



Universidad de Valladolid

Facultad de Medicina – Escuela de Ingenierías Industriales

**Trabajo Fin de Grado**

Grado en Ingeniería Biomédica

**Evaluación de electrodos EEG secos,  
húmedos y con gel para la implementación  
de sistemas BCI basados potenciales  
evocados P300**

Autor(a):

MARÍA VALENTINA SOSA ROJO

Tutores:

Dr. Eduardo Santamaría Vázquez  
Dr. Roberto Hornero Sánchez

Valladolid, 22 de septiembre de 2024

# Defensa

---

**Título** Evaluación de electrodos EEG secos, húmedos y con gel para la implementación de sistemas BCI basados potenciales evocados P300

**Autor** María Valentina Sosa Rojo

**Tutores** Dr. Eduardo Santamaría Vásquez  
Dr. Roberto Hornero Sánchez

---

## **Tribunal**

---

**Departamento** Ingeniería Biomédica

**Presidente** Dr. Roberto Hornero Sánchez

**Vocal** Jesús Poza Crespo

**Secretario** Javier Gómez Pilar

---

**Fecha** 30 de septiembre de 2024

---

# Índice General

Índice de Figuras	6
Índice de Tablas	7
Índice de Acrónimos	7
Resumen	9
Abstract	10
Agradecimientos	11
<b>1. Capítulo 1.</b>	<b>12</b>
Introducción	12
1.1. Sistemas Brain Computer Interface (BCI)	12
1.1.1. Electroencefalograma (EEG)	13
1.1.2. Tipos de sistemas BCI	17
1.1.3. Etapas de un sistema BCI	19
1.1.3.1. Adquisición de la señal	19
a. Equipos para registro EEG en sistemas BCI	19
b. Electroodos para registro EEG en sistemas BCI	20
c. Señales de control de un sistema BCI	20
1.1.3.2. Preprocesado de la señal	20
1.1.3.3. Procesado de la señal	21
a. Extracción de características	21
b. Selección de características	21
c. Clasificación y traducción características	22
1.1.3.4. Aplicación	23
a. Selección de comandos	23
1.1.4. Limitaciones de Viabilidad	23
1.2. Hipótesis	24
1.3. Objetivos del Trabajo Fin de Grado	24
1.4. Estructura del Trabajo Fin de Grado	24
<b>2. Capítulo 2.</b>	<b>26</b>
Sistemas BCI basados en ERPs	26
2.1. Introducción	26
2.2. Potenciales evocados P300	26
2.2.1. Características de los potenciales evocados P300	27
2.2.2. Respuesta de los potenciales evocados P300	27
2.3. Procesado de los potenciales evocados P300	28
2.3.1. Extracción de características de la señal EEG	28
2.3.1.1. Filtrado espacial	28
a. Filtro Laplaciano	28
b. Método de referencia de media común	28
c. Análisis de componentes independientes	28

d. Análisis de componentes principales	28
2.3.1.2. Filtrado temporal	28
a. Promediado sincronizado	28
b. Detección de picos y cálculo del área	28
c. Filtrado adaptativo	29
2.3.1.3. Análisis tiempo-frecuencia	29
a. Transformada de Fourier de Tiempo Corto	29
b. Transformadas Wavelet	29
2.3.2. Aplicación	29
2.4. Aplicaciones de los sistemas BCI basados en P300	29
2.5. Revisión del estado del arte de los tipos de electrodos en estudio (secos, húmedos, gel)	29
2.5.1. Tabla resumen rendimiento	29
2.5.2. Tabla resumen comparación de facilidad de uso	29
2.5.3. Tabla resumen de aplicabilidad	29
<b>3. Capítulo 3.</b>	<b>30</b>
Metodología	30
3.1. Protocolo experimental	30
3.1.1. Selección de participantes	30
3.1.2. Entorno de laboratorio	30
3.1.3. Instrucciones hacia los sujetos	31
3.1.4. Protocolo implementado	31
3.2. Adquisición de datos	32
3.2.1. Configuración del equipo de adquisición	32
3.2.2. Parámetros de grabación	33
3.2.3. Duración de las sesiones	33
3.3. Preprocesado de la señal	34
3.4. Procesado de señal	35
3.5. Caracterización de la señal	35
3.6. Implementación de modelo	36
3.7. Evaluación de la precisión	36
3.8. Cuestionario de satisfacción	36
<b>4. Capítulo 4.</b>	<b>37</b>
Resultados	37
4.1. Resultados del análisis basal	37
4.2. Resultados de la caracterización	37
4.3. Resultados de precisión	37
<b>5. Capítulo 5.</b>	<b>38</b>
Discusión de resultados	38
5.1. Discusión de resultados del análisis basal	38
5.2. Discusión de resultados de la caracterización	38

5.3. Discusión de resultados para la precisión	38
5.4. Limitaciones	39
<b>6. Capítulo 6.</b>	<b>40</b>
Conclusiones	40
Declaración de trabajo	41
<b>Referencias</b>	<b>42</b>

# Índice de Figuras

## Capítulo 1. Introducción

---

Figura 1- 1. Esquema de distintos métodos para la adquisición de señal para sistemas BCI.	13
Figura 1- 2. Montaje de electrodos según estándares internacionales	14
Figura 1-3. Representación gráfica de las diferentes ondas que se pueden encontrar en un EEG	16
Figura 1-4. Representación gráfica de densidad espectral de potencia	17
Figura 1-5. Componentes de un sistema de registro EEG	18
Figura 1-6. Potenciales relacionados a eventos para electrodos secos y húmedos	22
Figura 1-7. Respuesta armónica en una señal EEG ante estímulos repetitivos	23
Figura 1-8. Potenciales evocados visuales para electrodos secos y húmedos	23
Figura 1-9. Potenciales corticales lentos	24
Figura 1-10. Ritmos sensoriomotores	24

## Capítulo 2. Sistemas BCI basados en ERPs

---

Figura 2- 1. Representación de los componentes de una onda P300 en dos estados	34
Figura 2- 2. Métodos de filtrado espacial	36
Figura 2- 3. Impedancias de los electrodos secos	42
Figura 2- 4. Impedancias de los electrodos con gel	42
Figura 2- 5. Fiabilidad de los electrodos secos vs gel	43
Figura 2- 6. Imágenes SEM de la piel bajo pruebas de desgaste	44

## Capítulo 3. Metodología

---

Figura 3- 1. Protocolo experimental implementado	46
Figura 3- 2. Distribución de electrodos para la adquisición de los ERPs	47
Figura 3- 3. Dispositivo de adquisición de EEG (Enobio 8)	48
Figura 3- 4. Speller RCP	50
Figura 3- 5. Esquema del protocolo de una sesión	57
Figura 3- 6. Cuestionarios aplicados luego de la sesión	58

## Capítulo 4. Resultados

---

Figura 4- 1. Señal EEG electrodos secos	59
Figura 4- 2. Señal EEG electrodos húmedos	60
Figura 4- 3. Señal EEG electrodos con gel	60
Figura 4- 4. PSD promediada de todos los canales por condición	61
Figura 4- 5. PSD por sujeto por condición	61
Figura 4- 6. Frecuencia mediana por sujeto por condición	62
Figura 4- 7. Frecuencia mediana promediada de todos los canales por condición	62
Figura 4- 8. Complejidad de Lempel Ziv por sujeto por condición	63
Figura 4- 9. Complejidad de Lempel Ziv promediada de todos los canales por condición	63
Figura 4-10. Bandas de potencia promediada de todos los sujetos	64
Figura 4- 11. Topografías de la banda de potencia para electrodos secos	64
Figura 4- 12. Topografías de la banda de potencia para electrodos húmedos	65
Figura 4- 13. Topografías de la banda de potencia para electrodos con gel	65
Figura 4- 14. Representación gráfica de los ERPs para los electrodos secos	66
Figura 4- 15. Representación gráfica de los ERPs para los electrodos húmedos	66
Figura 4- 16. Representación gráfica de los ERPs para los electrodos con gel	67
Figura 4- 17. Representación gráfica de los ERPs con marcas temporales	69

## Capítulo 5. Discusión de resultados

---

Figura 5- 1. Representación de ERPs promediado con marcas temporales de 16 pacientes sanos para electrodos con gel

# Índice de Tablas

## Capítulo 1. Introducción

---

Tabla 1- 1. Bandas de potencia de una señal EEG	15
Tabla 1- 2. Artefactos en una señal EEG	16
Tabla 1-3. Características de los sistemas BCI endógenos y exógenos	19
Tabla 1-4. Compañías que han desarrollado equipos EEG adaptados tanto a electrodos secos como a electrodos con gel	24
Tabla 1-5. Métodos de preprocesado de una señal EEG	29

## Capítulo 2. Sistemas BCI basados en ERPs

---

Tabla 2- 1. Evaluación de la facilidad de uso de los diferentes electrodos	49
Tabla 2- 2. Evaluación de la aplicabilidad de los electrodos secos vs gel	45

## Capítulo 3. Metodología

---

## Capítulo 4. Resultados

---

Tabla 4- 1. Resumen de los resultados de la caracterización de los ERPs promediado por canal	74
Tabla 4-2. Resumen de la precisión del ERPs por sujeto para los electrodos secos.	76
Tabla 4- 3. Resumen de la precisión del ERPs por sujeto para los electrodos húmedos.	77
Tabla 4-4. Resumen de la precisión del ERPs por sujeto para los electrodos con gel.	78

## Capítulo 5. Discusión

---

Tabla 5-1. Resumen del promedio de las amplitudes y latencias de ERPs y VEPs respecto a otros autores.	86
Tabla 5-2. Resumen de los resultados del rendimiento de electrodos secos, húmedos y con gel, según diferentes autores.	88

# Índice de Acrónimos

ANN	Artificial Neural Networks
BCI	Brain Computer Interface
CAR	Common Average Reference
CFS	Correlation-based Feature Selection
CNS	Central Nervous System
CSP	Common Spatial Pattern
EEG	Electroencephalography
ECG	Electrocardiography
EMG	Electromyography
EOG	Electrooculography
ERD	Event-Related Desynchronization
ERPs	Event-Related Potentials
ERS	Event-Related Synchronization
FT	Fourier Transform
ICA	Independent Component Analysis
ISI	Inter-stimulus Interval
LDA	Linear Discriminant Analysis
LZC	Lempel Ziv Complexity
MF	Median Frequency
PCA	Principal Component Analysis
PSD	Power Spectral Density
RCP	Row-Column Paradigm
RT	Reaction Time
SCP	Slow Cortical Potentials



# Resumen

Con el paso de los años, se ha buscado la integración de sistemas inteligentes capaces de apoyar en procesos de rehabilitación y comunicación a aquellos pacientes que se encuentren en condiciones severas bien sea por enfermedades neurodegenerativas, congénitas o accidentes. La implementación de los sistemas Brain Computer Interfaces (BCI) en la vida cotidiana de estos usuarios trae consigo la oportunidad de mejorar la calidad de vida una vez salgan de un entorno clínico. Esta tecnología permite la comunicación y el control de dispositivos mediante el análisis en tiempo real de la actividad cerebral.

La técnica más utilizada para medir la actividad cerebral en sistemas BCI es la electroencefalografía (EEG). Esta técnica registra la actividad eléctrica generada por las neuronas mediante la colocación de electrodos sobre el cuero cabelludo, a los que se les aplica un gel conductor para mejorar la calidad de la señal. Emplear un material electrolítico en cada uso del equipo, viene siendo una de las limitaciones presentes en el objetivo de llevar los sistemas BCI fuera de los laboratorios. Dado lo anterior, diversas investigaciones han buscado métodos alternativos para dicha aplicación. El uso de electrodos secos es presentado como una solución. Sin embargo, este enfoque provoca una pérdida parcial de calidad en la señal EEG al eliminar el material conductor que disminuye la impedancia y la sensibilidad a artefactos externos. Es por ello, que el presente trabajo busca realizar la caracterización de electrodos, secos, húmedos y con gel para evaluar su viabilidad de uso en sistemas BCI basados en potenciales evocados P300.

Se realiza una adquisición de registros de EEG de 15 sujetos en 2 sesiones. En cada sesión se realiza (por condición) 1 registro basal en reposo (ojos cerrados) y 5 registros realizados bajo el *speller RCP*. Finalmente, se han obtenido 450 registros que servirán para la evaluación de los electrodos en los sistemas BCI. Una vez, adquiridos los datos, se realiza el debido preprocesado de las señales, procesado para la extracción de características de la señal y clasificación de intenciones para controlar el sistema BCI. De acuerdo con esto, se abre la posibilidad de comparar las diferentes respuestas de los electrodos para sistemas BCI. Los resultados mostraron diferencias significativas en las características del EEG entre las 3 condiciones. Por otra parte, el sistema BCI analizado alcanzó una precisión en la decodificación de comandos del 36%, 32%, y 87% utilizando electrodos secos, húmedos y con gel, respectivamente. Se concluye que, en las condiciones del experimento, los electrodos secos y húmedos no permiten un control satisfactorio del sistema BCI.

## **Palabras Clave:**

Brain Computer Interface (BCI), electroencefalograma (EEG), potenciales evocados (ERPs), P300, *Row-Column Paradigm*, rLDA, caracterización de electrodos, gel, húmedos, secos.

# Abstract

Over the years, there has been a search for the integration of intelligent systems capable of supporting rehabilitation and communication processes for patients in severe conditions, whether due to neurodegenerative diseases, congenital issues, or accidents. Implementing Brain-Computer Interface (BCI) systems in the daily lives of these users brings the opportunity to improve their quality of life once they leave a clinical environment. This technology enables communication and control devices through real-time analysis of brain activity

The most used technique to measure brain activity in BCI systems is electroencephalography (EEG). This technique records the electrical activity generated by neurons by placing electrodes on the scalp, where a conductive gel is applied to improve signal quality. However, using an electrolytic material each time the equipment is used presents a limitation in the goal of deploying BCI systems outside of laboratories. Considering this, various investigations have sought alternative methods for this application. Dry electrodes have been presented as a solution. However, this approach leads to a partial loss of EEG signal quality due to the removal of the conductive material, which reduces impedance and sensitivity to external artifacts. Therefore, this work aims to characterize dry, wet, and gel electrodes to assess their viability for use in BCI systems based on P300-evoked potentials.

EEG recordings were obtained from 15 subjects in 2 sessions. In each session (per condition) was performed: 1 resting-state recording (with eyes closed) and 5 recordings using the RCP speller. In total, 450 recordings were obtained to evaluate the electrodes in BCI systems. Once the data was collected, the signals were preprocessed, features were extracted, and the intentions were classified to control the BCI system. As a result, it became possible to compare the different electrode responses for BCI systems. The results showed significant differences in EEG characteristics across the 3 conditions. Moreover, the analyzed BCI system achieved command decoding accuracy rates of 36%, 32%, and 87% using dry, wet, and gel electrodes, respectively. It was concluded that, under the experimental conditions, dry and wet electrodes do not allow for satisfactory control of the BCI system.

## **Keywords:**

Brain Computer Interface (BCI), electroencephalogram (EEG), evoked related-potentials (ERPs), P300, *Row-Column Paradigm*, rLDA, electrodes characterization, dry, wet, gel.

# Agradecimientos

En primer lugar, quiero agradecer a mi familia por el esfuerzo que todos hemos realizado para alcanzar este logro, fueron meses con muchos altibajos pero que al final ha valido totalmente la pena. A mis amigos, por acompañarme en toda esta aventura y a mis compañeros que pudieron orientarme en todo este proceso.

Quiero expresar mi gratitud al profesor Roberto Hornero por haberme dado la oportunidad de ser parte de los estudiantes del Grado en Ingeniería Biomédica. Le doy las gracias nuevamente a Roberto, por permitirme ser parte de un equipo tan excepcional como lo es el Grupo de Ingeniería Biomédica.

Agradezco a Eduardo Santamaría por la paciencia y dedicación de su parte, desde el primer momento que ingresé al grupo. Gracias, al resto del equipo de la línea de BCI que ha puesto cada uno un granito de arena para mi aprendizaje y experiencia tanto en el laboratorio como por fuera del mismo.

# 1. Capítulo 1.

---

## Introducción

En este capítulo se realizará una introducción a los fundamentos de los sistemas Brain Computer Interface (BCI). En primer lugar, el electroencefalograma (EEG), una técnica que permite medir la actividad eléctrica del cerebro. Posteriormente, se detallan los diferentes tipos de sistemas BCI, que dependen según la estimulación al usuario. Por consiguiente, se exponen las etapas de un sistema basado en potenciales evocados P300 (ERP). Se muestran las limitaciones abordadas en este trabajo, así como las limitaciones para llegar a exportar los sistemas BCI fuera de un entorno de laboratorio. Finalmente, se definirán los objetivos del proyecto, junto con la planificación y estructura del Trabajo Fin de Grado.

### 1.1. Sistemas Brain-Computer Interface (BCI)

Un sistema BCI, permite la interacción entre un usuario y su entorno a través de dispositivos. Mide la actividad del sistema nervioso central (SNC), toma el potencial como una entrada y la convierte en una salida artificial capaz de controlar una máquina, permitiendo aplicaciones en el campo de rehabilitación o bien, entretenimiento. (Sellers et al. 2009a; J. Wolpaw and Wolpaw 2012a; Kam et al. 2018)

El punto de partida de un sistema BCI es el SNC, lugar donde está presente el centro de control de todas las funciones cognitivas y motoras en los seres humanos y, donde se procesa y se transmite la información a través de potenciales de acción que, hoy en día, pueden ser medidos, procesados y analizados para comprender el funcionamiento del cerebro. (J. Wolpaw and Wolpaw 2012a)

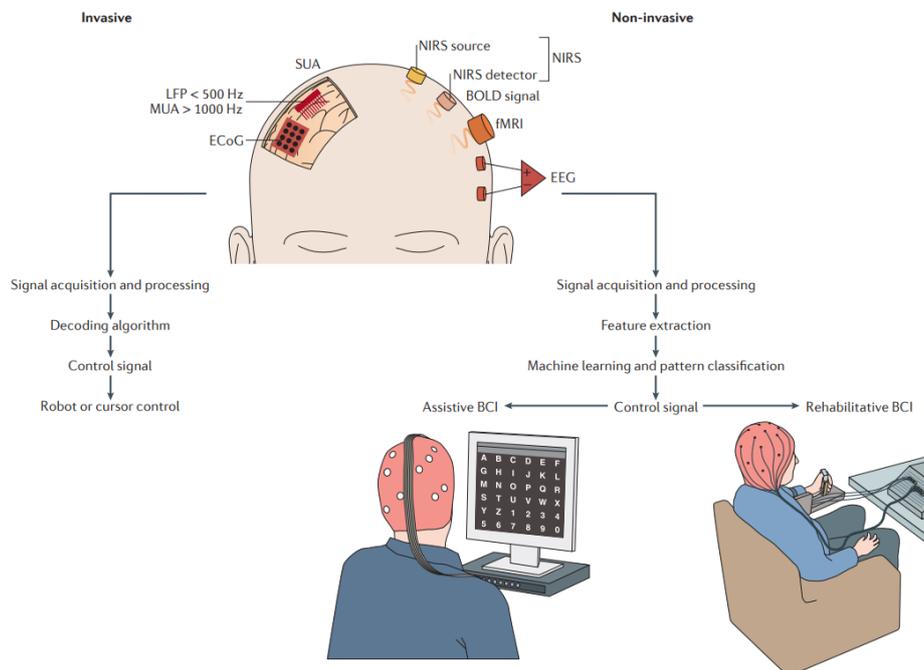
En la figura 1-1, se puede visualizar distintos métodos de adquisición de la señal con los respectivos procesos post-adquisición que engloba, la extracción y traducción de características que llevarán a un control del sistema BCI para distintas aplicaciones. Dentro de los métodos invasivos se encuentran: *local field potentials* (LFPs), *single-unit activity* (SUA), *multi-unit activity* (MUA) y electrocorticografía (ECoG) (Srikantharajah et al. 2021; Chaudhary, Birbaumer, and Ramos-Murguialday 2016). A su vez, se resumen métodos no invasivos como: electroencefalograma (EEG), resonancia magnética funcional (fMRI) y el método de espectroscopía de infrarrojo cercano (NIRS) (J. R. Wolpaw et al. 2002; Pflieger and Barbour 2012).

#### 1.1.1. Electroencefalograma (EEG)

El EEG es el método por excelencia para registrar la actividad eléctrica cerebral en los sistemas BCI. Esta técnica, es capaz de detectar el campo eléctrico generado por la actividad neuronal de la corteza cerebral mediante la colocación de electrodos sobre el cuero cabelludo. La señal, al ser el resultado de un impulso

sincronizado de un grupo de neuronas, ésta se ve atenuada dada la presencia de impedancias entre la corteza y el electrodo. (J. R. Wolpaw et al. 2002; J. Wolpaw and Wolpaw 2012a; Hinrichs et al. 2020)

Entre las ventajas más importantes del EEG se encuentra: (1) es una técnica no invasiva, (2) es portable, y (3) cuenta con una gran resolución temporal. Sin embargo, a pesar de estas ventajas, una de las limitaciones está relacionada a la sensibilidad a artefactos de ruido que degradan la señal que se está adquiriendo (Värbu, Muhammad, and Muhammad 2022).



**Figura 1-1.** Esquema de distintos métodos para la adquisición de señal para sistemas BCI. (Izquierda) Adquisición mediante métodos invasivos. Esto engloba el procesamiento de la señal y la implementación de algoritmos de decodificación para conseguir señales de control que permitan un dominio sobre sistemas BCI como, robots o cursores. (Derecha) Registro de la señal por métodos no invasivos. Se realiza una extracción de características que servirá para la clasificación de patrones que tomará un algoritmo de machine learning para conseguir el control de la señal que permitirá abrirse paso a aplicaciones enfocadas a asistencia y rehabilitación. Tomado de: Chaudhary, U .et .al (2016).

A la hora de analizar funciones sensoriales y/o motoras, la distribución de los electrodos sobre la corteza dependerá de la región cerebral que se desea estudiar. Los lóbulos denotan las regiones cerebrales que, junto con los puntos anatómicos (nasion, el inion y los puntos preauriculares) servirán de base para el posicionamiento de los electrodos basándose en el *sistema internacional 10/20*. Este sistema asegura una cobertura uniforme de las diferentes áreas del cerebro como puede apreciarse en la figura 1-2. La nomenclatura para nombrar los electrodos se basa en el lóbulo y el hemisferio en el que se ubican (H. Derecho números pares - H. Izquierdo número - 'Z' en la línea central entre ambos hemisferios). (J. Wolpaw and Wolpaw 2012a)

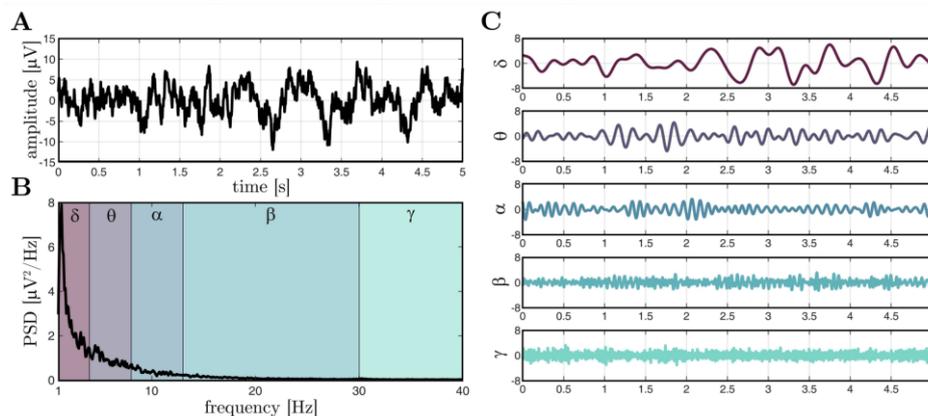


Bandas	Origen de la señal Lóbulos y regiones	Estado cognitivo
Delta $\delta$ (1–4 Hz)	Parietal   Central	Sueño profundo
Theta $\theta$ (4–8 Hz)	Frontal Parietal Temporal	Somnolencia Reconocimiento de emociones
Alpha $\alpha$ (8–13 Hz)	Corteza visual	Relajación Detección de ojos cerrados
Beta $\beta_1$ (13–20)   $\beta_2$ (20–30)	Corteza motora	Actividad motora
Gamma $\gamma$ (30–100 Hz)	Corteza somatosensorial	Atención Aprendizaje Memoria

**Tabla 1–1.** Bandas de potencia de una señal EEG. Tabla construida a partir de la información obtenida de: (J. Wolpaw and Wolpaw 2012b).

Como se ha mencionado anteriormente, las bandas de frecuencia se ven relacionadas con el estado del usuario, y su respuesta se puede visualizar con mayor predominancia en unas regiones frente a otras. En la tabla 1–1, se resumen las regiones donde aparece cada banda (J. Wolpaw and Wolpaw 2012b).

En la región frontal, se registra la actividad relacionada con las funciones ejecutivas, pero a su vez, en adultos se registra con mayor amplitud la banda de menor frecuencia delta que denota el sueño profundo. Mientras que, en la región parietal, se captan las señales relacionadas con la percepción sensorial y para estados de relajación, alfa tiene mayor predominancia en esta área. En la región temporal, se procesa toda la información relacionada con la memoria y es donde la banda beta tiene mayor presencia. Por otro lado, en la región central, es el área encargada del control motor primario y somatosensorial. En el caso de la región occipital, se registra toda la información que involucran los estímulos visuales, por ello en casos de estados de relajación con ojos cerrados, la amplitud de la onda aumenta en el área occipital (J. Wolpaw and Wolpaw 2012b).



**Figura 1–3.** Representación gráfica de las diferentes ondas que se pueden encontrar dentro de un EEG. (A) Señal EEG de 5 segundos de longitud. (B) Densidad Espectral de Potencia (PSD) extraído de una señal de EEG. (C) Descomposición del EEG en las diferentes bandas de potencia según el estado del usuario. Tomado de: Martínez-Cagigal, V. (2020).

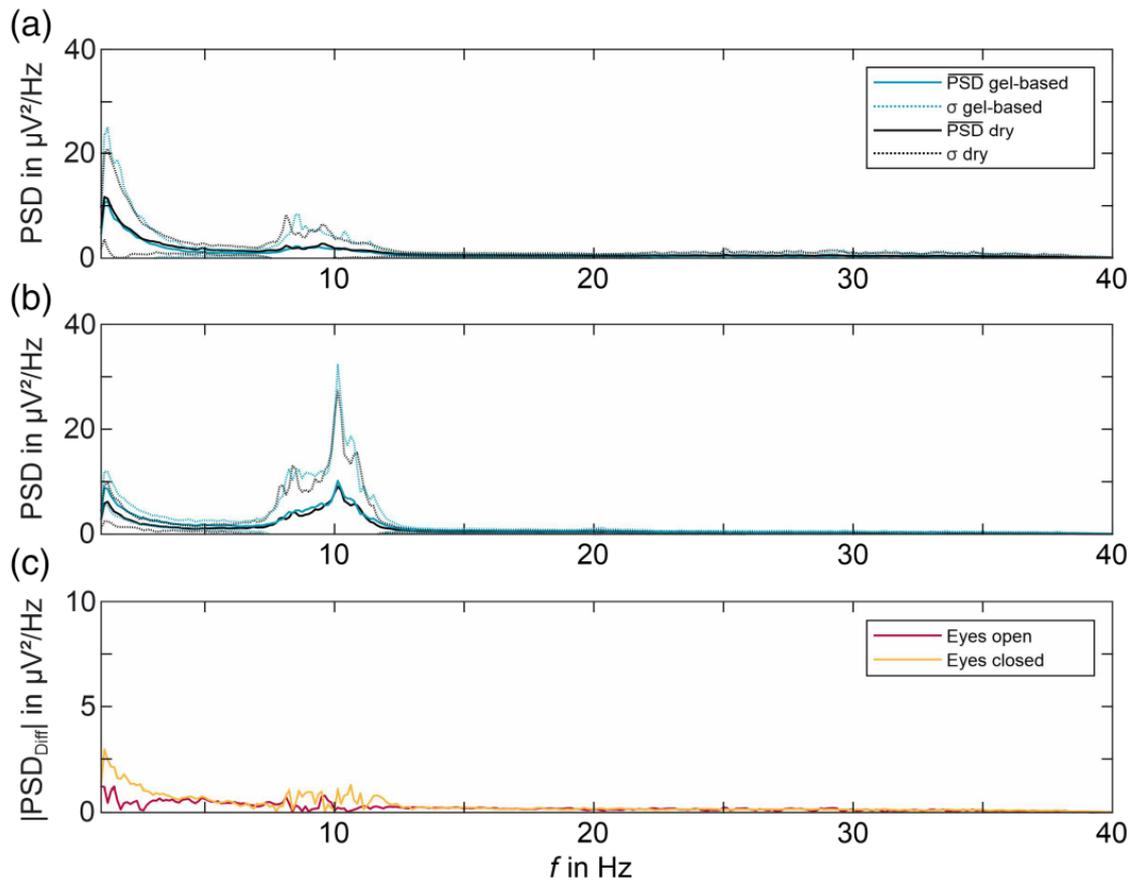
Existen componentes de artefactos externos que se solapan dentro de la señal a la hora de la adquisición, amplificación y digitalización, creando una capa de ruido sobre la señal que es necesario eliminar a partir de un filtrado. Este es uno de los primeros pasos que se realizan a la hora de preprocesar un EEG. Aunque la presencia de un electrodo de referencia aporta significativamente una reducción de estos componentes, generalmente es necesario aplicar una etapa de preprocesado para la reducción de ruido (Dagdevir and Tokmakci 2021).

Tipo de artefacto	Frecuencia [Hz]
EMG	~10
EOG *	* En estos artefactos, es posible visualizar la onda típica de la señal biológica inmersa a su vez en el EEG
ECG *	
Efectos mecánicos (movimiento de cable / electrodo)	<2
Impedancia del electrodo	50 - 60
Corriente eléctrica	50 - 60

**Tabla 1–2.** Artefactos que se pueden encontrar en una señal EEG. Tabla construida a partir de la información obtenida de: (J. Wolpaw and Wolpaw 2012b).

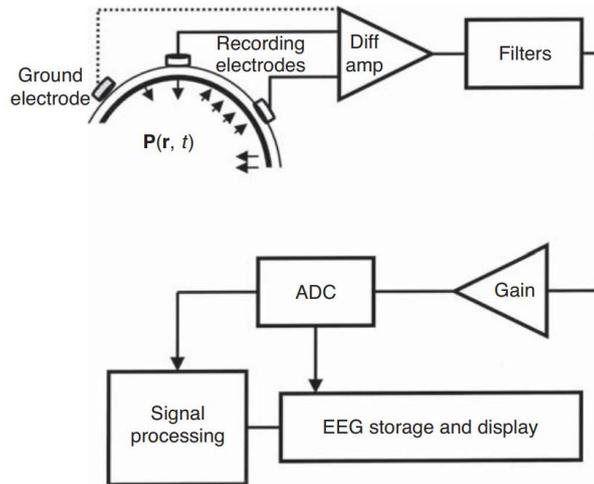
Dentro de los factores externos que pueden incurrir en la degradación de la señal de EEG se encuentran algunos artefactos fisiológicos como: la actividad muscular medida mediante electromiograma (EMG), movimientos oculares medidos mediante el electrooculograma (EOG), y actividad muscular cardiaca medido mediante electrocardiograma (ECG). Los artefactos biológicos se presentan en gran medida en diferentes bandas a lo largo de la densidad espectral de potencia (PSD), las mediciones que se han encontrado para cada artefacto están expuestas en la tabla 1-2 (J. Wolpaw and Wolpaw 2012b).

La PSD, aporta información para el análisis frecuencial, así como es posible identificar variaciones en el espectro debido al ruido, es posible observar cambios respecto al estado cognitivo de un usuario. En la figura 1–4, se observa una PSD promediada donde es posible observar dos momentos del estado cognitivo en reposo, ojos abiertos (figura 1–4A) y ojos cerrados (figura 1–4B). Esta condición basal, permite a los estudios evaluar estados antes de la ejecución de una tarea para conocer de forma individual o general la respuesta en reposo de la señal de EEG. La banda de potencia en alfa (8 a 13 Hz), correspondiente a los estados de reposo y relajación, se representa de forma gráfica con el pico de mayor amplitud en la PSD de la figura 1–4B (Fiedler et al. 2014).



**Figura 1–4.** Representación gráfica de la densidad espectral de potencia (PSD). (A) Ojos abiertos. (B) Ojos cerrados. (C) Valor absoluto de la diferencia de la PSD entre ojos abiertos y ojos cerrados. Tomado de: Fiedler *et al* (2021).

Las características dentro de la señal EEG trae consigo las intenciones del usuario, es por ello que, la etapa de preprocesamiento aporta métodos para alcanzar una buena relación señal ruido (SNR) y a su vez, el filtrado de frecuencias. La SNR es la relación entre la potencia de la señal y el ruido inmerso en ella. Obtener una señal EEG filtrada permitirá realizar una extracción de características para distinguir claramente las intenciones del usuario (J. R. Wolpaw et al. 2002; J. Wolpaw and Wolpaw 2012b; Saha et al. 2021; Dagdevir and Tokmakci 2021).



**Figura 1– 5.** Componentes de un sistema de registro de EEG. Tomado de: (J. Wolpaw and Wolpaw 2012b).

Hoy en día, los equipos de adquisición de EEG traen consigo un filtro de ranura integrado que permite rechazar el ruido de la corriente eléctrica inmediatamente se adquiere la señal. Se pueden aplicar filtros espaciales con ventana Hamming para reducir los errores a la hora de la clasificación. Los autores Pawan & Rohtash Dhiman (2023), sostienen que para aumentar la congruencia en sistemas BCI, utilizan métodos como el análisis de componentes principales (PCA) y la referencia media común (CAR).

Después de la etapa de preprocesado, se abre la posibilidad de interpretar las intenciones del usuario y convertirlas en acciones, cosa que los sistemas BCI aprovechan para traducir los patrones de actividad cerebral en comandos que pueden ser utilizados para controlar dispositivos externos.

### 1.1.2. Tipos de sistemas BCI

De forma habitual, los sistemas BCI se han clasificado en términos del estado actual del usuario (nivel de atención) o bien, en aquellos que proporcionan una comunicación y control del sistema. Los términos *pasivos* y *activos* en BCI van ligados, generalmente, a la condición de un sistema que tenga la capacidad de detectar una característica del EEG con el objetivo de aportar (o no) una retroalimentación. Un sistema *pasivo* es aquel empleado para monitorizar generalmente un estado o función cognitiva (sueño bajo anestesia). Se denota *pasivo* porque el usuario no interacciona con el sistema BCI. Por otro lado, los sistemas *activos* son aquellos en los que el usuario interacciona de forma voluntaria (un *speller*) (J. Wolpaw and Wolpaw 2012b).

Otra manera de categorizar los sistemas BCI en términos más precisos para lograr tener el control de un dispositivo es teniendo en cuenta el origen de la señal de control. La interpretación de las intenciones del usuario en sistemas BCI, que viene dada por la traducción de los potenciales en la señal de EEG. Estos potenciales conocidos como señales de control pueden clasificarse como señales endógenas o

exógenas. Estas se diferencian en que, para obtener el primer tipo de señal no se necesita de alguna estimulación externa para generar una respuesta nerviosa y poder identificar las intenciones del usuario. Mientras que, para el caso de los sistemas exógenos, ocurre lo contrario, para obtener una señal se busca estimular al usuario con el objetivo de producir una respuesta nerviosa capaz de ser identificada para interpretar la intención del usuario. A gran escala las características de ambos sistemas se ven expuestas en la tabla 1–3 (J. Wolpaw and Wolpaw 2012b).

