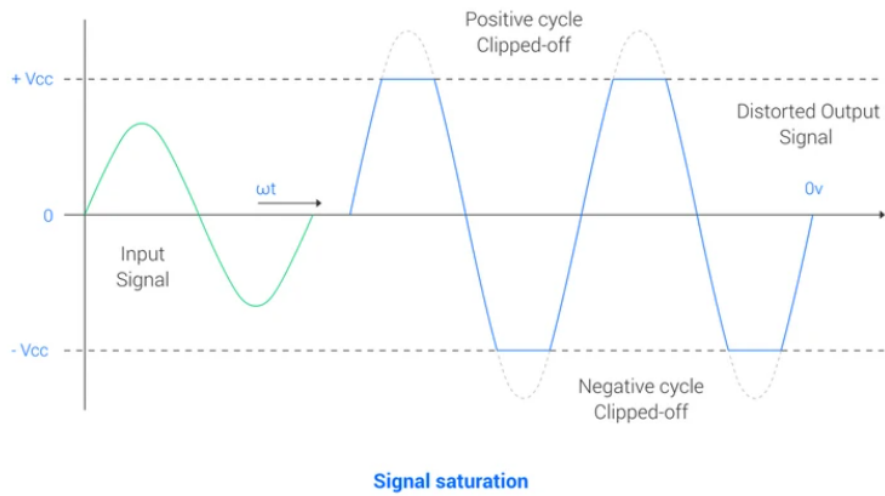


Figura 3.6: Representación de la saturación de la señal [Ortiz, 2020b].

- Relación de rechazo de modo común (*Common-Mode Rejection Ratio*, CMRR): cuantifica la capacidad de un amplificador diferencial para atenuar o eliminar la señal de modo común (*Common-Mode Voltage*, V_{CM}). Es decir, mide cuán bien el amplificador diferencia señales diferenciales de señales comunes. En EEG se busca que cualquier ruido que aparece por igual en el electrodo activo y el de referencia sea suprimido. Un valor más alto de este parámetro denota un rendimiento superior del amplificador. Este proceso está representado en el diagrama de la figura 3.7

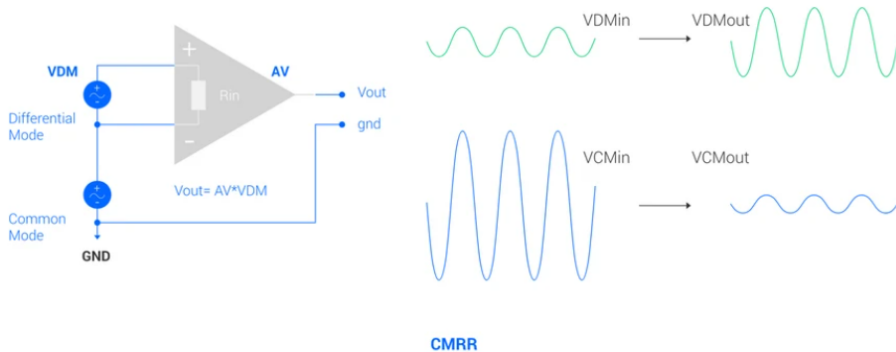


Figura 3.7: Diagrama explicativo del concepto CMRR [Ortiz, 2020b]

- Impedancia de entrada: indica cuánta carga eléctrica ofrece el amplificador a los electrodos. La impedancia de entrada del amplificador debe ser significativamente mayor que la de los electrodos para garantizar un registro de señal preciso [Bitbrain, 2020, Ortiz, 2020b].

Conectividad, transmisión de datos y alimentación

Las características de conectividad y energía definen la movilidad y robustez del sistema EEG, así como aspectos prácticos de uso:

- Alimentación: puede ser por cable de red o por batería. Con cable se garantiza duración ilimitada de grabación, pero se limita el movimiento del sujeto. Con batería se logra total movilidad, aunque la autonomía queda determinada por la capacidad. Las baterías pueden ser internas, que ofrecen mayor autonomía en menor espacio, pero exigen apagar para recargar, o intercambiables, que permiten cambio en caliente a costa de mayor tamaño y peso.
- Conectividad: la conexión entre el amplificador y el ordenador puede ser cableada (generalmente USB) o inalámbrica (wifi, Bluetooth o tecnologías propietarias). La comunicación cableada es muy robusta, de alta capacidad de datos y baja latencia, pero obliga a que el participante este físicamente conectado mediante cable, reduciendo la movilidad. La conexión inalámbrica permite libertad de movimiento completa, a cambio de una ligera pérdida de fiabilidad. Las diferentes características que presentan los distintos tipos de conexión se pueden observar en la figura 3.8. Para evitar pérdidas de datos en modo inalámbrico es frecuente el uso de protocolos de reconexión o almacenamiento local de respaldo [Bitbrain, 2020, Ortiz, 2020a].

3.3. Ventajas y desventajas del EEG

Ventajas

- No invasivo y seguro. El EEG se registra sobre el cuero cabelludo sin penetrar el cuerpo, por lo que es indoloro y no conlleva riesgos médicos [Ramos-Argüelles et al., 2009, Wikipedia contributors, 2026].
- Alta resolución temporal. Captura cambios cerebrales en escala de milisegundos, ideal para estudiar la dinámica rápida del cerebro [Tayeb, 2018, Wikipedia contributors, 2026].

	Data throughput	Impact on amplifier size	Impact on battery	Data packet delay	Movement freedom	Need for external elements
Wired	Very High	Low	Low	Very Low	No	No
WiFi TCP	High / Very high	Medium / Low	High	High	Yes	No
WiFi UDP	High / Very high	Medium / Low	High	High / Medium	Yes	No
Bluetooth	Medium / Low	Medium / Low	Medium / Low	Medium / Low	Yes	No
BLE	Low	Medium / Low	Low	Medium / Low	Yes	No
Proprietary technology	Adapted to the device	Medium / Low	Medium / Low	Medium / Low	Yes	Yes

Figura 3.8: Características de los diferentes tipos de conexión [Ortiz, 2020a]

- Costo moderado y portátil. Comparado con otras técnicas de neuroimagen, el EEG es relativamente barato y existen sistemas portátiles que permiten monitoreo continuo o en entornos no hospitalarios [Wikipedia contributors, 2026, Shure and Mínguez, 2024b].
- Amplia utilización clínica. Como se comentará en la siguiente sección tiene aplicaciones establecidas en neurología y otras áreas, siendo útil en el seguimiento de trastornos cerebrales [Ramos-Argüelles et al., 2009, Tayeb, 2018, Wikipedia contributors, 2026, Shure and Mínguez, 2024b].

Desventajas

- Baja resolución espacial. El EEG no localiza con precisión la fuente de la actividad cerebral, pues las señales se dispersan al atravesar huesos y tejidos [Tayeb, 2018].
- Susceptible a artefactos y ruido. Dado su bajo voltaje, las señales EEG se contaminan fácilmente con ruidos de origen biológico o ambiental. Esto exige un cuidadoso preprocesado y colocación de electrodos [Tayeb, 2018].
- Señal superficial. Solo capta actividad de la corteza cerebral cercana al cráneo; áreas profundas o regiones muy plegadas se registran mal o requieren técnicas invasivas adicionales [Wikipedia contributors, 2026].

3.4. Usos y aplicaciones del EEG

- Diagnóstico clínico neurológico. Es fundamental en neurología para detectar epilepsias y evaluar disfunción cerebral focal o generalizada (encefalopatías, alteraciones del nivel de conciencia). También se emplea en medicina del sueño (polisomnografía) para estudiar trastornos del sueño y en monitoreo intraoperatorio (junto con potenciales evocados) durante cirugías cerebrales [Ramos-Argüelles et al., 2009, Wikipedia contributors, 2026].
- Monitoreo y seguimiento. Se usa en unidades de cuidados intensivos (EEG continuo) para vigilar pacientes comatosos o con sospecha de crisis subclínicas, y en neurorrehabilitación para evaluar la recuperación tras lesiones [Wikipedia contributors, 2026].
- Investigación en neurociencia cognitiva. El EEG es muy utilizado en psicología experimental y neurociencia cognitiva por su alta resolución temporal. Sirve para estudiar procesos como percepción sensorial, atención, memoria de trabajo y respuestas a estímulos (potenciales relacionados con eventos, ERP). En este ámbito, se integran también interfaces cerebro-computadora (*Brain-Computer Interface*, BCI) para comunicación o control basados en la actividad EEG en tiempo real [Shure and Mínguez, 2024b].
- *Neurofeedback* y aprendizaje cerebral. El EEG en tiempo real se emplea en neurofeedback para entrenamiento neuronal. Se investiga su uso en tratamiento de trastornos como Trastorno por Déficit de Atención con Hiperactividad (TDAH), ansiedad o para mejorar el rendimiento cognitivo [Shure and Mínguez, 2024b].
- Neurotecnología y aplicaciones comerciales. Existen aplicaciones emergentes en *neuromarketing* (estudio de la respuesta cerebral a estímulos publicitarios), control de atención/fatiga, videojuegos BCI, y nuevas interfaces hombre-máquina no invasivas [Shure and Mínguez, 2024b].

3.5. Estado del arte y trabajos relacionados

Introducción histórica

Según [Evans, 2023], Hans Berger registró la actividad eléctrica cerebral en los años 1920, descubrimiento que resultó valioso para el estudio de epilepsia. Un cambio paradigmático ocurrió cuando el análisis digital reemplazó

el laborioso procesamiento analógico que implicaba observar trazas de tinta en papel continuo y realizar análisis visual manual, permitiendo la cuantificación simultánea de múltiples componentes cerebrales de forma objetiva y reproducible. Este cambio marcó el nacimiento del análisis cuantitativo de EEG moderno (QEEG). Aunque el desarrollo experimentó ralentización en finales de la década de 1970 y durante la de 1980, un resurgimiento ocurrió a finales de los 1980s con la formación de organizaciones profesionales, desarrollo de metodologías avanzadas y construcción de bases de datos normativas. Para 1994, hallazgos QEEG fueron aceptados como evidencia judicial, demostrando reconocimiento científico del campo.

Fundamentos del análisis de EEG moderno

***EEGLAB*: Herramientas de Procesamiento Estándar**

EEGLAB se presenta por [Delorme and Makeig, 2004], esta es una caja de herramientas de código abierto para análisis de dinámicas de ensayos únicos de EEG que incluye análisis de componentes independientes. *EEGLAB* surge como herramienta fundamental que democratiza el acceso a métodos de procesamiento de EEG avanzados mediante una interfaz gráfica intuitiva sobre el lenguaje *MATLAB*. El software implementa funciones básicas de procesamiento de señales, así como métodos sofisticados para separación de artefactos y análisis tiempo-frecuencia. La importancia de este trabajo es múltiple. En primer lugar, *EEGLAB* introduce una interfaz gráfica que democratiza el acceso a métodos complejos como Análisis de Componentes Independientes (*Independent Component Analysis*, ICA), permitiendo que investigadores sin ser expertos en programación avanzada puedan aplicar análisis sofisticados. En segundo lugar, proporciona herramientas visualización de componentes y artefactos que facilitan la interpretación de resultados. En tercer lugar, establece estándares en la comunidad neurocientífica para preprocesamiento de datos EEG que persisten hasta la actualidad.