Característica	Sistemas BCI Exógenos	Sistemas BCI Endógenos
Dependencia a un estímulo	Dependen de estímulos externos	No dependen de estímulos externos
Ejemplo de estímulos	Destellos visuales	Imaginación motora
Tipo de señal EEG	Potenciales evocados P300   SSVEP	Ritmos cerebrales espontáneos Ritmos $\mu$   $\beta$
Requerimientos del usuario	Menor carga cognitiva Usuario emite respuesta al estímulo	Mayor entrenamiento Usuario emite respuesta innata
Aplicaciones comunes	Sistemas de comunicación a través de interfaces visuales	Rehabilitación motora
Ventajas	Alta precisión en detección de señales	No requiere estímulos externos
Desventajas	Posible fatiga visual o auditiva	Requiere mayor entrenamiento Variabilidad en las señales
Tiempo de entrenamiento	Corto Usuarios aprenden rápidamente a responder a estímulos	Largo Requiere práctica y entrenamiento para generar señales consistentes

**Tabla 1–3.** Tabla resumen de características entre sistemas BCI exógenos y endógenos. Tabla construida a partir de la información obtenida de: (J. Wolpaw and Wolpaw 2012b).

Para controlar un sistema BCI, se debe seleccionar el tipo de señal de control con el que se va a trabajar según la naturaleza de esta. Dentro de las señales de control se encuentran: potenciales evocados P300, potenciales evocados VEP, ritmos sensoriomotores, potenciales corticales lentos, entre otras señales que se detallan en el siguiente apartado (Dagdevir and Tokmakci 2021).

Con los sistemas BCI basados en potenciales evocados P300, es posible alcanzar altas precisiones sin necesidad de entrenamiento, caso contrario que ocurre con los sistemas endógenos. Dado lo anterior, su aplicabilidad fuera de entornos no clínicos se puede considerar aún más útil para el caso de los sistemas exógenos. Es por ello que, en este trabajo se resaltan los sistemas BCI exógenos trabajando con potenciales evocados relacionados a estímulos, específicamente, con la onda P300 (J. Wolpaw and Wolpaw 2012b).

### 1.1.3. Etapas de un sistema BCI

Para lograr conseguir el control de un sistema BCI es necesario pasar por 3 etapas principales: (1) Adquisición de la señal, donde se realiza el registro EEG de un

usuario bajo un paradigma en específico. (2) Procesado de la señal, que engloba el pre-procesado, extracción y clasificación de características de la señal. (3) Aplicación de un sistema BCI (J. Wolpaw and Wolpaw 2012b).

#### 1.1.3.1. *Adquisición de la señal*

La primera etapa de un sistema BCI radica en la adquisición de la señal de EEG, inmerso en dicha etapa está el proceso de transformación de la señal analógica a la señal digital como se muestra en la figura 1-5 (J. Wolpaw and Wolpaw 2012b). Las diferencias de potencial vienen dadas por el campo eléctrico cerebral mezclado con artefactos biológicos y del entorno, como se comentó en el primer apartado de este capítulo. La precisión del sistema BCI va de la mano con la calidad de la señal, y depende del tipo de dispositivo, electrodo, tarea a realizar hasta el tipo de señal de control. En los siguientes puntos se detallan los factores que juegan un papel fundamental para obtener un control preciso de un sistema BCI.

##### a. *Equipos para registro EEG en sistemas BCI*

Hoy en día existe una amplia gama de equipos para la adquisición de señales EEG. No obstante, se ha evidenciado que la implementación de dichos equipos se ve restringida a la hora aplicarlos para sistemas BCI. Los dispositivos para sistemas cuentan con características individuales que hacen que su utilidad prime por encima de los demás, entre ellas, se encuentra el número de canales disponibles, la resolución temporal, frecuencias de muestreo, entre otros.

Los autores Jamil & Nasreddine *.et. al.* (2021), separan en distintos grupos algunos equipos para adquisición de señal EEG, según las áreas de investigación: educación, ingeniería, medicina y entretenimiento. Los autores comparan los equipos inalámbricos y no inalámbricos de 28 compañías, detallan las investigaciones que se han realizado en las distintas áreas; en su gran mayoría, el área que con mayor campo de investigación es el de medicina, dado que los sistemas BCI han sido aplicados para tecnologías de asistencia y rehabilitación. Para este proyecto, se busca enfocar en las áreas diferentes, es por ello que en la tabla 1-4, se muestran las compañías que han trabajado con sistemas BCI en áreas como ingeniería y entretenimiento (Jamil et al. 2021).

Los equipos con mayor portabilidad, aunque pueden ofrecer comodidad y facilidad en su aplicación, se ve afectada la parcialmente resolución de la señal (Jamil et al. 2021).

##### b. *Electrodos para registro EEG en sistemas BCI*

Algunos de estos equipos cuentan con variaciones en el tipo de electrodo que se puede utilizar para la adquisición. Las variaciones de estos son: electrodos secos, húmedos (agua), y electrodos con gel. Los electrodos secos, consisten en un tipo de electrodo con material conductor que permite la captación de señal de EEG sin necesidad de un gel conductor. Mientras que, los electrodos húmedos, son aquellos que requieren de un medio conductor (gel, agua) adicional para la conducción entre

el cuero cabelludo y el electrodo (Mathewson, Harrison, and Kizuk 2017; Heijs et al. 2021).

En los casos de los electrodos que no cuentan con un medio conductor para disminuir la impedancia, la precisión de las adquisiciones se ve afectada dada la cantidad de ruido y artefactos que intervienen en la señal EEG capturada. Aun así, se ha demostrado obtener una precisión suficiente para tener el control del sistema BCI como lo muestran los autores Samara & Farmaki *et al.* (2022). De acuerdo con sus resultados con un *speller* basado en SSVEP, la precisión de los electrodos secos fue de un 82%, mientras que con los electrodos con gel se superó el 92% de precisión (Samara et al. 2022).

Compañía	Area de investigación				Electrodes
	Educación	Ingeniería	Entretenimiento	Medicina	
Advanced Brain Monitoring		✓	✓	✓	Gel
ANT Neuro			✓	✓	Gel + Dry
Brain Products		✓	✓	✓	Gel + Dry
Cognitionics Inc		✓		✓	Gel + Dry
Compumedics Neuroscan		✓	✓	✓	Gel + Wet
Electrical Geodesics Inc		✓		✓	Gel
Emotiv	✓	✓	✓	✓	Gel + Dry
g.Tec		✓	✓	✓	Gel + Dry
InteraXon	✓			✓	Gel + Dry
Neuroelectronics		✓		✓	Gel + Dry
NeuroSky		✓		✓	Gel + Dry
OpenBCI			✓	✓	Gel + Dry

**Tabla 1-4.** Compañías que han desarrollado equipos EEG adaptados tanto a electrodos secos como a electrodos con gel. Tomado de: (Jamil et al. 2021).

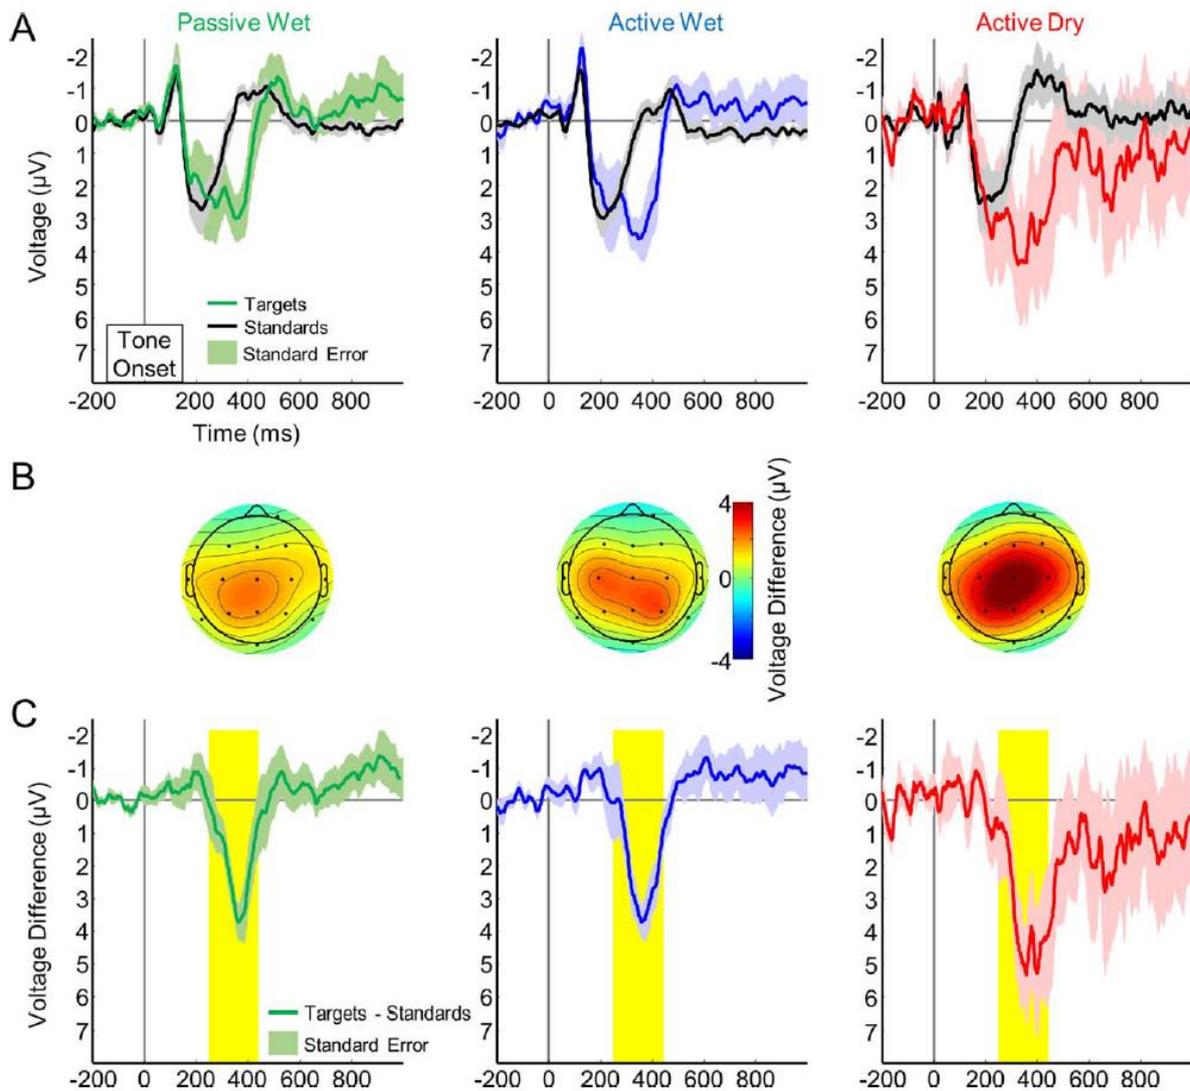
### c. Señales de control de un sistema BCI

Como se ha mencionado anteriormente, entre los tipos de sistemas BCI exógenos y endógenos, están inmersas las señales que permiten controlar una aplicación (p. e. selección de comandos, desplazamientos, entre otros). Estas señales de control son las siguientes:

#### i. Potenciales evocados relacionados a eventos (ERPs)

Estos potenciales vienen dados por el *speller odd-ball*. Consiste en la selección de un comando cuando se expone al usuario a una secuencia de destellos aleatoria sumado a un destello determinado sobre el comando objetivo. La onda P300 aparece a los 300 ms luego del estímulo visual, sobre la región parietal del cerebro (Pan et al. 2022; Santamaria-Vazquez et al. 2019).

En la figura 1-6, se reúnen los registros de los ERPs con diferentes electrodos, 1 pasivo seco y 2 activos (secos y con gel). En las tres condiciones en estudio se puede visualizar correctamente el ERPs, con la diferente entre cada uno es la presencia de artefactos en la señal. En los electrodos secos, los picos de ruido en la señal se ven con mayor presencia que en los electrodos húmedos (pasivos y activos), haciendo que la respuesta tanto del tono estándar como del tono *target* sean afectados (Mathewson, Harrison, and Kizuk 2017).

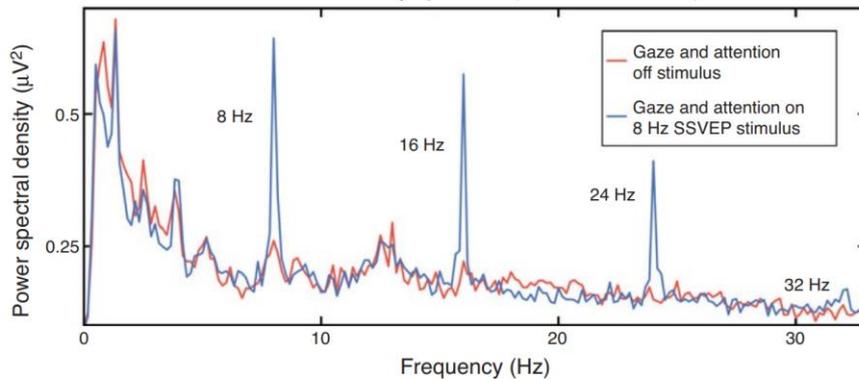


**Figura 1–6.** Representación gráfica de los potenciales relacionados a eventos (ERPs) adquiridos con diferentes tipos de electrodos (pasivos, activos con gel, activos secos). (A) Promedio general del ERPs del electrodo Pz donde se puede ver la respuesta ante el estímulo (onda verde, azul, rojo) frente a los distractores (onda negra). (B) Topografías de la respuesta de los ERPs. (C) Onda ERPs resultante de la resta entre la respuesta del tono estándar y el tono target. Tomado de: Mathewson KE .et .al (2017).

## ii. Potenciales evocados visuales *Steady-state* (SSVEP)

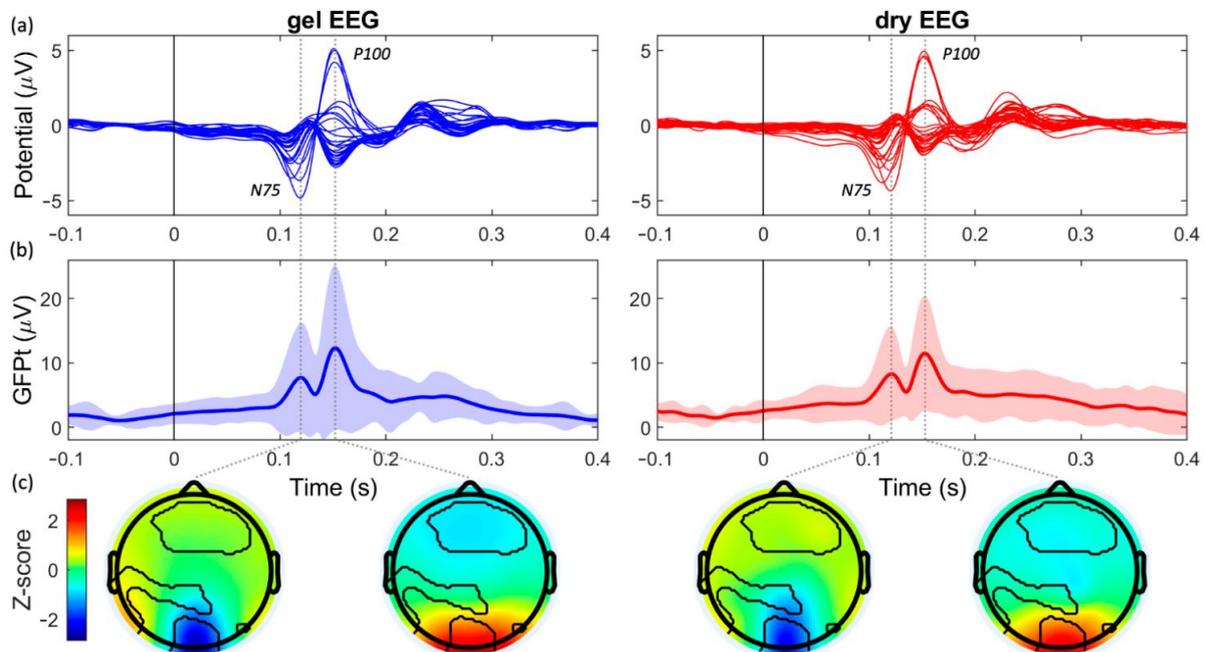
Los SSVEP son diferencias de potencial que aparecen a los 100 ms luego de estimulaciones visuales en forma de parpadeo a cierta frecuencia (superior a 4 Hz). Gracias a estas iluminaciones se produce un fenómeno de resonancia (figura 1–7) que se emplea para identificar la dirección de la mirada (J. Wolpaw and Wolpaw 2012b).

El pico de frecuencia que aparece en el EEG corresponde al destello al que se fijó el usuario, al reconocer estos picos se puede identificar la dirección o intención seleccionada por el usuario (J. Wolpaw and Wolpaw 2012b).



**Figura 1–7.** Respuesta armónica en una señal EEG ante estímulos repetitivos. Tomado de: Wolpaw & Wolpaw (2012).

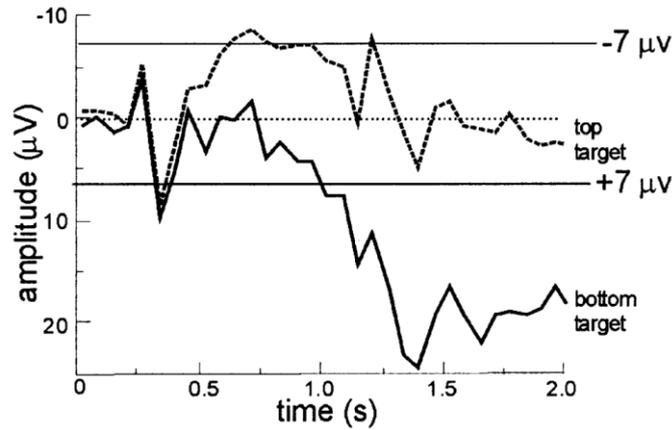
Los autores Heijs JJA *et al.* (2021) han realizado estudios sobre SSVEP donde evalúan electrodos secos y con gel para la implementación en sistemas BCI. Se pueden ver las diferencias en el potencial global promedio donde la amplitud de los electrodos de gel es mayor a la amplitud de los electrodos secos



**Figura 1–8.** Representación gráfica de los potenciales visuales evocados (SSVEPs) adquiridos con diferentes tipos de electrodos (gel, secos). (a) Respuesta promediada de los potenciales VEP por canales. (b) Potencia global promedio de todos los sujetos respecto al tiempo. (c) Topografía normalizados de los picos principales del VEP. Tomado de: Heijs JJA *et al.* (2021).

### iii. Potenciales corticales lentos (SCP)

Estos potenciales corresponden a la actividad cortical que ocurre a bajas frecuencias, dentro del rango [0.5, 1] segundos. Las variaciones de estos potenciales denotan un aumento o disminución de la actividad cortical asociada con la ejecución de un movimiento; con mayor predominancia en el vértex, en la región entre los lóbulos frontal y parietal.



**Figura 1–9.** Respuesta de los potenciales SCP de un usuario que desea mover el cursor hacia un comando (*target*) en la pantalla, *target* superior (línea discontinua) y *target* inferior (línea continua). Tomado de: Wolpaw JR .et .al (2022).

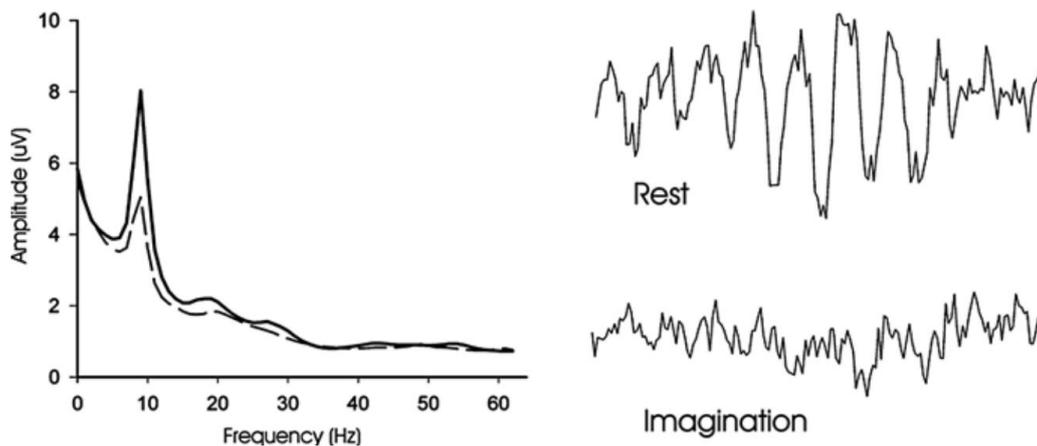
Estos potenciales a diferencias de los anteriores son señales de control endógenas y requiere de entrenamiento para poder controlar el sistema BCI. En la figura 1–9, denota la respuesta de los SCP entre el aumento o la disminución

#### iv. Ritmos sensoriomotores (ritmos $\mu$ y $\beta$ )

Son bandas de frecuencia que sufren una desincronización cuando se ejecuta (o se imagina) un movimiento. Los tipos de ritmos sensoriomotores están clasificados de acuerdo con la región cerebral donde se presenten, así como en el rango de frecuencia donde se observe su mayor amplitud (Han Yuan and Bin He 2014).

Los ritmos  $\mu$ , están presentes en la región somatosensorial de la corteza (lóbulo parietal), en un rango entre [8,12] Hz. Por otro lado, los ritmos  $\beta$ , aparecen en la zona visual de la corteza (lóbulo occipital) en un rango de [18,26] Hz (Sellers et al. 2009a).

Nuevamente, como ocurre con los potenciales SCP, estos ritmos son señales de control endógenas que requieren de entrenamiento para controlar un sistema BCI. Teniendo en cuenta que, en estos casos, no es necesario realizar la ejecución de un movimiento, basta con imaginarlo para generar la señal de control. La respuesta visual de estos movimientos se puede observar en la figura 1–10 (Sellers et al. 2009a).



**Figura 1–10.** Representación gráfica de la respuesta de los ritmos sensoriomotores. (Izquierda) Espectro de frecuencia del ritmo sensoriomotor,  $\mu$  (sobre los 10 Hz) y  $\beta$  (sobre los 20 Hz). La línea continua corresponde a estado de reposo, mientras que la discontinua corresponde al potencial durante la imaginación del movimiento. (Derecha) Segmentos de una señal de EEG, en reposo (superior) y ejecutando un movimiento (inferior). Tomado de: Sellers .et .al (2009).

### 1.1.3.2. Preprocesado de la señal

Dado que gran parte del ruido presente en la señal en estudio proviene de frecuencias altas, lo más conveniente es aplicar un filtro paso bajo justo en la salida del amplificador que permita deshacerse del componente de EMG (de alta frecuencia) y corriente eléctrica; comúnmente, es posible conseguir en el mercado muchos equipos de EEG con un filtro *notch* integrado para la eliminación de la interferencia por corriente eléctrica. Sin embargo, aun así, otra parte de los componentes de ruido siguen presentes dentro de la señal EEG previamente filtrada que puede confundirse con la señal en bruto; es por ello que se abre la posibilidad de aplicar otros filtros digitales en el análisis *offline* (Sellers et al. 2009a; J. Wolpaw and Wolpaw 2012b; J. R. Wolpaw et al. 2002; Dagdevir and Tokmakci 2021).

Dado lo anterior, una estrategia que recomienda el autor Srinivasan en el sexto capítulo del libro *Brain Computer Interfaces. Principles and Practice* para la reducción del ruido dentro de los sistemas BCI, es identificar características del EEG en lo posible en las bandas de frecuencia que están menos propensas a tener contaminación por ruido para así lograr alcanzar un mejor análisis espectrales y topográficos (J. Wolpaw and Wolpaw 2012b).

En la tabla 1–5, se resumen los métodos para reducción de artefactos. Se ha registrado que los métodos empleados para mejorar la calidad de la señal, paralelamente, sirven para la extracción de características de la señal. La clasificación realizada se centra en los métodos basados en dominio tiempo–frecuencia y en los espaciales. La aplicación de estos métodos dependerá del tipo de señal que se esté trabajando y de la capacidad computacional que requiere cada uno de ellos (Dagdevir and Tokmakci 2021; J. Wolpaw and Wolpaw 2012b).

Dominio	Método	Característica
	Referencia Media Común (CAR)	Aumenta la SNR, es implementado en registros con altos componentes de ruido
Espacio	Análisis de Componentes Independientes (ICA)	Realiza una separación entre las señales (ruido u otros potenciales) inmersas en la señal EEG
	Análisis de Componentes Principales (PCA)	Reduce la dimensionalidad de la señal, obteniendo un arreglo de datos con la misma varianza original pero de menor tamaño
	Patrones Espaciales Comunes (CSP)	Separa la clases que se pueden encontrar en un EEG para distinguir una acción frente a otra
	Filtro Laplaciado	Realza la resolución espacial de un electrodo respecto a los electrodos adyacentes
Tiempo - Frecuencia	Filtro <i>pasa bandas</i>	Descarta las frecuencias que se encuentren fuera de un rango indicado
	Transformada de Fourier	Convierte la señal del dominio del tiempo al dominio de la frecuencia, útil para el análisis espectral
	Transformada de Wavelet	Proporciona una representación tanto en tiempo como en frecuencia

**Tabla 1–5.** Clasificación de métodos para preprocesado de una señal EEG para sistemas BCI. Tabla construida a partir de la información obtenida de: (J. Wolpaw and Wolpaw 2012b).

En la etapa de preprocesado, se pueden aplicar otros métodos como la normalización a partir del *Z-Score* (Chen et al. 2023), técnica implementada en señales EEG que tengan amplia variabilidad con el objetivo de obtener señales que puedan ser comparables (Arevalillo-Herráez et al. 2019). Se ha registrado que una señal EEG varía entre sujetos, así como entre sesiones de un mismo sujeto. Tener diferentes condiciones de registro de EEG aumenta aún más la variabilidad entre las señales, es por ello, que se debe tener en cuenta este tipo de estandarización que permita contar con una misma escala todos los registros de EEG (Singh and Singh 2020; Apicella et al. 2023).

De igual manera, para el caso de las señales de EEG generadas a partir de un speller, es importante marcar un *baseline*, que denote el espacio de tiempo antes de presentarse un estímulo al usuario. Esto, con el objetivo de tener una referencia temporal a lo largo de la señal, para analizar los potenciales a partir de dicha marca en el tiempo (Peng 2019). Gracias a este método es posible reducir desviaciones temporales que se pueden presentar en el transcurso del registro, dado por fuentes externas diferentes a la tarea indicada al usuario (Maess, Schröger, and Widmann 2016). Tradicionalmente, la técnica de corrección del *baseline*, se realiza restando la media de los potenciales en cada uno de los electrodos dentro del rango del *baseline* (Tanner et al. 2016).

### 1.1.3.3. Procesado de la señal

En segundo lugar, la etapa de procesado engloba primero la extracción de características, para luego llegar a la traducción de estas y poder clasificarlas. En el primer apartado, se busca obtener información de las características del EEG para

poder discernir entre intenciones para alcanzar a conseguir la discriminación de la acción que el usuario desea realizar.

#### *a. Extracción de características*

A partir del EEG es posible obtener información relevante que designe una intención del usuario frente a artefactos y demás componentes en la señal, a esto se le denomina característica. Así como un artefacto puede alterar la señal EEG, estados como el nivel de atención, motivación, fatiga, entre otros factores, puede ocasionar una alteración en la señal EEG que, a su vez, altera el rendimiento del sistema BCI. Dado lo anterior, es importante conseguir una adaptabilidad del sistema BCI al usuario que permita el buen funcionamiento de la aplicación (J. R. Wolpaw et al. 2002; Ma et al. 2017; J. Wolpaw and Wolpaw 2012b).

Los métodos implementados para la extracción de características en los sistemas BCI se pueden clasificar en diferentes grupos dependiendo del tipo de señal con que se esté trabajando (Dagdevir and Tokmakci 2021; Lotte 2008). Particularmente, aunque los métodos de preprocesado y los métodos para extracción de características en algunos estudios consisten en técnicas diferentes, para este caso en los sistemas BCI en estudio, en estas etapas se pueden aplicar los mismos métodos que aparecen en la tabla 1–4 (J. Wolpaw and Wolpaw 2012b).

Como se ha mencionado anteriormente, los métodos que trabajan en el dominio temporal son los métodos más destacados gracias a la rapidez en la implementación y el coste computacional; gracias a la eficiencia en estos métodos es posible aplicarlos en estudios en tiempo real, un requisito indispensable para su aplicación en los sistemas BCI. Por otra parte, los métodos en el dominio frecuencial, aunque son un excelente método para análisis espectral, consumen mayor requerimiento computacional dado que necesitan realizar una transformación de la señal EEG para su procesado (J. Wolpaw and Wolpaw 2012b; Ma et al. 2017).

#### *b. Selección de características*

En esta etapa, se toman únicamente las características más relevantes del EEG que aporten significativamente al sistema BCI, de modo que pueda reducirse la dispersión de los datos y, por ende, sea más fácil la decodificación de la intención del usuario (Ma et al. 2017).

Entre las técnicas de selección de características que permite reducir el problema de la dimensionalidad es el Análisis de Componentes Principales (PCA). Este método se encarga de transformar un gran conjunto de las características del EEG, en pequeños conjuntos de nuevas variables no correlacionadas entre sí, pero que, al mismo tiempo, mantienen los patrones (Kundu and Ari 2018).

Otro de los métodos más utilizados es la selección basada en medidas de correlación (CFS). En este caso, se realiza el cálculo de correlación entre la característica y la variable objetivo, a partir de esto se aplica un filtrado que puede discernir entre las características mayormente correlacionadas y las que no,

descartándose del conjunto de datos, reduciendo así la dimensionalidad y potencialmente mejorando la precisión (Kabir et al. 2023).

Los métodos de selección basados en algoritmos genéticos es otro de los métodos de decodificación de intención para extraer características relevantes que consiste en aplicar procesos inspirados en la evolución natural para hallar el mejor subconjunto de características (Corralejo, Hornero, and Alvarez 2011; Rejer 2013).

### c. Clasificación y traducción características

En esta etapa, se toman las características obtenidas en la selección anterior y se convierten en posibles comandos que una máquina pueda interpretar. Para ello se emplean técnicas para la traducción de las características como los clasificadores lineales y no lineales (J. Wolpaw and Wolpaw 2012b; Garrett et al. 2003).

Con respecto a los clasificadores lineales, se da por sentado que los datos se pueden dividir a través de un hiperplano, separando en diferentes espacios los tipos de características; la presencia de gran porcentaje de artefactos en la señal puede inducir componentes indeseados en las características provocando la aparición de *outliers* haciendo que el clasificador lineal empiece a fallar. Es por ello que, entran en juego los clasificadores no lineales que aportan una mayor precisión en la clasificación a pesar de la alta demanda en los procesos (Garrett et al. 2003; Pawan and Dhiman 2023).

Para obtener una intención precisa, es importante aplicar un modelo clasificador que tenga la capacidad de identificar las relaciones entre las variables (por ejemplo, estados antes y después de un estímulo) para tener como resultado una salida que sea interpretable para la máquina (Garrett et al. 2003; Pawan and Dhiman 2023).

Dentro del campo de BCI, las condiciones entre las características de los sujetos cambian y no es aplicable de forma general para todos los usuarios. Dado lo anterior, la clasificación debe estar sujeta a una adaptabilidad dependiendo del usuario. Debido a la variación entre sujetos, el clasificador debe reconocer: las diferencias significativas, las variaciones entre la motivación (o fatiga), así como reconocer pequeños cambios en la atención de modo que pueda responder ante ellos (J. Wolpaw and Wolpaw 2012b; Chen et al. 2023; Stelmack, Houlihan, and McGarry-Roberts 1993).

En sistemas BCI, los clasificadores (en su mayoría no lineales) están basados en modelos de aprendizaje supervisado (Aloise et al. 2011). Estos clasificadores han demostrado ser un método de clasificación eficiente y rápido. Funcionan a partir de un entrenamiento con datos etiquetados, con el objetivo de establecer límites de decisión para separar clases, de modo que sean capaces de aprender las características de cada usuario para ser adaptados en los sistemas (J. Wolpaw and Wolpaw 2012b).

Entre los clasificadores no lineales están, las máquinas de soporte vectorial (SVM), busca posicionar el hiperplano a partir de la manipulación de los datos con kernels (Kundu and Ari 2018; Hashmi et al. 2022; J. Wolpaw and Wolpaw 2012b). El uso de redes neuronales artificiales (ANN) estudia la relación entre capas de

neuronas artificiales interconectadas una vez entrenadas con los datos etiquetados (Li et al. 2022; Santamaria-Vazquez et al. 2020; Garrett et al. 2003; J. Wolpaw and Wolpaw 2012b). Finalmente, otro método comúnmente empleado corresponde al análisis discriminante lineal (LDA) que busca plasmar en un hiperplano en la zona donde esté presente la mayor distancia entre medias de las clases y, a su vez, minimizar la varianza dentro de una clase (Pawan and Dhiman 2023; Santamaria-Vazquez et al. 2019; Martinez-Cagigal et al. 2017; Martínez-Cagigal et al. 2019).

Al momento de reconocer patrones de intención de un usuario y traducirlos a un lenguaje interpretable por una máquina, para que reconozca una acción y la ejecute, se abre la posibilidad de implementar estos datos para diferentes aplicaciones BCI.

#### 1.1.3.4. *Aplicaciones de los sistemas BCI*

En la fase de aplicación, se introduce en la última etapa del sistema BCI, la información extraída, clasificada y traducida de la señal de EEG. Esto con el objetivo de realizar acciones a través de aplicaciones (software - hardware), dentro de un contexto de tecnología de asistencia (rehabilitación) o bien, para entretenimiento (control de un videojuego). Un sistema BCI puede generar dos tipos de salidas que sirven para seleccionar un comando o bien, para controlar un proceso. La diferencia entre estos tipos de controles radica en que, el primero, el sistema BCI le indica a la aplicación qué es lo que debe hacer; el segundo, el sistema BCI le indica a la aplicación cómo debe hacerlo.

##### *a. Selección de comandos*

Con respecto a la selección de comandos, un usuario a través de un sistema BCI es capaz de comunicar una intención a la aplicación y ésta pueda ejecutar una acción. Este tipo de control se considera el más fácil de manejar, ya que una vez de transmite la intención, la aplicación en sí, se encarga de ejecutar todas las acciones que se requieran para alcanzar el objetivo de la intención del usuario.

Las aplicaciones de selección de objetivos (letras, números o comandos), resultan siendo una de las aplicaciones con mayor uso dentro de los sistemas BCI, que permiten la comunicación a personas con condiciones severas. Se pueden manejar mediante diferentes potenciales como, potenciales evocados P300, potenciales evocados visuales o potenciales corticales lentos.

1. Potenciales evocados P300: Para conseguir los ERPs se aplica el paradigma *odd-ball*. Al usuario se le presenta una matriz que contenga letras o números. Las filas y columnas son iluminadas secuencialmente, y a medida que se ilumina un comando deseado (*target*) se genera el potencial P300 (Santamaría-Vázquez et al. 2022; Mendoza-Montoya, Antelis, and Delijorge 2022; Aloise et al. 2011; Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019).
2. Potenciales evocados visuales: Para conseguir los SSVEPs se busca generar el fenómeno de resonancia visual que ocurre al someter al usuario a estímulos

luminosos a altas frecuencias. Estos potenciales, al igual que el anterior, al usuario se le presenta una matriz, donde cada celda tiene una frecuencia diferente. Al observar la celda que se desea, se genera una respuesta resonante a la misma frecuencia de la luz (Samara et al. 2022; Gutierrez-Martinez et al. 2021; Heijs et al. 2021; Santamaria-Vazquez et al. 2019).

3. Potenciales corticales lentos: Para los potenciales SCP, a diferencia de la aplicación con los otros potenciales, requiere de entrenamiento y la matriz se trabaja de forma diferente, dónde sólo se permiten selecciones binarias. En este caso, la selección de letras se realiza dividiendo el alfabeto a la mitad, una vez seleccionada se vuelve a dividir en dos partes, y así sucesivamente hasta llegar a la letra deseada (Hinterberger et al. 2004).

#### *b. Desplazamiento*

Para el caso del control de un proceso, tanto el usuario como el sistema BCI trabajan en conjunto para llevar a cabo la intención, indicando comandos concretos que vendrían siendo pequeñas acciones que, al sumarlas, se alcanza el objetivo del usuario.