MNE-Python*: análisis reproducible con *Python

MNE-Python se presenta por [Gramfort et al., 2013], esta es una biblioteca de código abierto construida sobre *NumPy*, *SciPy* y *Matplotlib* que proporciona herramientas completas para el procesamiento de datos de magnetoencefalografía (MEG) y EEG. El software implementa algoritmos modernos para preprocesamiento, análisis de fuentes, pruebas estadísticas y estimación de conectividad funcional. Este trabajo es fundamental para comprender la evolución del análisis de EEG hacia la programación científica

moderna. En primer lugar, introduce la filosofía de análisis reproducible mediante código abierto, permitiendo que otros investigadores verifiquen, repliquen y extiendan los resultados. En segundo lugar, integra las mejores prácticas de la comunidad neurocientífica en una interfaz consistente y bien documentada basada en *Python*. En tercer lugar, proporciona implementaciones eficientes de algoritmos complejos (como ICA, análisis de fuentes con *sLORETA*, pruebas de permutación) que anteriormente requerían múltiples herramientas diferentes.

***Pipeline* PREP: estandarización del preprocesamiento**

El problema de la falta de estandarización en el preprocesamiento de EEG se aborda en [Bigdely-Shamlo et al., 2015], mediante la propuesta del *pipeline* PREP. La ausencia de protocolos estandarizados de preprocesamiento constituye un obstáculo para la realización de análisis a gran escala. PREP propone un protocolo estándar que incluye: identificación robusta de canales defectuosos mediante criterios estadísticos, interpolación de baja resolución espacial a través de canales malos y re-referenciación robusta a un promedio común. El trabajo demuestra que aplicar este protocolo de forma consistente mejora significativamente la calidad de los datos y la fiabilidad de los análisis posteriores al preprocesamiento.

Mejoras en el análisis de artefactos y clasificación automática

***ICLabel*: clasificación automática de componentes ICA**

ICLabel se presenta por [Pion-Tonachini et al., 2019], este es un clasificador automático de componentes por ICA basado en redes neuronales convolucionales que resuelve un problema crítico del análisis de EEG. Aunque la identificación de artefactos mediante ICA es una práctica estándar desde las primeras implementaciones de Makeig en *EEGLAB*, determinar manualmente qué componentes representan artefactos y cuáles representan actividad cerebral genuina es una tarea laboriosa, subjetiva y propensa a errores. *ICLabel* aborda este problema mediante automatización basada en aprendizaje profundo, entrenado con más de 200.000 componentes ICA etiquetados manualmente por expertos. El clasificador proporciona probabilidades de confianza para cada componente, permitiendo decisiones automatizadas para casos claros e intervención manual cuando hay ambigüedad.

MNE-ICALabel: integración en ecosistema Python

ICLabel se integra en el ecosistema de *MNE-Python*, democratizando el acceso a la clasificación automática de componentes ICA [Li et al., 2022]. El modelo de *ICLabel* fue previamente disponible únicamente en *MATLAB*. La migración a *PyTorch* en formato *Python* mediante *MNE-ICALabel* garantiza el mantenimiento futuro del modelo y su integración perfecta en *pipelines* modernos de análisis de EEG basados en *Python*.

Impacto del preprocesamiento en análisis posteriores

Se investiga si el preprocesamiento siempre mejora la calidad de los resultados analíticos [Kessler et al., 2025]. Los autores compararon múltiples estrategias de preprocesamiento (filtrado, ICA automática con *ICLabel*, rechazo de épocas automático y diferentes re-referenciaciones) en el contexto de decodificación mediante aprendizaje automático. Hallaron que el preprocesamiento excesivo puede reducir el rendimiento de los modelos, sugiriendo un balance óptimo entre limpieza de artefactos y conservación de información neural.

De forma complementaria, [Delorme, 2023] demuestran basándose en múltiples datasets públicos que diferentes estrategias de preprocesamiento (filtrado, re-referenciación, rechazo de épocas) producen efectos variables dependiendo del objetivo analítico específico. Este trabajo proporciona evidencia empírica de que no todas las prácticas tradicionales de preprocesamiento son uniformemente beneficiosas, validando que las decisiones metodológicas deben adaptarse al contexto particular de cada análisis.

Metodología

El desarrollo de este capítulo se centra en la exposición detallada de la metodología y los recursos técnicos que han permitido alcanzar los objetivos de la investigación. El análisis incluye la procedencia y descripción de los datos, la especificación de las herramientas de *software* y *hardware* utilizadas, y una descripción de los entornos de ejecución y las plataformas empleadas, entre otros elementos relevantes.

4.1. Descripción de los datos

El presente trabajo se fundamenta en el análisis de datos empíricos, obtenidos directamente mediante sesiones prácticas con la tecnología de electroencefalografía (EEG). Los participantes firmaron previamente un consentimiento informado, aceptando su participación en la recolección de datos. Estos documentos no son de acceso público, dado que contienen información sujeta a la normativa de protección de datos personales. El desarrollo del estudio se enmarca en el proyecto de I+D+i “*Análisis multidimensional de la carga cognitiva en estudiantes universitarios: un estudio multicanal integrado (MACLUS-IMS)*”, dirigido por la Dra. María Consuelo Sáiz Manzanares, y cuenta con informe positivo de la Comisión de Bioética de la Universidad de Burgos (UBU N.º IO 5/2024, fecha de expedición 29/01/2025).

A diferencia de estudios que emplean bases de datos preexistentes, esta investigación se ha centrado en la adquisición de información original en contextos empíricos. Este enfoque garantiza una mayor precisión y relevancia en los resultados, ya que la información es directamente representativa de los sujetos de estudio. Los datos obtenidos fueron posteriormente sometidos a procesos de extracción, preparación (limpieza y filtrado) y procesamiento

para su análisis. El Apéndice D proporciona detalles adicionales sobre el proceso de recolección y las características de los datos.

4.2. Herramientas *hardware* y *software*

En este apartado, se procede a una caracterización detallada del instrumental y las herramientas de *software* utilizadas para la recolección de los datos. A diferencia de la conceptualización general del *hardware* de EEG, aquí se proporciona una descripción precisa del modelo exacto del dispositivo y del *software* empleado, lo que permite una comprensión más rigurosa de las especificaciones técnicas que condicionan el proceso de adquisición y, por consiguiente, la naturaleza de los datos obtenidos.

Minimal EEG Diadem

El registro de la actividad electroencefalográfica se llevó a cabo utilizando el dispositivo *Diadem* de *Bitbrain*, que se puede observar en la figura 4.1, un sistema de 12 sensores secos diseñado específicamente para fines de investigación, que ha sido validada para la medición de estados emocionales y cognitivos. Es importante señalar que este equipo no está clasificado como un dispositivo médico y, por lo tanto, no se ha diseñado para diagnóstico o tratamiento clínico, sino exclusivamente para investigación.



Figura 4.1: *Diadem* de *Bitbrain* [Bitbrain, sfa].

Este dispositivo fue seleccionado por sus características operativas y su tecnología de sensores secos, que optimizan la comodidad del participante y la eficiencia en la configuración experimental. La diadema cuenta con 12 sensores ubicados en áreas cerebrales específicas (prefrontal, frontal,

parietal y occipital), además de un electrodo de tierra (*Ground*, GND) y uno de referencia (REF) colocado en la oreja izquierda. El electrodo REF proporciona el potencial base para medir la diferencia de potencial entre cada electrodo activo de registro y este punto de referencia común, mientras que el electrodo GND establece una conexión común para todos los amplificadores del sistema, mejorando el rechazo de modo común y reduciendo artefactos electromagnéticos [Inc., sfa]. En la figura 4.2, se puede observar la ubicación de los sensores que se adhieren al estándar internacional 10/10, cubriendo las siguientes posiciones en el cuero cabelludo: AF7, Fp1, Fp2, AF8, F3, F4, P3, P4, PO7, O1, O2 y PO8.




Figura 4.2: Disposición de los electrodos conforme al montaje estándar internacional 10/10 [Bitbrain, sfa].

La alta calidad de la señal, un factor crítico para la fiabilidad de los resultados, se asegura mediante un sistema de apantallamiento activo y un diseño mecánico que minimiza los artefactos, incluso en condiciones de movimiento o en registros de larga duración. Las especificaciones técnicas del *hardware* son las siguientes:

- Frecuencia de muestreo: 256 Hz.
- Resolución: 24 bits.
- El sistema opera en un rango de frecuencia de corriente continua (DC) a 40 Hz, con un filtro pasa-bajos de tercer orden (*3rd order LPF*) que asegura la eliminación de componentes de alta frecuencia.
- Rango de entrada y ruido: El rango dinámico de entrada es de ± 100 mV, mientras que el ruido del sistema es inferior a $1 \mu\text{V}_{\text{rms}}$ en el rango de 0.5 a 30 Hz a una frecuencia de muestreo de 256 Hz.
- Rechazo de modo común e impedancia de entrada: El sistema presenta una alta tasa de rechazo de modo común (CMRR) superior a 100 dB a 50 Hz, lo que minimiza el ruido de la red eléctrica. La impedancia de entrada es superior a $50 \text{ G}\Omega$, lo que garantiza una medición precisa de las señales de baja amplitud del EEG.
- Autonomía: La batería ofrece una autonomía de más de 8 horas en modo en línea y más de 10 horas en modo con respaldo en tarjeta MicroSD. El tiempo de carga es de 3 horas o menos.
- Conectividad: La transmisión de datos es inalámbrica, utilizando tecnología Bluetooth 2.1 + EDR, lo que significa *Enhanced Data Rate* (Velocidad de Datos Mejorada). Esto proporciona una mayor velocidad de transferencia de datos y un alcance de hasta 10 metros en línea de visión directa.
- Respaldo de datos: El sistema permite el respaldo de datos en una tarjeta MicroSD extraíble, que debe ser de 8 GB y de clase 10 o superior para evitar la pérdida de datos.
- Disponen además de una unidad de medida inercial (*Inertial Measurement Unit*, IMU) interna de 9 DOF (*Degrees of Freedom*), así como de control de impedancia relativa en línea, lo que facilita la verificación en tiempo real de la calidad del contacto de los electrodos [Bitbrain, sfa].

SennsLab

SennsLab es la plataforma de *Bitbrain* para el diseño experimental, la adquisición multimodal sincronizada de señales biométricas y la gestión de estudios [Bitbrain, sfb, Bitbrain, 2023]. El software integra el flujo completo de trabajo experimental: definición del estudio (plantillas y parámetros), asignación de participantes y sensores, ejecución y registro sincronizado

de datos y exportación para análisis externo o para su posterior análisis con herramientas *Bitbrain*. Está organizado en tres bloques operativos, como se observa en la figura 4.3: *Design*, *Launch* y *Analyze*, que cubren, respectivamente, la creación y parametrización de estudios (incluyendo plantillas preconfiguradas), la ejecución (chequeo de sensores, calibraciones y grabación) y la gestión y exportación de los datos registrados. En la fase de

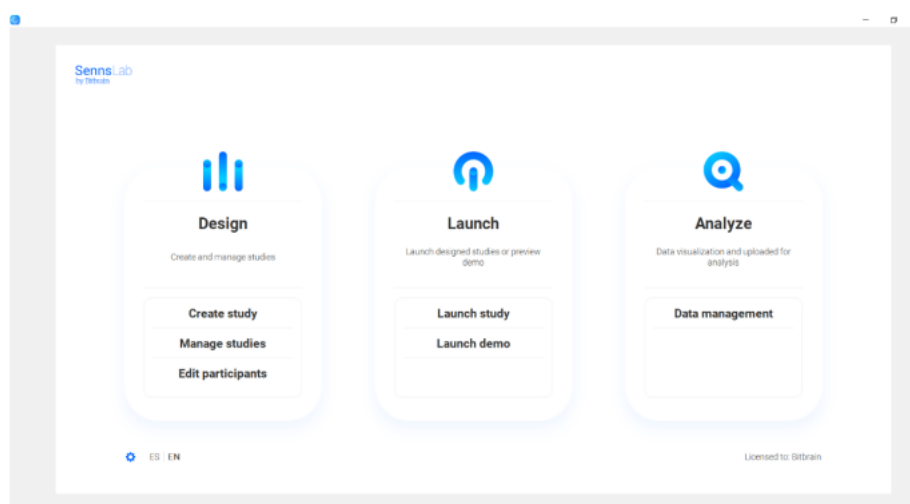


Figura 4.3: Pantalla principal *Sennslab* [Bitbrain, 2023].

diseño es posible seleccionar plantillas estándar o crear estudios totalmente personalizados. Antes de cada grabación *Sennslab* permite comprobar el estado de los sensores (con indicadores de señal y calidad) y visualizar las señales en tiempo real; dispone de filtros de visualización por defecto, aunque estos filtros afectan solamente a la presentación en tiempo real y no alteran los datos brutos exportados. Asimismo, el software informa del estado de grabación en micro-SD del propio dispositivo (opción disponible en *Diadem*) y muestra mensajes de estado relacionados con la conectividad (Wi-Fi / Bluetooth) y la integridad de la escritura. Estas funciones facilitan la detección temprana de problemas durante la adquisición. *Sennslab* ofrece dos formatos de exportación principales: *Lite*, y *Full*. El formato *Lite* es orientado a investigadores porque preserva los datos crudos con información técnica detallada como número de secuencia y *timestamps* de recepción, permitiendo detectar problemas en la adquisición y aplicar correcciones personalizadas según sus necesidades analíticas; mientras que *Full* es dirigido a usuarios generales porque presenta los datos alineados temporalmente con frecuencia de muestreo fija, relleno automático de datos faltantes y opciones

de corrección disponibles, resultando en información estructurada y lista para usar [Bitbrain, 2023].

4.3. Técnicas metodológicas de programación

El procesamiento de los datos, que incluye su carga, limpieza, filtrado y posterior análisis, requirió el uso de herramientas y metodologías de programación especializadas.

Python

Python es un lenguaje de programación de alto nivel, interpretado y de propósito general, cuyo desarrollo es gestionado por la *Python Software Foundation* [Wikipedia, 2025c, Services, sf]. Entre sus características más destacadas se encuentran:

- Legibilidad y simplicidad sintáctica. *Python* prioriza la claridad en la escritura del código, lo que reduce la curva de aprendizaje y facilita la colaboración en proyectos de investigación y desarrollo.
- Lenguaje interpretado. *Python* ejecuta directamente el código a través de un intérprete, lo que elimina la necesidad de compilación y facilita la depuración y el desarrollo ágil.
- Multiparadigma. Ofrece soporte para diversos estilos de programación (orientada a objetos, funcional e imperativa), lo que otorga flexibilidad para afrontar problemas heterogéneos en investigación.
- Tipado dinámico. No requiere declarar de forma explícita el tipo de datos de las variables, lo que acelera la escritura de *scripts* y prototipos.
- Lenguaje multiplataforma. Está disponible en los principales sistemas operativos (*Windows*, *macOS* y *Linux*), lo que permite su uso en entornos de laboratorio heterogéneos.
- Extenso ecosistema científico. *Python* cuenta con una amplia variedad de librerías y entornos de desarrollo orientados al análisis de datos, cálculo numérico y visualización.
- Código abierto y gratuito.

El procesamiento de señales EEG puede realizarse en otros entornos consolidados, como *MATLAB*, que dispone de *toolboxes* específicos tales como *EEGLAB* o *BCILAB* [Bitbrain, sfb]. Si bien estas herramientas son potentes y cuentan con una comunidad de uso muy extensa, su principal limitación es el coste de las licencias y la dependencia de software propietario. En cambio, *Python*, con librerías como *MNE-Python* [Gramfort et al., 2013], ha alcanzado un nivel de madurez comparable, ofreciendo además mayor flexibilidad, interoperabilidad con entornos de aprendizaje automático y una filosofía de acceso abierto. Por estas razones, en el presente trabajo se ha seleccionado *Python* como entorno de procesamiento de señales EEG. Su combinación de facilidad de uso, ecosistema científico especializado, carácter multiplataforma y gratuidad lo convierten en una opción idónea frente a *MATLAB*.

Markdown

Markdown es un lenguaje de marcado ligero diseñado para optimizar la legibilidad y la facilidad de publicación. Su estructura sintáctica, inspirada en las convenciones de formato de texto plano utilizadas en los correos electrónicos, prioriza la claridad del código fuente, permitiendo a los usuarios escribir documentos de manera sencilla y natural. Esta filosofía de diseño proporciona una combinación ideal de simplicidad, legibilidad, portabilidad y flexibilidad de formato. Permite la creación rápida de documentos estructurados sin sacrificar claridad, y facilita su conversión a formatos finales ampliamente usados [Wikipedia, 2024b]. La utilización de *Markdown* en el *Jupyter Notebook* en este proyecto se debe a su capacidad para conectar de manera fluida y elegante los diferentes componentes de un análisis de datos: el texto explicativo (análisis metodológico, justificación) y el código fuente (*Python* para el procesamiento). Esta sinergia permite documentar el proceso de forma clara y accesible, asegurando la transparencia y facilitando la reproducibilidad de los trabajos, aspectos que son pilares fundamentales en la investigación científica contemporánea.

Bibliotecas de Python

El ecosistema de desarrollo en *Python* se nutre de la disponibilidad de bibliotecas, que actúan como repositorios de código predefinido y reutilizable. Estas colecciones de funciones y módulos están diseñadas para ser integradas en proyectos, lo que optimiza el proceso de programación y evita la duplicación de esfuerzos al no tener que reescribir soluciones comunes. Por defecto, la instalación de *Python* incorpora la biblioteca estándar, un

conjunto exhaustivo de funcionalidades que abarca desde la manipulación de datos hasta la gestión de archivos. Más allá de esta base, la comunidad de desarrolladores ha contribuido con una amplia gama de bibliotecas, superando las 137.000, para cubrir una vasta diversidad de dominios de aplicación [Services, sf]. La metodología de este proyecto se ha apoyado en el empleo de las siguientes bibliotecas para la implementación de sus algoritmos y funcionalidades:

Pandas

Pandas es una biblioteca de código abierto para *Python* que se especializa en la manipulación y el análisis de datos. Entre sus principales características se encuentra la capacidad de leer y escribir fácilmente en diversos formatos (como *CSV* y *Excel*), así como la eficiencia para acceder, reordenar y combinar grandes conjuntos de datos [Team, 2025c, con ALF, 2025]. En el contexto de este trabajo, se ha utilizado *Pandas* para la gestión del flujo de datos. En particular, se ha empleado para la carga inicial de los datos y para almacenar los resultados del procesamiento en una estructura de *DataFrame*, que posteriormente se ha guardado en un archivo *CSV* para garantizar la persistencia de los resultados.

NumPy

Es una biblioteca fundamental de *Python* diseñada para la computación numérica avanzada. Proporciona estructuras de datos optimizadas (*arrays* y matrices multidimensionales), junto con una amplia gama de funciones matemáticas eficientes. Como herramienta de código abierto, está especialmente preparada para trabajar con grandes volúmenes de datos, ofreciendo una velocidad y rendimiento superiores a las estructuras nativas de *Python*, y ha sido clave en el ecosistema científico del lenguaje. En este trabajo se utiliza *NumPy* por su capacidad para gestionar de forma eficiente datos numéricos mediante arreglos y operaciones vectorizadas, lo que permite simplificar los cálculos y optimizar el rendimiento en comparación con las estructuras de datos básicas de *Python*.

Matplotlib

Matplotlib es una biblioteca de *Python* versátil y completa, diseñada para la creación de gráficos y visualizaciones de datos de alta calidad. Permite generar representaciones estáticas, animadas e interactivas en 2D. Con esta herramienta, es posible personalizar y crear una amplia variedad de

gráficos [Hunter, 2007, con ALF, 2021]. Es una herramienta fundamental en el análisis de datos, facilitando la visualización y exploración de información.

Scipy

Es una biblioteca de código abierto para *Python* que proporciona herramientas y algoritmos científicos y numéricos. Ofrece módulos para optimización, integración, interpolación, problemas de valor propio, ecuaciones algebraicas, ecuaciones diferenciales, estadística y otras tareas comunes en ciencia e ingeniería. Se construye sobre la extensión *NumPy* de *Python*, incorporando potentes funciones de alto nivel para la manipulación y el análisis de datos [Virtanen et al., 2020, Team, 2025b]. En particular, *SciPy* se ha empleado para la aplicación de la regla de Simpson, utilizada para aproximar áreas bajo la curva. La descripción detallada de esta técnica se presenta más adelante en el apartado 4.5.

MNE-Python

MNE-Python es una biblioteca de código abierto en *Python* diseñada para el procesamiento, análisis y visualización de datos neurofisiológicos humanos, como Electroencefalograma (*Electroencephalogram*, EEG), Magnetoencefalograma (*Magnetoencephalogram*, MEG), Estereoelectroencefalograma (*Stereoelectroencephalogram*, sEEG), Electroencefalograma (*Electrocorticogram*, ECoG) y Espectroscopia de Infrarrojo Cercano (*Near-Infrared Spectroscopy*, NIRS). Ofrece herramientas para tareas como la estimación de fuentes corticales, análisis de conectividad, modelos de decodificación, análisis de oscilaciones neuronales, estadísticas paramétricas y no paramétricas, y visualización de datos. Su integración con otras bibliotecas científicas como *NumPy*, *SciPy* y *scikit-learn* permite realizar análisis avanzados en neurociencia computacional [contributors, 2025, Newman, sf, Gramfort et al., 2013]. Complementariamente, se ha empleado *mne-icalabel*, un paquete que automatiza la clasificación de componentes independientes [Developers, 2025]. *MNE-Python* y su paquete complementario *mne-icalabel* se utilizan de manera conjunta, permitiendo un flujo de trabajo eficiente y preciso en el análisis de datos neurofisiológicos. La descripción detallada de estas herramientas se presenta más adelante en el apartado 4.5.

Streamlit

Streamlit es un *framework* de código abierto basado en *Python* que permite la creación de aplicaciones web interactivas y visualizar análisis de datos sin necesidad de conocimientos profundos de desarrollo web frontend.