Existen aplicaciones de desplazamiento que consiste en el control de movimiento dentro de un espacio (real o entorno virtual) donde se puede desplazar hacia distintos lados del entorno dando comandos de dirección. El movimiento de un cursor permite interactuar a un usuario con aplicaciones como desplazamiento dentro de un menú o movimientos dentro de un videojuego. Estas aplicaciones se pueden controlar con potenciales corticales lentos o ritmos sensoriomotores.

1. Potenciales corticales lentos: Así como se ha mencionado en la aplicación anterior, los SCP permiten selecciones binarias, que sirve en aplicaciones como el de un cursor que se desplaza de forma horizontal (1D) a una velocidad constante. Para controlar el desplazamiento, el usuario cambia la dirección del cursor sea derecha o izquierda empleando los potenciales SCP (Zhao et al. 2009).
2. Ritmos Sensoriomotores: Estos potenciales se descomponen en dos componentes, los eventos relacionados con sincronización (ERS) y desincronización (ERD) para controlar el movimiento del cursor. Cada uno de estos estados podría indicar una selección para el desplazamiento tanto vertical como horizontal (Han Yuan and Bin He 2014).

#### **1.1.4. Viabilidad**

La implementación de sistemas BCI fuera del entorno hospitalario y/o laboratorio de investigación trae consigo una serie de limitaciones que impiden integrar estos sistemas en la vida cotidiana de los usuarios, especialmente en lo que respecta a los equipos de EEG y tipos los electrodos para la adquisición de la señal.

Partiendo desde los equipos de EEG, hoy en día, los dispositivos que se manejan para aplicaciones en BCI tienden a ser de gama alta, resultando que sean demasiados costosos y, por tanto, la accesibilidad para el uso cotidiano se limite. Por

otro lado, estos equipos traen consigo una complejidad técnica que provocan que su manipulación requiera de personal especializado para su colocación y configuración (Shen et al. 2000).

Asimismo, se han analizado los tipos de electrodos existentes en el mercado. El electrodo por excelencia para adquirir una buena calidad señal de EEG son los electrodos de plata/cloruro de plata (Ag/AgCl) que emplean el uso un gel electrolítico para la conducción entre el cuero cabelludo y el electrodo. La limitación de este tipo de electrodo se centra en tres partes: (1) la aplicación del gel requiere tiempo y saber cómo aplicarlo, (2) el mantenimiento del gel durante el uso del equipo, y (3), la comodidad del usuario con la sensación de gel durante el tiempo que se requiera y la limpieza a posteriori (Shen et al. 2000).

El uso de electrodos secos representa una solución prometedora, ya que su colocación no requiere de preparación especial del cuero cabelludo ni la aplicación de gel, permitiendo una colocación rápida del equipo. Sin embargo, diversos estudios han identificado limitaciones en el uso de estos electrodos, como alta interferencia de ruido, inestabilidad del sistema porque se satura la señal, así como la desconexión de electrodos. Al estar en un medio con mucha impedancia, esto llega a afectar la calidad de la señal y, por ende, la fiabilidad de la adquisición al tener presente un mayor componente de artefactos acoplados a la señal.

Finalmente, se ha intentado buscar un punto medio entre estos dos electrodos, implementado otros medios de conducción sobre electrodos secos que puedan hacer una mejora en la calidad y estabilidad de la señal de EEG. Sin embargo, se mantienen algunos de las limitaciones mencionadas anteriormente.

En este sentido, se requieren más estudios para identificar las ventajas y desventajas de los distintos tipos de electrodos en el campo de los sistemas BCI.

## 1.2. Hipótesis

A pesar del potencial, la implementación de sistemas BCI en la vida cotidiana se ve afectada por varias limitaciones relacionadas en su gran mayoría con los equipos de EEG y los tipos de electrodos. Es por ello que se busca superar estas limitaciones para mejorar la viabilidad y la adopción de sistemas BCI en aplicaciones diarias. La hipótesis sostiene que los electrodos húmedos y secos presentan una precisión suficiente para controlar un sistema BCI, aunque el rendimiento sea menor a comparación de los electrodos con gel. Partiendo desde el conocimiento que los electrodos de gel son el *gold standard* para sistemas BCI ya que proporcionan la mejor calidad de señal debido a su baja impedancia y que, por su lado los electrodos secos y húmedos ofrecen ventajas en términos de rapidez y facilidad en la colocación.

## 1.3. Objetivos del Trabajo Fin de Grado

El objetivo general del presente Trabajo de Fin de Grado es caracterizar el EEG registrado mediante electrodos secos, húmedos y con gel con el fin de comparar y analizar la eficacia de estos tipos de electrodos para la implementación en sistemas

BCI basados en potenciales P300. Para alcanzar el objetivo general, se plantean los siguientes objetivos específicos:

1. Realizar la adquisición de señales EEG utilizando el protocolo desarrollado para las condiciones en estudio
2. Evaluar las características de la señal EEG basal, así como la precisión del sistema BCI basado en potenciales evocados P300 en las tres condiciones de registro.
3. Discusión de resultados y extracción de conclusiones de los registros basales y ERPs bajo las tres condiciones en estudio.

## 1.4. Estructura del Trabajo Fin de Grado

El presente trabajo está estructurado en diferentes apartados que constituyen el desglose del proyecto, partiendo desde la introducción donde se da apertura al contenido teórico del proyecto, explicando las bases que sirvieron de soporte para la metodología implementada que dio paso a la adquisición de los resultados y, por consiguiente, al análisis y discusión del rendimiento de los electrodos para su implementación en sistemas BCI.

En el primer capítulo, se describen los sistemas BCI desde el punto de partida en el CNS pasando por la señal biomédica designada para estos sistemas, explicando cómo a partir de las características del EEG es posible extraer patrones que se traduzcan en intenciones del usuario para finalmente terminar en comandos que sirvan para el control de una máquina.

En el segundo capítulo, se profundiza en el tipo de sistema BCI que se trabaja en el proyecto que ha sido introducido previamente en el primer capítulo. Seguido de esto, se detalla el procesado para obtener potenciales evocados P300 que sirven para diferentes aplicaciones, las cuales se exponen en este mismo apartado. Asimismo, se resume el estado del arte de los electrodos que se estudian dentro de las aplicaciones de BCI basados en ERPs P300.

En el tercer capítulo, se especifica la metodología empleada para la adquisición de datos a partir del protocolo experimental. Adicionalmente, se expresan los métodos para procesado y caracterización de la señal, para la posterior clasificación e implementación del modelo utilizado para la evaluación de la precisión que se espera alcanzar bajo las tres condiciones de registro.

En el cuarto capítulo, se exponen todos los resultados obtenidos, empezando por el apartado de *resting*, pasando por la revisión general de la señal de EEG bajo las diferentes condiciones, así como la Densidad Espectral de Potencia (PSD), la distribución por bandas de potencia y la visualización de las bandas mediante mapas topográficos. Seguidamente, se muestran los resultados del apartado del *speller Row-Column Paradigm (RCP)*, donde se realiza la visualización del ERPs, se obtiene la caracterización y, por consiguiente, la evaluación de la precisión del modelo. Adicionalmente, se muestran los resultados de los cuestionarios de satisfacción realizados al final del protocolo.

En el quinto capítulo, se realiza la discusión de resultados de los tres apartados desglosados en el capítulo anterior, junto con las limitaciones y sugerencias para aumentar el desempeño de los electrodos en sistemas BCI.

En el sexto capítulo, se demarcan las conclusiones del trabajo y el trazo de líneas futuras.

## 2. Capítulo 2.

---

### Sistemas BCI basados en ERPs

En este capítulo, se exploran los sistemas BCI basados en potenciales evocados P300, detallando las características de las respuestas de los ERPs bajo estímulos según el paradigma *odd-ball*. Adicionalmente, se expone la revisión del estado del arte sobre el uso de diferentes electrodos empleados en sistemas BCI, mostrando las ventajas y desventajas de su implementación en estos sistemas.

#### 2.1. Introducción

Como se ha mencionado en apartados anteriores, los sistemas BCI son controlados por potenciales que resultan de la señal de EEG, los cuales dependen del estímulo al que se someta el usuario. Este proyecto está enfocado en el uso de sistemas BCI basados en potenciales evocados P300. Dichos sistemas aprovechan la amplitud de la onda más prominente que aparece sobre los siguientes 300 ms luego de la aparición de un estímulo. Como se ha mencionado en el capítulo anterior, el posicionamiento de los electrodos depende de la señal que se desea captar, en este caso, los potenciales P300 se pueden registrar sobre toda la región centro-parietal del cerebro con los electrodos, por ejemplo, Cz, Fz, Pz (Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019; J. Wolpaw and Wolpaw 2012b; Santamaria-Vazquez et al. 2019).

Estos potenciales vienen dados por el paradigma *odd-ball* que consiste en exponer un estímulo específico (*target*) en tiempos determinados al mismo tiempo que otros estímulos están actuando (*non-target*) (Pan et al. 2022; Santamaria-Vazquez et al. 2019).

#### 2.2. Potenciales evocados P300

Los potenciales evocados relacionados con eventos son respuestas que se producen como resultado de ejecutar tareas de atención a un estímulo entre distractores (Krusienski et al. 2008; J. R. Wolpaw et al. 2002; J. Wolpaw and Wolpaw 2012b). Estas respuestas tienen una tendencia de deflexiones positivas y negativas de voltaje, siendo la deflexión más pronunciada la que aparece en la señal después de aproximadamente 300 ms del estímulo. Este potencial, denominado P300, ha sido ampliamente utilizado para la implementación de sistemas BCI (Santamaria-Vazquez et al. 2019; Gutierrez-Martinez et al. 2021; Mendoza-Montoya, Antelis, and Delijorge 2022).

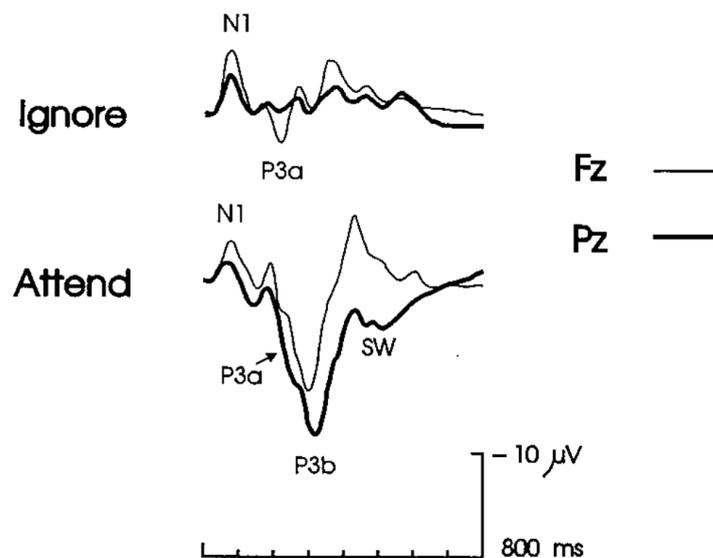
La aplicación que se encuentra con mayor frecuencia en dicho paradigma consiste en una matriz donde cada celda es un comando (letra, número, íconos, entre otros). Una secuencia corresponde a una iluminación por cada celda de la matriz que, aleatoriamente se va iluminando por filas y columnas hasta completar

el esquema de la matriz entera. Por ejemplo, al tener 10 secuencias, las filas y columnas de la matriz se habrán iluminado 10 veces (Krusienski et al. 2008; Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019; Santamaria-Vazquez et al. 2019; Martínez Cagigal 2020).

Se reconoce el comando seleccionado por el sujeto, una vez se detecte la respuesta (potencial) al estímulo por cada celda y se determine la curva P300 con mayor amplitud.

### 2.2.1. Características de los potenciales evocados P300

El cambio desde la actividad basal al aumento de la amplitud por los estímulos, varían de acuerdo con el electrodo que se esté observando, las características de la amplitud y latencia van a estar sujetas de un electrodo a otro ya que cada región cerebral está encargada de un proceso cognitivo diferente y puede que la adquisición de la onda en un electrodo tenga el componente de diferentes procesos (J. Wolpaw and Wolpaw 2012b).



**Figura 2–1.** Representación de los componentes de una onda P300 en dos estados en los canales Fz y Pz. (Superior) Respuesta ante un estímulo desatendido. (Inferior) Respuesta ante un estímulo atendido. Tomado de: T. W. Picton (1992).

El autor Terence W. Picton (1992) sostiene un análisis más detallado del potencial evocado P300 donde muestran que, dicha onda, es la resultante de ondas positivas superpuestas de diferentes regiones, como se puede observar en la figura 2–1 (Picton 1992). Empezando por P3a, que alcanza su máxima amplitud aproximadamente a los 250 ms en la zona frontal, seguido por la P3b, que expone su punto máximo sobre los 350 ms en la región parietal, para finalmente observar una onda lenta denotada como *Slow Wave* (SW) (Polich 2007; Picton 1992). Existe una dependencia de la atención respecto a cada una de estas ondas, donde P3a no se ve afectada por la atención del usuario frente al estímulo mientras que P3b aumenta su amplitud según la atención al estímulo. Estas características se pueden identificar mediante un análisis basado en PCA la técnica mencionada en el capítulo anterior

donde es posible dividir en pequeños conjuntos las características manteniendo los patrones de la señal.

### 2.2.2. Respuesta de los potenciales evocados P300

La respuesta de los ERPs es particular a cada usuario y depende de condiciones como la atención. Se ha demostrado que la amplitud de la onda P300 va relacionado directamente con dicha condición, así como su relación respecto a la probabilidad de ocurrencia del estímulo. Estudios sostienen que a medida que el tiempo interestímulo aumenta, mayor será la amplitud de la onda P300 (J. Wolpaw and Wolpaw 2012b; Mendoza-Montoya, Antelis, and Delijorge 2022; Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019).

Las características de los potenciales P300 varían de acuerdo con la dificultad de la tarea que deba realizar el usuario. En este sentido, existe una modificación en la amplitud y latencia de la onda P300 a medida que la confianza del individuo se ve afectada por una tarea difícil: la amplitud disminuye y la latencia aumenta (J. Wolpaw and Wolpaw 2012b).

El tiempo de reacción (RT), ocurre dentro de los primeros 50 ms después del P300, y se ve igualmente influenciada con la dificultad de las acciones en tareas complejas. En estos casos el RT es mayor, haciendo que la respectiva latencia aumente, caso contrario con tareas más fáciles donde la amplitud del P300 aumenta y seguido por el RT (Stelmack, Houlihan, and McGarry-Roberts 1993).

Individualmente, factores como la edad alteran la tendencia de la onda P300, en el rango entre 5 a 20 años, la presencia de componentes de ruidos y distracciones en la atención son condiciones que modifican el trazo del P300. Se ha demostrado que la latencia de la onda tiene dos fases con el paso de los años, la inicial, es cuando se reduce la latencia de la onda en los primeros años, manteniéndose una amplitud un poco mayor a la tendencia en adultos (pero con mayor latencia), seguido de esto, la siguiente fase, es donde ocurre un leve decrecimiento en la amplitud alcanzando el parecido en adultos y se va ampliando la latencia [ $1.3 \pm 31$ ] ms a partir de los 20 años (Polich, Ladish, and Burns 1990).

## 2.3. Preprocesado de los potenciales evocados P300

Adicionalmente a las herramientas mencionadas en el primer capítulo, métodos de filtrado espaciales se tienen en cuenta para el preprocesado de los potenciales relacionados a eventos gracias a que incrementan la relación señal-ruido. Al realizar un filtrado espacial, se busca disminuir el difuminado espacial provocado por la distancia entre los electrodos y el punto de origen de la señal en la corteza cerebral. Al ser una señal dada por un campo eléctrico, la fuente que genera la señal se encuentra dentro de un conjunto de tejidos no homogéneos que ocasionan este efecto difuminado sobre la señal EEG (Ma et al. 2017).

Para reducir este efecto, se plantean métodos Laplacianos, de referencia media común (CAR) y componentes independientes (ICA) (Ma et al. 2017; Blankertz et al. 2011).

a. *Filtro Laplaciano*

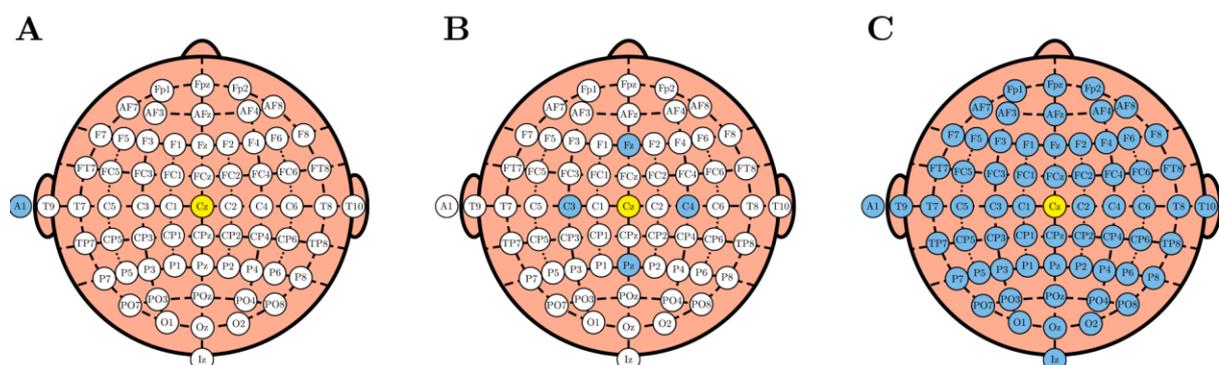
El filtro Laplaciano, es un método de filtrado espacial que consiste en enfatizar la actividad registrada dentro del radio de un electrodo. Esto se realiza a partir del cálculo (por cada electrodo) de la segunda derivada de la distribución de voltaje espacial. En otras palabras, se calcula la diferencia entre la señal EEG en un electrodo específico y la media de las señales EEG registradas de los electrodos circundantes (J. Wolpaw and Wolpaw 2012b).

Las características del filtro varían de acuerdo con la distancia entre el electrodo central y los electrodos adyacentes (Figura 2-2B); es decir, el filtrado será más sensible a los potenciales en la señal EEG a medida que la distancia se acorte y las frecuencias espaciales aumentan. Viéndolo desde otra perspectiva, el filtro Laplaciano, se comporta como un filtro paso alto que permite el paso de las altas frecuencias denotadas por la actividad más localizada sobre la corteza (Tsuchimoto et al. 2021; J. Wolpaw and Wolpaw 2012b).

b. *Método de referencia de media común (CAR)*

Respecto con el método anterior, el funcionamiento del CAR frente al método Laplaciano, varía en la diferencia de la media que, para este caso, se realiza la resta de la media común de todos los electrodos, en lugar de únicamente la resta de la media de los electrodos circundantes, como se ve en la figura 2-2 (J. Wolpaw and Wolpaw 2012b).

De esta forma, se reduce el componente de artefactos comunes de todos los electrodos. Sin embargo, los autores sostienen que, al aplicar un CAR, se está sujeto a un sesgo en los potenciales independientes. Esto debido a que puede contener algún grado de error debido a la referencia empleada, que viene viendo el promedio de todas las señales de todos los electrodos. No obstante, para sopesar dicho sesgo, a medida que aumente la densidad de electrodos, el error de aproximación se irá disminuyendo (Tsuchimoto et al. 2021; J. Wolpaw and Wolpaw 2012b).



**Figura 2-2.** Métodos de filtrado espacial para el electrodo Cz (amarillo) respecto a la media de los demás electrodos (azul). (a) *Ear Reference*. (b) *Laplaciano*. (c) *CAR*. Tomado de: J. Wolpaw and E. W. Wolpaw (2012).

### c. *Análisis de componentes independientes (ICA)*

La técnica de análisis ICA, tiene como objetivo exponer las características inmersas en la señal EEG que se encuentran camufladas por debajo del ruido basal. Como se ha mencionado en el primer capítulo, la señal EEG al ser el resultado de la superposición de varios potenciales en un campo eléctrico, requiere de la extracción de determinadas características que permitan controlar un sistema BCI (J. Wolpaw and Wolpaw 2012b).

Este método, descompone la señal en componentes estadísticamente independientes entre sí. Dado lo anterior, la aplicación de un ICA solventa el problema de la separación de fuentes, permitiendo conseguir señales independientes a partir de la resultante (EEG en bruto) (Wei, Ma, and Lu 2010).

## 2.4. Procesado de los potenciales evocados P300

Una vez realizada la primera etapa de preprocesado de la señal de EEG, ésta ya se encuentra en condiciones para analizar la presencia de los potenciales P300 inmersos en la señal.

### 2.4.1. Extracción de características de la señal EEG para P300

El proceso para la extracción de características se realiza junto con el procesado de la señal para remover los elementos que afectan a la señal y poder obtener una salida que servirá de entrada para la traducción de las características. Entre los métodos implementados para el procesado está el filtrado espacial, el filtrado temporal y análisis tiempo-frecuencia.

#### 2.4.1.1. *Análisis temporal*

Para los análisis en tiempo real, el análisis temporal en la etapa de extracción de características cobra importancia gracias a su rapidez y menor demanda computacional.

#### a. *Promediado sincronizado*

Este método es empleado para identificar los potenciales evocados P300 frente al ruido basal en la señal EEG. Se aplica sobre la señal realizando un promediado de las épocas distribuidas a lo largo de la señal, marcadas por una referencia temporal (estímulo).

Para el caso del *speller RCP*, es posible detectar la onda P300, realizando un promediado sincronizado de las filas y columnas que constituyen la matriz del paradigma (Santamaria-Vazquez et al. 2019; Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019; Martínez Cagigal 2020).

#### b. *Detección de picos y cálculo del área*

Esta técnica es el paso siguiente al método anterior, que busca identificar los ERPs cuantificando la amplitud y la latencia de la onda P300. Para conseguir dichas magnitudes, se calcula la diferencia desde el punto más negativo previo a la ventana temporal donde se desea detectar la onda, hasta el punto más alto dentro de la ventana temporal. Una vez conseguido el pico, se compara con una señal basal (J. Wolpaw and Wolpaw 2012b).

Por otro lado, el cálculo del área bajo la curva (señal promediada) es otra herramienta para la identificación de las ondas P300. Sencillamente, consta de sumar todos los puntos dentro de la ventana temporal, tanto de la señal basal como del ERPs, de tal forma que se pueda comparar, e identificar un cambio drástico en la magnitud de las áreas (J. Wolpaw and Wolpaw 2012b; Mendoza-Montoya, Antelis, and Delijorge 2022).

#### 2.4.1.2. *Filtrado espacial*

Como método para la extracción de características, se tiene en cuenta el filtrado espacial a partir del análisis de componentes principales (PCA).

##### - *Análisis de componentes principales (PCA)*

El PCA es un método que permite dividir la señal EEG para identificar y discriminar la información útil frente a la información redundante, para así reducir la dimensionalidad de la señal. Este método busca encontrar la varianza máxima entre los componentes, proyectando los datos en un espacio geométrico de N dimensiones que dependerá de la cantidad de fuentes en la señal (J. Wolpaw and Wolpaw 2012b; Ma et al. 2017; Di Flumeri et al. 2019a).

Este análisis funciona calculando una matriz de covarianza que permite medir la relación entre componentes de la señal. A partir de esta, es posible conseguir los respectivos *eigenvectors* y *eigenvalue*, que representan la dirección de la máxima varianza (significativa) en el espacio y la magnitud de varianza, respectivamente. Por consiguiente, se seleccionan los componentes principales que sería uno de los subconjuntos con mayor varianza (J. Wolpaw and Wolpaw 2012b; Ma et al. 2017; Ravipati et al. 2023; Lotte 2008; Hashmi et al. 2022).

De esta forma, se reduce la dimensionalidad de la señal sin perder información significativa, porque se descartan los *eigenvectors* con los respectivos *eigenvalue* de menor magnitud que corresponde a la información que no aporta a la clasificación para el control del sistema BCI (J. Wolpaw and Wolpaw 2012b; Hashmi et al. 2022).

#### 2.4.1.3. *Análisis tiempo-frecuencia*

A diferencia de los métodos anteriores, el análisis tiempo-frecuencia, aunque conlleva una transformación en la señal, es el indicado para estudios offline ya que permite analizar el espectro de frecuencia. Dentro de estas técnicas de análisis se

encuentran la transformada de Fourier y la transformada de wavelet (Morales and Bowers 2022).

*a. Transformada de Fourier de Tiempo Corto (STFT)*

La Transformada de Fourier de tiempo corto, es un método que segmenta una señal y calcula la transformada de Fourier (FT) en cada uno de los segmentos. De esta forma, es posible realizar un análisis de frecuencia a lo largo del tiempo. Esta técnica, varía de la técnica FFT original ya que ésta muestra la variación de frecuencia en la señal, más no indica los instantes donde aparecen estas frecuencias en el tiempo (Leonardo Duque-Muñoz, Espinosa-Oviedo, and Castellanos-Dominguez 2014; Di Flumeri et al. 2019b).

El proceso de aplicación de la STFT se puede establecer en 4 pasos: (1) Segmentación de la señal en pequeñas fracciones de tiempo. (2) Aplicación de una ventana (Hann o Hamming), esto se realiza con el objetivo de suavizar los extremos de la señal y disminuir alguna discontinuidad en los bordes de cada segmento. (3) Se aplica la FT, para obtener las frecuencias presentes dentro de las fracciones de tiempo. Luego de esta transformación, es posible cuantificar las frecuencias en el tiempo y poder interpretar las variaciones espectrales (Di Flumeri et al. 2019a; J. Wolpaw and Wolpaw 2012b).

La STFT puede contener sesgos en la resolución espacio-temporal a la hora de realizar la segmentación del tiempo (Leonardo Duque-Muñoz, Espinosa-Oviedo, and Castellanos-Dominguez 2014). Al elegir fracciones muy pequeñas, aunque se tiene información temporal, se pierde resolución de la frecuencia, y viceversa. Por ello, para la detección de eventos transitorios que se presentan de forma breve en la señal EEG, con la STFT se puede perder información al no tener forma de adaptarse a diferentes escalas de tiempo. Dado lo anterior, la transformada Wavelet aporta significativamente en casos donde se desea evaluar patrones en la señal EEG que la STFT no puede captar con precisión (Leonardo Duque-Muñoz, Espinosa-Oviedo, and Castellanos-Dominguez 2014; L. Duque-Muñoz, Pinzon-Morales, and Castellanos-Dominguez 2015a).

*b. Transformadas Wavelet (WT)*

Este método de análisis tiempo-frecuencia, a diferencia de la FT y STFT, transforma la señal en pequeñas ondas (*wavelets*) que se ubican a lo largo de dicha señal para analizar las variaciones en distintos instantes de tiempo. Este método involucra un escalado y una convolución para luego realizar un mapeo tiempo-frecuencia donde se obtienen coeficientes que denotan la variación de la frecuencia respecto al tiempo (Perseh and Sharafat 2012; L. Duque-Muñoz, Pinzon-Morales, and Castellanos-Dominguez 2015a).

La WT aporta una resolución adaptativa gracias a la descomposición de la señal en pequeñas ondas, esto permite tener una buena resolución tanto a altas como a bajas frecuencias (L. Duque-Muñoz, Pinzon-Morales, and Castellanos-Dominguez 2015a; J. Wolpaw and Wolpaw 2012b). Este análisis permite evaluar

cambios repentinos en la señal EEG. Para realizarlo, consta de 3 etapas: (1) Elección de la *wavelet* madre, se realiza teniendo en cuenta el tipo de señal que se está trabajando; es la señal de la cual van a derivar las *wavelets*. (2) Escalado, en esta etapa, la *wavelet* madre se transforma para adaptarse a la frecuencia en la señal. (3) Desplazamiento, así como se adapta a la frecuencia, la *wavelet* madre progresivamente avanza por la señal para analizarla a lo largo del tiempo (J. Wolpaw and Wolpaw 2012b; L. Duque-Muñoz, Pinzon-Morales, and Castellanos-Dominguez 2015b; Perseh and Sharafat 2012).

Existen variaciones de la WT para tiempo continuo (CWT) y tiempo discreto (DWT), su aplicación depende del objetivo del análisis a realizar. Para análisis de las características EEG, la CWT ha demostrado conseguir un análisis más detallado en el dominio tiempo-frecuencia (Bajaj 2021; J. Wolpaw and Wolpaw 2012b).

#### 2.4.2. Traducción de características de la señal EEG para ERPs

De acuerdo con algunos autores, se han realizado estudios que evalúan el rendimiento de algoritmos de clasificación para los potenciales evocados P300 como: (1) Máquinas de soporte vectorial, (2) Análisis discriminante lineal paso a paso, (3) Discriminante lineal de Fisher, (4) Análisis discriminante lineal regularizado y (5) Algoritmos de Deep Learning (J. Wolpaw and Wolpaw 2012b).

##### A. Máquinas de soporte vectorial (SVM)

Esta herramienta de clasificación busca maximizar la separación entre clases para generar una mayor generalización; lo realiza encontrando el hiperplano que mejor separa dos clases en un espacio de características (J. Wolpaw and Wolpaw 2012b).

Para lograr esta clasificación, la SVM tiene dos componentes. El primero es la medición de la distancia *Euclidiana* entre las observaciones y el hiperplano, es decir, se mide la distancia desde los puntos de cada clase respecto al hiperplano. El segundo componente es la distancia *Euclidiana* entre los márgenes, estos márgenes son la región más lejana al hiperplano; se busca maximizar esa distancia debido a que, un margen amplio implica una mejor separación de clases (Hashmi et al. 2022).

Por consiguiente, al tener estos dos componentes, se mantienen las características que aportan información alejadas del margen, ya que, las más cercanas al margen son aquellas que no aportan información (J. Wolpaw and Wolpaw 2012b; Hashmi et al. 2022; Ma et al. 2017).

##### B. Discriminante lineal de Fisher (FLD)

El clasificador FLD es un método lineal empleado en la traducción de características en una señal EEG, que tiene como objetivo simplificar la separación de dos clases mediante un hiperplano. La aplicación de este clasificador se realiza en los casos donde se encuentran clasificaciones con matrices de covarianza iguales y distribuciones gaussianas (J. Wolpaw and Wolpaw 2012b).

### C. Análisis discriminante lineal paso a paso (SW-LDA)

Este análisis es uno de los métodos de clasificación con mayor utilidad dentro del procesamiento de los potenciales evocados P300 (Blankertz et al. 2011; Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019).

Algunos autores argumentan que el LDA es un análisis basado en FLD con reducción del espacio de características tomadas para la clasificación. Esta técnica busca una combinación lineal para separar clases a partir del cálculo de estadísticas de segundo orden para obtener un vector de pesos. Esto trae consigo una dependencia a la covarianza que, por ende, dificulta su aplicación debido a la demanda computacional y tiempo, a la hora de obtener todos los datos para aplicar una buena clasificación (Krusienski et al. 2008).

Dado lo anterior, la técnica original LDA original se modificó para conseguir una estimación de la covarianza de las características, pero con una menor cantidad de datos y costos en tiempo y recursos (Dias et al. 2007).

### D. Análisis discriminante lineal regularizada (rLDA)

Al igual que el anterior método, esta técnica es ampliamente utilizada en la detección de los potenciales evocados P300 gracias al rendimiento y simplicidad en la aplicación. Gracias al rLDA se han conseguido resultados con alta precisión a la hora de realizar análisis *single-trial* y clasificación de los componentes ERPs (Martínez-Cagigal, Santamaría-Vázquez, and Hornero 2019; Santamaria-Vazquez et al. 2019).

El LDA clásico, disminuye el rendimiento en casos donde se tienen muchas características (alta dimensionalidad) y pocos datos que permitan al modelo aprender a clasificar. El problema con LDA ocurre al estimar la matriz de covarianza (donde se relacionan las características) respecto a los datos de provenientes de los patrones de un ERP, y ocurre el sobreajuste (Blankertz et al. 2011).

Como solución a la problemática anterior, se plantean los estimadores de reducción *shrinkage*. Consiste en emplear una matriz de identidad donde se supone que las variables son independientes entre sí (no hay correlación), junto con un parámetro (*shrinkage*) que controla cuánto se combina la matriz de covarianza real respecto a la identidad, de forma que pueda reducir la influencia de las variaciones sobre los datos. Este parámetro ajusta el modelo para que tenga en cuenta las fluctuaciones sin ajustarse demasiado a las estadísticas del conjunto de entrenamiento (Blankertz et al. 2011).

Esta regularización de la técnica LDA básica, aporta ventajas sobre el SWLDA (Blankertz et al. 2011). Creando así un método con buen rendimiento y baja complejidad que pueda ser comparado con otros modelos de clasificación más avanzados.

### E. Algoritmos de Deep Learning

Como método alternativo a las técnicas convencionales de clasificación, numerosos estudios han sustentado la implementación de algoritmos de Deep

Learning (DL) para clasificar características de los potenciales P300 (Santamaría-Vázquez et al. 2022; Ravipati et al. 2023). Dentro de las limitaciones de los métodos convencionales están los casos donde las clases no están correctamente divididas y se resumen en un mal rendimiento del método de clasificación, al no tener como identificar un hiperplano que permita separar las clases. Asimismo, métodos como el SVM, para grandes conjuntos de datos puede resultar difícil de implementar, ya que tiene una alta demanda en tiempo y costo computacional para el entrenamiento.

En este sentido, se abre la posibilidad de conseguir un mejor rendimiento en la clasificación con la integración de algoritmos de DL. Estos se basan en una arquitectura en cascada donde, están presentes múltiples capas que se encargan de extraer y transformar las características de un conjunto de datos (LeCun, Bengio, and Hinton 2015). Las capas iniciales van reconociendo características simples, hasta alcanzar las capas superiores donde aprenden a identificar patrones más complejos. A medida que incrementa el número de capas, las características de los datos son de mayor relevancia para clasificar. Gracias a lo anterior, este método solventa algunas de las limitaciones mencionadas respecto a la separación de clases y al manejo de grandes conjuntos de datos (LeCun, Bengio, and Hinton 2015; Ravipati et al. 2023).

#### 2.4.3. Aplicación del paradigma *odd-ball*

Las aplicaciones para estos potenciales P300 en su mayoría están basados en paradigmas *odd-ball*, como se ha mencionado, el uso de una matriz para selección de comandos abre la posibilidad de construir palabras para facilitar la comunicación para usuarios con discapacidades.

El paradigma *odd-ball*, tiene tres atributos principales según los autores Donchin & Coles (1988): (1) Se estimula a un usuario mediante una serie de eventos (estímulos) que están dentro de dos clases (*target*, *non-target*). (2) De estos eventos, uno tiene mayor frecuencia (distractor *non-target*) frente al otro evento (*target*) de la otra clase. (3) El usuario realiza una tarea donde debe clasificar cada evento entre las dos clases; y el potencial evocado P300 aparece en los eventos menos frecuentes.

La aplicación de este paradigma puede desarrollarse a través de estímulos tanto visuales como auditivos. Los estímulos pueden estar distribuidos a partir de un 80% de distractores frente a un 20% de los *targets*. A medida que cada uno de los estímulos aparece, un marcador en el registro de la señal es anotado para identificar el tipo de estímulo, *target* o distractor. A su vez, se le pregunta al usuario la cantidad de estímulos que puso visualizar. Cada estímulo se presenta alrededor de los 100 ms, y luego hay un espacio de 900 ms antes de presentar el siguiente estímulo que corresponde al intervalo inter-estímulo (ISI).

### 2.5. Aplicaciones de los sistemas BCI basados en P300

Los sistemas BCI basados en potenciales P300, van enfocados a apoyar a usuarios con deficiencias y/o trastornos neurológicos que se hayan presentado por

una patología, así como aquellas afecciones que requieran rehabilitación tales como, entrenamiento cognitivo o evaluaciones del rendimiento cognitivo.

Dentro de las aplicaciones de los sistemas BCI basados en ERPs, se encuentran: (1) Apoyo en la comunicación, (2) Rehabilitación, (3) Entretenimiento y (4) Monitorización de la atención (J. R. Wolpaw et al. 2002).