Proporciona *widgets* preconstruidos para interfaces interactivas, se integra con librerías de visualización y utiliza una arquitectura reactiva [Inc., sfc, Inc., sfb]. *Streamlit* se eligió para este proyecto por su capacidad de crear una interfaz gráfica interactiva que permite a los usuarios procesar datos EEG y su facilidad para generar un flujo de trabajo mas intuitivo durante el procesamiento y visualización de resultados.

4.4. Entornos y aplicaciones

Para llevar a cabo los objetivos de este trabajo, se ha utilizado un conjunto de aplicaciones y entornos que se describen a continuación.

Visual Studio Code (VS Code)

VS Code un editor de código fuente multiplataforma y de código abierto, desarrollado por *Microsoft*, que se caracteriza por su versatilidad, ligereza y amplio ecosistema de extensiones que facilitan la programación en múltiples lenguajes, incluyendo *Python* [Microsoft, 2025]. En este proyecto, *VS Code* constituyó el entorno principal de desarrollo, integrando tanto la creación de módulos en *Python*, en el que se definieron las funciones necesarias para el procesamiento de los datos de EEG, como la utilización de *Jupyter Notebook*, lo que facilitó un flujo de trabajo modular, estructurado y flexible. Además, *VS Code* se empleó para observar y explorar los archivos CSV generados durante la adquisición y procesamiento de los datos de EEG, permitiendo analizar la estructura de los datos antes de su uso en el *notebook* y verificar el contenido de los resultados, tanto el CSV como las imágenes.

Jupyter Notebook

Es una aplicación web que permite combinar código ejecutable, texto explicativo y gráficos en un único documento, facilitando el análisis de datos, la documentación de procesos y la comunicación de resultados de manera reproducible [Team, 2015]. Concretamente, *Jupyter Notebook* se utilizó como herramienta de desarrollo para validar progresivamente las funciones de preprocesamiento y análisis de EEG. Su capacidad de combinar código ejecutable, visualizaciones y documentación permitió garantizar reproducibilidad y trazabilidad de cada etapa del procesamiento de datos antes de su implementación final.

Overleaf

Es un editor en línea de *LaTeX* que facilita la redacción, edición y producción de documentos científicos y técnicos. Entre sus características destacadas se incluyen la edición simultánea por múltiples usuarios, la posibilidad de comentar y chatear dentro del documento, el seguimiento de cambios en tiempo real y un historial completo del proyecto [Overleaf, 2025]. *LaTeX* es un sistema de preparación de documentos que permite crear textos académicos y científicos con alta calidad tipográfica, especialmente útil para fórmulas, tablas y referencias bibliográficas [Team, 2025a]. En este proyecto, *Overleaf* se utilizó para la redacción de la memoria y anexos, aprovechando su capacidad de colaboración y control de versiones.

MiKTeX

MiKTeX es una distribución *TeX/LaTeX* de código abierto moderna para *Windows*, *Linux* y *macOS* [Wikipedia, 2023a].

TeXstudio

TeXstudio es un editor integrado (IDE) multiplataforma especializado en *LaTeX* que ofrece herramientas avanzadas como coloreado de sintaxis, autocompletado y corrector ortográfico interactivo [Wikipedia, 2024d]. Debido a limitaciones en los tiempos de compilación de *Overleaf* en línea, se utilizaron *MiKTeX* y *TeXstudio* para compilar localmente.

GitHub

GitHub es una plataforma de desarrollo colaborativo basada en *Git*, que permite alojar, versionar y gestionar proyectos de software. Facilita la colaboración entre múltiples usuarios mediante control de versiones, seguimiento de incidencias y revisión de código [GitHub, 2025]. Esta plataforma se utilizó para registrar y controlar los avances del desarrollo del código, así como para llevar un seguimiento de la elaboración de la memoria y los anexos, asegurando la trazabilidad de los cambios realizados, facilitando la colaboración y manteniendo un historial completo de las versiones del módulo de *Python*, del *notebook* de *Jupyter* y de los documentos asociados al proyecto.

Zube

Zube es una herramienta de gestión de proyectos ágil que se integra de manera fluida con *GitHub Issues*, permitiendo a los equipos de desarrollo organizar, priorizar y realizar un seguimiento de las tareas mediante tableros *Kanban*, *sprints* y *epics*. Su interfaz intuitiva y su potente integración con *GitHub* facilitan la colaboración entre desarrolladores y otros miembros del equipo [WebCatalog, 2025]. Esta herramienta se utilizó junto con *GitHub* para planificar y registrar los avances, asignar tareas y mantener un seguimiento organizado tanto del desarrollo del código como de los análisis realizados, garantizando un flujo de trabajo estructurado y eficiente.

4.5. Procesamiento de la señal EEG

El análisis de la señal EEG requiere un conjunto de procedimientos estandarizados que permitan transformar los registros en bruto en datos interpretables y libres de artefactos. Todas las operaciones se implementaron en *Python* utilizando principalmente la librería *MNE-Python* como se ha comentado anteriormente. A continuación se describen las principales técnicas empleadas en el presente trabajo.

Filtrado digital

El EEG es susceptible a diversas fuentes de ruido, como se ha explicado en los conceptos teóricos, para atenuarlas se emplean técnicas de filtrado digital:

Filtro pasa-banda

El filtro pasa-banda permite conservar únicamente las frecuencias comprendidas en un intervalo definido, atenuando las que se encuentran por debajo o por encima [Wikipedia, 2024a]. Existen dos implementaciones habituales de filtros digitales:

- Filtros FIR (*Finite Impulse Response*): caracterizados por una respuesta al impulso finita y fase lineal [Wikipedia, 2025a], lo que evita distorsión temporal en las ondas EEG.
- Filtros IIR (*Infinite Impulse Response*): incluyen retroalimentación, lo que los hace computacionalmente más eficientes, aunque con posibles problemas de estabilidad y distorsión de fase [Wikipedia, 2025b].

En este trabajo se ha empleado un filtro de respuesta de impulso finito (FIR), que es el método por defecto en MNE para EEG, dado que asegura fase lineal y, por tanto, preserva la morfología temporal de las señales.

Filtro *notch* o filtro elimina banda

Diseñado para suprimir únicamente un rango de frecuencias. Se ha utilizado para eliminar la interferencia procedente de la red eléctrica [Wikipedia, 2019].

Referencia promedio

Consiste en sustraer a cada canal el promedio de todos los canales en cada instante de tiempo, según la siguiente expresión:

$$x'_i(t) = x_i(t) - \frac{1}{N} \sum_{j=1}^N x_j(t)$$

donde $x_i(t)$ representa la señal original del canal i , N es el número total de canales y $x'_i(t)$ es la señal referenciada [Torres-García et al., 2013].

Análisis de Componentes Independientes (ICA)

Es una técnica estadística de separación ciega de fuentes, utilizada para descomponer una señal multicanal en componentes subyacentes que se asumen estadísticamente independientes entre sí. Su objetivo es identificar las fuentes subyacentes que contribuyen a la señal registrada, como actividad cerebral, artefactos o ruido [Hyvärinen and Oja, 2000, developers, 2025, Hramov et al., 2021]. Matemáticamente, se considera que las señales EEG registradas, representadas como un vector $\mathbf{x}(t)$, son combinaciones lineales de fuentes independientes $\mathbf{s}(t)$:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t),$$

donde \mathbf{A} es una matriz de mezcla desconocida. El objetivo de ICA es estimar una matriz de separación \mathbf{W} tal que:

$$\mathbf{s}(t) = \mathbf{W}\mathbf{x}(t),$$

maximizando la independencia estadística de los componentes obtenidos [Hyvärinen and Oja, 2000, Hramov et al., 2021]. En términos prác-

ticos, esto permite descomponer la señal EEG en fuentes latentes, separando aquellas de origen neuronal de las que corresponde a artefactos [Campos Viola et al., 2009].

A modo de ejemplo, la figura 4.4 ilustra la interpretación de componentes ICA y su relación con artefactos y señales neuronales:

- (a) Componente (*Component*): Muestra la señal resultante de un solo componente ICA antes de su clasificación. Se aprecian picos regulares que combinan tanto actividad neural como artefactual, junto a ruido de fondo.
- (b) Artefacto (*Artifact*): Representa exclusivamente el artefacto identificado. Conserva la forma y la amplitud de los picos observados en (a), pero con mucho menos ruido alrededor, evidenciando que ha sido separado del contenido neural.
- (c) Señal neural (*Neural*): Contiene la señal *limpia* tras la eliminación del artefacto. Su amplitud es menor y la morfología es más irregular, reflejando la verdadera actividad cerebral sin las contribuciones indeseadas.

La figura 4.4 ejemplifica la utilidad de ICA: separar señales con morfologías y espectros diferentes, de modo que los trazados correspondientes a artefactos puedan identificarse y excluirse de la reconstrucción de la señal limpia.

ICLabel

Tras la estimación de los componentes independientes mediante ICA, resulta necesario diferenciar aquellos de origen cerebral de los que corresponden a artefactos. La clasificación manual realizada por expertos es considerada precisa, pero presenta limitaciones importantes en términos de escalabilidad y reproducibilidad cuando se trabaja con grandes volúmenes de datos. En este contexto, se empleó *ICLabel*, un clasificador automático basado en aprendizaje supervisado. Este algoritmo toma como entrada diferentes características de cada componente y genera una distribución de probabilidad sobre diversas categorías: cerebro, ojo, músculo, corazón, ruido de red eléctrica [Pion-Tonachini et al., 2019]. La principal ventaja del uso de *ICLabel* es su automatización y reproducibilidad, ya que permite procesar de manera eficiente grandes volúmenes de datos sin necesidad de una inspección manual exhaustiva, reduciendo tanto el tiempo de análisis




Figura 4.4: Comparación de señales extraídas por ICA en registros EEG [Hramov et al., 2021].

como la subjetividad del evaluador. El coste potencial de esta estrategia es una ligera pérdida de eficiencia en casos límite, donde la clasificación automática puede resultar menos precisa que la revisión humana. No obstante, en estudios que implican un número elevado de sujetos o sesiones, la automatización compensa ampliamente esa pequeña pérdida relativa de precisión [Pion-Tonachini et al., 2019].

Corrección de línea base

En el análisis de señales neurofisiológicas como el EEG, la línea base se define como un periodo de registro previo a la aparición de un estímulo o al inicio de un bloque experimental, utilizado como referencia para la corrección de la señal posterior. Su finalidad es garantizar que la actividad cerebral analizada esté relacionada con los eventos experimentales y no con fluctuaciones previas o artefactos residuales [Abril Ronderos, 2020, Community, sf]. Existen dos razones fundamentales para aplicar esta corrección [Abril Ronderos, 2020]:

- Corrección de cambios verticales en el voltaje: durante el registro, el ruido o las condiciones técnicas pueden provocar desplazamientos de la señal respecto al eje y (voltaje en microvoltios μV), de manera que esta oscile en torno a un valor distinto de cero. La corrección de línea base elimina dicho desplazamiento, garantizando que la señal se centre en torno a $y = 0$.
- Comparación entre actividad no relacionada con la tarea y actividad relacionada: al restar la actividad registrada en un intervalo inmediatamente anterior al estímulo (actividad basal), es posible aislar la actividad neuronal inducida por el evento. De este modo, se obtiene una estimación más precisa de la respuesta cognitiva.

En términos teóricos, el funcionamiento de la línea base se fundamenta en el supuesto de que la actividad registrada en el periodo previo al estímulo o al bloque corresponde a actividad basal, es decir, procesos no relacionados directamente con la tarea experimental. De este modo, al restar este valor de referencia a la señal posterior al estímulo, se asume que lo que queda corresponde a la actividad neuronal evocada por el evento experimental. Sin embargo, esta premisa es válida solo si se cumplen las siguientes condiciones:

- Divagación: la actividad mental no relacionada con la tarea puede ocurrir en cualquier momento, pero es más frecuente durante los periodos de descanso empleados como línea base, lo cual introduce actividad cerebral no deseada que puede sesgar la corrección.
- Posición: la postura corporal o la posición de registro debe mantenerse constante entre participantes y condiciones. Pequeños cambios posturales han demostrado afectar la actividad cerebral registrada, comprometiendo la validez de la línea base como referencia estable.

En consecuencia, la corrección de línea base no debe interpretarse como una eliminación completa de toda la actividad no relacionada con la tarea, sino como una aproximación que mejora la comparación entre condiciones siempre que el diseño experimental minimice factores como divagación o variaciones posturales [[Abril Ronderos, 2020](#)].

Estimación de la Densidad Espectral de Potencia (PSD)

La densidad espectral de potencia (PSD, por sus siglas en inglés) es una función que describe cómo se distribuye la potencia de una señal en el

dominio de la frecuencia. Permite calcular la potencia absoluta de la señal en un rango de frecuencias determinado mediante la integración de la PSD en dicho intervalo, proporcionando una medida directa de la potencia contenida [Luengas C. and Toloza, 2020]. Su método de estimación se detalla en el apéndice “E_Estudio experimental” del anexo.

Potencia de banda promedio

La potencia de banda promedio es una medida que resume en un único valor la contribución de una banda de frecuencia específica a la potencia total de la señal. Se obtiene mediante la integración de la PSD en el intervalo de frecuencias correspondiente a la banda de interés, utilizando métodos de integración numérica como la regla de Simpson [Vallat, 2018]. Su método de integración se detalla en el apéndice “E_Estudio experimental” del anexo.

Transformada Rápida de Fourier (FFT)

La Transformada Rápida de Fourier (FFT) es el algoritmo computacional clave que permite transformar una señal discreta del dominio temporal al dominio frecuencial de manera eficiente. Este es un algoritmo eficiente que permite calcular la transformada de Fourier discreta (DFT) y su inversa [Wikipedia, 2024e]. Esta transformación es esencial para descomponer señales EEG en componentes de frecuencia. Este algoritmo genera, para cada frecuencia del espectro, un valor complejo. A partir de dicho valor, es posible obtener de forma directa y precisa la amplitud y la fase de la señal en cada una de sus frecuencias constituyentes [Vallat, 2018]. Para facilitar la comprensión de este proceso, en la Figura 4.5 se muestra un esquema ilustrativo: una señal compleja en el dominio temporal puede descomponerse en varias ondas sinusoidales simples, que luego se representan en el dominio frecuencial según su amplitud y frecuencia.

Fórmula matemática

La base matemática de la FFT es la Transformada Discreta de Fourier (DFT), definida como [Wikipedia, 2024e, Wikipedia, 2023b]:

$$X_k = \sum_{n=0}^{N-1} x_n \cdot e^{-\frac{2\pi i}{N} kn}, \quad k = 0, \dots, N - 1 \quad (4.1)$$

donde X_k es un conjunto de números complejos que representan la señal en el dominio frecuencial, x_n es la señal discreta en el dominio del tiempo, N es el número total de muestras, i es la unidad imaginaria y $e^{-\frac{2\pi i}{N} kn}$

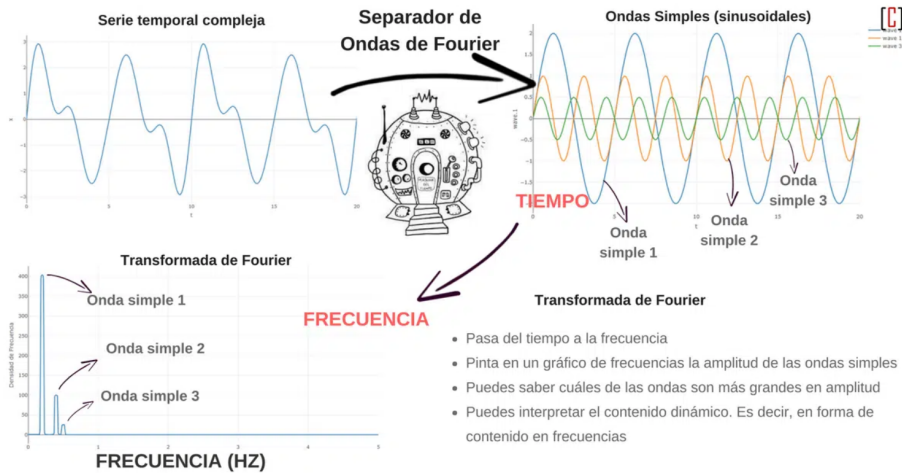


Figura 4.5: Representación conceptual del funcionamiento de la Transformada de Fourier [Ollé, sf].

es el núcleo de la transformada, representando las funciones base seno y coseno. La evaluación directa de esa fórmula requiere $O(N^2)$ operaciones aritméticas, pero con un algoritmo FFT se puede obtener el mismo resultado con solo $O(N \log N)$ operaciones mediante descomposición recursiva de la transformada en subproblemas más simples [Wikipedia, 2024e].

La transformada inversa (IDFT) permite reconstruir la señal temporal:

$$x_n = \frac{1}{N} \sum_{k=0}^{N-1} X_k e^{\frac{2\pi i}{N} kn}, \quad n = 0, \dots, N-1 \quad (4.2)$$

Cada coeficiente complejo X_k contiene información de amplitud y fase de la componente frecuencial correspondiente. Utilizando la forma polar y la función atan2 (arcotangente de dos argumentos): Amplitud espectral:

$$A_k = |X_k| = \sqrt{\text{Re}(X_k)^2 + \text{Im}(X_k)^2} \quad (4.3)$$

Fase:

$$\phi_k = \arg(X_k) = \text{atan2}(\text{Im}(X_k), \text{Re}(X_k)) \quad (4.4)$$

donde $\text{Re}(X_k)$ e $\text{Im}(X_k)$ son la parte real e imaginaria del coeficiente de Fourier X_k , respectivamente [Wikipedia, 2023b].

Esta formulación matemática demuestra que cualquier señal cerebral registrada en el dominio temporal puede descomponerse en una suma de

oscilaciones sinusoidales discretas, cada una con su propia amplitud (A_k) y fase (ϕ_k) características. Además la eficiencia computacional de la FFT facilita el análisis espectral de grandes volúmenes de datos. En la figura 4.6 se muestra la descomposición de una señal de EEG mediante la transformada de Fourier, ilustrando la conversión entre el dominio del tiempo (B) y el dominio de la frecuencia (A). El panel A presenta el espectro de potencia en el dominio de la frecuencia, donde se identifican las diferentes bandas de oscilación neuronal (delta, theta, alpha, beta y gamma) y su distribución de potencia, mientras que el panel B muestra la representación temporal de cada componente de frecuencia, evidenciando cómo la FFT descompone una señal compleja en sus oscilaciones neuronales constituyentes.

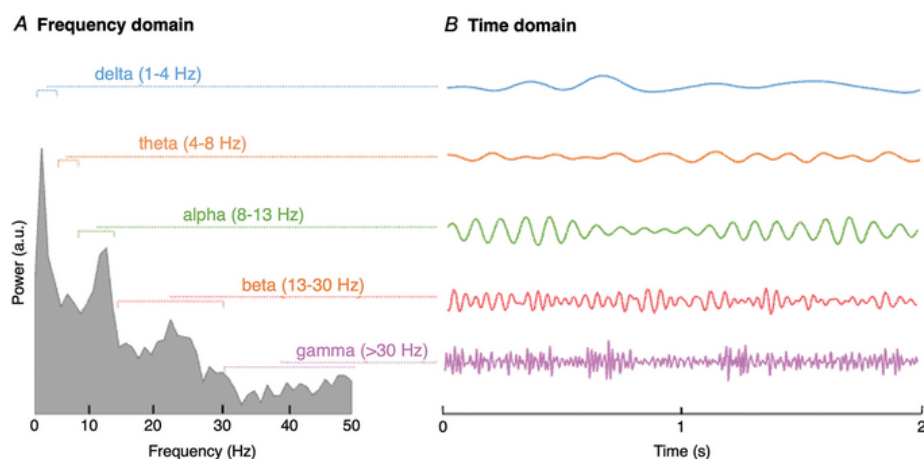


Figura 4.6: Oscilaciones neuronales en el registro de EEG [Marino and Mantini, 2026].

Visualización de resultados

Para facilitar la interpretación de los datos obtenidos a partir del EEG, los resultados se representan mediante diversas técnicas gráficas. Entre ellas se incluyen:

- Inspección de la señal: permite observar de forma directa la señal EEG, inspeccionar su morfología.
- Espectros de potencia: permiten identificar los picos dominantes en frecuencia.
- Mapas topográficos de potencia por banda: muestran la distribución espacial de la actividad cerebral sobre el cuero cabelludo.

- Diagramas de barras por banda y canal: cuantifican la contribución de cada banda en diferentes regiones.

Estas representaciones permiten comparar condiciones experimentales y explorar la información neurofisiológica de manera clara. Y están explicadas con mayor profundidad en el apéndice “E_Estudio experimental” del anexo.

Resultados

5.1. Resumen de resultados

En primer lugar, se realizó un preprocesado para eliminar el ruido ambiental y fisiológico, reduciendo significativamente los artefactos presentes en la señal original. Esta mejora se comprobó de manera visual mediante la función `raw.plot()`, que permitió visualizar simultáneamente todos los canales del registro, mostrando una señal más estable y con trazas más limpias tras la etapa de preprocesado. En la Figura 5.1 se muestra un ejemplo de este resultado, donde se aprecia la reducción de ruido entre la señal original y la preprocesada.