Como se ha mencionado en apartados anteriores, el apoyo en la comunicación a personas con condiciones severas es uno de los campos de aplicación de mayor peso los sistemas BCI (Chaudhary, Birbaumer, and Ramos-Murguialday 2016). Debido a la creciente implementación de estos sistemas en entornos clínicos, se ha despertado el interés de ampliar su aplicación fuera de los límites de laboratorios y hospitales, empleando dispositivos de bajo costo con softwares que permiten la interacción humano-computador con propósitos generales diferentes a los ya mencionados (Mendoza-Montoya, Antelis, and Delijorge 2022; Käthner et al. 2017; Sellers et al. 2009b).

A su vez, en el campo de la rehabilitación los sistemas BCI basados en P300, han apoyado en la recuperación de formas de lenguaje aportando un *feedback* a pacientes con afasia *post-ictus* (Kleih and Botrel 2024). Asimismo, se han presentado estudios de *neurofeedback* de apoyo a usuarios con déficit de atención e hiperactividad (ADHD) en sesiones donde empleaban videojuegos para el entrenamiento cognitivo (Orban et al. 2022; Saha et al. 2021).

Por otro lado, la monitorización de la atención en pacientes con esclerosis lateral amiotrófica (ELA), ha demostrado que es posible establecer los estados de atención que permitan un buen rendimiento en sistemas BCI basados en potenciales evocados P300. No obstante, el reto se encuentra más en mantener la atención, que establecerla en sí (Riccio et al. 2013; Arvaneh, Robertson, and Ward 2019). Asimismo, estas aplicaciones han traído consigo una búsqueda de formas para conseguir una comunicación de los sistemas BCI desde el laboratorio hasta los hogares de los usuarios con ELA (Riccio et al. 2013).

## 2.6. Revisión del estado del arte

En esta sección se expone la revisión realizada de las tres condiciones en estudio (electrodos secos, húmedos, gel) para la implementación en sistema BCI.

### 2.6.1. Rendimiento

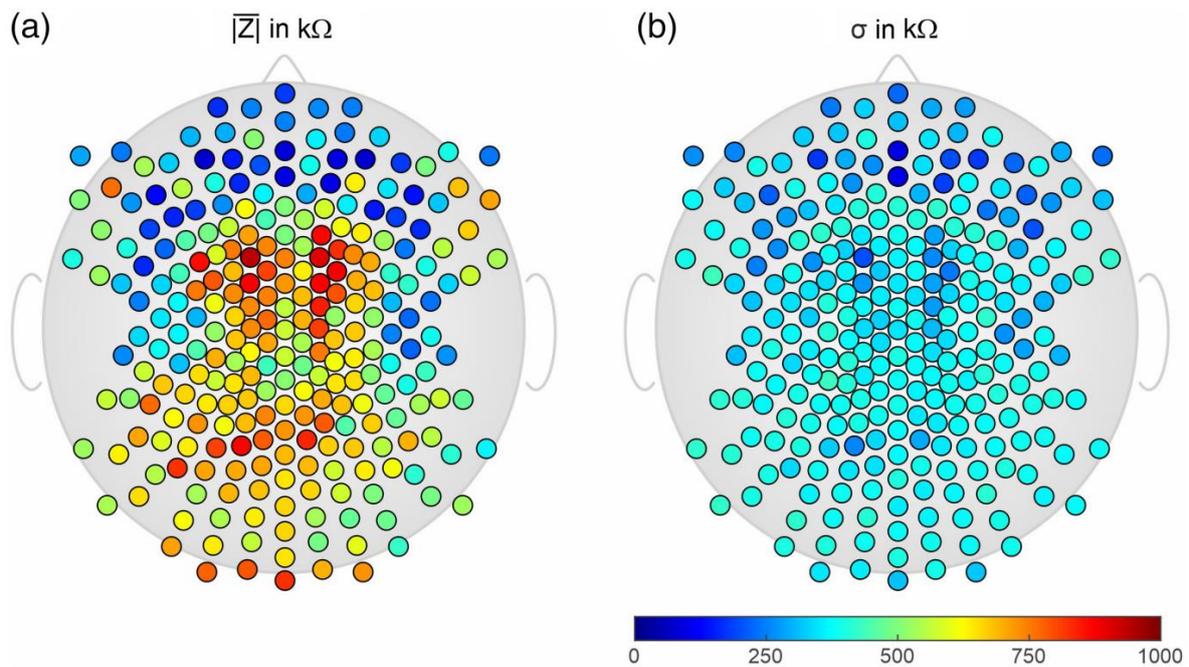
En este apartado se reúne toda la información recopilada respecto al rendimiento de un sistema BCI registrado con electrodos secos y electrodos húmedos. Donde se incluyen métricas como la precisión, la latencia y la estabilidad de la señal. Se evalúa la eficiencia de los electrodos en las diferentes condiciones para conocer la viabilidad de implementación de dichos electrodos en sistemas BCI (Yuan et al. 2021).

A su vez, se analizan estudios de impedancias de electrodos para EEG, en la figura 2–3, los autores Fiedler *et al* (2021) muestran una representación topográfica de las regiones donde se puede encontrar mayor impedancia, se visualizan tanto el

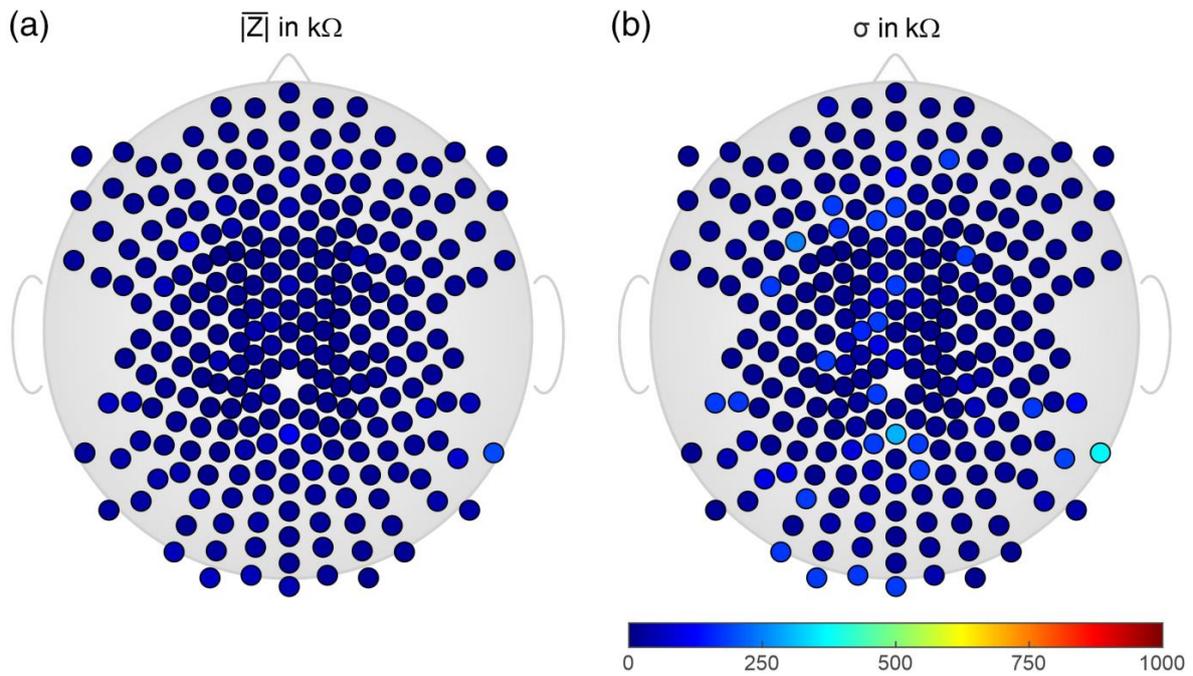
promedio como la desviación estándar del comportamiento de estos electrodos. Se puede determinar que la región frontal es la que tiene menor magnitud de impedancia dado que tiene la menor cantidad de cabello a comparación de la zona central y posterior. Las magnitudes de las impedancias en los electrodos secos aumentan cerca de los 1000 k $\Omega$  (Fiedler et al. 2014).

En contraposición en la figura 2–4, se visualiza la representación topográfica de la impedancia en los electrodos con gel, donde el rango de colores queda cercano a 0 k $\Omega$ , gracias a la presencia del líquido conductor que permite mejor conductividad.

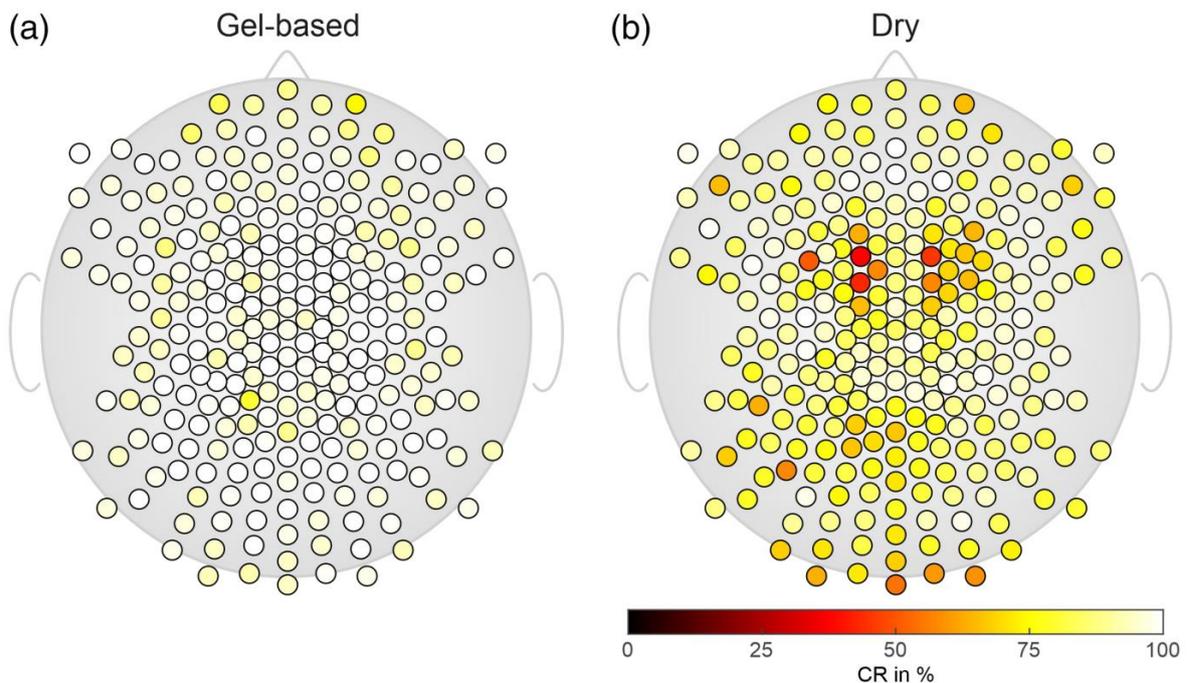
En la figura 2–5, se muestran los resultados de fiabilidad que han alcanzado los autores Fiedler .et .al (2021), donde encontraron el 84% de fiabilidad en electrodos secos frente a un 97% en electrodos con gel (Fiedler et al. 2014).



**Figura 2–3.** Distribución topográfica de un estudio de impedancias de los electrodos secos (promedio de todos los sujetos). (A) Promedio. (B) Desviación estándar. Tomado de: Fiedler .et .al (2021).



**Figura 2–4.** Distribución topográfica de un estudio de impedancias de los electrodos con gel (promedio de todos los sujetos). (A) Promedio. (B) Desviación estándar. Tomado de: Fiedler .et .al (2021).



**Figura 2–5.** Distribución topográfica de un estudio de fiabilidad de los electrodos (channel reliability, CR) con gel vs electrodos secos. Tomado de: Fiedler .et .al (2021).

### 2.6.2. Facilidad de uso

Determinar la practicidad en el uso de los electrodos secos vs gel para la adquisición de señal EEG en sistemas BCI, se rige en gran medida por el uso de un

material que aumente la conductividad y disminuye la impedancia entre electrodo y la corteza cerebral (J. Wolpaw and Wolpaw 2012b).

La tabla 2-1, resume la información adquirida por diferentes autores que han estudiado las condiciones de electrodos secos, húmedos y con gel para ser aplicados en sistemas BCI. Un factor como el tiempo de preparación, es crucial tenerlo en cuenta ya que se refiere al tiempo para acomodar el gorro con cada tipo de electrodo y prepararlo para su uso. Para aplicar los sistemas BCI en el día a día, se busca emplear métodos de adquisición rápidos que no requieran tanto tiempo ni personal especializado para colocarlo. Los electrodos secos, al no depender de ningún medio conductor para su funcionamiento, son la alternativa más rápida de implementar a comparación de los electrodos húmedos o con gel (Sellers et al. 2009a; Käthner et al. 2017).

Tipo de Electrodo	Tiempo de Preparación (min)	Colocación	Requiere gel/agua	Sensibilidad a artefactos	Proceso de limpieza	Ref.
Secos	1-2	Fácil	No	Alta	Baja	(Leach et al. 2020; Mathewson, Harrison, and Kizuk 2017; Fiedler et al. 2014; Shen et al. 2000; Guger et al. 2012; Samara et al. 2022; Kam et al. 2018; Hinrichs et al. 2020)
Húmedos	10	Moderado	Agua	Alta	Media	No reportado
Gel	8-10	Moderado	Gel	Baja	Alta	(Leach et al. 2020; Mathewson, Harrison, and Kizuk 2017; Fiedler et al. 2014; Shen et al. 2000; Guger et al. 2012; Samara et al. 2022; Kam et al. 2018; Hinrichs et al. 2020)

**Tabla 2-1.** Evaluación de la facilidad de uso de los diferentes electrodos para adquisición de señal EEG en estudios con sistemas BCI. Tomado de: Leach et al. 2020; Mathewson, Harrison, and Kizuk 2017; Fiedler et al. 2014; Shen et al. 2000; Guger et al. 2012; Samara et al. 2022; Kam et al. 2018; Hinrichs et al. 2020.

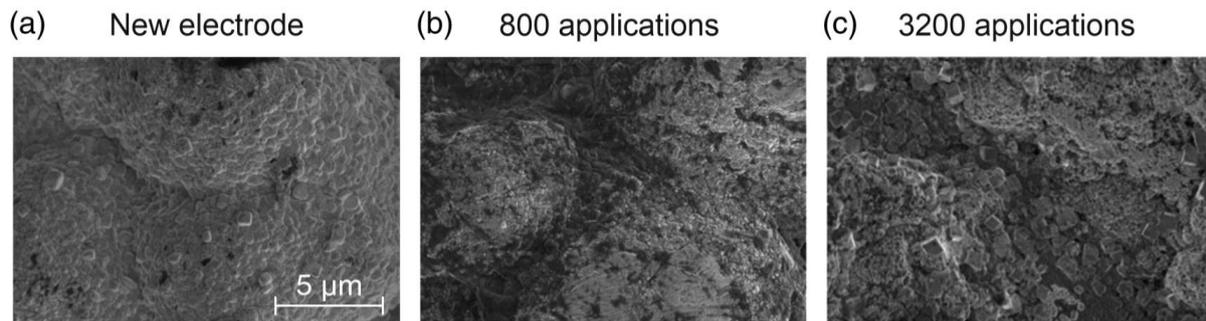
Otro parámetro importante a tener en cuenta es la sensibilidad a artefactos externos que interfieren en la facilidad de conexión y estabilidad del sistema. Los electrodos secos, al ser más susceptibles a ruido, se dificulta conseguir una calidad en la señal que se mantenga en el tiempo. Implementar este tipo de electrodos en ambientes no controlados aumenta la dificultad a la hora de controlar un sistema BCI (Käthner et al. 2017).

### 2.6.3. Aplicabilidad

También se analizaron las ventajas y desventajas de usar electrodos secos frente a los de gel en sistemas BCI tanto dentro como fuera del contexto de investigación y/o clínico. Concretamente, se han evaluado los potenciales usos de los electrodos secos para conseguir exportar los sistemas BCI fuera de entornos controlados que puedan abrir campo a otras áreas de implementación de sistemas BCI (tabla 2-2).

También, es necesario conocer la comodidad en cada condición para los usuarios. Parámetros como la comodidad del gorro en usos prolongados, la sensación en la piel y adaptabilidad al usuario, harán que se defina la aplicabilidad de estos sistemas. En la figura 2-6, se visualizan imágenes tomadas con un microscopio electrónico de barrido (SEM) de la piel bajo pruebas de desgaste por electrodos secos (Fiedler .et .al 2021). Se pueden observar las micro figuras que

pueden llegar a ocasionar los electrodos secos luego del uso continuo, empezando con la piel sin haber usado los electrodos hasta llegar a ver el deterioro en la piel luego de 3200 aplicaciones.



**Figura 2–6.** Imágenes de microscopio electrónico de barrido (SEM) de la piel bajo pruebas de desgaste por electrodos secos. (A) Piel sin aplicación de electrodos secos. (B) Piel (real) luego de 800 usos con electrodos secos. (C) Piel (artificial) luego de 3200 usos de los electrodos secos. Tomado de: Fiedler .et .al (2021).

Tipo de Electrodo	Entornos Clínicos	Aplicaciones en Ingeniería	Investigación Científica	Sensación en la Piel	Fatiga	Adaptabilidad	Comodidad	Ref
Secos	Baja	Media	Baja	Incómodo por dureza Cómodo porque no requiere gel	Baja	Alta	Alta	(Leach et al. 2020; Mathewson, Harrison, and Kizuk 2017; Fiedler et al. 2014; Shen et al. 2000; Guger et al. 2012; Samara et al. 2022; Kam et al. 2018; Hinrichs et al. 2020)
Húmedos	Media	Media	Media	Moderada	Media	Media	Media	No reportado
Gel	Alta	Baja	Alta	Incómodo porque requiere gel	Alta	Baja	Baja	(Leach et al. 2020; Mathewson, Harrison, and Kizuk 2017; Fiedler et al. 2014; Shen et al. 2000; Guger et al. 2012; Samara et al. 2022; Kam et al. 2018; Hinrichs et al. 2020)

**Tabla 2–2.** Evaluación de la aplicabilidad de los electrodos secos vs gel en sistemas BCI. Tomado de: Leach et al. 2020; Mathewson, Harrison, and Kizuk 2017; Fiedler et al. 2014; Shen et al. 2000; Guger et al. 2012; Samara et al. 2022; Kam et al. 2018; Hinrichs et al. 2020.

## 3. Capítulo 3.

---

# Metodología

En esta sección se describe la metodología implementada en el proyecto para la caracterización de los diferentes tipos de electrodos buscando el objetivo de ser implementados en sistemas BCI prácticos. Se exponen los pasos del protocolo que se requirieron para la adquisición de datos. Se detalla el preprocesado que permitirá obtener señales con menos artefactos. Se describe el procesado de la señal para poder conseguir las características que sirvan para evaluar la precisión del modelo rLDA.

### 3.1. Protocolo experimental

Para el protocolo experimental se establecen los parámetros de las tres condiciones en estudio, teniendo en cuenta los tiempos que requiere cada procedimiento como la colocación de los electrodos y la calibración del dispositivo hasta finalmente realizar el registro de EEG.

#### 3.1.1. Selección de participantes

Para llevar a cabo la adquisición, previamente se realizó una encuesta de participación a usuarios sanos que, luego de ser informados sobre el proyecto, dieron su consentimiento para su participación. En la tabla 3-1, se resume la información de cada usuario, en total participaron 8 hombres y 7 mujeres, sin patologías diagnosticadas, donde las edades rondaban desde 24 a 40 años, con una media de 26 años.

N° Sujeto	Edad (años)	Sexo (H/M)
1	24	H
2	31	H
3	21	M
4	22	M
5	30	H
6	34	H
7	21	M
8	28	H
9	24	M
10	24	M
11	40	H
12	29	H
13	21	M
14	23	M
15	24	H

Tabla 3-1. Información de cada sujeto participante en el estudio.

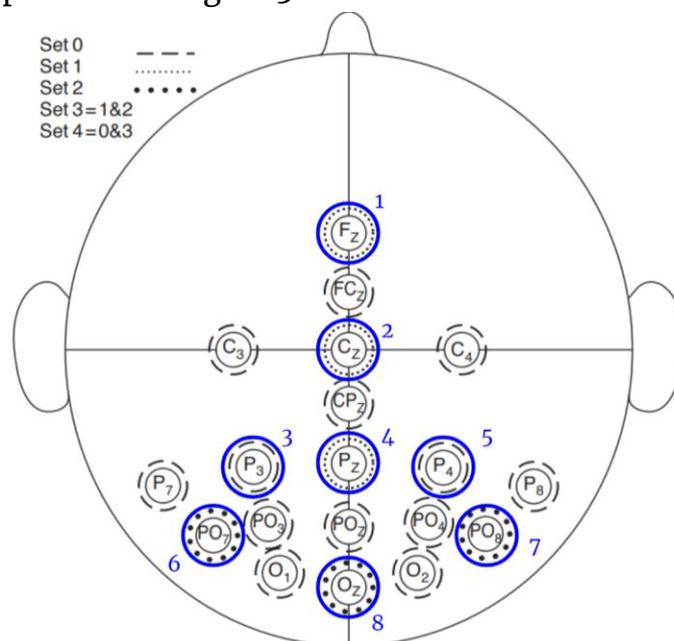


**Figura 3-1.** Protocolo experimental implementado para la adquisición de registros de EEG de la primera sesión. (A) Especificaciones por condición que se replican en las demás condiciones. (B) Protocolo general de una sesión completa para todas las sesiones.

## 3.2. Adquisición de datos

En este apartado se construye una base de datos de los registros de EEG por cada condición, sujeto y sesión. Se detalla la configuración del equipo empleado para la adquisición de la señal, se explican los parámetros de grabación y la duración de las sesiones.

Para la adquirir la señal de EEG, se toma el protocolo de electrodos habitual para ERPs en las posiciones Fz, Cz, Pz, P3, P4, PO7, Oz y PO8 (siguiendo la distribución del *SI 10-20*) (Acharya et al. 2016); como se ha mencionado en apartados anteriores, el posicionamiento de electrodos depende del potencial que se desea adquirir, para el caso de la onda P300 se conoce que su incurrencia más predominante es en la región parietal y occipital, es por ello que se sigue la distribución que aparece en la figura 3-2.



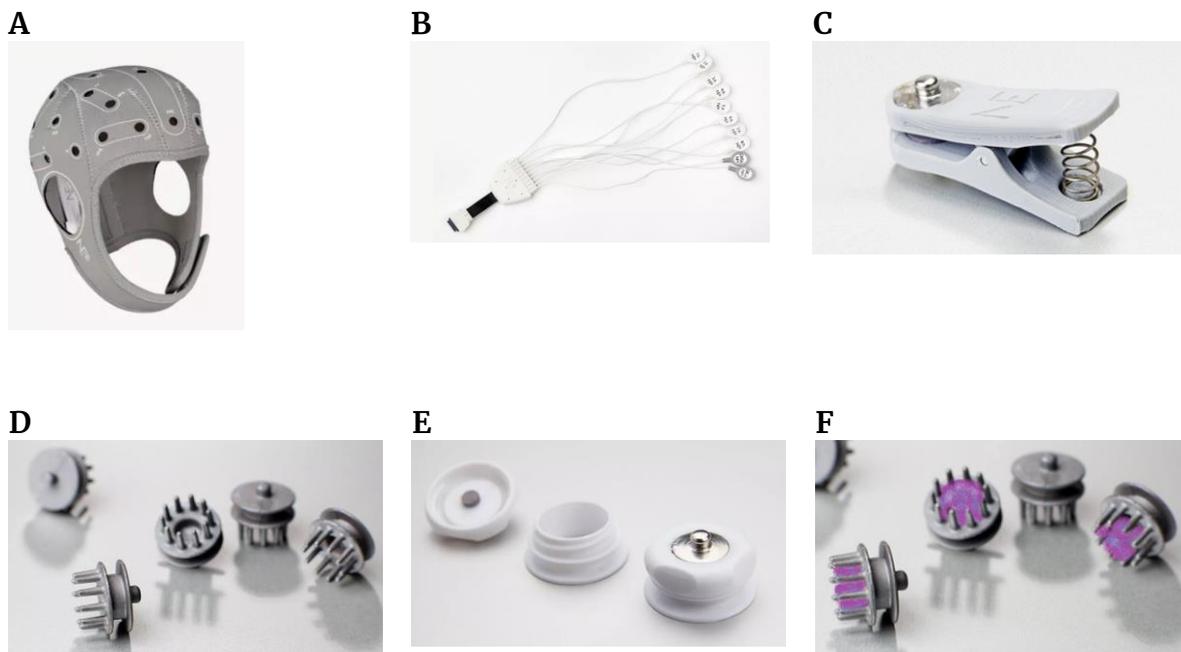
**Figura 3-2.** Distribución de electrodos para adquisición de ERPs, se aprecian diferentes configuraciones para la onda P300. (azules) Montaje de electrodos empleada en la adquisición. Tomado de: (J. Wolpaw and Wolpaw 2012b)

### 3.2.1. Configuración del equipo de adquisición

El equipo empleado para la adquisición corresponde al *Enobio 8* de la empresa *Neuroelectrics* (figura 3-3). Con una frecuencia de muestreo de 500 Hz. Este equipo consta de 8 canales que se colocan de acuerdo con el protocolo deseado (en este caso, para la adquisición de los ERPs) más 2 de referencia que se colocan en la oreja con la ayuda de una pinza. El equipo trae consigo dos tipos de electrodos, 8 electrodos para

gel y 8 electrodos secos. La implementación de electrodos ‘húmedos’ fue realizada en el laboratorio con la ayuda de una esponja y agua. El dispositivo al que van conectados los electrodos funciona de forma inalámbrica y por cable. Para garantizar una mayor estabilidad al sistema BCI se siguen las instrucciones del fabricante que recomienda usar el dispositivo cable para evitar interrupciones en la transmisión. Asimismo, el equipo de Neuroelectrics añade un gorro de neopreno capaz de ajustarse a la cabeza con la ayuda de un velcro.

La transmisión de los datos desde el dispositivo se realiza a través de una plataforma de monitorización en tiempo real llamada *NIC2*, que permite la visualización de la señal EEG filtrada (o sin filtrar), espectro del análisis tiempo–frecuencia, visualización de bandas de potencia, entre otras alternativas de monitorización de la actividad cerebral. A partir de esta plataforma, se realiza el enlace a Medusa Platform mediante protocolo *Lab-Streaming Layer* (LSL) (<https://labstreaminglayer.org/#/>), que permitirá la transmisión de datos de un software a otro en tiempo real.



**Figura 3–3.** Dispositivo de adquisición de señal de EEG, Enobio 8 de la empresa Neuroelectrics. (A) Gorro de Neopreno. (B) Cables de electrodo. (C) Pinza de electrodo de referencia dual. (D) Electrodo secos. (E) Electrodo de gel. (F) Electrodo secos modificados con esponja.

### 3.2.2. Parámetros de grabación

Dentro de los parámetros de la grabación, la distribución de los registros para una sesión por condición corresponde a: 1 registro basal (ojos cerrados), 2 registros para *train*, 3 registros para *test*.

### 3.2.2.1. Aplicaciones utilizadas

#### a. Recorder

Para obtener los registros basales de ojos cerrados, se utilizó la aplicación de REC del repositorio de Medusa<sup>©</sup> (Santamaría-Vázquez et al. 2023). Este ecosistema ha sido desarrollado con el objetivo de facilitar el uso de sistemas BCI; inmerso en este sistema se encuentra el apartado de Medusa<sup>©</sup> Platform y el paquete de librería MEDUSA<sup>©</sup> Kernel. Estas herramientas están basadas en lenguaje Python que permiten el procesamiento de señales de forma fácil e intuitiva.

Dentro de Medusa<sup>©</sup> Platform, se configuró la aplicación para que realizara la grabación del EEG durante 3 minutos (180 segundos). A partir de este software, es posible grabar a través de la aplicación y monitorizar el estado de la señal EEG a lo largo del registro. Tanto la aplicación REC como la aplicación empleada para el *speller RCP* se encuentran en el *app market* de la página web de MEDUSA<sup>©</sup> (<https://medusabci.com/market/rec/>).

#### b. Speller RCP

El paradigma por el que se rige este *speller*, fue implementado por Farwell & Donchin (1988). Consiste en una secuencia de iluminación de las filas y columnas de una matriz compuesta por comandos. El usuario al fijarse en un comando observa los destellos que aparecen en cada secuencia, produciéndose así el potencial evocado P300 en cada iluminación (Farwell and Donchin 1988). El sistema detecta el potencial, y determina el comando que desea seleccionar (*target*), basándose en las filas y columnas donde apareció dicho potencial.

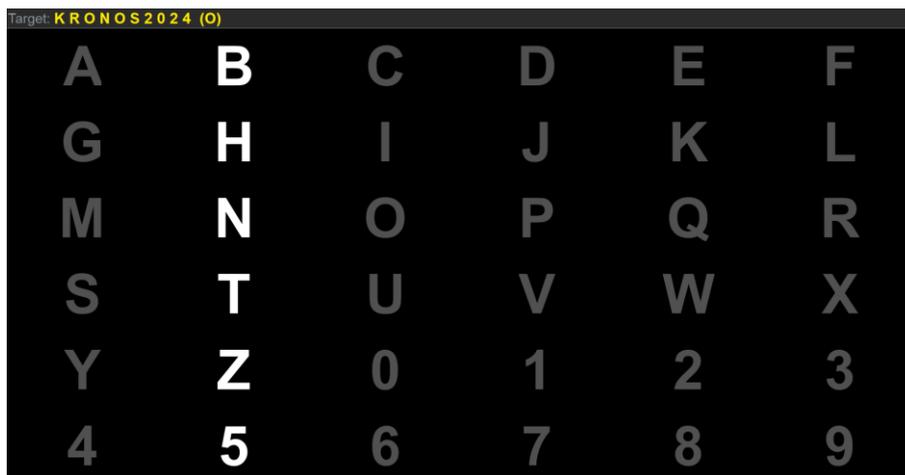
Los autores Santamaría-Vázquez *et al* (2019) incorporaron a este paradigma la detección de SSVEPs adicional a los P300. Sostuvieron la hipótesis de que los estímulos periféricos que se producían por los *non-target* en el paradigma RCP podrían producir SSVEPs débiles. Realizaron un análisis de la frecuencia de los SSVEPs para entender la variación en las características de estos respecto a la frecuencia de estimulación. Esto con el objetivo de identificar las frecuencias de estimulación más efectivas para obtener los SSVEPs. Asimismo, analizaron la independencia entre las dos señales de control. Gracias a esto, pudieron identificar estados controlados y no controlados, para saber cuándo aparecen los P300 y los SSVEPs. En el estado controlado, la atención del usuario radicaba en el *target* deseado y parece el potencial P300 con los SSVEPs débiles. Mientras que, en el estado no controlado, el usuario no tiene la atención al estímulo del comando a seleccionar (Santamaria-Vazquez et al. 2019).

Para la adquisición de los ERPs, se selecciona el *speller RCP* del repositorio de Medusa Platform desarrollado por los autores mencionados anteriormente (Santamaría-Vázquez et al. 2023) ([https://medusabci.com/market/rcp\\_speller/](https://medusabci.com/market/rcp_speller/)). El *speller RCP* tiene dos modos de registro, modo *train* y modo *test*. El modo *train*, corresponde al tipo de registro que se realiza para el entrenamiento con el *speller*, en este modo se indica al usuario los *targets* que debe intentar seleccionar. Se realiza el

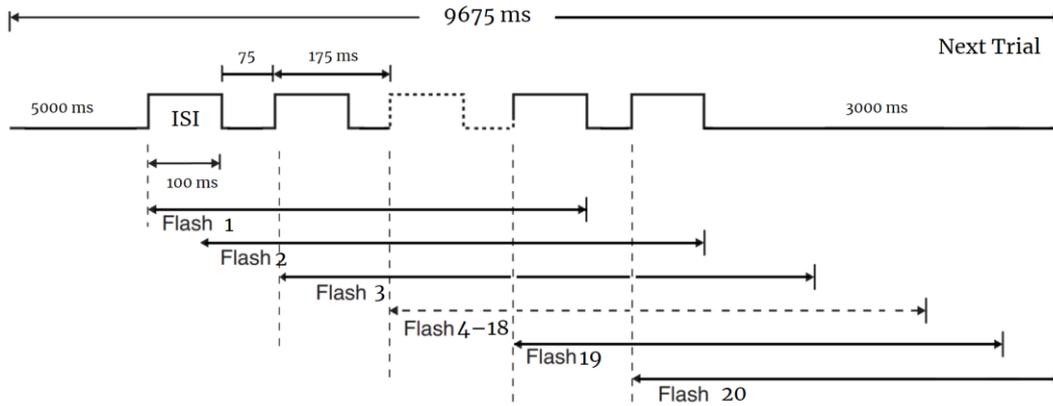
entrenamiento del modelo con los registros de *train*, para conseguir un modelo capaz de reconocer los patrones de selección de un *target*. Por otro lado, en el modo *test*, se carga el modelo y es el modo donde el usuario puede seleccionar los *targets* que desee, y se pone a prueba la precisión del modelo de acuerdo con la selección deseada. Normalmente, el modelo se pone a prueba en modo *test*, para evaluar la habilidad del usuario de seleccionar el comando. No obstante, es posible cargar en modelo en modo *train*, donde la aplicación le indica al usuario la letra que debe seleccionar nuevamente y, a su vez, dentro de los parámetros de registro se queda guardado tanto el comando que debería haber seleccionado como el comando que realmente ha seleccionado. Todos los registros de las pruebas con el *speller RPC* se realizaron en modo *train* con el objetivo de asegurar conocer las letras que se estaban seleccionando.

Dentro de cada registro (*Run*) estaban presentes 10 trials con las letras ['K', 'R', 'O', 'N', 'S', '2', '0', '2', '4'], por cada comando se decide tener 10 secuencias, donde una secuencia corresponde al número de destellos por columna y por fila, para tener finalmente 20 iluminaciones por comando. La frecuencia de muestreo de la señal corresponde a 500 Hz (número de muestras por segundo). La duración del intervalo inter-estímulo (ISI) es de 100 ms, mientras que el estímulo *target* es de 75 ms. En la figura 3-4, se puede observar la matriz 6x6 empleada en el *speller* así como los tiempos que transcurren en la secuencia de destellos por trial (letra).

A



B



**Figura 3-4.** (A) Matriz 6x6 presentada del *speller RCP* del sistema BCI empleado. (B) Duración de una secuencia desde el tiempo de inicio ( $t=0$  segundos) donde se tiene en cuenta el tiempo *pre-run* de 5000 ms. Se tiene en cuenta que la duración de un estímulo consta de la duración del ISI (100 ms) y el destello (75 ms). Al ser 10 secuencias con iluminaciones por fila y columna, se tienen en total 20 iluminaciones por trial. A su vez, al tener 10 trials, el tiempo inter-trial es de 3000 ms.

### 3.2.3. Duración de las sesiones

Las sesiones se construyeron con el objetivo de poder registrarse las tres condiciones en un mismo día. El registro R0, que corresponde a la condición basal con ojos cerrados duraba 3 minutos. A continuación, el tiempo de cada registro del R1 a R5 se calcula a partir de la ecuación 3-1, donde se expresan en minutos aproximadamente la duración de un registro por condición. El primer parámetro corresponde a los segundos de duración del destello de luz ( $Seg. Stimuli = 0.175 s$ ), seguido por el número de veces que aparece el destello ( $N. Stimuli = 10$ ), teniendo en cuenta que una secuencia corresponde a la iluminación por fila y columna, para finalmente, multiplicar por el número de trials escogido ( $N. Trials = 10$ ). Se suman 30 segundos a cada registro para tener un tiempo margen para preparación y finalización del *run*.

$$Time_{per\ run} = \frac{[(Seg_{stimuli}) * (N_{stimuli}) * (N_{seq}) * (N_{trials})] + 30}{60} \quad (3-1)$$

Teniendo en cuenta, los datos anteriores y, a su vez, siguiendo la expresión mencionada, en total, una sesión por sujeto con las tres condiciones estudiadas abarca aproximadamente 90 minutos. En el siguiente capítulo se muestran los tiempos reales requeridos en cada sesión por condición.