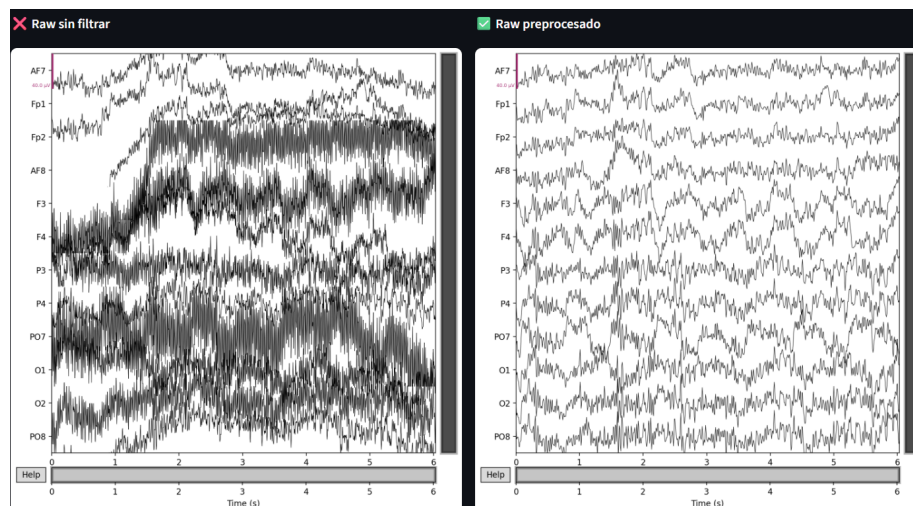


Figura 5.1: Comparativa raw vs preprocesado. Fuente propia

El preprocesamiento de las señales EEG permitió obtener registros relativamente libres de artefactos y listos para su análisis en el dominio de la frecuencia. No obstante, cabe señalar que, como es habitual en el preprocesado de señales EEG, la eliminación de artefactos no es perfecta y es esperable que persista cierto nivel de ruido residual incluso tras aplicar métodos automáticos de detección y corrección. En particular, en algunos registros y canales se observan todavía artefactos o distorsiones residuales tras el preprocesamiento, como se puede observar en la Figura 5.2, lo que sugiere que el algoritmo no consigue suprimir completamente todas las contaminaciones sin riesgo de eliminar también información neural.

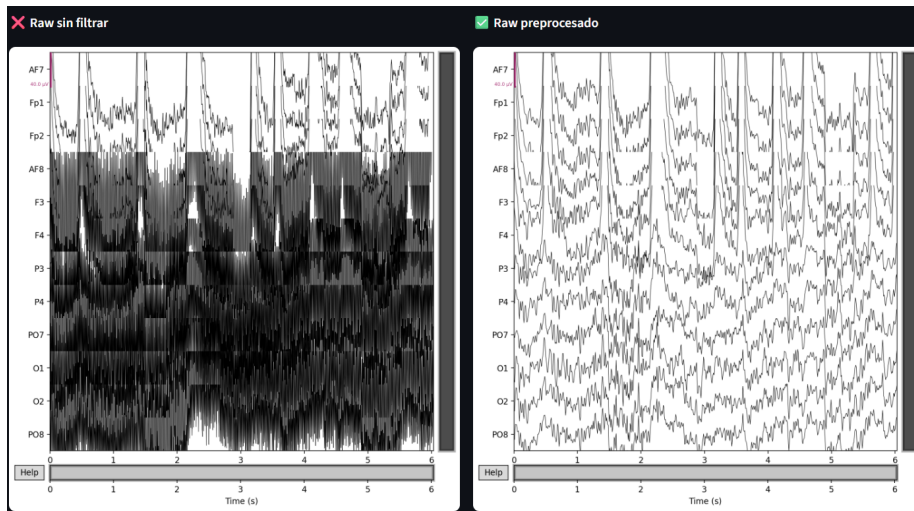


Figura 5.2: Comparativa raw vs preprocesado contaminado. Fuente propia

Una vez obtenida la señal preprocesada, se abordó el análisis espectral. Mediante la estimación de la Densidad Espectral de Potencia (PSD), que permite apreciar la distribución de potencia en frecuencia de la señal procesada por canal. En la Figura 5.3 se muestra los resultados de este análisis.

A partir de la PSD se calculó la potencia de banda promedio, que resume la contribución de cada banda de frecuencia a la potencia total de la señal. Para visualizar los resultados, éstos se presentan mediante cuatro representaciones integradas:

1. Tabla numérica (tabla 5.1: valores cuantitativos por electrodo y banda de frecuencia).

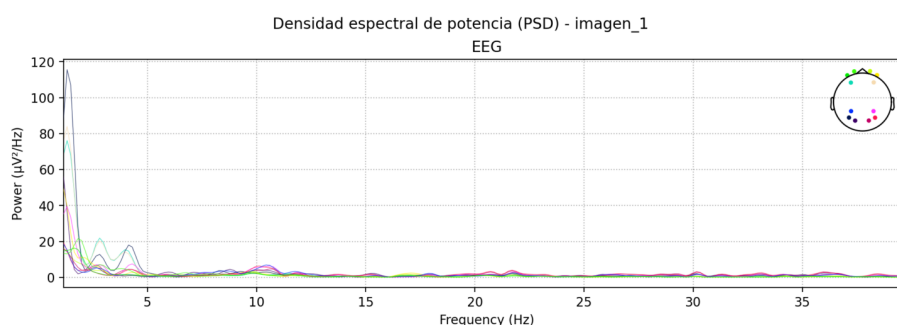


Figura 5.3: Gráfico Densidad Espectral de Potencia (PSD). Fuente propia

Electrodo	Delta	Theta	Alpha	Beta	Gamma baja
AF7	18.73	3.27	6.14	8.40	3.58
Fp1	28.23	6.55	7.06	8.79	2.80
Fp2	15.89	4.08	6.13	9.29	2.95
...

Tabla 5.1: Potencia espectral (μV^2) por banda de frecuencia y electrodo. Fuente propia




Figura 5.4: Mapas topográficos potencia espectral. Fuente propia

- Mapas topográficos (Figura 5.4): distribución espacial de potencia.
- Tabla de electrodo con máxima potencia espectral por banda (tabla 5.2).
- Gráfico de barras (Figura 5.5): distribución comparativa de potencia.

En conjunto, estos resultados reflejan claramente el proceso de obtención de señales de EEG de calidad, con la eliminación automática de artefactos, y su análisis en el dominio frecuencial, cumpliendo con los objetivos planteados.

Banda de frecuencia	Electrodo máximo
Delta (1-4 Hz)	PO7
Theta (4-8 Hz)	PO7
Alpha (8-13 Hz)	P3
Beta (13-30 Hz)	PO8
Gamma baja (30-40 Hz)	PO8

Tabla 5.2: Electrodo con máxima potencia espectral por banda. Fuente propia

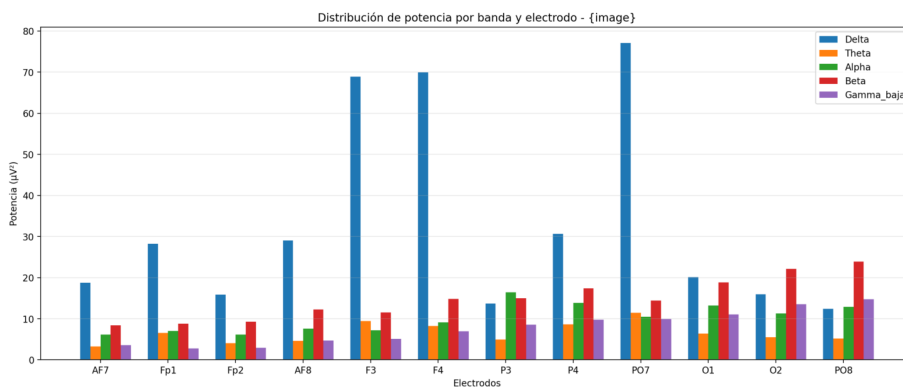


Figura 5.5: Gráfico de barras por electrodo y banda. Fuente propia

Finalmente, se desarrolló una aplicación interactiva con *Streamlit* que facilita el acceso al análisis complejo de EEG sin requerir experiencia en programación. La interfaz gráfica implementada permite a usuarios con diferentes niveles de competencia técnica realizar análisis avanzados del registro EEG. En la figura 5.6, se puede observar la configuración modular de la herramienta, que integra funcionalidades de preprocesamiento, procesamiento y visualización de datos EEG. La arquitectura de la aplicación facilita la carga de archivos de datos, la visualización de los parámetros de análisis empleados y la visualización de resultados.

5.2. Discusión

El procesamiento aplicado ha demostrado ser eficaz para generar señales EEG depuradas y métricas espectrales consistentes y reproducibles. La validación visual mediante `raw.plot()` mostró una atenuación clara de artefactos y una mejora en la estabilidad de la señal en la mayoría de los

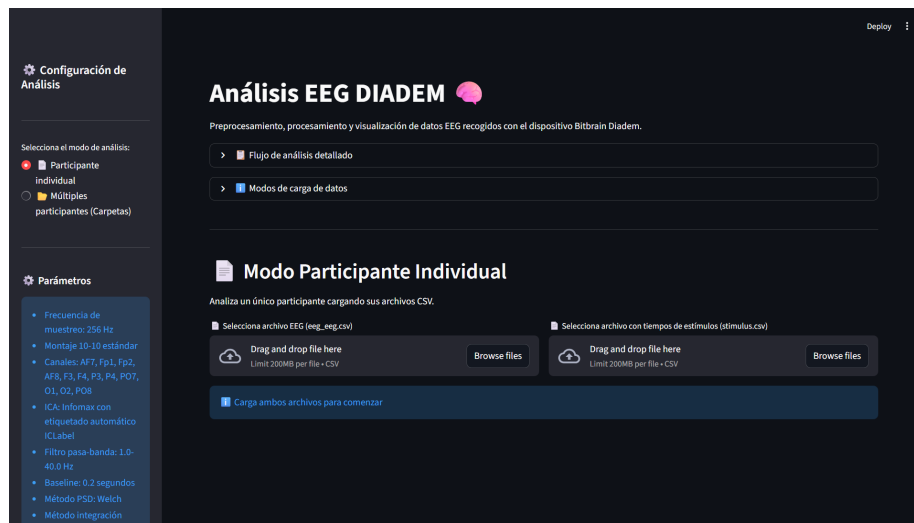


Figura 5.6: Interfaz de la aplicación desarrollada en modo Participante Individual. Fuente propia

casos, lo que garantiza una base sólida para la estimación de la PSD. Sin embargo, es preciso matizar los alcances de los resultados:

- Limitación de la limpieza de artefactos. El proceso automático de detección y corrección de artefactos no asegura una limpieza completa en todos los registros.
- Justificación de la automatización. La elección de un enfoque automatizado respondió a criterios de reproducibilidad, eficiencia y escalabilidad, ya que permite procesar múltiples sesiones de forma homogénea y reduce la variabilidad introducida por una limpieza manual, debida a la subjetividad para la identificación de los artefactos. Sin embargo, este enfoque automático conlleva cierta pérdida de precisión, ya que en algunos casos concretos una limpieza manual adicional podría mejorar los resultados.
- Robustez metodológica. El uso de Welch para estimar la PSD y el posterior cálculo de potencias de banda mediante integración atenúan el impacto de componentes transitorios y reducen la varianza de las estimaciones, incrementando la estabilidad de las métricas frente a fluctuaciones puntuales.