## 3.3. Preprocesado de la señal

Como se ha explicado en el capítulo 1, es necesario limpiar la señal con el objetivo de obtener los potenciales P300 que sirvan para ser clasificados. Existe una solución parcial ante la presencia de componentes ruidosos: eliminar épocas que superen un determinado umbral puede ser una solución que sirve para reducir los

artefactos externos, pero que, al mismo, estaría ocasionando la pérdida de datos de un registro.

En este apartado se resume la etapa de preprocesado de la señal de EEG de todos los registros adquiridos para todas las condiciones. En este preprocesado se busca eliminar toda interferencia que afecte directamente la precisión de los resultados en el análisis posterior. Se detalla el preprocesado para los registros basales separados de los registros del *speller RCP*, debido a que no se utilizó exactamente la misma configuración.

### 3.3.1. Preprocesado para los registros basales

En primer lugar, se realiza el preprocesado de la señal basal partiendo con un filtro FIR pasobandas de orden 2000 en el rango [1, 30] Hz para eliminar las frecuencias altas (corriente eléctrica 50 Hz) y poder obtener, las frecuencias relevantes que se desean estudiar en la señal de EEG como las bandas de potencia (delta, theta, alfa, beta). El orden del filtro se estableció en 2000 porque, aunque trae consigo un alto coste computacional, permite aumentar la calidad del filtro, un factor especialmente importante con los electrodos secos. Para suavizar las transiciones en los extremos del filtro se aplica la ventana Hamming con el objetivo de reducir ondulaciones que afectan la señal en los puntos donde están presentes los cortes de entre las frecuencias que pasan y que se rechazan (Gonçales et al. 2021).

En segundo lugar, se aplica un filtro espacial *CAR*, para reducir el ruido entre todos los electrodos. Como se comentó en el capítulo anterior, esto se realiza calculando el promedio de la señal de todos los electrodos para luego ser restada a cada uno de ellos de forma individual.

### 3.3.2. Preprocesado para los registros P300

Para el caso de los registros del *speller RCP*, se realiza el mismo preprocesado aplicado para los registros basales en reposo, pero aplicando también una normalización *Z-Score* utilizando una ventana *baseline* de 100 ms previa a cada estímulo, para homogenizar las señales entre registros y sujetos, así como para poder marcar un espacio en reposo antes del inicio de la actividad cognitiva que se le indica al usuario.

## 3.4. Procesado de la señal EEG de registros basales

En esta etapa, los registros preprocesados son divididos en épocas de 10 segundos. Posteriormente, se aplican técnicas de extracción de características que reduzcan los artefactos y sirvan para obtener la información buscada en la señal EEG.

Posteriormente a la segmentación por épocas, al conjunto de datos resultante [épocas x muestras x canales] se le aplica una función para transformar la señal al dominio de la frecuencia. Concretamente, la función de Medusa Kernel utilizada para calcular la densidad espectral de potencia (PSD) emplea internamente el método de *Welch* para realizar la estimación. Dentro de los parámetros de esta función está: el

porcentaje de segmentación del 60%, que corresponde al tamaño de los segmentos en los que se va a dividir la señal; el porcentaje de solapamiento de 25% entre segmentos; y la ventana *boxcar* buscando reducir el *spectral leakage* analizando la señal en pequeñas partes. Se realiza la normalización de la PSD, para comparar los picos de potencia que puedan estar presentes a una misma escala.

Se realiza una comparación entre los electrodos en estudio para visualizar las variaciones tanto de forma individual por sujeto como la tendencia general. Para ello se realiza un promedio de la PSD de todos los sujetos donde se observará la respuesta en el dominio de la frecuencia de estos electrodos.

### 3.5. Caracterización de los registros basales

Para analizar los registros basales una vez ya procesados, se extrae información a partir de la PSD como las bandas de potencia absoluta y la frecuencia mediana, y del conjunto de datos de las épocas, la complejidad de Lempel Ziv (Borowska and Syczewska 2021; Lempel and Ziv 1976).

En primer lugar, se realiza el cálculo de la potencia absoluta de las diferentes bandas de potencias que se desean analizar (delta, theta, alpha, beta) dentro de los rangos ya establecidos en el primer capítulo. Los parámetros dentro de la función `medusa.local_activation.spectral_parameters.absolute_band_power()` son la PSD con el conjunto de datos, la *fs*, y la banda que se desea. Esto se realiza para todo el conjunto de datos para obtener el cálculo para todos los sujetos y así, poder conseguir también para la tendencia general de los electrodos para cada una de las bandas, permitiendo obtener información del estado cognitivo que se está evaluando (en reposo).

Posteriormente, se realiza el cálculo de la frecuencia mediana, por sujeto y por tipo de electrodo y se representan en *boxplots*. Esto se realiza para comparar la distribución de potencias en las 3 condiciones para tener otro factor de análisis espectral de la señal. Entre los factores de esta función está la PSD, la *fs*, y rango de frecuencias a analizar de 1 a 30 Hz. Para analizar las diferencias entre electrodos, se realiza el Test de Wilcoxon para analizar las diferencias estadísticamente significativas (*p-value* = 0.05), donde se toman los valores de la frecuencia mediana por canal y se comparan los resultados entre: secos vs gel, húmedos vs gel y secos vs húmedos.

A su vez, se realiza el análisis de la complejidad de *Lempel Ziv* (LZC) y se representan en *boxplots*, para evaluar la estructura de la señal de acuerdo con el estado cognitivo. El parámetro de entrada de esta función es el conjunto de datos de las épocas de la señal, que tiene información por épocas, muestras y canales, e inmerso en ellas está toda la información de los sujetos y las sesiones. Esto aporta información para denotar las diferencias en las estructuras de las señales de un estado de relajación frente a un estado de alerta, y al mismo tiempo, es posible denotar información sobre la calidad de la señal frente a diferentes electrodos. Para analizar dichas diferencias se aplica nuevamente, el Test de Wilcoxon para comparar

los resultados por tipo de electrodo entre: secos vs gel, húmedos vs gel y secos vs húmedos.

### 3.6. Procesado de los registros del *speller RCP*

Las etapas del procesado de los potenciales P300 fueron: (1) Caracterización de los ERPs, donde se aplicó un promediado sincronizado para obtener una tendencia general de todas las épocas de la señal EEG, y un análisis de amplitud y latencia de los picos inmersos en el ERP. (2) Clasificación de las características a partir del modelo rLDA.

Para empezar el procesado de los registros del *speller RCP*, nuevamente, como ocurre con los registros basales, se dividen los registros en épocas de 1 segundo, con la diferencia que la función cambia dado a que la señal se segmenta por épocas de eventos. Estas épocas son marcadas según los *onsets*, que denotan el inicio de los eventos que se desean analizar (iluminaciones de cada fila y columna del *speller RCP*).

Debido a la presencia de un gran componente de artefactos en los electrodos secos en muchos casos los canales se saturaron, ocasionando problemas en la normalización y cálculo en el promedio y la desviación estándar.

Seguido de esto, se busca realizar el rechazo de épocas ruidosas para reducir al mínimo la cantidad de artefactos en los análisis posteriores.

Se realiza la agrupación de las épocas de EEG según la etiqueta del evento al que corresponde, '0' si son épocas correspondientes a *non-target*, '1' si corresponde a las épocas *target*. A partir de esto, se realiza el cálculo del promedio de las etiquetas según el conjunto de datos, por sujeto y tipo de electrodo.

### 3.7. Caracterización de los registros del *speller RCP*

Una vez procesados los registros, se realiza la caracterización de los ERPs a partir de la señal de EEG. En este apartado se analizan parámetros como la amplitud, la latencia y la morfología de la onda P300.

Al realizar el promediado de los eventos, se distinguen 2 etiquetas, '*target*' y '*non-target*', cada uno de ellos tiene información de los canales, los usuarios y el tipo de electrodo empleado.

Para realizar la caracterización es necesario separar estos datos, y analizar de forma individual la tendencia de los ERPs por tipo electrodo y canal (haciendo un promedio de los sujetos para evaluar una respuesta general). Se realiza la detección de los picos, tanto máximos como mínimos, se aplica una función para hallar los índices de los picos a lo largo de la señal. Esto con el objetivo de hallar la deflexión positiva más predominante en la señal que denota el P300 luego del estímulo. Se aplica un valor absoluto para comparar las amplitudes tanto máximas (magnitudes positivas) como mínimas (magnitudes negativas) para hallar la mayor onda en la señal, ya que en algunos casos la polarización puede cambiar según la ubicación de los electrodos.

Para determinar la amplitud, se selecciona una ventana de tiempo (200 a 600 ms), se toma la mayor magnitud resultante del valor absoluto y se calcula la latencia de ese pico en el tiempo. A su vez, se realiza el cálculo del margen de error de cada una de estas mediciones para conocer la variabilidad y precisión en los registros.

Para visualizar los resultados, se presenta una gráfica con 8 subgráficas inmersas en ellas que representan los canales con la onda P300. Asimismo, se construye una gráfica donde se plasman 4 tiempos (50 ms, 180 ms, 320 ms, 580 ms) a lo largo de un ERPs, donde se observan los canales y las representaciones topográficas de la actividad cerebral.

### 3.8. Implementación de modelo rLDA

En esta sección, se busca describir el proceso del modelo de aprendizaje supervisado implementado para la clasificación de las intenciones de los usuarios. Una vez cargado el conjunto de datos de los registros por condición, se realiza la extracción de características procedentes de la señal EEG.

#### a. Extracción de características

Se aplica la función `erp_spellers.StandardFeatureExtraction()` que instancia una clase incluida en la biblioteca de Medusa © Kernel diseñada para extraer características de los ERPs procedente del *Speller RCP* según la metodología explicada anteriormente. Seguido de esto, se aplica `feat_extractor.transform_dataset()` al conjunto de datos en modo *train*. Esta función retorna dos parámetros. El primero, contiene el conjunto de datos del ERPs, mientras que, el segundo, contiene información adicional sobre las características como el número de run, las épocas, así como la información de las etiquetas, *target (1)* y *non-target (2)*. Este paso de extracción transforma los datos de los registros del *Speller RCP* a un formato que sea posible ser entrenado con el modelo.

#### b. Entrenamiento del modelo

Una vez extraídas las características y probado la decodificación de comando, es el momento donde se requiere entrenar el modelo de Machine Learning, específicamente rLDA. Para ello, se instancia el modelo `CMDModelRLDA`, diseñado para decodificar comandos para ERPs. Se realiza la configuración del modelo según los parámetros, (1) filtro pasa-banda de 1 a 30 Hz, (2) la longitud de la época para la extracción de características (0 a 1000 ms luego del estímulo), (3) submuestreo de la señal de las épocas a 20 Hz. Finalmente, se construye el modelo a partir de la configuración dada con `cmd_model.build()` (Pawan and Dhiman 2023; Zander et al. 2011; Guger et al. 2012; Santamaria-Vazquez et al. 2020; Blankertz et al. 2011).

Seguido de lo anterior, se entrena el modelo con los datos de entrenamiento, que en este caso la configuración de los datos permaneció en modo *train*. En este apartado es donde el modelo aprende a reconocer patrones que están asociadas a las intenciones de los usuarios.

### c. Evaluación del modelo

En este apartado, se realiza la evaluación del modelo para analizar la precisión en la selección de los comandos, se aplica la función `cmd_model.predict_dataset()`, aunque los datos están dentro de un diccionario como 'test', este conjunto de datos en realidad se registró en modo train para conocer los *target* que se buscaban seleccionar y así evaluar la precisión del modelo. En este apartado es donde se realizan las predicciones de las características y se analiza qué tan preciso fueron las selecciones de los comandos.

### d. Decodificación de comandos

En esta parte, se realiza una simulación del entrenamiento del modelo recibiendo como entrada la información extraída del segundo parámetro de las características extraídas. Se realiza un promedio por fila y columna de los *scores* que el rLDA asigna a cada época, que representan la probabilidad de contener un ERP. Seguido de esto, se selecciona el comando que corresponde a la fila y columna con mayor *score*. Para conseguirlo, se aplica `erp_spellers.decode_commands()`, y retorna 3 parámetros.

El primero, contiene los comandos seleccionados para cada prueba considerando todas las secuencias. Los comandos están estructurados en una matriz [`matrix_idx`, `command_id`]. Por consiguiente, se retorna un parámetro de con dimensión [`n_runs` x `n_trials` x `n_levels` x 2].

El segundo, contiene los comandos de cada secuencia, para calcular el comando, se tiene en cuenta los *scores* de todas las secuencias anteriores. Retorna dimensiones de [`n_runs` x `n_trials` x `n_levels` x `n_sequences` x 2].

Finalmente, el tercero, contiene el *score* de la clasificación para cada comando que tiene dimensiones [`n_runs` x `n_trials` x `n_levels` x `n_sequences` x `n_commands` x 1].

## 3.9. Cuestionario de satisfacción

Al final del protocolo se aplica un cuestionario de satisfacción para todos los usuarios con el objetivo de conocer la experiencia y percepción de los electrodos utilizados y su implementación dentro de sistemas BCI. Se recopila la información para obtener un *feedback* de los resultados esperados frente a los que se obtuvieron.

El cuestionario se basó en la escala de likert (1: Totalmente en desacuerdo - 5: Totalmente de acuerdo) (Robinson 2023), teniendo en cuenta las siguientes preguntas:

- **Q1:** La duración de la sesión fue adecuada
- **Q2:** La concentración requerida fue difícil durante la sesión
- **Q3:** Experimenté fatiga visual durante la sesión
- **Q4:** La interfaz del *Speller RCP* fue amigable a la vista

- Q5: La selección de la letra deseada con electrodos secos fue efectiva
- Q6: La selección de la letra deseada con electrodos húmedos fue efectiva
- Q7: La selección de la letra deseada con electrodos de gel fue efectiva
- Q8: Sentí molestias durante la sesión
- Q9: La plataforma Medusa es intuitiva y fácil de usar
- Q10: El casco fue cómodo durante la sesión
- Q11: Los electrodos húmedos fueron cómodos durante la sesión
- Q12: Los electrodos secos fueron cómodos durante la sesión
- Q13: Los electrodos con gel fueron cómodos durante la sesión
- Q14: El electrodo de referencia fue cómodo durante la sesión

### 3.10. Cuaderno de laboratorio

Tanto el protocolo como los cuestionarios fueron elaborados en Excel para mayor facilidad en la organización de la toma de datos de los usuarios en las sesiones. En la figura 3–5, se visualiza el esquema de cuestionario de satisfacción que se empleó durante todas las sesiones de registro.

En la figura 3–6, se visualiza el esquema del protocolo de toda una sesión de registro. Se exponen los minutos destinados para cada acción a lo largo de una sesión completa de registro donde, los primeros 15 minutos corresponde al tiempo (estimado) para llevar a cabo toda la preparación previa a los registros; en la columna de especificaciones se denotan puntualmente las instrucciones de cada acción, seguido de esto, el apartado de *check list* era la sección que se iba rellenando paulatinamente mientras la sesión avanzaba, aclarando las condiciones de tiempo reales que se conseguían.



Figura 3–5. Cuestionarios aplicados luego de la sesión.

Min	INICIO	Especificaciones	CHECK LIST			
			T0	Observación	T7	Observación
		CRONÓMETRO	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
5	Posicionar electrodos	Protocolo para P300 FZ; CZ; PZ;OZ; P3;P4; PO7;PO8	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
5	Aplicar gel o agua (si aplica)		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
5	Colocar y calibrar Enobio	NIC2	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
		<b>SECOS</b>	<input checked="" type="checkbox"/>	47 min SÓLO calibrando	<input checked="" type="checkbox"/>	9 colocando 13 calibrando
3	Basal (3 O. Cerrados)	Run 0 REC APP in Medusa® Platform	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 1 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 2 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
2	Cargar modelo del sujeto y entrenarlo (2*)	RCP Speller App in Medusa® Platform	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 3 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 4 10 trial 10 seq	<input checked="" type="checkbox"/>	1h 24 min	<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 5 10 trial 10 seq	<input checked="" type="checkbox"/>	se repitieron algunos Run por error de concentración	<input checked="" type="checkbox"/>	1h04min
		<b>SEMIHUMEDOS</b>	<input checked="" type="checkbox"/>	No se obtuvo señal dentro de los primeros 20 min	<input checked="" type="checkbox"/>	3 min colocando 5 min calibrando
3	Basal (3 O. Cerrados)	Run 0 REC APP in Medusa® Platform	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 1 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 2 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
2	Cargar modelo del sujeto y entrenarlo (2*)	RCP Speller App in Medusa® Platform	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 3 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 4 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 5 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	59 min
		<b>GEL</b>	<input checked="" type="checkbox"/>	15 min colocar todo e iniciar (reiniciando Medusa)	<input checked="" type="checkbox"/>	9min
3	Basal (3 O. Cerrados)	Run 0 REC APP in Medusa® Platform	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 1 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 2 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
2	Cargar modelo del sujeto y entrenarlo (2*)	RCP Speller App in Medusa® Platform	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 3 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 4 10 trial 10 seq	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
4	Recording modo Train	Run 5 10 trial 10 seq	<input checked="" type="checkbox"/>	40 min	<input checked="" type="checkbox"/>	41 min
<b>90</b>	<b>Total min</b>	<b>FIN</b>	<b>TOTAL TRIAL</b>	<b>150</b>		

Figura 3–6. Esquema del protocolo de una sesión.

## 4. Capítulo 4.

---

# Resultados

En el presente capítulo, se muestran los resultados obtenidos a lo largo del trabajo. Se ha estructurado en tres grandes partes: (1) Resultados del análisis basal de la señal EEG, (2) Resultados del análisis de los ERPs, y (3) Resultados de la precisión de los electrodos para su implementación en sistemas BCI. Cada una de las partes abordan las respuestas de los ERPs y comportamiento de la señal EEG estudiada con los diferentes electrodos, para que en el siguiente capítulo analizar las características, rendimiento y precisión de cada una de las condiciones.

### 4.1. Resultados del análisis basal

En primer lugar, se exponen los resultados del análisis basal de la señal EEG bajo las condiciones en estudio donde se evalúa: (1) Señal EEG de todos los canales de un sujeto por cada electrodo, (2) PSD promediada y por sujeto, (3) Frecuencia mediana promedio (junto con los *P-value* del *Wilcoxon Test*) y Frecuencia mediana por sujeto y condición, (4) Complejidad de Lempel Ziv promediada (junto con los *P-value* del *Wilcoxon Test*) y Complejidad de Lempel Ziv por sujeto y condición, (5) Bandas de potencia promediadas para todos los sujetos por condición, y (6) Topografías de las bandas de potencia promediada.

#### a. Visualización del EEG

A continuación, se presenta la señal EEG de todos los canales en las tres condiciones de registro, empezando con los electrodos secos, luego electrodos húmedos y, por último, los electrodos de gel.

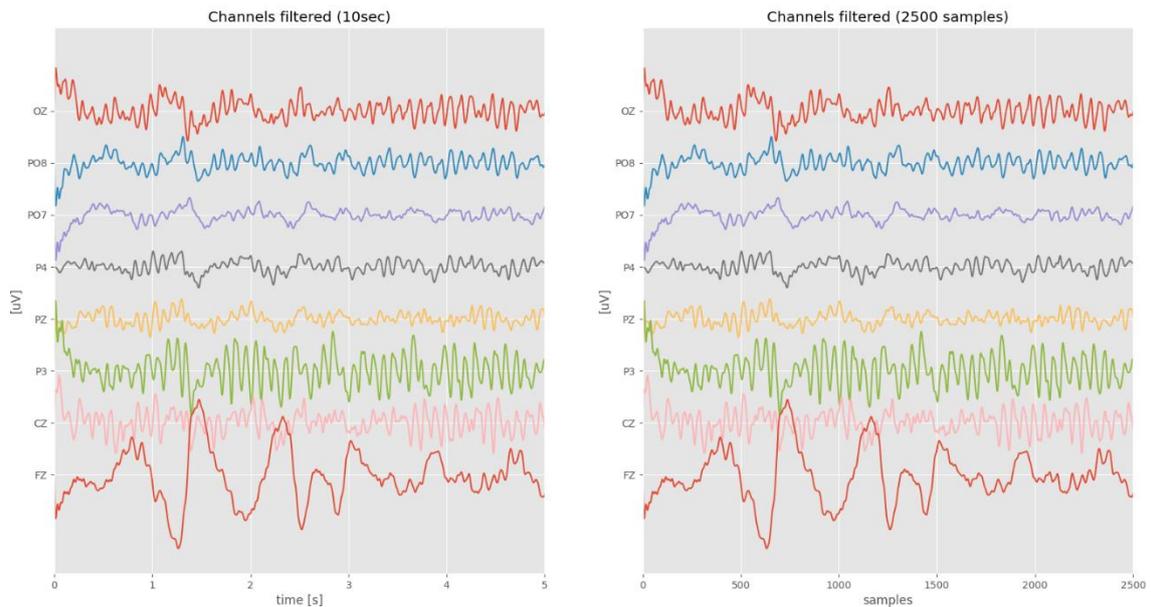
Los registros se realizaron en el orden: secos, húmedos y gel. Esto se debe a que se buscaba asegurar que tanto los electrodos como el cuero cabelludo no estuviese impregnado por un agente externo (agua o gel) diferente a las condiciones naturales de cada usuario.

Las siguientes figuras se representa una ventana de 5 segundos de los registros basales (ojos cerrados) del sujeto 7. En cada figura se visualizan los 8 canales del EEG, donde se pueden apreciar las diferencias entre electrodos. Para el caso de los electrodos secos, Fz se puede ver claramente las alteraciones que pueden aparecer a lo largo de las sesiones de adquisición.

Las amplitudes entre electrodos, aunque pueden ser comparables, no es igual para todos los usuarios. El registro del sujeto 7 fue elegido para demostrar la efectividad en las adquisiciones de señal EEG. No obstante, no es el caso para todos los sujetos en las condiciones de electrodos húmedos y secos, debido a que, en la

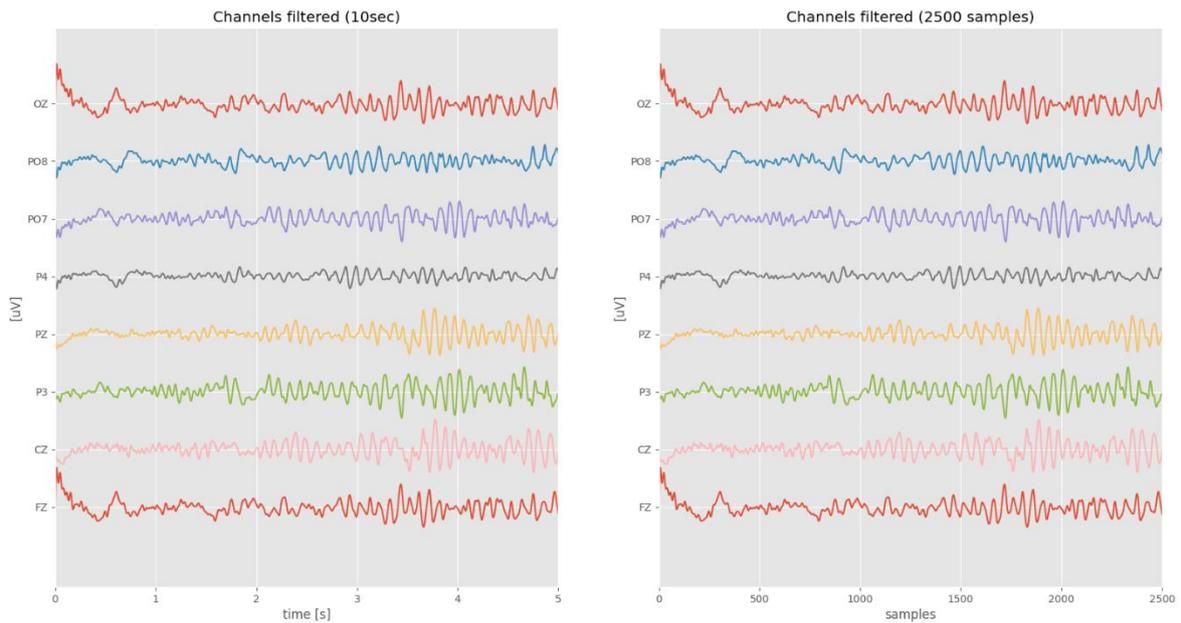
mayoría de los casos, las amplitudes se ven afectadas por la interferencia de artefactos, donde incluso los canales se veían saturados, o se desconectaban.

**Registro EEG 8 canales - Sujeto = 7 - Electrode Type = Secos**



**Figura 4–1.** Ejemplo de representación (5 segundos) de la señal EEG de todos los canales, para los electrodos secos del sujeto S07.

**Registro EEG 8 canales - Sujeto = 7 - Electrode Type = Humedos**



**Figura 4–2.** Ejemplo de representación (5 segundos) de la señal EEG de todos los canales, para los electrodos húmedos del sujeto S07.

### Registro EEG 8 canales - Sujeto = 7 - Electrode Type = Gel

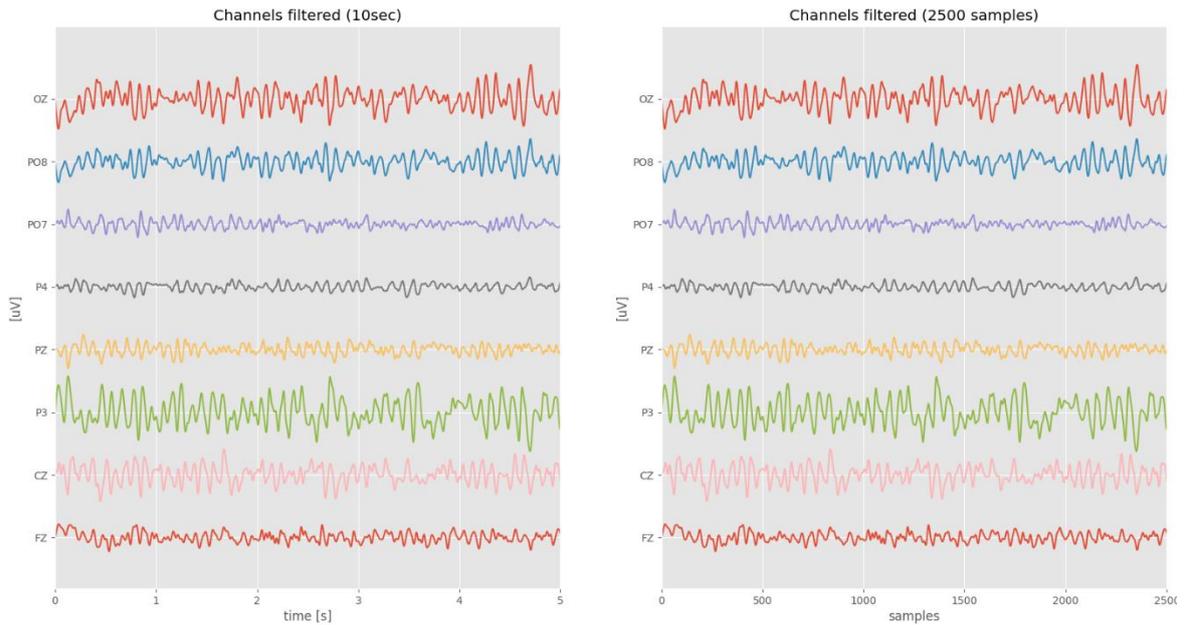


Figura 4–3. Ejemplo de representación (5 segundos) de la señal EEG de todos los canales, para los electrodos con gel del sujeto S07.

#### b. Visualización de la PSD

A continuación, se visualizan los resultados de la PDS general para todos los sujetos por tipo de electrodo, así como las representaciones individuales por sujeto y por tipo de electrodo.

Este estudio se realiza con el objetivo de realizar un análisis espectral que demuestre la condición que se evalúa (en reposo) así como la presencia de ruido que interfiere en la señal. Se evalúa tanto la tendencia general como el espectro de frecuencia de cada uno de los sujetos.

#### PSD promediada para todos los sujetos

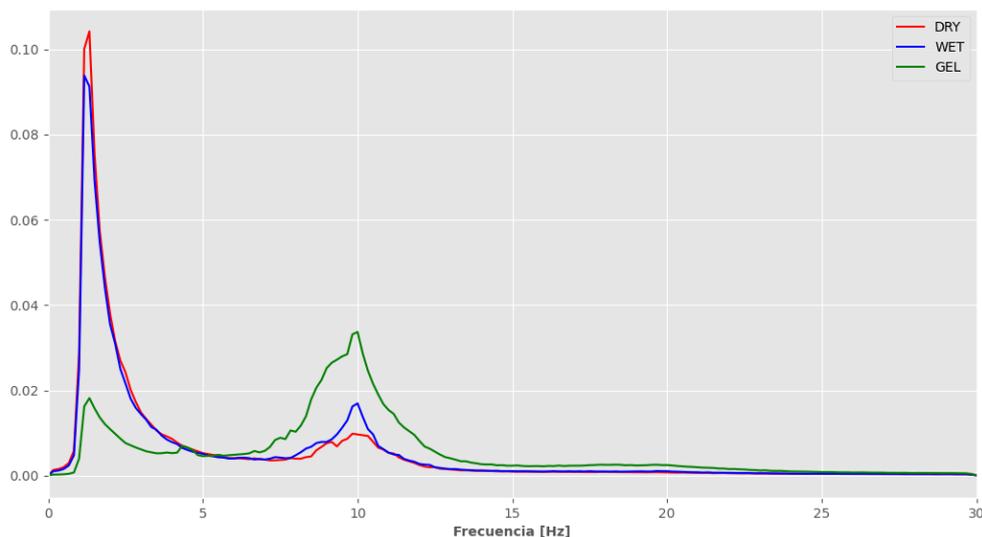
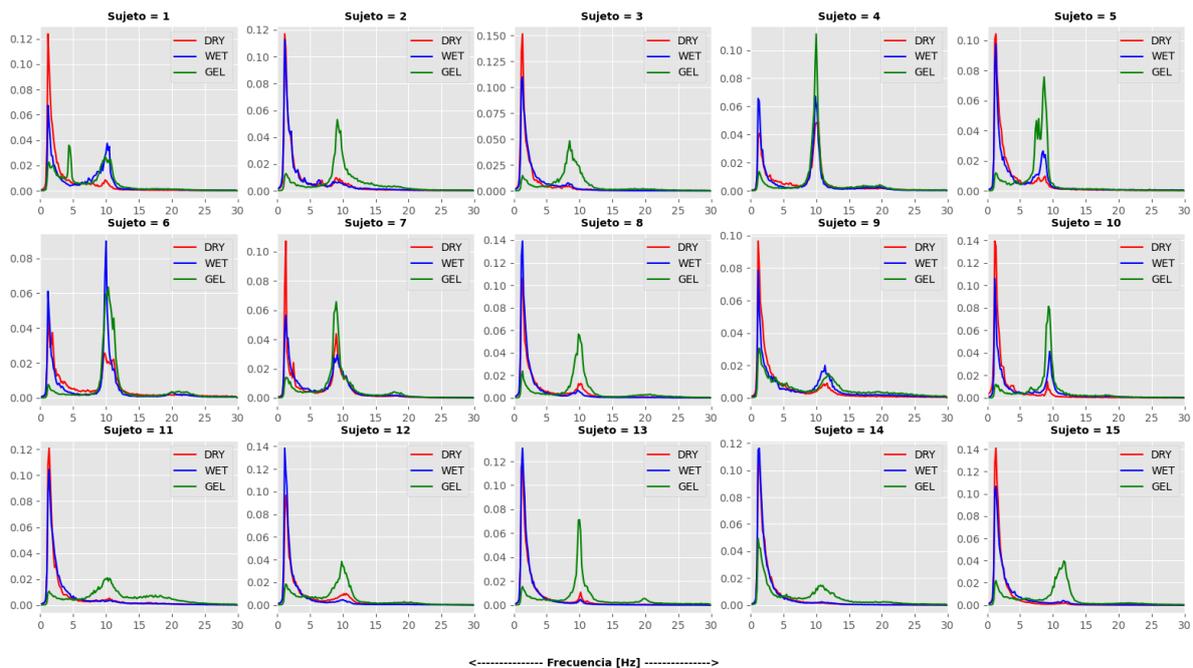


Figura 4–4. Representación de la PSD promediada para todos los sujetos y los canales para las tres condiciones. (verde) Electrodo de gel. (azul) Electrodo húmedo. (rojo) Electrodo seco.

En la figura 4-4, se observan dos picos de frecuencia en la PSD, en el rango de 0 a 5 Hz se observa con mayor amplitud la tendencia de los electrodos secos y húmedos que puede deberse al ruido inmerso en la señal. Por otro lado, los electrodos con gel tienen una mayor amplitud alrededor de 10 Hz, donde se esperaba observar el pico de frecuencia gracias a la onda alfa que se presenta con mayor predominancia en estado de reposo.

De igual manera, la tendencia por sujeto en la figura 4-5, para el caso de los electrodos en gel, en todos los usuarios el pico en alfa se ve presente. Mientras que, para los electrodos secos y húmedos, se pudo conseguir un pico alrededor de 10 Hz en 8 de 15 sujetos (S1, S4, S5, S6, S7, S8, S9, S10).

**PSD para cada sujeto y tipo de electrodo**



**Figura 4-5.** Representación de la PSD de todos los sujetos, todos los canales, para las tres condiciones. (verde) Electrodo de gel. (azul) Electrodo húmedo. (rojo) Electrodo seco.

### c. Frecuencia Mediana

De igual manera, se expresan los resultados de la frecuencia mediana calculados a partir de la PSD. Se denotan los resultados por sujeto y por tipo de electrodo; la frecuencia mediana promediada para todos los sujetos para todas las condiciones; y los *P-values* del *Wilcoxon Test* de la frecuencia mediana promediada de las tres condiciones.

Frecuencia mediana para cada sujeto y tipo de electrodo

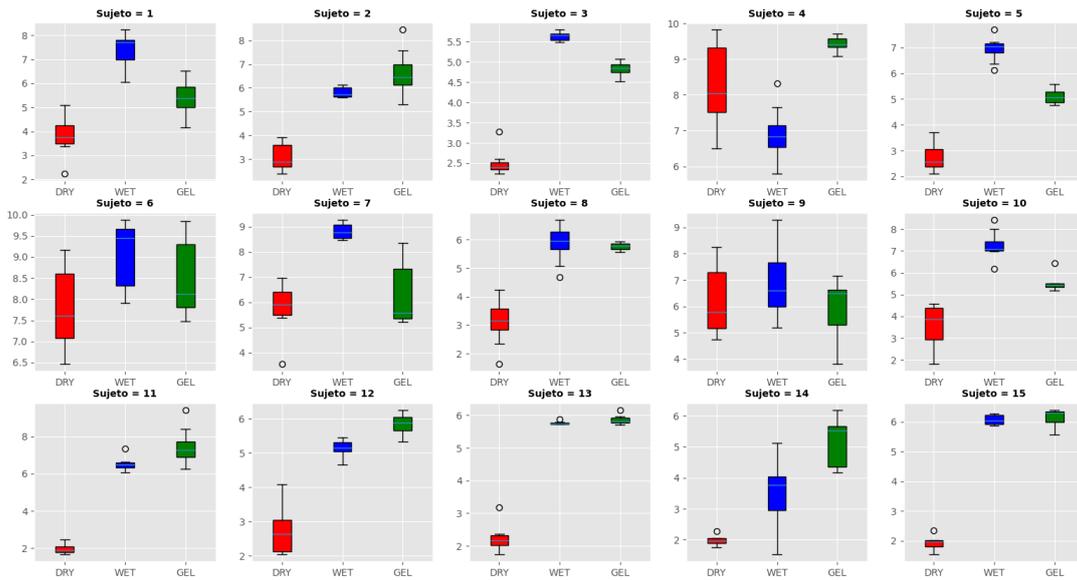
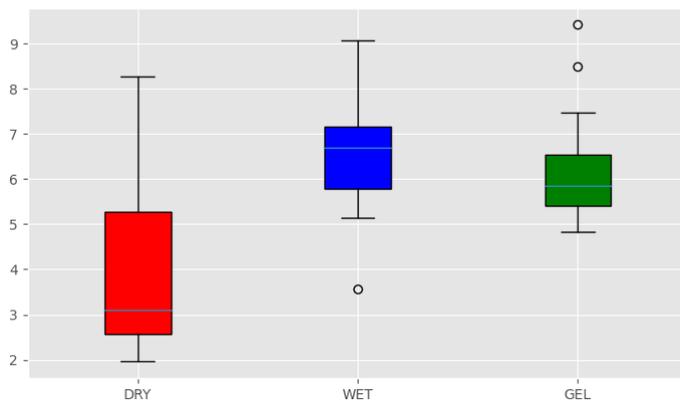


Figura 4-6. Representación por boxplot de la frecuencia mediana de todos los sujetos, todos los canales, para las tres condiciones. (verde) Electrodo de gel. (azul) Electrodo húmedo. (rojo) Electrodo seco.