Conclusiones

El proyecto ha cumplido los objetivos planteados: se ha desarrollado y validado un proyecto reproducible para el preprocesado de señales EEG y la extracción de métricas espectrales en el dominio de la frecuencia. Los resultados principales son:

- Obtención de señales con reducción apreciable de ruido y artefactos, verificada visualmente.
- Estimación estable de densidades espectrales de potencia (PSD) por canal mediante el método de Welch.
- Extracción de valores de potencia de banda promedio para las bandas delta, theta, alpha, beta y gamma, que resumen cuantitativamente la contribución de cada intervalo frecuencial.
- Documentación exhaustiva de parámetros, pruebas alternativas y casos con artefactos residuales en el capítulo “E_Estudio experimental” del anexo, lo que garantiza la reproducibilidad y permite evaluación crítica.
- Desarrollo de una aplicación interactiva que encapsula los procedimientos de preprocesamiento, procesamiento y visualización en una interfaz accesible para usuarios sin experiencia en programación, democratizando el acceso a análisis neurofisiológicos reproducibles.

En conclusión, los resultados constituyen un conjunto de productos metodológicos que cumplen los objetivos del proyecto y sirven como base para análisis posteriores, siempre teniendo en cuenta la posible necesidad de pasos adicionales de limpieza para estudios que requieran limpieza absoluta. Debido a que como se ha podido observar en los resultados, no consigue

una limpieza absoluta, esto es debido en parte a que uno de los objetivos era el de realizar el preprocesamiento de forma automática. Mostrando que dependiendo la calidad con la que se quiera analizar los datos de EEG podría ser conveniente emplear revisión manual de los artefactos además de la automática.

6.1. Aspectos relevantes

Este apartado pretende recoger los aspectos de desarrollo más significativos, las decisiones no triviales y las lecciones prácticas obtenidas:

- Automatización frente a limpieza manual. Se adoptó un procedimiento automático de detección y corrección de artefactos para garantizar coherencia y escalabilidad. Esta decisión facilitó el procesamiento homogéneo de múltiples registros, aunque algunos artefactos puntuales persisten y quedarían mejor tratados mediante limpieza manual o técnicas supervisadas.
- Validación visual como control operativo. El empleo de `raw.plot()` como herramienta de control permitió detectar problemas y ajustar el flujo sin sobrecargar el documento principal con detalles de limpieza.
- Selección del método de PSD. Se seleccionó el método de Welch por su equilibrio entre robustez y simplicidad de implementación en un contexto de datos biológicos ruidosos.
- Integración de la PSD para potencias de banda. La transformación de PSD discreta a valores de potencia absoluta por banda se realizó mediante un método numérico preciso y eficiente, proporcionando métricas fácilmente interpretables y comparables.

En el desarrollo del proyecto también se evaluaron diversas alternativas metodológicas que, finalmente, fueron descartadas por no ofrecer mejoras significativas o por presentar limitaciones prácticas. Estas alternativas se enumeran en la memoria a modo de referencia, mientras que su descripción detallada se encuentra recogida en el apéndice “E_Estudio experimental” del anexo. Las opciones exploradas fueron:

- Filtrado digital sin ICA.
- Uso de *ICLabel*.

- Variantes de filtrado.
- Estrategia de línea base.
- Métodos alternativos de estimación espectral.

Limitaciones y recomendaciones prácticas:

- Artefactos residuales: para aplicaciones que requieran limpieza total se recomienda complementar el proceso automático con limpieza manual.
- Formación y coste temporal: la mejora por limpieza manual exige inversión en formación y tiempo operativo, por lo que su uso debe evaluarse según la finalidad del estudio.

En conjunto, el proyecto ha culminado con la puesta a punto de un procedimiento reproducible y documentado para la preparación y el análisis espectral de señales EEG. Las métricas y visualizaciones generadas constituyen productos metodológicos sólidos y reutilizables. Más allá de estos productos científicos, se desarrolló una aplicación interactiva que encapsula el flujo completo de preprocesamiento, análisis espectral y visualización. Esta aplicación, implementada con *Streamlit*, democratiza el acceso a procedimientos reproducibles permitiendo que investigadores y clínicos sin experiencia en programación realicen análisis de señales EEG de forma automática y consistente. Aunque la aplicación hereda las limitaciones metodológicas del procesamiento automático, su desarrollo amplía el alcance del proyecto hacia la transferencia tecnológica práctica. La decisión de priorizar un enfoque automatizado se consideró adecuada para el alcance y los recursos disponibles; no obstante, para investigaciones que requieran la máxima limpieza de las señales se recomienda integrar fases adicionales de limpieza manual o aplicar técnicas avanzadas de corrección.

Lineas de trabajo futuras

El presente trabajo establece una base metodológica sólida que puede ser ampliada en múltiples direcciones, tanto desde el punto de vista técnico como en lo relativo a la interpretación científica de los resultados. Una primera línea de desarrollo natural consistiría en profundizar en el análisis de las métricas obtenidas. Mientras que este proyecto se ha centrado en la obtención y representación de indicadores espectrales, futuros estudios deberían orientarse hacia su interpretación neurocientífica, explorando la relación entre las variaciones de potencia en distintas bandas de frecuencia y procesos cognitivos, emocionales o conductuales específicos.

De forma complementaria, resulta conveniente enriquecer los métodos de análisis aplicados sobre las señales preprocesadas. Más allá de la simple representación de la densidad espectral de potencia y de los valores promedios por banda, sería deseable implementar análisis estadísticos estratificados, estimaciones de variabilidad y procedimientos de control de calidad cuantitativo. Estas técnicas permitirían valorar la robustez de las métricas frente a la heterogeneidad interindividual y mejorar la fiabilidad de las conclusiones derivadas.

Otra línea de trabajo con un gran potencial consiste en la aplicación de técnicas de aprendizaje automático sobre los datos procesados. Los descriptores espectrales extraídos podrían emplearse como variables de entrada para algoritmos de clasificación o regresión, con el objetivo de identificar patrones asociados a distintos estados mentales o condiciones experimentales. Este tipo de enfoques podría abrir el camino hacia sistemas predictivos o de monitorización en tiempo real.

La integración multimodal representa igualmente una dirección de interés prioritario. La incorporación de señales complementarias como el electrocar-

diograma (ECG), el electrooculograma (EOG), el electromiograma (EMG), la electroscopía funcional del infrarrojo cercano (fNIRS), la respuesta galvánica de la piel (GSR) o el *eye-tracking* permitiría obtener una visión más completa del estado fisiológico del sujeto, mejorar la discriminación de artefactos y aumentar la sensibilidad de los análisis. Una ventaja adicional radica en la flexibilidad del *software* utilizado en este trabajo, que facilita la sincronización de registros procedentes de diferentes dispositivos sin necesidad de desarrollar procesos de compatibilización complejos. Esta capacidad técnica supone un punto de partida idóneo para futuras investigaciones que busquen enriquecer el análisis del EEG mediante la integración de múltiples modalidades de registro.

La aplicación interactiva desarrollada constituye un complemento operativo a los análisis metodológicos descritos anteriormente. En futuras líneas de investigación, esta herramienta podría enriquecerse mediante la incorporación de los métodos estadísticos avanzados y técnicas de aprendizaje automático mencionados previamente. Su arquitectura flexible permite integrar nuevos módulos analíticos manteniendo la accesibilidad para usuarios sin experiencia en programación, facilitando así que los avances metodológicos se trasladen rápidamente a herramientas operativas y reproducibles.

En contextos educativos, la aplicación facilita la enseñanza de técnicas de procesamiento y análisis de señales biomédicas, permitiendo que estudiantes de ingeniería biomédica, neurociencia y disciplinas relacionadas realicen prácticas con datos EEG auténticos sin formación técnica especializada en programación. En el ámbito de la investigación, la arquitectura modular y los requerimientos computacionales bajos hacen viable su uso en instituciones académicas con recursos limitados, ampliando el acceso a métodos de análisis que de otro modo quedarían limitados a centros con infraestructura avanzada.

Un campo de interés futuro lo constituyen las interfaces cerebro-máquina (*Brain-Computer Interfaces*, BCI). Estos sistemas establecen comunicación directa entre el cerebro y dispositivos externos, permitiendo que usuarios controlen aplicaciones o dispositivos mediante actividad cerebral. La arquitectura modular de la aplicación desarrollada permitiría, en futuras investigaciones, explorar su potencial para el desarrollo de sistemas BCI, facilitando que investigadores accedan a esta línea de trabajo sin requerir infraestructura especializada.

En conjunto, las líneas de trabajo futuras apuntan hacia un triple objetivo. En primer lugar, profundizar en la interpretación neurocientífica y el rigor estadístico de los resultados, y ampliar el alcance metodológico mediante la incorporación de nuevas técnicas analíticas y señales fisiológicas

adicionales. En segundo lugar, evolucionar la aplicación interactiva hacia una plataforma más versátil y funcional, expandiendo sus capacidades analíticas y su potencial de transferencia tecnológica en contextos de educación e investigación. En tercer lugar, explorar la viabilidad de la herramienta para aplicaciones BCI, incluyendo tanto investigación neurocientífica como desarrollo de aplicaciones prácticas. De este modo, el proyecto aquí desarrollado podría evolucionar hacia un marco integral y versátil para el estudio del EEG, con aplicaciones potenciales que abarquen desde la investigación fundamental hasta la ingeniería de soluciones para poblaciones con necesidades específicas.

Bibliografía

- [Abril Ronderos, 2020] Abril Ronderos, J. P. (2020). Líneas base, anotaciones enfocadas al diseño experimental fnirs y eeg. Blog de Brainlatam. Último acceso: 10 de septiembre de 2025.
- [Barbey et al., 2022] Barbey, F. M., Farina, F. R., Buick, A. R., Danyeli, L., Dyer, J. F., Islam, M. N., Krylova, M., Murphy, B., Nolan, H., Rueda-Delgado, L. M., Walter, M., and Whelan, R. (2022). Neuroscience from the comfort of your home: Repeated, self-administered wireless dry eeg measures brain function with high fidelity. *Frontiers in Digital Health*, Volume 4 - 2022.
- [Bigdely-Shamlo et al., 2015] Bigdely-Shamlo, N., Mullen, T., Kothe, C., Su, K.-M., and Robbins, K. A. (2015). The prep pipeline: standardized preprocessing for large-scale eeg analysis. *Frontiers in Neuroinformatics*, Volume 9 - 2015.
- [Bitbrain, 2020] Bitbrain (2020). The most important features of eeg systems explained. Blog de Bitbrain. Accedido el 1 de septiembre de 2025.
- [Bitbrain, 2023] Bitbrain (2023). *SennsLab: Manual de usuario*. Bitbrain. Manual de usuario en formato PDF.
- [Bitbrain, sfa] Bitbrain (s.f.a). Diadem | auriculares eeg secos portátiles. <https://www.bitbrain.com/es/productos-neurotecnologia/dry-eeg/diadem>. Consultado el 5 de septiembre de 2025.
- [Bitbrain, sfb] Bitbrain (s.f.b). Sennslab: Software para la sincronización de bioseñales y diseño de experimentos. <https://www.bitbrain.com/es/productos-neurotecnologia/software/sennslab>. Consultado el 5 de septiembre de 2025.