Al evaluar la tendencia general de todos los sujetos, la frecuencia promediada de entre las condiciones muestran diferencias significativas según los resultados del test de Wilcoxon en la figura 4-7B. Asimismo, se ve un comportamiento parecido entre los electrodos húmedos y gel, teniendo en cuenta que los electrodos húmedos tienen gran componente de artefactos. Mientras que los electrodos secos se ven disminuidos por mayor presencia de ruido inmerso en el espectro de frecuencia.

A

Frecuencia mediana promediada



B

P-valores Wilcoxon Test para frecuencia mediana promediada

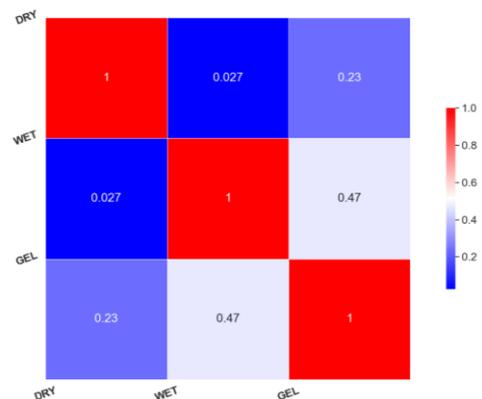


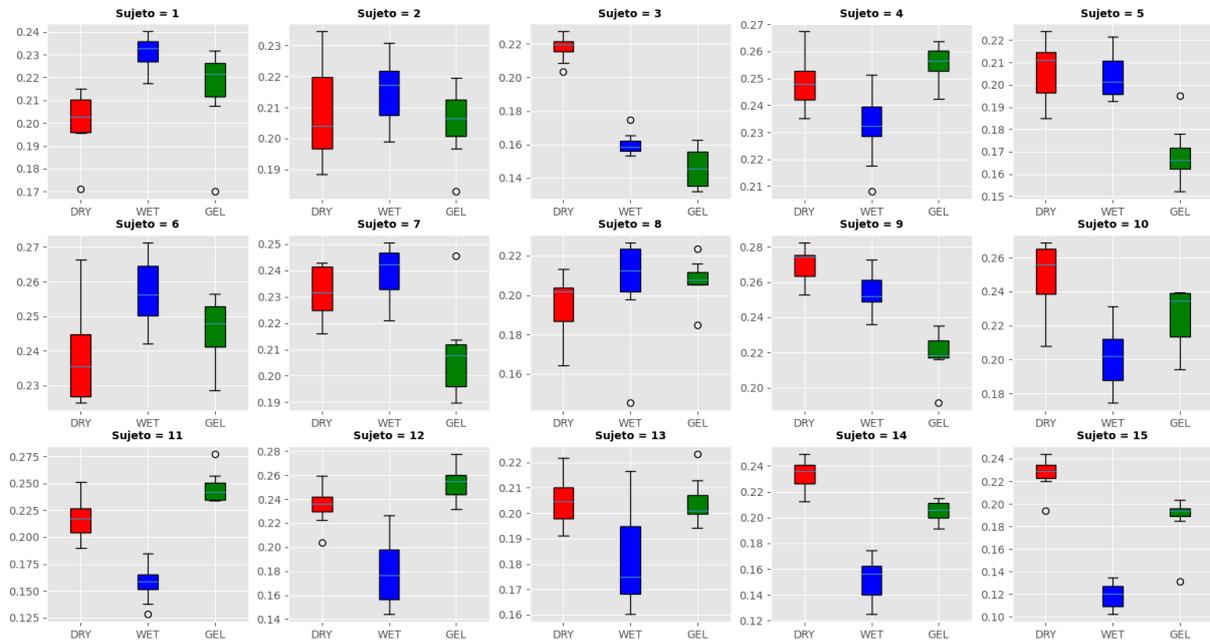
Figura 4-7. Representación por boxplot de la frecuencia mediana promediada (A) para las tres condiciones. (verde) Electrodo de gel. (azul) Electrodo húmedo. (rojo) Electrodo seco. Junto con los P-values del Wilcoxon Test (B).

d. Complejidad de Lempel Ziv

Asimismo, se muestran los resultados de la complejidad de Lempel Ziv, por sujeto - por tipo de electrodo; promediada para todos los sujetos; p-values del Wilcoxon Test de la complejidad de Lempel Ziv promediada.

La complejidad de *Lempel Ziv*, para electrodos secos y húmedos se espera que sea mayor debido a que tiene mayor presencia de artefactos inmersos en la señal haciendo que las variaciones de la onda resulten más complejas a comparación de los electrodos con gel.

**Complejidad de Lempel Ziv para cada sujeto y tipo de electrodo**

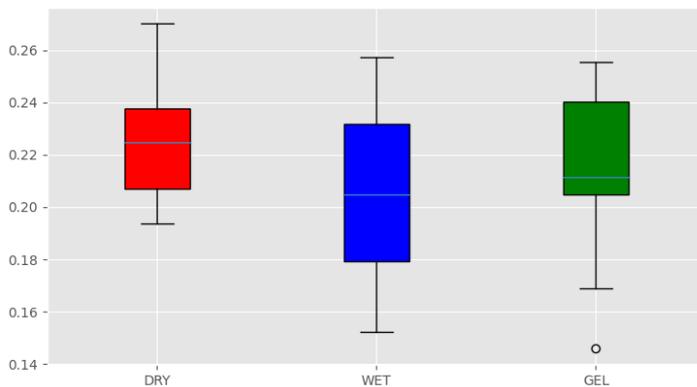


**Figura 4–8.** Representación de la complejidad de *Lempel Ziv* de todos los sujetos, todos los canales, para las tres condiciones. (verde) Electrodos de gel. (azul) Electrodos húmedos. (rojo) Electrodos secos.

Se puede apreciar que la tendencia general de las condiciones resulta nivelada de acuerdo con la figura 4-9A, no obstante, el test de Wilcoxon muestra diferencias significativas entre las condiciones. Al ser un promedio de la complejidad de *Lempel Ziv* de todos los sujetos puede que se camufle la tendencia individual que tuvieron unos usuarios respecto a la calidad de señal frente a otros.

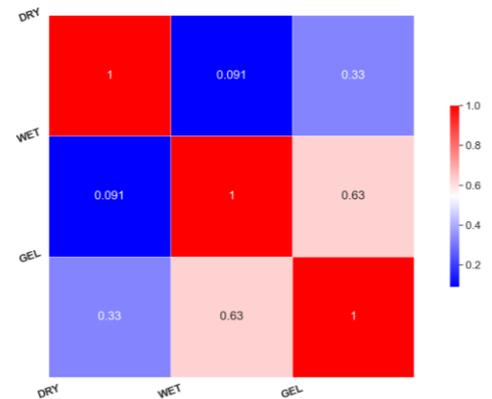
A

**Complejidad de Lempel Ziv promediada**



B

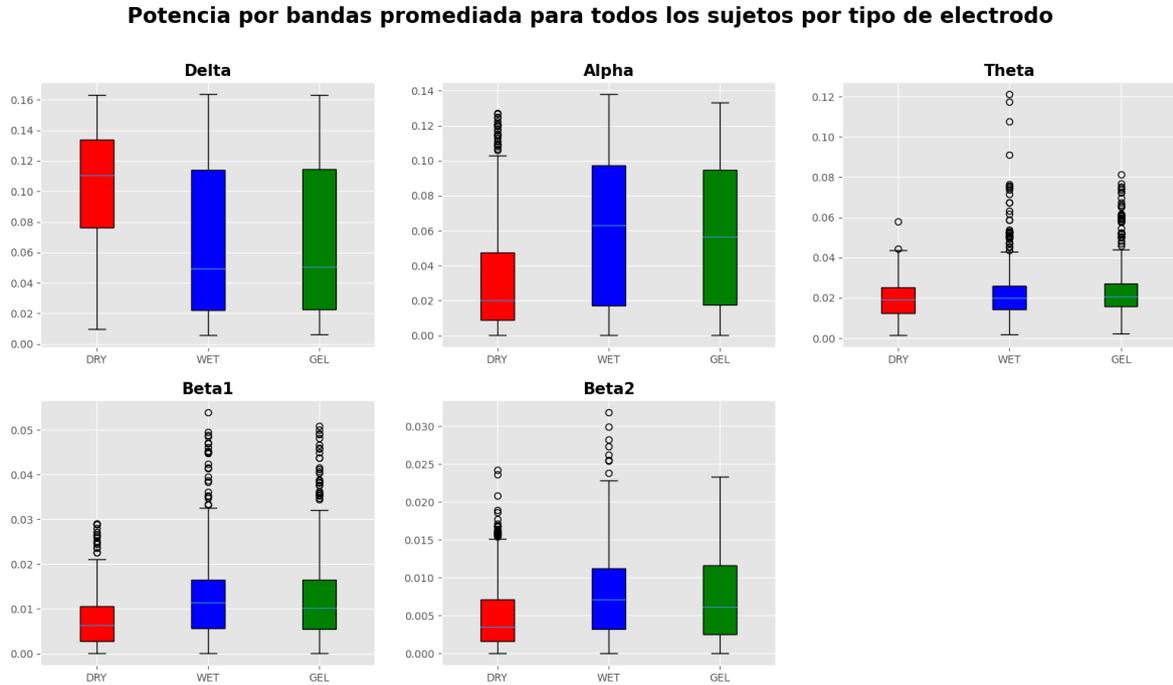
**P-values Wilcoxon Test para Complejidad de Lempel Ziv promediada**



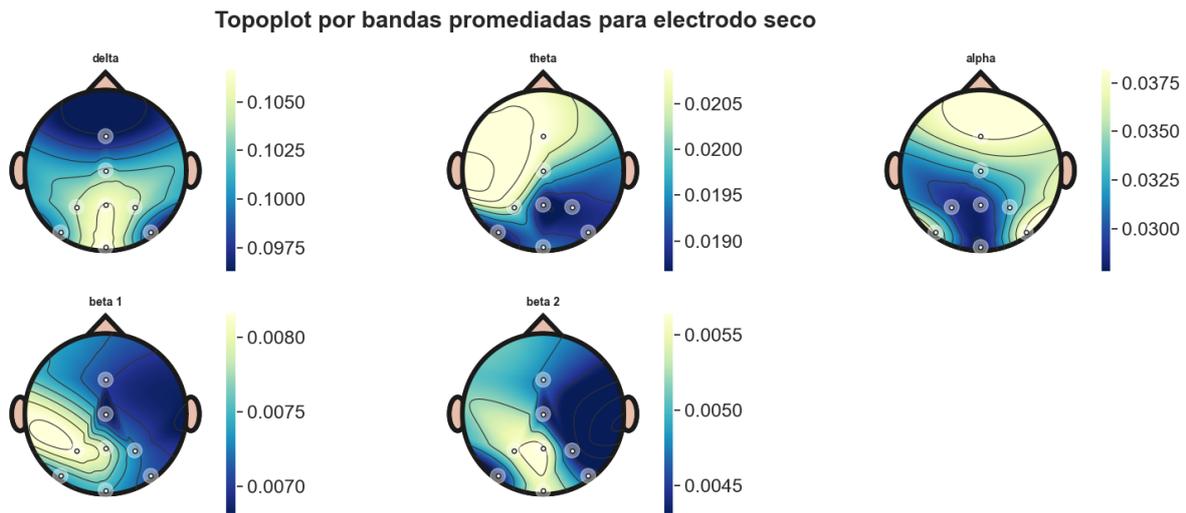
**Figura 4–9.** Representación por boxplot de la complejidad de *Lempel Ziv* promediada (A) para las tres condiciones, junto con los *P-values* del Wilcoxon Test (B).

### e. Bandas de Potencia

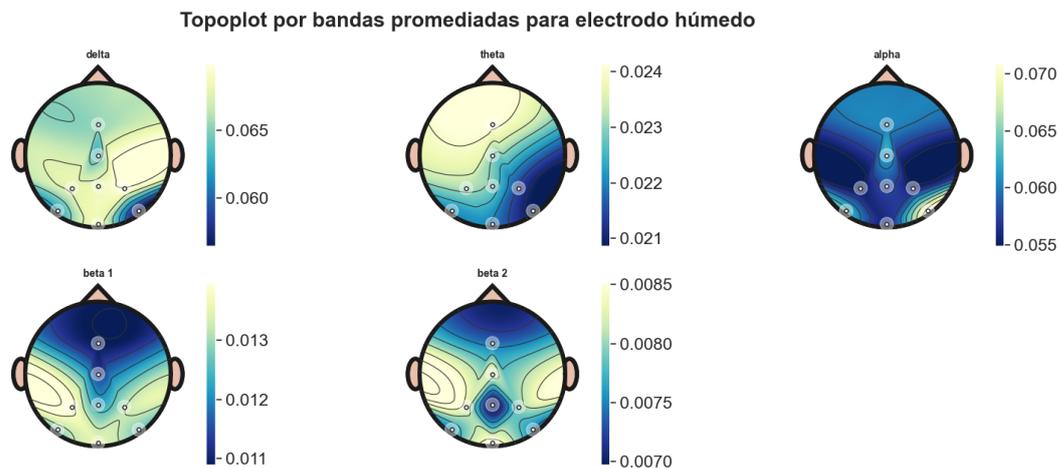
Para finalizar el apartado del análisis basal, se resumen las bandas de potencia promediada para todos los sujetos por tipo de electrodo y las topografías por bandas promediadas.



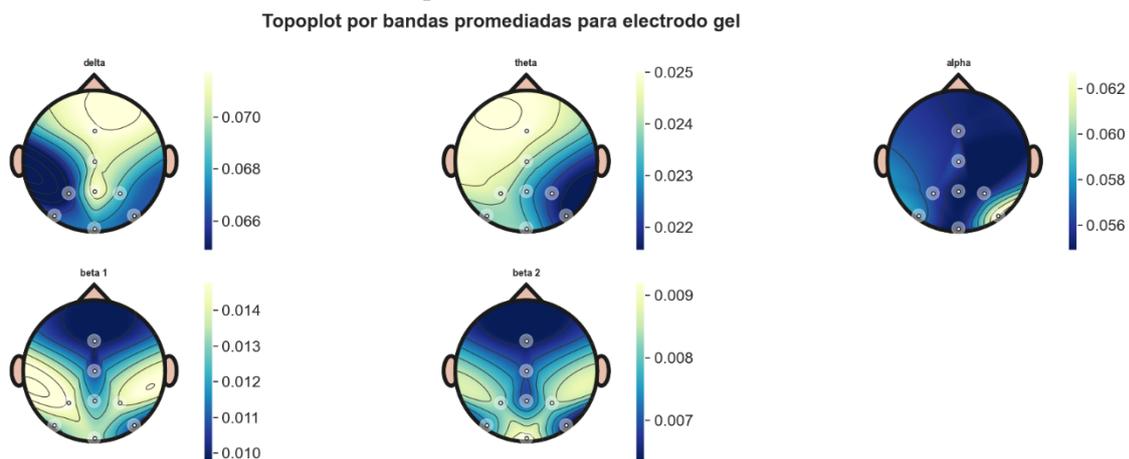
**Figura 4–10.** Representación por boxplot de las bandas de potencia para todos los sujetos en las tres condiciones. (verde) Electrodo de gel. (azul) Electrodo húmedo. (rojo) Electrodo seco



**Figura 4–11.** Representación por topografía de las bandas de potencia promedio de todos los sujetos para los electrodos secos.



**Figura 4–12.** Representación por boxplot de las bandas de potencia promedio de todos los sujetos para los electrodos húmedos.



**Figura 4–13.** Representación por boxplot de las bandas de potencia promedio de todos los sujetos para los electrodos con gel.

## 4.2. Resultados de la caracterización

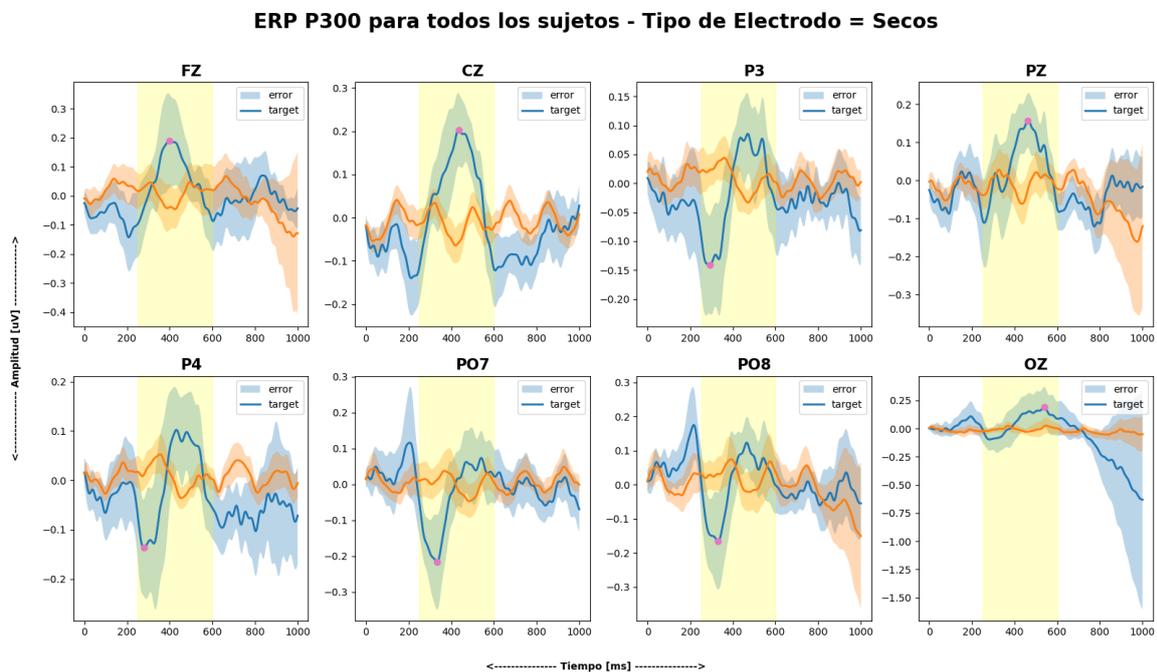
En segundo lugar, se exponen los resultados de la caracterización de los ERPs bajo las condiciones en estudio donde se evalúa: (1) Onda P300 de todos los canales promediado para cada una de las condiciones, (2) ERPs promediados de todos los canales junto con las topografías en tres tiempos, y (3) Resultados de la caracterización de los ERPs promediados por condición.

### *a. Visualización del ERP de todos los sujetos por tipo de electrodo*

Enseguida, se visualizan los ERPs extraídos por un promediado sincronizado, evaluando la amplitud y latencia de la onda P300.

A partir de la figura 4-14 a la figura 4-16, se observan los potenciales P300 de los diferentes canales del EEG para los electrodos secos, húmedos y con gel, respectivamente. Se busca un rango de evaluación alrededor de los 200 ms hasta los 600 ms para estudiar la morfología del pico P300.

Para los electrodos secos, la tendencia de la onda es comparable con los electrodos con gel, no obstante, las amplitudes y latencias varían entre sí. En este caso, el canal Oz está afectado por razones que se pueden atribuir a la conexión entre electrodo y cuero cabelludo. Como tendencia general en todos los electrodos, se visualizan variaciones (por ruido) inmersas en la señal que son las que afectan a la precisión en el *speller* RCP.



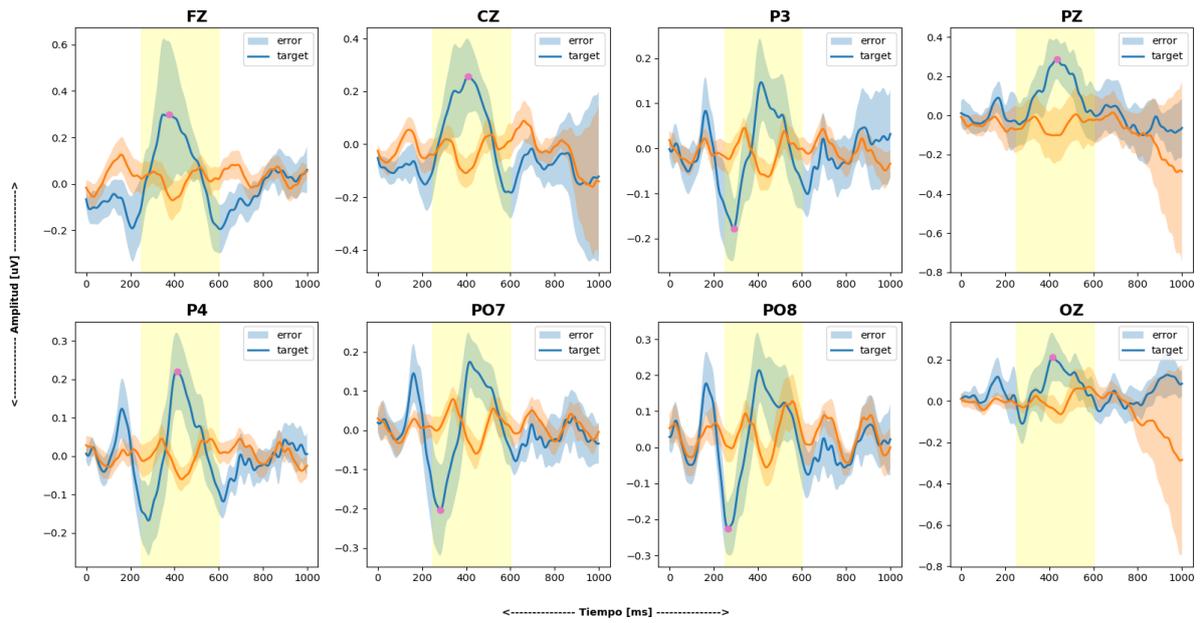
**Figura 4–14.** Representación gráfica de los ERPs para los electrodos secos, con la ventana temporal (amarillo), con el pico de la onda P300 (rosa)

Por otro lado, los electrodos húmedos, algunos canales nuevamente son comparables con los electrodos con gel, pero las amplitudes y latencias varían considerablemente. En este caso tanto Pz como Oz, presentan modificaciones en su comportamiento respecto a los electrodos con gel. Esto se debe a la presencia de componente externo que daña la calidad de la señal haciendo que se distorsione la onda.

Finalmente, para el caso de los electrodos con gel en la figura 4-16, se observan los potenciales P300 en los diferentes canales del EEG. Para todas las condiciones, estos resultados corresponden a la tendencia general de todos los sujetos en estudio. Dentro de la ventana temporal en estudio se consiguen los picos P300 con morfología, amplitud y latencia normal.

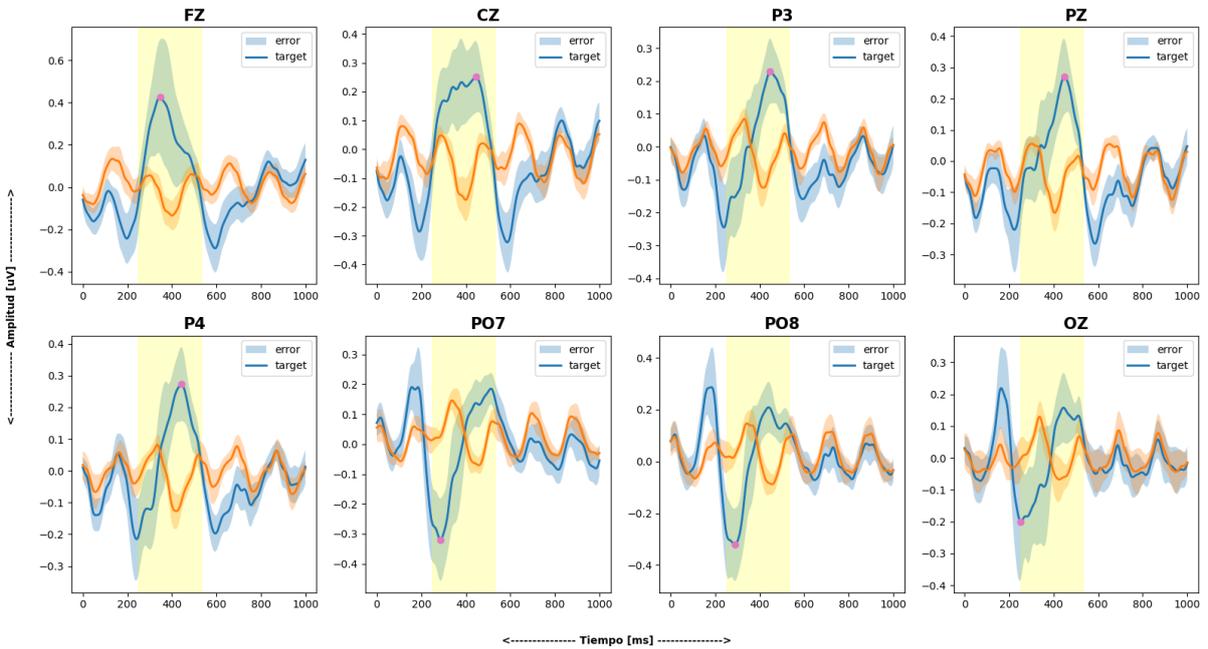
Los canales frontales y occipitales se ubican en regiones opuestas del cerebro. La visualización de picos de forma inversa se debe a que el campo eléctrico generado por el P300 puede tener orientaciones positivas en áreas frontales, parietales y centrales, mientras que en regiones occipitales la polaridad cambia a negativo.

**ERP P300 para todos los sujetos - Tipo de Electrodo = humedos**



**Figura 4-15.** Representación gráfica de los ERPs para los electrodos húmedos, con la ventana temporal (amarillo), con el pico de la onda P300 (rosa)

**ERP P300 para todos los sujetos - Tipo de Electrodo = Gel**



**Figura 4-16.** Representación gráfica de los ERPs para los electrodos con gel, con la ventana temporal (amarillo), con el pico de la onda P300 (rosa)

b. Caracterización de la amplitud y latencia del ERP

Para evaluar la característica del ERP, se estudia la latencia y la amplitud de la onda P300 y se comparan los resultados de las tres condiciones en estudio. En general se puede observar que el promedio de la latencia ronda entre los 360 ms a los 380 ms aproximadamente. Aunque el promedio no tenga variaciones entre las condiciones, la latencia entre cada canal de las condiciones, en algunos casos se alcanza a duplicar su valor.

DRY			GEL			WET		
Channel	Latency [ms]	Amplitud [uV]	Channel	Latency [ms]	Amplitud [uV]	Channel	Latency [ms]	Amplitud [uV]
FZ	398.80 ± 15.15	0.188 ± 0.013	FZ	346.69 ± 15.15	0.426 ± 0.032	FZ	376.75 ± 15.15	0.300 ± 0.023
CZ	434.87 ± 15.15	0.203 ± 0.014	CZ	585.17 ± 15.15	-0.323 ± 0.028	CZ	408.82 ± 15.15	0.257 ± 0.021
P3	292.59 ± 15.15	-0.140 ± 0.012	P3	446.89 ± 15.15	0.230 ± 0.021	P3	290.58 ± 15.15	-0.177 ± 0.014
PZ	462.93 ± 15.15	0.158 ± 0.012	PZ	448.90 ± 15.15	0.271 ± 0.023	PZ	432.87 ± 15.15	0.288 ± 0.016
P4	280.56 ± 15.15	-0.137 ± 0.013	P4	442.89 ± 15.15	0.273 ± 0.023	P4	410.82 ± 15.15	0.221 ± 0.018
PO7	334.67 ± 15.15	-0.217 ± 0.015	PO7	286.57 ± 15.15	-0.320 ± 0.025	PO7	282.57 ± 15.15	-0.203 ± 0.018
PO8	330.66 ± 15.15	-0.165 ± 0.014	PO8	288.58 ± 15.15	-0.321 ± 0.027	PO8	264.53 ± 15.15	-0.226 ± 0.020
OZ	539.08 ± 15.15	0.191 ± 0.015	OZ	252.51 ± 15.15	-0.201 ± 0.018	OZ	414.83 ± 15.15	0.213 ± 0.013
<b>Mean</b>	<b>383,02</b>	<b>0,173</b>	<b>Mean</b>	<b>369,74</b>	<b>0,287</b>	<b>Mean</b>	<b>360,22</b>	<b>0,236</b>

Tabla 4-1. Resumen de los resultados la caracterización del ERPs promediado por canal y tipo de electrodo.

De acuerdo con los resultados anteriores, se realiza el test de Wilcoxon para evaluar las diferencias estadísticas de las amplitudes y latencias entre cada uno de los electrodos.

P-values Wilcoxon Test de la amplitud de la onda P300 P-values Wilcoxon Test de la latencia de la onda P300

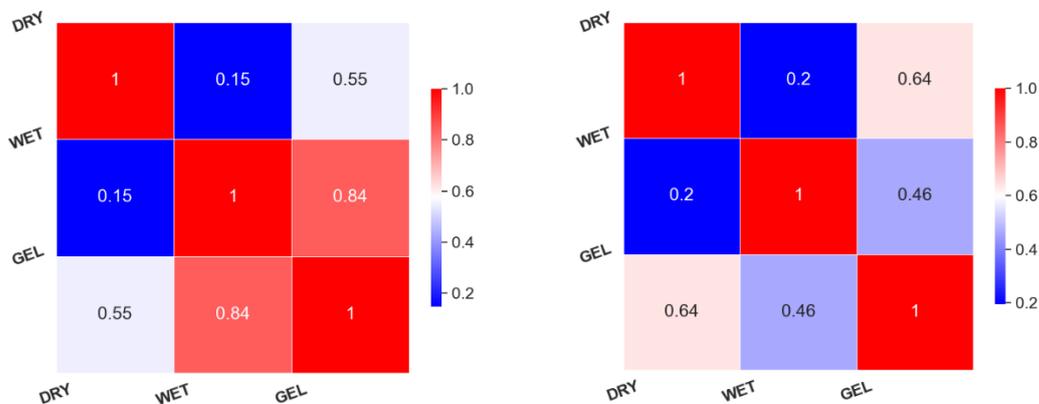
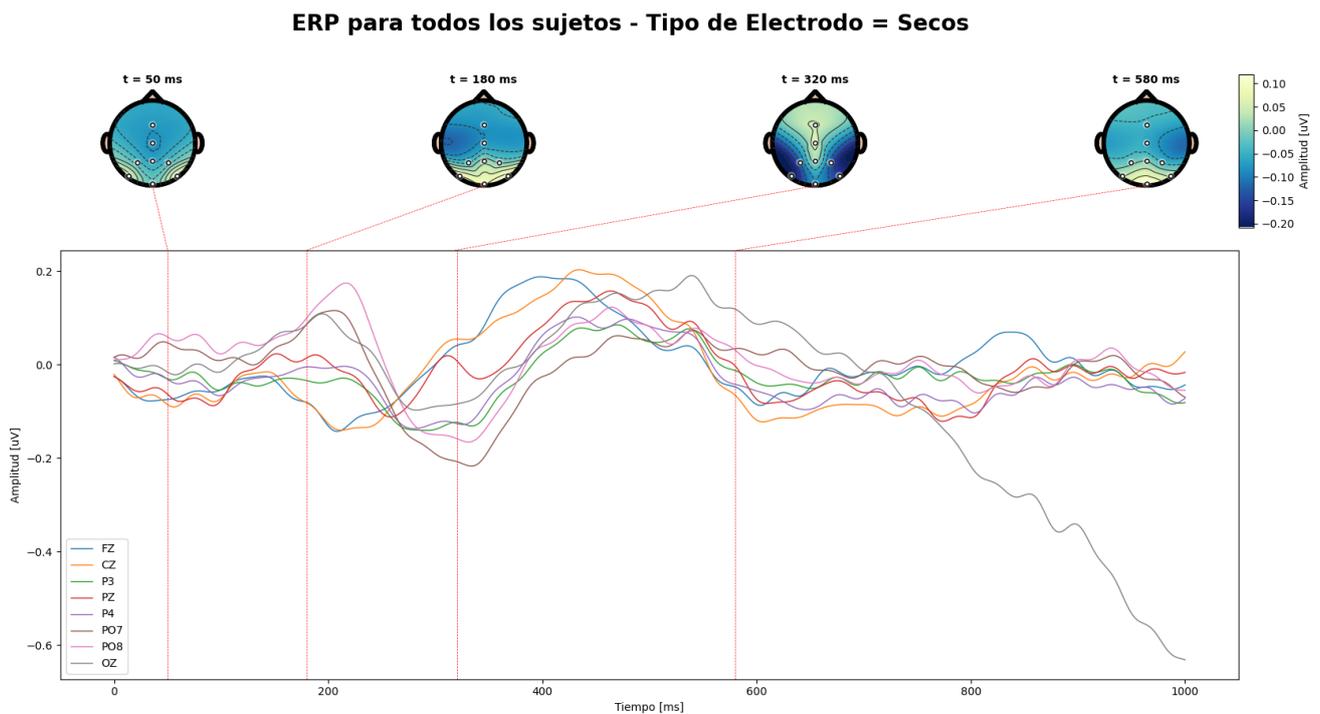


Figura 4-17. Test de Wilcoxon de la amplitud (izquierda) y latencia (Derecha) entre las condiciones estudiadas.

c. Visualización ERP + Topografía de todos los sujetos por tipo de electrodo

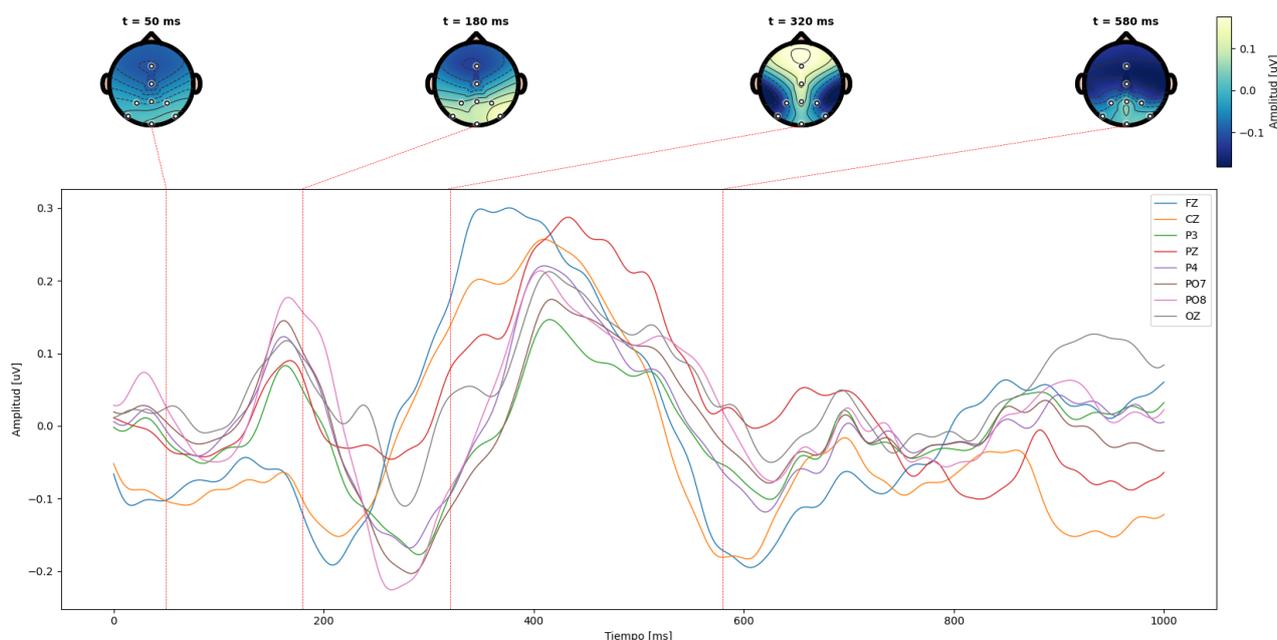
Con el objetivo de observar las variaciones en el tiempo de los diferentes momentos del potencial P300, se construye la figura 4-17, donde es posible comparar las regiones del cerebro donde ocurre la mayor actividad antes, durante y después de un estímulo. Las marcas temporales que se tuvieron en cuenta fueron  $t = 50 \text{ ms}$  cercano al *onset*, luego a  $t = 180 \text{ ms}$  de la aparición del estímulo, seguido de  $t = 320 \text{ ms}$  tiempo donde se espera observar el potencial P300 y finalmente, los siguientes 580 ms donde ya ha ocurrido el estímulo, se ha emitido el potencial se encuentra a la espera del siguiente.