- [Campos Viola et al., 2009] Campos Viola, F., Thorne, J., Edmonds, B., Schneider, T., Eichele, T., and Debener, S. (2009). Semi-automatic identification of independent components representing eeg artifact. *Clinical Neurophysiology*, 120(5):868–877.
- [Community, sf] Community, T. J. B. (s.f.). Baseline correction. Último acceso: 10 de septiembre de 2025.
- [con ALF, 2021] con ALF, A. (2021). La librería matplotlib. <https://aprendeconalf.es/docencia/python/manual/matplotlib/>. Último acceso: 8 de septiembre de 2025.
- [con ALF, 2025] con ALF, A. (2025). La librería pandas. <https://aprendeconalf.es/docencia/python/manual/pandas/>. Manual de Python: sección de la librería Pandas.
- [contributors, 2025] contributors, M.-P. (2025). Mne-python: Open-source python package for exploring, visualizing, and analyzing human neurophysiological data. Último acceso: 8 de septiembre de 2025.
- [Delorme, 2023] Delorme, A. (2023). Eeg is better left alone. *Scientific Reports*, 13(1):2372.
- [Delorme and Makeig, 2004] Delorme, A. and Makeig, S. (2004). Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1):9–21.
- [Developers, 2025] Developers, M. (2025). Mne-icalabel. Último acceso: 8 de septiembre de 2025.
- [developers, 2025] developers, M. (2025). Repairing artifacts with ica. Último acceso: 9 de septiembre de 2025.
- [Evans, 2023] Evans, J. R. (2023). *Introduction to Quantitative EEG and Neurofeedback*. Elsevier, 3rd edition.
- [Fleur et al., 2021] Fleur, D. S., Bredeweg, B., and van den Bos, W. (2021). Metacognition: ideas and insights from neuro- and educational sciences. *npj Science of Learning*, 6(1):13.
- [García-Monge et al., 2023] García-Monge, A., Rodríguez-Navarro, H., and Marbán-Prieto, J.-M. (2023). Potentialities and limitations of the use of eeg devices in educational contexts; [potencialidades y limitaciones de la usabilidad de dispositivos eeg en contextos educativos]. *Comunicar*,

31(76). Cited by: 7; All Open Access, Gold Open Access, Green Open Access.

[GitHub, 2025] GitHub, I. (2025). *Acerca de GitHub y Git*. Último acceso: 8 de septiembre de 2025.

[Gramfort et al., 2013] Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., Goj, R., Jas, M., Brooks, T., Parkkonen, L., and Hämäläinen, M. (2013). Meg and eeg data analysis with mne-python. *Frontiers in Neuroscience*.

[Hramov et al., 2021] Hramov, A. E., Maksimenko, V. A., and Pisarchik, A. N. (2021). Physical principles of brain–computer interfaces and their applications for rehabilitation, robotics and control of human brain states. *Physics Reports*, 918:1–133. Physical principles of brain–computer interfaces and their applications for rehabilitation, robotics and control of human brain states.

[Hunter, 2007] Hunter, J. D. (2007). Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, 9(3):90–95.

[Hyvärinen and Oja, 2000] Hyvärinen, A. and Oja, E. (2000). Independent component analysis: algorithms and applications. *Neural Networks*, 13(4):411–430.

[Inc., sfa] Inc., B. S. (s.f.a). What is the difference between ground and reference in eeg recording? Último acceso: 12 de enero de 2026.

[Inc., sfb] Inc., S. (s.f.b). Streamlit documentation. Último acceso: 03 de enero de 2026.

[Inc., sfc] Inc., S. (s.f.c). Streamlit • a faster way to build and share data apps. Último acceso: 03 de enero de 2026.

[Jiang et al., 2025] Jiang, R., Tong, S., Wu, J., Hu, H., Zhang, R., Wang, H., Zhao, Y., Zhu, W., Li, S., and Zhang, X. (2025). A novel eeg artifact removal algorithm based on an advanced attention mechanism. *Scientific Reports*, 15(1):19419.

[Kessler et al., 2025] Kessler, R., Enge, A., and Skeide, M. A. (2025). How eeg preprocessing shapes decoding performance. *Communications Biology*, 8(1):1039.

- [Li et al., 2022] Li, A., Feitelberg, J., Saini, A. P., Höchenberger, R., and Scheltienne, M. (2022). Mne-icalabel: Automatically annotating ica components with iclabel in python. *Journal of Open Source Software*, 7(76):4484.
- [Luengas C. and Toloza, 2020] Luengas C., L. A. and Toloza, D. C. (2020). Análisis frecuencial y de la densidad espectral de potencia de la estabilidad de sujetos amputados. *TecnoLógicas*, 23(48):1–16.
- [Marino and Mantini, 2026] Marino, M. and Mantini, D. (2026). Human brain imaging with high-density electroencephalography: Techniques and applications. *The Journal of Physiology*, 604(2):783–812. Último acceso: 12 de enero de 2026.
- [Microsoft, 2025] Microsoft (2025). *Visual Studio Code*. Microsoft. Último acceso: 8 de septiembre de 2025.
- [Newman, sf] Newman, A. J. (s.f.). Mne-python. Neural Data Science. Último acceso: 8 de septiembre de 2025.
- [Ollé, sf] Ollé, J. (s.f.). ¿qué es la transformada de fourier y para qué sirve? cómo descubrir la dinámica de una serie temporal. Conceptos Claros. Último acceso: 15 de septiembre de 2025.
- [Ortiz, 2020a] Ortiz, A. (2020a). Connectivity Layer and Other Features of EEG Headsets Explained. Blog de Bitbrain. Accedido el 3 de septiembre de 2025.
- [Ortiz, 2020b] Ortiz, A. (2020b). Main Features of an EEG Amplifier. Blog de Bitbrain. Accedido el 1 de septiembre de 2025.
- [Ortiz, 2020c] Ortiz, A. (2020c). Main features of the eeg sensor layer. Blog de Bitbrain. Accedido el 1 de septiembre de 2025.
- [Overleaf, 2025] Overleaf (2025). *Overleaf Features Overview*. Overleaf. Último acceso: 8 de septiembre de 2025.
- [Pion-Tonachini et al., 2019] Pion-Tonachini, L., Kreutz-Delgado, K., and Makeig, S. (2019). Icalabel: An automated electroencephalographic independent component classifier, dataset, and website. *NeuroImage*, 198:181–197.
- [Ramos-Argüelles et al., 2009] Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R., and M.T., A. (2009). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. *Anales del Sistema Sanitario de Navarra*, 32:69 – 82.

- [Services, sf] Services, A. W. (s.f.). ¿qué es python? - explicación del lenguaje python. <https://aws.amazon.com/es/what-is/python/>. Último acceso: 7 de septiembre de 2025.
- [Shure and Mínguez, 2024a] Shure, C. and Mínguez, J. (2024a). La historia olvidada de las ondas cerebrales alfa. Blog de Bitbrain. Último acceso: 10 de septiembre de 2025.
- [Shure and Mínguez, 2024b] Shure, C. and Mínguez, J. (2024b). ¿qué es el eeg y para qué se utiliza? Blog de Bitbrain. Accedido el 4 de septiembre de 2025.
- [Sun et al., 2020] Sun, W., Su, Y., Wu, X., and Wu, X. (2020). A novel end-to-end 1d-rescnn model to remove artifact from eeg signals. *Neurocomputing*, 404:108–121.
- [Tayeb, 2018] Tayeb, H. O. (2017-2018). Neurofisiología clínica y electroencefalografía. Coleccionable 76/94, SNC Pharma. Capítulo 76. Disponible en el sitio web de SNC Pharma.
- [Team, 2020] Team, B. (2020). All about eeg artifacts and filtering tools. Blog de Bitbrain. Accedido el 4 de septiembre de 2025.
- [Team, 2015] Team, J. (2015). *Jupyter Notebook Documentation*. Jupyter. Último acceso: 8 de septiembre de 2025.
- [Team, 2025a] Team, L. (2025a). *LaTeX – A document preparation system*. LaTeX Project. Último acceso: 8 de septiembre de 2025.
- [Team, 2025b] Team, S. D. (2025b). *SciPy*. SciPy. Último acceso: 8 de septiembre de 2025.
- [Team, 2025c] Team, T. P. D. (2025c). *Package overview*. Último acceso: 8 de septiembre de 2025.
- [Torres-García et al., 2013] Torres-García, A., Reyes-García, C., Villaseñor-Pineda, L., and Ramírez-Cortés, J. (2013). Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista mexicana de ingeniería biomédica*, 34(1):23–39.
- [Vallat, 2018] Vallat, R. (2018). Compute the average bandpower of an eeg signal. Último acceso: 10 de septiembre de 2025.

- [Virtanen et al., 2020] Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., Burovski, E., Peterson, P., Weckesser, W., Bright, J., van der Walt, S. J., Brett, M., Wilson, J., Millman, K. J., Mayorov, N., Nelson, A. R. J., Jones, E., Kern, R., Larson, E., Carey, C. J., Polat, İ., Feng, Y., Moore, E. W., VanderPlas, J., Laxalde, D., Perktold, J., Cimrman, R., Henriksen, I., Quintero, E. A., Harris, C. R., Archibald, A. M., Ribeiro, A. H., Pedregosa, F., van Mulbregt, P., and SciPy 1.0 Contributors (2020). SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, 17:261–272.
- [WebCatalog, 2025] WebCatalog, I. (2025). Zube. Último acceso: 8 de septiembre de 2025.
- [Wikipedia, 2019] Wikipedia (2019). Filtro elimina banda — wikipedia, la enciclopedia libre. [Internet; descargado 30-agosto-2019].
- [Wikipedia, 2023a] Wikipedia (2023a). Miktex — wikipedia, la enciclopedia libre. [Internet; descargado 9-enero-2023].
- [Wikipedia, 2023b] Wikipedia (2023b). Transformada de fourier discreta — wikipedia, la enciclopedia libre. [Internet; descargado 9-enero-2023].
- [Wikipedia, 2024a] Wikipedia (2024a). Filtro paso banda — wikipedia, la enciclopedia libre. [Internet; descargado 30-agosto-2024].
- [Wikipedia, 2024b] Wikipedia (2024b). Markdown — wikipedia, la enciclopedia libre. [Internet; descargado 29-octubre-2024].
- [Wikipedia, 2024c] Wikipedia (2024c). Media cuadrática — wikipedia, la enciclopedia libre. [Internet; descargado 7-octubre-2024].
- [Wikipedia, 2024d] Wikipedia (2024d). Texstudio — wikipedia, la enciclopedia libre. [Internet; descargado 23-febrero-2024].
- [Wikipedia, 2024e] Wikipedia (2024e). Transformada rápida de fourier — wikipedia, la enciclopedia libre. [Internet; descargado 25-agosto-2024].
- [Wikipedia, 2025a] Wikipedia (2025a). Fir (finite impulse response) — wikipedia, la enciclopedia libre. [Internet; descargado 18-mayo-2025].
- [Wikipedia, 2025b] Wikipedia (2025b). Iir — wikipedia, la enciclopedia libre. [Internet; descargado 28-marzo-2025].
- [Wikipedia, 2025c] Wikipedia (2025c). Python — wikipedia, la enciclopedia libre. [Internet; descargado 22-agosto-2025].

[Wikipedia contributors, 2026] Wikipedia contributors (2026). Electroencephalography — Wikipedia, the free encyclopedia. [Online; accessed 12-January-2026].