A



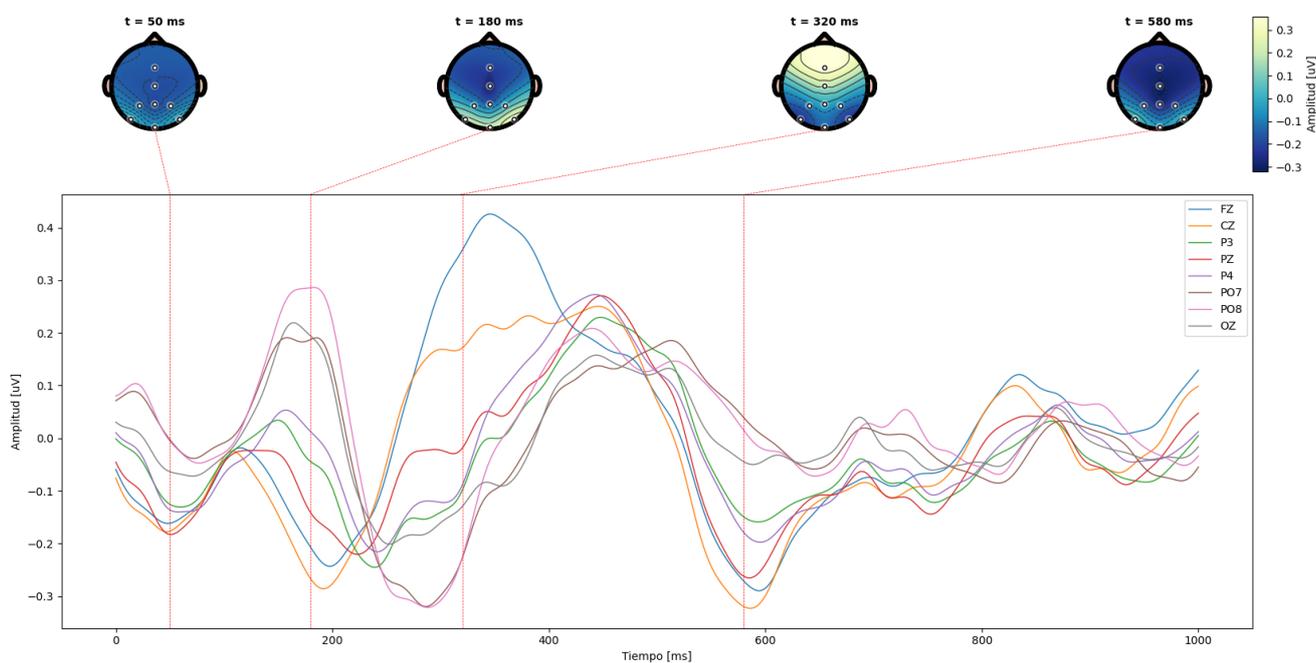
B

**ERP para todos los sujetos - Tipo de Electrodo = Húmedos**



**C**

**ERP para todos los sujetos - Tipo de Electrodo = Gel**



**Figura 4-17.** Representación gráfica de los ERPs junto a las topografías en diferentes marcas temporales. (A) Electrodo secos. (B) Electrodo húmedos. (C) Electrodo con gel. Las marcas temporales corresponden: (1) 50 ms, antes de la ocurrencia del estímulo, (2) 180 ms, el instante aproximado cuando ocurre el estímulo, (3) 320 ms, cuando aparece el pico de la onda P300, luego de los 300 ms del estímulo, (4) 580 ms, estado post-estímulo

### 4.3. Resultados de precisión

Finalmente, desde la tabla 4-2 a la tabla 4-4, se ven expuestos los resultados de la precisión de cada tipo de electrodo por sujeto, para cada una de las secuencias realizadas en un registro.

Para los electrodos secos, en la tabla 4-1, factores como concentración y conocimiento de la aplicación afectaron el score en las secuencias. Sin embargo, en su mayoría, la precisión de los electrodos se ve mayormente afectada por la presencia de artefactos que interfieren en la señal y degradan de forma considerable las características con las intenciones de los usuarios. Aunque se lograron conseguir resultados aceptables en 5 de 15 sujetos, no se tienen resultados congruentes para comparar con la precisión de los electrodos con gel.

Sub/ Seq	Secos									
	1	2	3	4	5	6	7	8	9	10
SUBJECT 1	6.67	13.33	10.00	13.33	13.33	10.00	3.33	3.33	10.00	<b>6.67</b>
SUBJECT 2	3.33	0.00	10.00	6.67	0.00	0.00	0.00	0.00	3.33	<b>3.33</b>
SUBJECT 3	3.33	3.33	0.00	0.00	0.00	0.00	0.00	0.00	0.00	<b>0.00</b>
SUBJECT 4	10.00	10.00	16.67	20.00	23.33	16.67	23.33	30.00	20.00	<b>30.00</b>
SUBJECT 5	17.50	40.00	42.50	37.50	45.00	52.50	57.50	60.00	65.00	<b>70.00</b>
SUBJECT 6	13.33	20.00	13.33	26.67	33.33	36.67	36.67	40.00	33.33	<b>40.00</b>
SUBJECT 7	16.67	43.33	40.00	43.33	56.67	53.33	66.67	70.00	80.00	<b>70.00</b>
SUBJECT 8	20.00	40.00	43.33	53.33	46.67	46.67	60.00	70.00	73.33	<b>80.00</b>
SUBJECT 9	30.00	33.33	63.33	76.67	76.67	86.67	76.67	80.00	80.00	<b>93.33</b>
SUBJECT 10	6.67	6.67	6.67	6.67	3.33	10.00	10.00	6.67	10.00	<b>6.67</b>
SUBJECT 11	0.00	6.67	6.67	10.00	6.67	6.67	6.67	6.67	3.33	<b>6.67</b>
SUBJECT 12	13.33	40.00	40.00	63.33	73.33	80.00	83.33	83.33	86.67	<b>90.00</b>
SUBJECT 13	6.67	6.67	6.67	6.67	13.33	13.33	10.00	3.33	6.67	<b>10.00</b>
SUBJECT 14	3.33	0.00	3.33	3.33	0.00	0.00	3.33	3.33	0.00	<b>3.33</b>
SUBJECT 15	6.67	13.33	16.67	13.33	16.67	26.67	23.33	23.33	26.67	<b>30.00</b>
MEAN	10.50	18.44	21.28	25.39	27.22	29.28	30.72	32.00	33.22	<b>36.00</b>
STD	7.73	15.68	18.59	23.18	25.69	27.79	29.11	31.15	32.50	<b>33.89</b>

Tabla 4-2. Resumen de la precisión del ERPs por sujeto para los electrodos secos.

Así como ocurre en los resultados de la precisión de los electrodos secos, el caso de los electrodos húmedos continúa con la misma tendencia, donde 4 de 15 usuarios lograron superar el 60% de la precisión para el control del sistema BCI basado en P300.

Sub/ Seq	Húmedos									
	1	2	3	4	5	6	7	8	9	10
SUBJECT 1	0.00	3.33	6.67	6.67	6.67	10.00	10.00	0.00	6.67	<b>6.67</b>
SUBJECT 2	10.00	3.33	3.33	6.67	10.00	10.00	10.00	10.00	10.00	<b>10.00</b>
SUBJECT 3	20.00	40.00	43.33	53.33	46.67	46.67	60.00	70.00	73.33	<b>80.00</b>
SUBJECT 4	3.33	3.33	3.33	0.00	0.00	0.00	3.33	3.33	3.33	<b>3.33</b>
SUBJECT 5	0.00	13.33	10.00	6.67	10.00	16.67	16.67	20.00	16.67	<b>23.33</b>
SUBJECT 6	20.00	33.33	43.33	63.33	63.33	70.00	73.33	83.33	83.33	<b>90.00</b>
SUBJECT 7	20.00	40.00	53.33	46.67	53.33	53.33	56.67	60.00	63.33	<b>63.33</b>
SUBJECT 8	7.50	15.00	17.50	22.50	40.00	37.50	42.50	55.00	55.00	<b>50.00</b>
SUBJECT 9	13.33	26.67	36.67	50.00	46.67	66.67	63.33	60.00	60.00	<b>66.67</b>
SUBJECT 10	10.00	20.00	20.00	13.33	13.33	13.33	16.67	16.67	26.67	<b>16.67</b>
SUBJECT 11	0.00	6.67	3.33	0.00	6.67	3.33	6.67	3.33	3.33	<b>3.33</b>
SUBJECT 12	16.67	16.67	26.67	16.67	13.33	23.33	26.67	23.33	20.00	<b>26.67</b>
SUBJECT 13	3.33	0.00	3.33	3.33	6.67	3.33	10.00	10.00	6.67	<b>6.67</b>
SUBJECT 14	3.33	10.00	3.33	10.00	6.67	6.67	6.67	13.33	16.67	<b>16.67</b>
SUBJECT 15	13.33	20.00	16.67	26.67	26.67	30.00	20.00	23.33	13.33	<b>26.67</b>
<b>MEAN</b>	<b>9.39</b>	<b>16.78</b>	<b>19.39</b>	<b>21.72</b>	<b>23.33</b>	<b>26.06</b>	<b>28.17</b>	<b>30.11</b>	<b>30.56</b>	<b>32.67</b>
<b>STD</b>	<b>7.31</b>	<b>12.80</b>	<b>16.73</b>	<b>20.61</b>	<b>20.15</b>	<b>22.74</b>	<b>23.34</b>	<b>26.63</b>	<b>27.09</b>	<b>28.50</b>

Tabla 4–3. Resumen de la precisión del ERPs por sujeto para los electrodos húmedos.

Mientras que, para el caso de los electrodos con gel, la mayoría de los usuarios consiguieron hasta un 100% de precisión con el *speller* RCP. Para estos casos, la concentración y control de la tarea si puede haber afectado la precisión a diferencia de las otras condiciones donde se ven afectadas por el ruido inmerso en la señal. Para

estos electrodos, 3 de 15 sujetos tuvieron un score parcialmente bajo a comparación de los demás usuarios.

Sub/ Seq	GEL									
	1	2	3	4	5	6	7	8	9	10
SUBJECT 1	13.33	23.33	46.67	50.00	60.00	63.33	53.33	60.00	66.67	63.33
SUBJECT 2	63.33	80.00	90.00	96.67	96.67	96.67	100.00	96.67	100.00	100.00
SUBJECT 3	30.00	53.33	56.67	70.00	73.33	80.00	83.33	90.00	90.00	96.67
SUBJECT 4	30.00	50.00	50.00	56.67	66.67	73.33	73.33	83.33	80.00	90.00
SUBJECT 5	46.67	63.33	70.00	80.00	86.67	90.00	90.00	90.00	90.00	93.33
SUBJECT 6	40.00	63.33	83.33	96.67	100.00	96.67	96.67	100.00	100.00	96.67
SUBJECT 7	16.67	26.67	46.67	66.67	73.33	73.33	86.67	93.33	80.00	83.33
SUBJECT 8	26.67	43.33	60.00	66.67	83.33	80.00	90.00	90.00	93.33	96.67
SUBJECT 9	60.00	76.67	80.00	80.00	83.33	90.00	90.00	93.33	96.67	93.33
SUBJECT 10	16.67	26.67	50.00	60.00	60.00	73.33	76.67	83.33	80.00	83.33
SUBJECT 11	20.00	30.00	23.33	30.00	43.33	46.67	53.33	50.00	53.33	60.00
SUBJECT 12	53.33	63.33	76.67	93.33	96.67	96.67	96.67	96.67	96.67	96.67
SUBJECT 13	20.00	33.33	43.33	40.00	53.33	60.00	56.67	60.00	66.67	63.33
SUBJECT 14	40.00	60.00	73.33	70.00	80.00	80.00	83.33	90.00	86.67	90.00
SUBJECT 15	40.00	53.33	83.33	83.33	93.33	93.33	100.00	100.00	100.00	100.00
MEAN	34.44	49.78	62.22	69.33	76.67	79.56	82.00	85.11	85.33	87.11
STD	15.67	17.87	18.37	19.21	16.64	14.45	15.67	15.15	13.71	13.38

Tabla 4-4. Resumen de la precisión del ERPs por sujeto para los electrodos con gel.

#### 4.4. Resultados de los cuestionarios de satisfacción

Finalmente, en este apartado de resumen los resultados de la satisfacción de los usuarios al realizar las sesiones de registro con las preguntas detalladas en el protocolo.

La respuesta de los usuarios ante las condiciones estudiadas fueron claras respecto a los electrodos secos, la duración de las sesiones y la fatiga que se pudo presentar. En su mayoría, para cada pregunta del cuestionario los sujetos tuvieron inclinaciones parecidas, donde realizaron comentarios como: la duración de las

sesiones demandaba mucho tiempo; los electrodos secos no se aguantan por más de 1 hora de uso; o bien, mostraban frustración por no seleccionar la letra correcta.

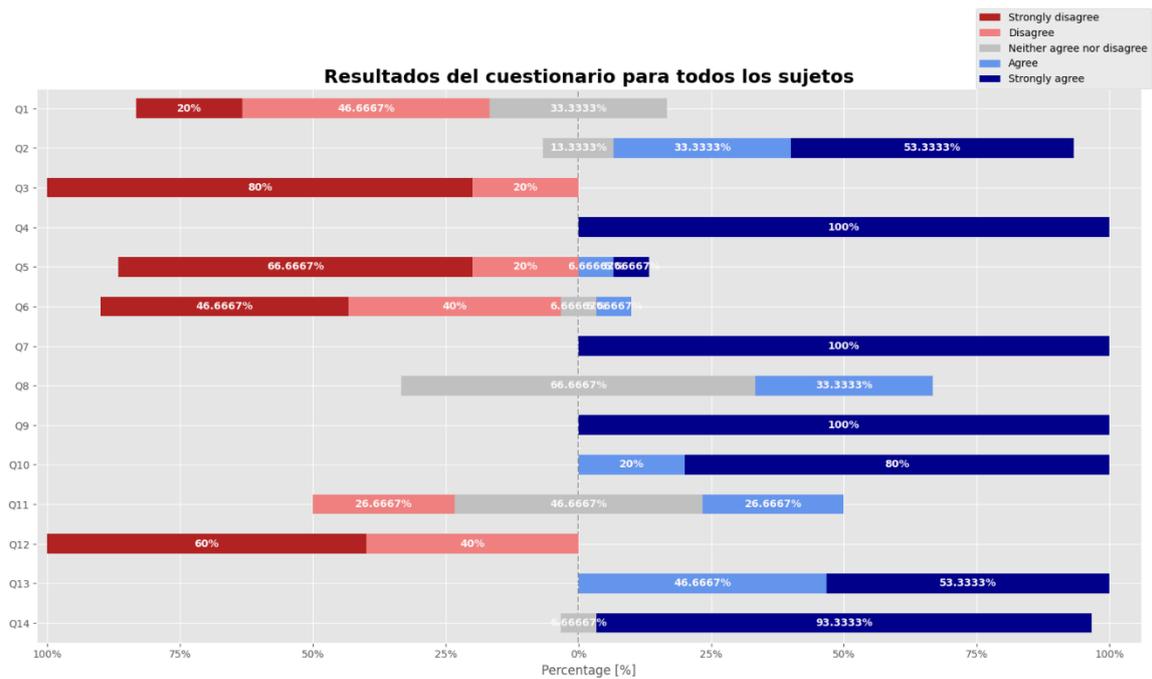


Figura 4-18. Resultados de los cuestionarios realizados a los sujetos al final de las sesiones.

Otro parámetro para analizar en las sesiones, fueron los tiempos que se demoraba en posicionar los electrodos y conseguir obtener señal EEG de calidad. Por ello, se resume el tiempo que se requirió desde posicionar un electrodo hasta iniciar el registro basal por cada condición.

En la siguiente figura, se observa claramente la diferencia entre los electrodos secos y húmedos frente a los electrodos con gel. Donde para las dos primeras condiciones, se lograba conseguir señal EEG de calidad y estable, luego de aproximadamente 20 minutos incluso alcanzando a superar los 60 minutos en este proceso. Esto ocasionaba que las sesiones se extendieran considerablemente hasta no conseguir el objetivo.



Figura 4-19. Representación gráfica del tiempo que se demoró en conseguir señal EEG de calidad a lo largo de las sesiones registro para cada una de las condiciones.



## 5. Capítulo 5.

---

### Discusión de resultados

En el presente capítulo se detalla el análisis y discusión de los resultados obtenidos en la caracterización de electrodos secos, húmedos y con gel. Se sigue la estructura presentada en los resultados, empezando por el análisis basal de los registros en reposo, para luego continuar con la caracterización de los potenciales evocados P300 bajo las diferentes condiciones.

#### 5.1. Discusión de resultados del análisis basal

Los resultados de este apartado, presentados en el capítulo anterior, muestran factores de calidad de la señal EEG (en reposo - ojos cerrados) y sensibilidad a artefactos tanto internos como externos.

##### *a. Visualización del EEG*

A partir de los resultados de la figura 4-1 a la figura 4-3, se ha podido visualizar la señal EEG de un registro basal con los ojos cerrados en tiempo para los electrodos secos, húmedos y con gel, respectivamente. En las gráficas está dispuesta una ventana de 5 segundos de la señal EEG tanto en tiempo (izquierda) como en muestras (derecha), de todos los canales. Se puede visualizar claramente la diferencia entre las tres condiciones.

Al visualizar los electrodos secos, aunque se puede percibir parte de la onda alfa, se ve distorsionada por la presencia un alto componente de ruido ocasionando que la morfología de la onda alfa se vea afectada (O'Sullivan et al. 2019). Por otra parte, en los electrodos húmedos se percibe una atenuación en la señal que se puede deber a la presencia de la esponja que humedece el electrodo. Lo anterior puede deberse a que en varios casos la esponja se salía del lugar fácilmente, de igual forma, se puede atribuir estas atenuaciones a que los electrodos secos no están diseñados para aplicaciones con agua, ocasionando un incremento en la sensibilidad a artefactos. La esponja, aunque aumenta la distancia entre el electrodo y el cuero cabelludo, aumenta la conductividad entre los 10 puntos de contacto que tiene el electrodo seco. Finalmente, en el caso de los electrodos con gel, como se esperaba, la amplitud de la onda alfa en la señal EEG adquirida corresponde a la morfología habitual de esta banda de potencia.

##### *b. Visualización de la PSD*

A la hora de realizar la transformación de la señal para el análisis tiempo-frecuencia, la PSD general de todos los sujetos que se observa en la figura 4-4,

expone los picos de frecuencia que se ven en todo el espectro desde 1 hasta 30 Hz. Esto aporta información de las potencias dentro de la señal promediada de todos los sujetos. Pueden estar dadas por componente de ruido, donde se visualiza la mayor amplitud del pico a bajas frecuencias (menores a 5 Hz) en las tres condiciones. Aunque más predominante en los electrodos secos y húmedos, por la sensibilidad a los artefactos externos, movimientos involuntarios, e impedancias entre el electrodo y la corteza cerebral. Pero que, a su vez, puede estar relacionado a estados cognitivos, como se puede observar el pico dentro del rango de frecuencia alfa de 8 a 13 Hz, relacionado con el estado de relajación. Este último, se ve con mayor amplitud para el electrodo con gel dado a que es el que alcanza mayor calidad de la señal, mientras que los otros electrodos se ven más atenuados dentro de ese rango por las razones ya mencionadas.

Gracias a la PSD promediada, se pudo observar una tendencia grupal en el espectro de frecuencia, siendo congruente con los resultados de la PSD individual por sujeto como se puede observar en la figura 4-5. Realizar el análisis individualmente, permite observar las variaciones inter-sujetos, donde se ha comprobado que los electrodos secos funcionan diferentes en cada usuario. Dichas diferencias pueden atribuirse a diferentes factores: (1) La variabilidad en la colocación de los electrodos, dado a que hay casos en los que consigue mejor contacto que en otros. (2) Las morfologías innatas de cada sujeto, es decir, cada usuario tiene un EEG con amplitudes y latencias únicas. Asimismo, se ha comprobado que establecer una conexión estable en los electrodos húmedos y secos, no implica que la adquisición de la señal EEG no contenga variaciones de un mismo sujeto entre una sesión y otra. Las variaciones que se han visualizado están presentes incluso en una misma sesión cuando un electrodo se satura o se desconecta.

### *c. Frecuencia Mediana*

Una vez transformada la señal es posible visualizar la frecuencia mediana en el análisis espectral de una señal EEG, este indicador denota una magnitud dentro de la distribución de potencias en el dominio de la frecuencia. Dicha magnitud corresponde el punto de frecuencia donde se divide en partes iguales la potencia acumulada dentro del espectro. En otras palabras, valores superiores/inferiores a la frecuencia mediana resumen el 50% del valor de la potencia total dentro de la señal EEG (Tonner and Bein 2006).

Evaluando los resultados individuales de la frecuencia mediana que se presentan en la figura 4-6, al estar estudiando el estado en reposo se esperaría que las magnitudes se ubicaran dentro del rango de alfa, con frecuencia bajas en torno a 8-13 Hz. Al observar cada sujeto en las diferentes condiciones, la frecuencia mediana para los electrodos en gel permanece dentro de un rango similar para todos los usuarios. Mientras que, para el caso de los electrodos secos, se evidencia una disminución en las magnitudes que puede deberse a la atenuación de la señal que se debe a la presencia de un alto porcentaje de artefactos en la señal generados por la baja conductividad de los electrodos secos. Por su lado, para los electrodos húmedos

se tiene una tendencia parecida a la de los electrodos con gel, se observa que, aunque esté presente el gran componente de ruido en la señal por la impedancia entre electrodo–esponja–corteza, los comportamientos en el espectro potencia de estos electrodos se inclinan más hacia lo que se esperaría ver en estado de reposo, con respecto a los electrodos en gel.

Al observar la tendencia general del promedio de todos los sujetos en la frecuencia mediana en la figura 4–7B, el test de Wilcoxon resume las diferencias estadísticamente significativas entre las condiciones. En los electrodos secos ( $p$ -value = 0.23) y húmedos ( $p$ -value = 0.47), respecto a los electrodos con gel, no existen diferencias estadísticamente significativas. La ausencia de estas diferencias puede ser debida en parte al número de sujetos incluido en el estudio, ya que a simple vista pueden apreciarse comportamientos diferentes. Por su parte, para los electrodos secos y húmedos, si existe una ligera diferencia estadísticamente significativa.

#### d. Complejidad de Lempel Ziv

A partir del conjunto de épocas de la señal EEG, se puede analizar el conjunto de datos inmersos con la complejidad de Lempel Ziv para estudiar cuán estructurada es la señal (Borowska and Syczewska 2021). Una baja complejidad, podría denotar una actividad cerebral sincronizada, que puede apreciarse especialmente en la señal EEG correspondiente a los estados de reposo donde las ondas de la señal EEG tienen menor variabilidad y su amplitud es mayor gracias a la sincronía en la actividad. Por otro lado, estados cognitivos relacionados con estados de atención y concentración hacen que la señal tenga mayor complejidad y variaciones inmersas en ella (Borowska and Syczewska 2021; Lempel and Ziv 1976).

En el artículo “Neural Markers of Responsiveness to the Environment in Human Sleep”, los autores *Andrillon .et. al* (2016), sostienen la idea de *Casali .et. al* (2013), donde expresan que se puede medir una predicción temporal de la señal EEG reduciéndose a un valor, la complejidad de Lempel Ziv. Esta modulación se resume en que, en estados de vigilia la señal es compleja e impredecible, mientras que, es posible predecir aquellos estados de sueño al ser menos compleja (Borowska and Syczewska 2021; Andrillon et al. 2016).

Una de las ventajas de emplear la complejidad de Lempel Ziv es que complementa el análisis frecuencial, basado en la PSD y las bandas de potencias. Gracias a esto, las condiciones que no sean posible detectarlas con el espectro de frecuencia, es posible obtener más información con la complejidad de Lempel Ziv.

En la figura 4–8, se observan las complejidades de todos los usuarios bajo las diferentes condiciones de registro. Como ya se ha mencionado, en este apartado se analizan el estado de reposo con ojos cerrados, por ende, la complejidad de Lempel Ziv para estos registros según los autores *Andrillon .et. al* (2016) es baja por las razones ya mencionadas.

Al analizar la tendencia por electrodo y por sujeto, se observa que la caja correspondiente a los electrodos secos está más elevada a comparación de los demás

electrodos en estudio. Esto se puede deber a que existe mayor variación en los datos dentro de la señal por la presencia de artefactos que, a su vez, vuelven a la señal más compleja de analizar y predecir. Asimismo, los electrodos húmedos exhiben una gran variabilidad, solamente alcanzando en algunos casos, valores de complejidad similares a los electrodos con gel (sujetos 11 a 15). En estos casos, posiblemente se alcanzó un mejor contacto de los electrodos húmedos, en parte también a la experiencia acumulada durante la adquisición de la base de datos y la optimización del procedimiento de colocación del gorro y las esponjas.

En la figura 4-9, se resume el promedio de todos los sujetos con los resultados de la complejidad de Lempel Ziv por tipo de electrodo, donde se obtiene una tendencia parecida para las tres condiciones en estudio, pero al analizar el test de Wilcoxon, los electrodos secos ( $p$ -value = 0.33) y húmedos ( $p$ -value = 0.63), respecto a los electrodos con gel, no tienen diferencias estadísticamente significativas. Al analizar la comparación entre únicamente electrodos secos respecto a los húmedos ( $p$ -value = 0.091), se obtienen valores cercanos a los al margen, no obstante, no es posible asegurar que las diferencias se pueden deber a mejor conductividad de los electrodos húmedos frente a los secos.

#### e. *Bandas de Potencia*

Desde la figura 4-10 hasta la 4-13, se analizan las bandas de potencia promediada de todos los sujetos por tipo de electrodo. Al observar la tendencia en la figura 4-10, en todas las bandas, los electrodos húmedos tienden a estar parcialmente alineados con los electrodos con gel en la parte superior de la gráfica, mientras que los electrodos secos se concentran en la parte inferior.

En la banda Delta, ocurre lo contrario, donde los electrodos secos se ubican en la parte superior de la gráfica respecto a los otros electrodos que se encuentran en el inferior. Esto se debe a que la mayor potencia tiene los electrodos secos, viene dada a las bajas frecuencias del componente de ruido en la señal.

El estado cognitivo en reposo con ojos cerrados, la predominancia está en alfa, es de esperarse que los rangos de los ejes en las potencias vayan disminuyendo su amplitud a partir de Theta en adelante, debido a que la presencia de estas potencias es nula.

Las diferencias entre electrodos pueden atribuirse a la impedancia entre electrodo y corteza, sensibilidad al ruido y estabilidad del sistema a la hora de la adquisición de la señal de EEG. Aunque es posible percibir señal en las tres condiciones, unas más atenuadas que en otras, en la distribución topográfica de las diferentes bandas de potencia por electrodo, se observa la actividad cognitiva de forma espacial a lo largo de la distribución de electrodos empleada.

Para el caso de los electrodos secos, en la figura 4-11, la potencia está distribuida no tan uniforme como se presenta en la figura 4-12 y figura 4-13, para los electrodos húmedos y con gel, respectivamente. A la hora de observar la banda alfa, tanto en los electrodos húmedos como con gel, el espectro aparece con mayor potencia de forma unilateral en PO8, con una porción un poco más atenuada en el

costado izquierdo a la altura de PO7. Para el caso de beta 1 y beta 2, están ubicadas en ambos casos (húmedos y con gel) de forma bilateral en la región parieto–occipital. Mientras que, delta y theta, se desplazan más a la región frontal y central de la corteza. Para los electrodos húmedos y con gel, theta, se ubica sobre los electrodos Fz y Cz. No obstante, el caso de delta en los electrodos húmedos se ve un poco más distorsionada y repartida a lo largo de toda la corteza.

## 5.2. Discusión de resultados de la caracterización

Los resultados de este apartado corresponden a los registros de los ERPs a partir del *Speller RCP*. En primer lugar, se analizan las ondas P300 de toda la configuración de canales (8 canales) por condición; a su vez se visualizan los ERPs por condición, en una sola gráfica donde es posible observar la actividad cerebral antes y después de un estímulo visual. Seguido de esto, se compara la caracterización de la amplitud y la latencia del pico de la onda P300 de los tres electrodos. Finalmente, se resumen los resultados de la precisión alcanzada por cada electrodo y se discuten los resultados obtenidos por secuencias.

### a. Caracterización de la amplitud y latencia del ERP por tipo de electrodo por canal

Para evaluar las características de los resultados de las ondas P300, es esencial identificar la morfología de una onda ERPs. En la figura 4–14, se visualizan los ERPs de los electrodos secos donde parcialmente en los primeros 5 canales se observa una onda positiva dentro del rango de estudio (aprox. 200 a 600 ms), es posible señalar que se alcanza una amplitud suficiente para visualizar el P300.

Al comparar un electrodo seco con un electrodo con gel (figura 1–16), Fz (el seco) alcanza una latencia de  $[398.80 \pm 15.15 \text{ ms}]$  y una amplitud  $[0.188 \pm 0.013 \text{ uV}]$ , magnitudes bastante alejadas a lo que se consigue con el *gold standard* en estas adquisiciones, dado que Fz (gel) se alcanza una latencia de  $[346.69 \pm 15.15 \text{ ms}]$ , con una amplitud de  $[0.426 \pm 0.032 \text{ uV}]$ , esta amplitud alcanza a ser más del doble que los electrodos secos. Para electrodos parieto–occipitales donde tiende a haber mayor presencia de los ERPs, para los electrodos secos, PO7 tiene una latencia  $[334.67 \pm 15.15 \text{ ms}]$  con una amplitud  $[-0.217 \pm 0.015 \text{ uV}]$ , mientras que los electrodos de gel tienen una latencia  $[286.57 \pm 15.15 \text{ ms}]$  y una amplitud  $[-0.320 \pm 0.025 \text{ uV}]$ .

En la figura 4–15, los ERPs que se visualizan están presente en casi todos los electrodos. Al comparar los electrodos húmedos (con esponja) respecto a los de gel (figura 1–16), para Fz se ubica la latencia  $[376.75 \pm 15.15 \text{ ms}]$  y la amplitud  $[0.300 \pm 0.023 \text{ uV}]$ . Variación con el electrodo en gel, que tiene una amplitud  $[346.69 \pm 15.15 \text{ ms}]$ , con una amplitud de  $[0.426 \pm 0.032 \text{ uV}]$ . Al comparar nuevamente con electrodos parieto–occipitales, PO7 (húmedos) tiene una latencia  $[282.57 \pm 15.15]$  con una amplitud  $[-0.203 \pm 0.018]$ , mientras que PO7 (gel), tienen una latencia  $[286.57 \pm 15.15 \text{ ms}]$  y una amplitud  $[-0.320 \pm 0.025 \text{ uV}]$ .

La diferencia entre amplitudes y latencias puede deberse a la atenuación de la señal que aparece por el ruido intrínseco que tienen los electrodos secos y húmedos,

a diferencia de la calidad de la señal de los electrodos con gel que su impedancia es mínima y la sensibilidad a artefactos se reduce por la presencia del gel.

En la tabla 5-1, es posible observar las diferencias en las magnitudes de la latencia y la amplitud, respecto a diferentes señales de control. El autor Heijs .et .al que emplea un equipo con un mayor número de canales que permite obtener con mayor precisión los resultados de la respuesta dada por los VEPs (Heijs et al. 2021). Mientras que, en el presente trabajo, aunque también se analizan las amplitudes y latencias de los electrodos secos y húmedos, se tiene una señal de control diferente cuya amplitud y latencia cambian.

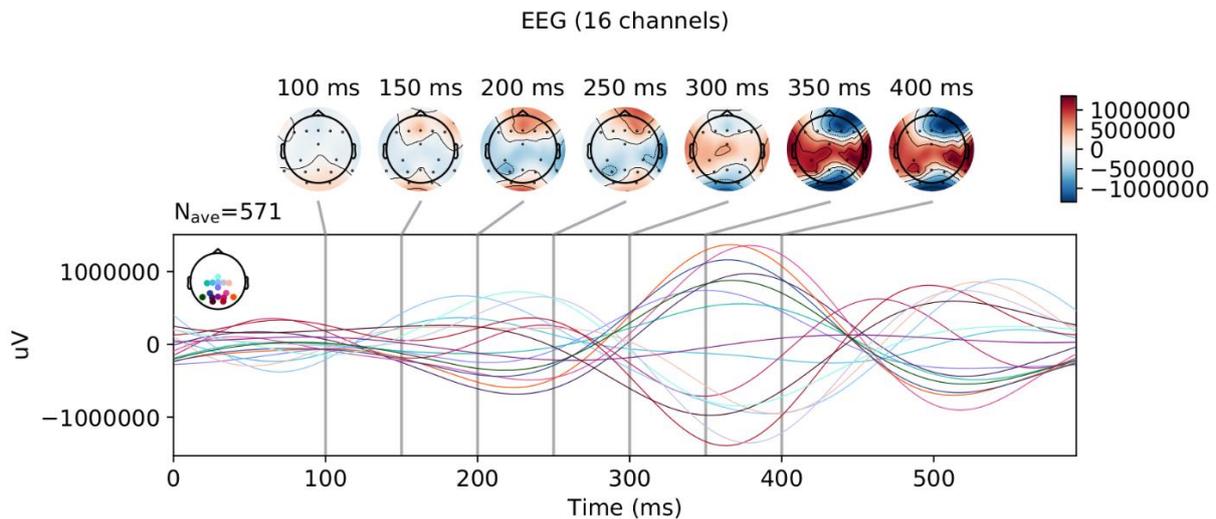
DRY						
Autor	Sujetos	Dispositivo	# Canales	Señal de control	Latency	Amplitud [uV]
Heijs .et .al	15	Waveguard original Ant Neuro	32	Visual evoked potential (P100)	0.153 ± 0.004 s	11.81 ± 4.39
Heijs .et .al	15	Waveguard original Ant Neuro	32	Auditory evoked potential (P1)	0.410 ± 0.030 s	12.05 ± 3.96
Presente trabajo	15	Enobio 8 Neuroelectrics	8	Event-Related Potential (P300)	383.63 ± 15.15 ms	0.175 ± 0.01
GEL						
Autor	Sujetos	Dispositivo	# Canales	Señal de control	Latency	Amplitud [uV]
Heijs .et .al	15	Waveguard original Ant Neuro	32	Visual evoked potential (P100)	0.152 ± 0.003 s	12.66 ± 6.42
Heijs .et .al	15	Waveguard original Ant Neuro	32	Auditory evoked potential (P1)	0.402 ± 0.027 s	12.15 ± 3.80
Presente trabajo	15	Enobio 8 Neuroelectrics	8	Event-Related Potential (P300)	386.63 ± 15.15 ms	296 ± 0.02

**Tabla 5-1.** Resumen del promedio de las amplitudes y latencias de ERPs y VEPs respecto a otros autores.

*b. Visualización ERP promedio con topografías de todos los sujetos por tipo de electrodo*

Para la figura 1-17, engloba todos los ERPs de todos los canales en las tres condiciones en estudio y muestra 4 marcas temporales a lo largo de una época, teniendo: (1) 50 ms, antes de la ocurrencia del estímulo, (2) 180 ms, el instante aproximado cuando ocurre el estímulo, (3) 320 ms, cuando aparece el pico de la onda P300, luego de los 300 ms del estímulo, (4) 580 ms, estado post-estímulo. Para las tres condiciones, tanto en los 180 ms como en los 320 ms, se ve la actividad occipital y luego frontal, respectivamente, que corresponde al momento del estímulo y los 300 ms siguientes.

De acuerdo con los tiempos, la respuesta en la reacción y aparición de los ERPs es más demorada en los registros de los electrodos secos y húmedos a comparación de la respuesta en los electrodos con gel. Se puede inferir que esto se debe, nuevamente, a los componentes que interfieren en la señal EEG, desde la impedancia por baja conductividad, hasta el ruido y artefactos externos, que producen un difuminado temporal del potencial.



**Figura 5-1.** Representación de ERPs promediado con marcas temporales de 16 pacientes sanos para electrodos con gel. Tomado de: Abibullaev & Zollanvari (2021).

Para los registros de la figura 5-1, los autores Abibullaev & Zollanvari (2021), realizaron un análisis de potenciales P300 donde establecieron los siguientes parámetros para el paradigma *Row-Column*: intervalo inter-estímulo se estableció en 150 ms, duración del estímulo 100 ms, onset 250 ms. Con respecto, a los resultados obtenidos se pueden observar similitudes entre los resultados de gel y los resultados de los electrodos de gel de los autores mencionados. Asimismo, es posible comparar las respuestas de los electrodos secos y húmedos donde es posible identificar los diferentes estados previos y posteriores al estímulo.

### c. Precisión por tipo de electrodo

Desde la tabla 4-2 a la tabla 4-4, se resumen los resultados de la precisión alcanzada con el modelo rLDA para la selección del comando *target* deseado. En los casos de los electrodos secos y húmedos, las precisiones varían según cada sujeto, esto ocurre dado a que cada sesión con cada sujeto, aunque se realiza el mismo protocolo, la estabilidad del sistema, la conexión de todos los canales y los artefactos depende de varios factores, haciendo que la congruencia en las adquisiciones para estos tipos de electrodos sea casi nula.

Para el caso de los electrodos secos, en la tabla 4-2, se observa que se alcanza una precisión aceptable en 5 sujetos que superan el 70% de la precisión, gracias a esto, se puede inferir que los electrodos secos para el caso de los electrodos de Neuroelectronics, en las condiciones analizadas, tienen un potencial para las aplicaciones en sistemas BCI, pero no el suficiente para asegurar que puedan ser implementado completamente dentro de este campo.

Asimismo, para los electrodos húmedos, en la tabla 4-3, se alcanza una precisión mayor al 60% en 4 sujetos. Para estos electrodos, a comparación de los electrodos secos, alcanzaron una menor precisión que puede deberse a la inestabilidad del sistema. En algunos casos, cuando se aplicaba agua como conductor entre electrodo y el cuero cabelludo, en varias ocasiones las gotas de agua

hacían contacto con un radio mayor al del electrodo, haciendo que capturara señal de zonas adyacentes al mismo. En otros casos, la esponja se movía del sitio donde estaba el electrodo dificultando la conducción, a su vez, incrementando la dificultad de mantener los electrodos húmedos en contacto directo al no poder ejercer presión sobre el electrodo y la esponja debido a que se corría el riesgo de lastimar al usuario.

Finalmente, los electrodos con gel se siguen manteniendo como el método de adquisición por excelencia dentro de los sistemas BCI, donde es posible alcanzar hasta el 100% en la precisión como se puede observar en la tabla 4–4.

Autor	Señal de control	Paradigma	Tipo de electrodo	Número de sujetos	Método extracción de características	Método traducción de características	Mean Accuracy	Área de desarrollo
Guger .et .al	ERPs	IntendiX RC	dry	23	No especificado	SWLDA	90.4 %	Ingeniería-Clinica
	ERPs	IntendiX RC	gel	81	No especificado	SWLDA	91 %	Ingeniería-Clinica
Zander .et .al	ERPs	Oddball	dry	12	No especificado	rLDA	72.1 %	Ingeniería-Clinica
	ERPs	Oddball	gel	12	No especificado	rLDA	77.8 %	Ingeniería-Clinica
		Alpha paradigm	dry	12	logarithmic band power values	rLDA	90.7 %	Ingeniería-Clinica
		Alpha paradigm	gel	12	logarithmic band power values	rLDA	94 %	Ingeniería-Clinica
Samara .et .al	SSVEP	Checkerboard	dry	23	CCA	LDA	82.14%	Ingeniería-Clinica
	SSVEP	Checkerboard	gel	23	CCA	LDA	92.95 %	Ingeniería-Clinica
Presente trabajo	ERPs	Speller RCP	dry	15*2	Detección de picos	rLDA	36 %	Ingeniería
	ERPs	Speller RCP	wet	15*2	Detección de picos	rLDA	32.67 %	Ingeniería
	ERPs	Speller RCP	gel	15*2	Detección de picos	rLDA	87.11 %	Ingeniería

**Tabla 5–2.** Resumen de los resultados del rendimiento de electrodos secos, húmedos y con gel, según diferentes autores. Tomado de: (Guger et al. 2012; Zander et al. 2011; Samara et al. 2022)

Respecto a los resultados de algunos autores, resumidos en la tabla 5–2, el rendimiento en la precisión de los electrodos secos respecto a los electrodos de gel para sistemas BCI basados en potenciales ERPs, tienen ligeras variaciones entre sí. Para el caso de los autores Guger .et al. (2011), emplearon el clasificador SWLDA alcanzando precisiones sobre los 90% y 91% para los electrodos secos y con gel, respectivamente. Por otro lado, los autores, Zander .et .al (2012), alcanzaron precisiones que superaron el 70% en ambas condiciones para ERPs; estos autores realizaron la misma comparación basándose en el *Alpha Paradigm*, se logró conseguir 90.7% y 94% en la precisión siendo otro paradigma, dando como resultado una de las mayores precisiones que se han conseguido en esta revisión para sistemas BCI empleando el mismo clasificador que se utiliza en el presente estudio. Finalmente, autores Samara .et .al (2022), trabajan con señales de control SSVEPs e incluye en su estudio de caracterización de electrodo secos y húmedos el clasificador LDA, alcanzando precisiones alrededor de 82% y 92%, respectivamente.

Las diferencias entre los demás autores, en parte, se puede atribuir a los diferentes hardware empleados en cada uno de ellos, aunque no todos especifican los dispositivos, autores como Guger .et al. (2011) emplea el equipo g.Nautilus de la compañía g.Tec, con los electrodos secos g.Sahara. Por otro lado, Zander .et .al.

emplea el actiCap de la compañía Brain Products. Asimismo, se pueden dar variaciones en la adquisición por la calidad del gel utilizado, dado a que algunos pueden contener mayor porcentaje electrolítico.

Otra diferencia puede deberse a las características de los electrodos empleados. Los electrodos secos tienen puntos de contacto sobre el cuero cabelludo para el registro de la señal EEG. De acuerdo con el número de pines y la punta de cada uno de ellos, pueden mejorar los puntos de adquisición de señal, y cada compañía tiene una configuración de electrodos diferentes (Guger et al. 2012; Zander et al. 2011; Samara et al. 2022).

Asimismo, las condiciones experimentales entre cada uno de los estudios pueden alterar los resultados. Los factores que pudieron marcar la diferencia pueden atribuirse tanto al entorno de registro como el protocolo experimental realizado por cada autor. La presencia de distractores externos en las pruebas del *speller* puede ocasionar una disminución en la precisión. Las diferencias en los métodos implementados como el tipo de tarea, los tiempos de descanso, movimientos involuntarios pueden influir negativamente en los resultados, desviando considerablemente la precisión frente a otros estudios (Guger et al. 2012; Zander et al. 2011; Samara et al. 2022).

Diferencias en las etapas de preprocesamiento, procesamiento de señal y algoritmos implementados por cada autor puede alterar la congruencia de los estudios. Aunque los modelos sean el mismo, la extracción de características influye directamente en la precisión del modelo.

Finalmente, contar con experiencia técnica de los investigadores a la hora de manejar equipos y electrodos puede minimizar errores en la adquisición.

### 5.3. Discusión de resultados de los cuestionarios

En su mayoría la satisfacción de los usuarios con respecto a la duración de las sesiones fue negativa debido a que eran largas (aproximadamente 3h cada una). Debido a esto los niveles de fatiga fueron altos dado a que se sometía al usuario a una tarea de concentración durante un largo tiempo.

A su vez, se estudió la comodidad de los electrodos, para el caso de la condición de los electrodos secos y húmedos, luego de cierto tiempo generaba molestia a los usuarios, a diferencia de los electrodos con gel que, aunque tenía gel electrolítico, no generaba tanta molestia como las otras condiciones.

Debido a los resultados, y las opiniones expresadas en los cuestionarios, se ha intentado mejorar la experiencia del usuario añadiendo alternativas que transformaran la sesión de registros un grado más llevadero.

### 5.4. Limitaciones abordadas en este trabajo

Algunas de las limitaciones encontradas a lo largo del trabajo, empezaron a partir desde la familiarización del equipo de adquisición con el que se trabajó con los respectivos elementos.

En primer lugar, alcanzar a obtener una calidad de señal EEG en electrodos secos, fue una de las problemáticas que más se presentó a lo largo del estudio. En este sentido, para los electrodos húmedos, registrar estas condiciones demandaban con mayor trabajo al no contar con electrodos diseñados específicamente para la condición.

En segundo lugar, los resultados obtenidos no pueden generalizarse debido a que únicamente se ha probado un hardware (Enobio 8). Existen diferentes tecnologías que pueden abordar de diferentes formas los electrodos secos, incluso con mayor cantidad de canales que permitirían un mejor abordaje para la caracterización de electrodos.

Por otro lado, se ha realizado análisis basado en rLDA para la clasificación de características de los ERPs. Un análisis implementando algoritmos de Deep Learning podría mitigar el impacto de los electrodos secos, buscando conseguir resultados más estables a partir de características de alto nivel.

Aumentar el tamaño de la base de datos podría ser beneficioso para conseguir resultados más robustos y, a su vez, tener análisis estadísticos más precisos que aporten significativamente a los estudios.

Por otro lado, se ha analizado un paradigma basado en P300. Implementar otros paradigmas para trabajar con señales de control como SSVEPs o C-VEPs, podría solventar algunos problemas de los electrodos secos, abriendo la posibilidad de ser más funcionales con otros tipos de sistemas BCI.

## 6. Capítulo 6.

---

### Conclusiones

#### 6.1. Principales contribuciones del estudio.

A continuación, se enumeran las principales contribuciones de este trabajo:

1. Se ha realizado satisfactoriamente la caracterización de los diferentes electrodos para la adquisición de señal de EEG para evaluar su implementación en sistemas BCI. Empezando con el estudio del método de registro de señal EEG, pasando por el conocimiento de las señales de control que pueden gobernar distintas aplicaciones de sistemas BCI.
2. Se ha realizado la construcción de una base de datos con 90 registros de EEG basal (3 minutos ojos cerrados), donde 30 registros corresponden a un tipo de electrodo, es decir, 30 registros por condición, y 2 registros corresponden a un solo sujeto en diferentes sesiones. Asimismo, se ha construido una base de datos con 450 registros de EEG del *speller RCP* regido por el paradigma odd-ball, 150 registros por condición.
3. Se han estudiado cada una de las etapas que involucra un sistema BCI, aclarando la etapa de preprocesado que es fundamental para limpiar la señal EEG, para obtener una extracción y traducción de características de la señal que permita controlar un sistema BCI mediante las intenciones del usuario.
4. Se han investigado los métodos para preprocesado de la señal y a su vez, los métodos para la extracción de características junto con los diferentes clasificadores que se implementan hoy en día en investigaciones en el área de BCI.
5. Para el caso de la extracción de características, se han estudiado los métodos en los dominios espaciales, temporales y espectrales. Se ha implementado el promediado sincronizado y la detección de picos. Para la traducción de estas, se estudian técnicas como el discriminante lineal de Fisher, análisis discriminante lineal y máquinas de soporte vectorial. Se aplica el modelo rLDA para la clasificación de características.
6. Se detalla a profundidad las características de un sistema BCI basado en potenciales evocados P300, conociendo la respuesta del usuario ante el estímulo

#### 6.2. Conclusiones

A continuación, se enumeran las principales conclusiones de este trabajo:

1. Se sigue demostrando que el método de adquisición de señal de EEG por excelencia sigue siendo los equipos de EEG con electrodos en gel. Aunque se

alcanzaron algunos buenos resultados en la precisión del sistema BCI con electrodos secos y húmedos, la variabilidad entre estos sigue siendo amplia, ocasionando resultados incongruentes a la hora de comparar entre los electrodos, entre sujetos e incluso de un mismo sujeto y las variaciones entre sesiones.

2. Respecto a los cuestionarios de satisfacción, los usuarios han mostrado un rechazo a los electrodos secos (incluso los húmedos con esponja). Esto debido a que se tenía que presionar en varias ocasiones para intentar alcanzar señal EEG generando incomodidad. Al presentarse las desconexiones de los canales se debía nuevamente ejercer presión sobre los electrodos, haciendo que, a lo largo de la sesión, se incrementa la sensibilidad a las puntas del electrodo. De igual manera, aunque la interfaz fue considerada amigable al usuario y la tarea fácil de dominar, en repetidas ocasiones se seleccionaron comandos no deseados ocasionando frustración a quien intentaba realizar la tarea.
3. Los resultados de este trabajo frente a los trabajos en otros estudios difieren en gran medida, empezando por la incongruencia de los resultados para todos los electrodos, cosa que en otros estudios si ha permanecido y la variabilidad entre sujeto no era tan notable como se presenta en este. Aunque sí se alcanzó una precisión suficiente en electrodos secos y húmedos para la implementación en sistemas BCI, como lo demuestran estudios anteriores. La presencia de registros notablemente malos hace que la viabilidad de estas adquisiciones con el equipo y los electrodos utilizados no sea aceptable.

### 6.3. Líneas futuras

- Lograr mejorar el tipo de electrodo seco implementado para las adquisiciones es uno de los principales objetivos del trabajo a futuro de este proyecto. Buscar conseguir una aleación capaz de captar la señal EEG manteniendo una calidad parecida a la de los electrodos con gel, con buena conductividad y aportando mayor comodidad al usuario. A su vez, modificar los pines de contacto del electrodo para alcanzar una buena adquisición, sin tener la necesidad de ejercer presión sobre el usuario.
- Construir una base de datos más robusta al incluir estudios paralelos con otros hardware para comparar el rendimiento de otros dispositivos bajo las mismas condiciones. Asimismo, implementar estudios con otros tipos de electrodos secos con pines de contacto diferentes para mejorar la comodidad de los usuarios luego de usos prolongados.
- Por otro lado, buscar otras señales de control donde puedan ser implementados los electrodos secos y húmedos para la evaluación de estas condiciones en otros sistemas BCI.
- Plantear algoritmos de Deep Learning para análisis de las características de los ERPs de las diferentes condiciones para conseguir un mejor rendimiento en la clasificación.



# Declaración de trabajo

Trabajo realizado por *María Valentina Sosa Rojo* dentro del Grupo de Ingeniería Biomédica en la línea de investigación en Brain Computer Interfaces, perteneciente a la Universidad de Valladolid, Valladolid, España.

# Referencias

- Acharya, Jayant N., Abeer J. Hani, Janna Cheek, Parthasarathy Thirumala, and Tammy N. Tsuchida. 2016. "American Clinical Neurophysiology Society Guideline 2: Guidelines for Standard Electrode Position Nomenclature." *The Neurodiagnostic Journal* 56 (4): 245–52. <https://doi.org/10.1080/21646821.2016.1245558>.
- Aloise, F, F Schettini, P Aricò, F Leotta, S Salinari, D Mattia, F Babiloni, and F Cincotti. 2011. "P300-Based Brain-Computer Interface for Environmental Control: An Asynchronous Approach." *Journal of Neural Engineering* 8 (2): 025025. <https://doi.org/10.1088/1741-2560/8/2/025025>.
- Andrillon, Thomas, Andreas Trier Poulsen, Lars Kai Hansen, Damien Léger, and Sid Kouider. 2016. "Neural Markers of Responsiveness to the Environment in Human Sleep." *The Journal of Neuroscience* 36 (24): 6583–96. <https://doi.org/10.1523/JNEUROSCI.0902-16.2016>.
- Apicella, Andrea, Francesco Isgrò, Andrea Pollastro, and Roberto Prevete. 2023. "On the Effects of Data Normalization for Domain Adaptation on EEG Data." *Engineering Applications of Artificial Intelligence* 123 (August):106205. <https://doi.org/10.1016/j.engappai.2023.106205>.
- Arevalillo-Herráez, Miguel, Maximo Cobos, Sandra Roger, and Miguel García-Pineda. 2019. "Combining Inter-Subject Modeling with a Subject-Based Data Transformation to Improve Affect Recognition from EEG Signals." *Sensors* 19 (13): 2999. <https://doi.org/10.3390/s19132999>.
- Arvaneh, Mahnaz, Ian H. Robertson, and Tomas E. Ward. 2019. "A P300-Based Brain-Computer Interface for Improving Attention." *Frontiers in Human Neuroscience* 12 (January). <https://doi.org/10.3389/fnhum.2018.00524>.
- Bajaj, Nikesh. 2021. "Wavelets for EEG Analysis." In *Wavelet Theory*. IntechOpen. <https://doi.org/10.5772/intechopen.94398>.
- Blankertz, Benjamin, Steven Lemm, Matthias Treder, Stefan Haufe, and Klaus Robert Müller. 2011. "Single-Trial Analysis and Classification of ERP Components--a Tutorial." *NeuroImage* 56 (2): 814–25. <https://doi.org/10.1016/J.NEUROIMAGE.2010.06.048>.
- Borowska, Marta, and Małgorzata Syczevska. 2021. "Multiscale Permutation Lempel-Ziv Complexity Measure for Biomedical Signal Analysis: Interpretation and Application to Focal EEG Signals." *Entropy* 2021, Vol. 23, Page 832 23 (7): 832. <https://doi.org/10.3390/E23070832>.
- Chaudhary, Ujwal, Niels Birbaumer, and Ander Ramos-Murguialday. 2016. "Brain-Computer Interfaces for Communication and Rehabilitation." *Nature Reviews Neurology* 12 (9): 513–25. <https://doi.org/10.1038/nrneurol.2016.113>.
- Chen, Huayu, Shuting Sun, Jianxiu Li, Ruilan Yu, Nan Li, Xiaowei Li, and Bin Hu. 2023. "Personal-Zscore: Eliminating Individual Difference for EEG-Based Cross-Subject Emotion Recognition." *IEEE Transactions on Affective Computing* 14 (3): 2077–88. <https://doi.org/10.1109/TAFFC.2021.3137857>.

- Corralejo, Rebeca, Roberto Hornero, and Daniel Alvarez. 2011. "Feature Selection Using a Genetic Algorithm in a Motor Imagery-Based Brain Computer Interface." In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 7703–6. IEEE. <https://doi.org/10.1109/IEMBS.2011.6091898>.
- Dagdevir, Eda, and Mahmut Tokmakci. 2021. "Optimization of Preprocessing Stage in EEG Based BCI Systems in Terms of Accuracy and Timing Cost." *Biomedical Signal Processing and Control* 67 (May). <https://doi.org/10.1016/j.bspc.2021.102548>.
- Dias, N. S., M. Kamrunnahar, P. M. Mendes, S. J. Schiff, and J. H. Correia. 2007. "Comparison of EEG Pattern Classification Methods for Brain-Computer Interfaces." In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2540–43. IEEE. <https://doi.org/10.1109/IEMBS.2007.4352846>.
- Duque-Muñoz, L., R. D. Pinzon-Morales, and G. Castellanos-Dominguez. 2015a. "EEG Rhythm Extraction Based on Relevance Analysis and Customized Wavelet Transform." In , 419–28. [https://doi.org/10.1007/978-3-319-18914-7\\_44](https://doi.org/10.1007/978-3-319-18914-7_44).
- . 2015b. "EEG Rhythm Extraction Based on Relevance Analysis and Customized Wavelet Transform." In , 419–28. [https://doi.org/10.1007/978-3-319-18914-7\\_44](https://doi.org/10.1007/978-3-319-18914-7_44).
- Duque-Muñoz, Leonardo, Jairo Espinosa-Oviedo, and Cesar Castellanos-Dominguez. 2014. "Identification and Monitoring of Brain Activity Based on Stochastic Relevance Analysis of Short-Time EEG Rhythms." *BioMedical Engineering OnLine* 13 (1): 123. <https://doi.org/10.1186/1475-925X-13-123>.
- Farwell, L.A., and E. Donchin. 1988. "Talking off the Top of Your Head: Toward a Mental Prosthesis Utilizing Event-Related Brain Potentials." *Electroencephalography and Clinical Neurophysiology* 70 (6): 510–23. [https://doi.org/10.1016/0013-4694\(88\)90149-6](https://doi.org/10.1016/0013-4694(88)90149-6).
- Fiedler, Patrique, Jens Haueisen, Dunja Jannek, Stefan Griebel, Lena Zentner, Filipe Vaz, Carlos Fonseca, and Paolo Carbone. 2014. "Comparison of Three Types of Dry Electrodes for Electroencephalography." *Acta IMEKO*. Vol. 3. identifier. [www.imeko.org](http://www.imeko.org).
- Flumeri, Gianluca Di, Pietro Aricò, Gianluca Borghini, Nicolina Sciaraffa, Antonello Di Florio, and Fabio Babiloni. 2019a. "The Dry Revolution: Evaluation of Three Different Eeg Dry Electrode Types in Terms of Signal Spectral Features, Mental States Classification and Usability." *Sensors (Switzerland)* 19 (6). <https://doi.org/10.3390/s19061365>.
- . 2019b. "The Dry Revolution: Evaluation of Three Different Eeg Dry Electrode Types in Terms of Signal Spectral Features, Mental States Classification and Usability." *Sensors (Switzerland)* 19 (6). <https://doi.org/10.3390/s19061365>.
- Garrett, D., D.A. Peterson, C.W. Anderson, and M.H. Thaut. 2003. "Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal

- Classification.” *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11 (2): 141–44. <https://doi.org/10.1109/TNSRE.2003.814441>.
- Gonçales, Lucian Jose, Kleinner Farias, Lucas Kupssinskü, and Matheus Segalotto. 2021. “The Effects of Applying Filters on EEG Signals for Classifying Developers’ Code Comprehension.” *Journal of Applied Research and Technology* 19 (6): 584–602. <https://doi.org/10.22201/icat.24486736e.2021.19.6.1299>.
- Guger, Christoph, Gunther Krausz, Brendan Z. Allison, and Guenter Edlinger. 2012. “Comparison of Dry and Gel Based Electrodes for P300 Brain–Computer Interfaces.” *Frontiers in Neuroscience*, no. MAY. <https://doi.org/10.3389/fnins.2012.00060>.
- Gutierrez-Martinez, Josefina, Jorge A. Mercado-Gutierrez, Blanca E. Carvajal-Gómez, Jorge L. Rosas-Trigueros, and Adrian E. Contreras-Martinez. 2021. “Artificial Intelligence Algorithms in Visual Evoked Potential–Based Brain–Computer Interfaces for Motor Rehabilitation Applications: Systematic Review and Future Directions.” *Frontiers in Human Neuroscience*. Frontiers Media S.A. <https://doi.org/10.3389/fnhum.2021.772837>.
- Han Yuan, and Bin He. 2014. “Brain–Computer Interfaces Using Sensorimotor Rhythms: Current State and Future Perspectives.” *IEEE Transactions on Biomedical Engineering* 61 (5): 1425–35. <https://doi.org/10.1109/TBME.2014.2312397>.
- Hashmi, Mohammad Farukh, Jagdish D. Kene, Deepali M. Kotambkar, Praveen Matte, and Avinash G. Keskar. 2022. “An Efficient P300 Detection Algorithm Based on Kernel Principal Component Analysis–Support Vector Machine.” *Computers & Electrical Engineering* 97 (January):107608. <https://doi.org/10.1016/j.compeleceng.2021.107608>.
- Heijs, Janne J.A., Ruben Jan Havelaar, Patrique Fiedler, Richard J.A. van Wezel, and Tjitske Heida. 2021. “Validation of Soft Multipin Dry Eeg Electrodes.” *Sensors* 21 (20). <https://doi.org/10.3390/s21206827>.
- Hinrichs, Hermann, Michael Scholz, Anne Katrin Baum, Julia W.Y. Kam, Robert T. Knight, and Hans Jochen Heinze. 2020. “Comparison between a Wireless Dry Electrode EEG System with a Conventional Wired Wet Electrode EEG System for Clinical Applications.” *Scientific Reports* 10 (1). <https://doi.org/10.1038/s41598-020-62154-0>.
- Hinterberger, T., S. Schmidt, N. Neumann, J. Mellinger, B. Blankertz, G. Curio, and N. Birbaumer. 2004. “Brain–Computer Communication and Slow Cortical Potentials.” *IEEE Transactions on Biomedical Engineering* 51 (6): 1011–18. <https://doi.org/10.1109/TBME.2004.827067>.
- Jamil, Nuraini, Abdelkader Nasreddine Belkacem, Sofia Ouhbi, and Abderrahmane Lakas. 2021. “Noninvasive Electroencephalography Equipment for Assistive, Adaptive, and Rehabilitative Brain–Computer Interfaces: A Systematic Literature Review.” *Sensors*. MDPI AG. <https://doi.org/10.3390/s21144754>.
- Kabir, Md. Humaun, Shabbir Mahmood, Abdullah Al Shiam, Abu Saleh Musa Miah, Jungpil Shin, and Md. Khademul Islam Molla. 2023. “Investigating Feature Selection Techniques to Enhance the Performance of EEG–Based Motor

- Imagery Tasks Classification.” *Mathematics* 11 (8): 1921. <https://doi.org/10.3390/math11081921>.
- Kam, Julia W Y, Sandon Griffin, Alan Shen, Shawn Patel, Hermann Hinrichs, Hans-Jochen Heinze, Leon Y Deouell, and Robert T Knight. 2018. “Systematic Comparison between a Wireless EEG System with Dry Electrodes and a Wired EEG System with Wet Electrodes.” <https://doi.org/10.1016/j.neuroimage.2018.09.012>.
- Käthner, Ivo, Sebastian Halder, Christoph Hintermüller, Arnau Espinosa, Christoph Guger, Felip Miralles, Eloisa Vargiu, et al. 2017. “A Multifunctional Brain-Computer Interface Intended for Home Use: An Evaluation with Healthy Participants and Potential End Users with Dry and Gel-Based Electrodes.” *Frontiers in Neuroscience* 11 (MAY). <https://doi.org/10.3389/fnins.2017.00286>.
- Kleih, Sonja C., and Loic Botrel. 2024. “Post-Stroke Aphasia Rehabilitation Using an Adapted Visual P300 Brain-Computer Interface Training: Improvement over Time, but Specificity Remains Undetermined.” *Frontiers in Human Neuroscience* 18 (May). <https://doi.org/10.3389/fnhum.2024.1400336>.
- Krusienski, D. J., E. W. Sellers, D. J. McFarland, T. M. Vaughan, and J. R. Wolpaw. 2008. “Toward Enhanced P300 Speller Performance.” *Journal of Neuroscience Methods* 167 (1): 15. <https://doi.org/10.1016/J.JNEUMETH.2007.07.017>.
- Kundu, Sourav, and Samit Ari. 2018. “P300 Detection with Brain-Computer Interface Application Using PCA and Ensemble of Weighted SVMs.” *IETE Journal of Research* 64 (3): 406–14. <https://doi.org/10.1080/03772063.2017.1355271>.
- Leach, Sven, Ku Young Chung, Laura Tüshaus, Reto Huber, and Walter Karlen. 2020. “A Protocol for Comparing Dry and Wet EEG Electrodes During Sleep.” *Frontiers in Neuroscience* 14 (June):515628. <https://doi.org/10.3389/FNINS.2020.00586/BIBTEX>.
- LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. 2015. “Deep Learning.” *Nature* 521 (7553): 436–44. <https://doi.org/10.1038/nature14539>.
- Lempel, Abraham, and Jacob Ziv. 1976. “On the Complexity of Finite Sequences.” *IEEE Transactions on Information Theory* 22 (1): 75–81. <https://doi.org/10.1109/TIT.1976.1055501>.
- Li, Qi, Yan Wu, Yu Song, Di Zhao, Meiqi Sun, Zhilin Zhang, and Jinglong Wu. 2022. “A P300-Detection Method Based on Logistic Regression and a Convolutional Neural Network.” *Frontiers in Computational Neuroscience* 16 (June). <https://doi.org/10.3389/fncom.2022.909553>.
- Lotte, Fabien. 2008. “Study of Electroencephalographic Signal Processing and Classification Techniques towards the Use of Brain-Computer Interfaces in Virtual Reality Applications.” <https://www.researchgate.net/publication/30514309>.
- Ma, Ye, Guangping Jiang, Tanqing Chang, and Libin Guo. 2017. “Research on Feature Extraction and Classification of P300 EEG Signals.”
- Maess, Burkhard, Erich Schröger, and Andreas Widmann. 2016. “High-Pass Filters and Baseline Correction in M/EEG Analysis. Commentary on: ‘How Inappropriate High-Pass Filters Can Produce Artefacts and Incorrect

- Conclusions in ERP Studies of Language and Cognition.’’ *Journal of Neuroscience Methods* 266 (June):164–65. <https://doi.org/10.1016/j.jneumeth.2015.12.003>.
- Martínez Cagigal, Víctor. 2020. “Toward Practical P300-Based Brain–Computer Interfaces: Asynchrony, Channel Optimization and Assistive Applications.” Universidad de Valladolid. <https://doi.org/10.35376/10324/47516>.
- Martínez-Cagigal, Víctor, Javier Gomez-Pilar, Daniel Alvarez, and Roberto Hornero. 2017. “An Asynchronous P300-Based Brain-Computer Interface Web Browser for Severely Disabled People.” *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 25 (8): 1332–42. <https://doi.org/10.1109/TNSRE.2016.2623381>.
- Martínez-Cagigal, Víctor, Eduardo Santamaría-Vázquez, Javier Gomez-Pilar, and Roberto Hornero. 2019. “Towards an Accessible Use of Smartphone-Based Social Networks through Brain-Computer Interfaces.” *Expert Systems with Applications* 120 (April):155–66. <https://doi.org/10.1016/j.eswa.2018.11.026>.
- Martínez-Cagigal, Víctor, Eduardo Santamaría-Vázquez, and Roberto Hornero. 2019. “Asynchronous Control of P300-Based Brain–Computer Interfaces Using Sample Entropy.” *Entropy* 2019, Vol. 21, Page 230 21 (3): 230. <https://doi.org/10.3390/E21030230>.
- Mathewson, Kyle E., Tyler J.L. Harrison, and Sayeed A.D. Kizuk. 2017. “High and Dry? Comparing Active Dry EEG Electrodes to Active and Passive Wet Electrodes.” In *Psychophysiology*, 54:74–82. Blackwell Publishing Inc. <https://doi.org/10.1111/psyp.12536>.
- Mendoza-Montoya, Omar, Javier M. Antelis, and Jonathan Delijorge. 2022. “P300-Based Brain–Computer Interface for Communication and Control.” *Biosignal Processing and Classification Using Computational Learning and Intelligence: Principles, Algorithms, and Applications*, January, 271–92. <https://doi.org/10.1016/B978-0-12-820125-1.00026-9>.
- Morales, Santiago, and Maureen E. Bowers. 2022. “Time-Frequency Analysis Methods and Their Application in Developmental EEG Data.” *Developmental Cognitive Neuroscience* 54 (April):101067. <https://doi.org/10.1016/J.DCN.2022.101067>.
- Orban, Mostafa, Mahmoud Elsamanty, Kai Guo, Senhao Zhang, and Hongbo Yang. 2022. “A Review of Brain Activity and EEG-Based Brain–Computer Interfaces for Rehabilitation Application.” *Bioengineering*. MDPI. <https://doi.org/10.3390/bioengineering9120768>.
- O’Sullivan, Mark, Andriy Temko, Andrea Bocchino, Conor O’Mahony, Geraldine Boylan, and Emanuel Popovici. 2019. “Analysis of a Low-Cost EEG Monitoring System and Dry Electrodes toward Clinical Use in the Neonatal ICU.” *Sensors* 2019, Vol. 19, Page 2637 19 (11): 2637. <https://doi.org/10.3390/S19112637>.
- Pan, Jiahui, Xue Ning Chen, Nianming Ban, Jia Shao He, Jiayi Chen, and Haiyun Huang. 2022. “Advances in P300 Brain–Computer Interface Spellers: Toward Paradigm Design and Performance Evaluation.” *Frontiers in Human Neuroscience* 16 (December):1077717. <https://doi.org/10.3389/FNHUM.2022.1077717/BIBTEX>.

- Pawan, and Rohtash Dhiman. 2023. "Machine Learning Techniques for Electroencephalogram Based Brain-Computer Interface: A Systematic Literature Review." *Measurement: Sensors* 28 (August). <https://doi.org/10.1016/j.measen.2023.100823>.
- Peng, Weiwei. 2019. "EEG Preprocessing and Denoising." In *EEG Signal Processing and Feature Extraction*, 71–87. Singapore: Springer Singapore. [https://doi.org/10.1007/978-981-13-9113-2\\_5](https://doi.org/10.1007/978-981-13-9113-2_5).
- Perseh, Bahram, and Ahmad Sharafat. 2012. "An Efficient P300-Based BCI Using Wavelet Features and IBPSO-Based Channel Selection." *Journal of Medical Signals and Sensors* 2 (3): 128. <https://doi.org/10.4103/2228-7477.111994>.
- Pflieger, Mark E., and Randall L. Barbour. 2012. "Multimodal Integration of FMRI, EEG, and NIRS." In *Biomedical Optics and 3-D Imaging*, BSu2A.1. Washington, D.C.: OSA. <https://doi.org/10.1364/BIOMED.2012.BSu2A.1>.
- Picton, Terence W. 1992. "The P300 Wave of the Human Event-Related Potential." *Journal of Clinical Neurophysiology* 9 (4): 456–79. <https://doi.org/10.1097/00004691-199210000-00002>.
- Polich, John. 2007. "Updating P300: An Integrative Theory of P3a and P3b." *Clinical Neurophysiology* 118 (10): 2128–48. <https://doi.org/10.1016/J.CLINPH.2007.04.019>.
- Polich, John, Christine Ladish, and Tim Burns. 1990. "Normal Variation of P300 in Children: Age, Memory Span, and Head Size." *International Journal of Psychophysiology* 9 (3): 237–48. [https://doi.org/10.1016/0167-8760\(90\)90056-J](https://doi.org/10.1016/0167-8760(90)90056-J).
- Ravipati, Yashwanth, Nader Pouratian, Corey Arnold, and William Speier. 2023. "Evaluating Deep Learning Performance for P300 Neural Signal Classification." *AMIA ... Annual Symposium Proceedings. AMIA Symposium 2023*:1218–25. <http://www.ncbi.nlm.nih.gov/pubmed/38222383>.
- Rejer, Izabela. 2013. "Genetic Algorithms in EEG Feature Selection for the Classification of Movements of the Left and Right Hand." In , 579–89. [https://doi.org/10.1007/978-3-319-00969-8\\_57](https://doi.org/10.1007/978-3-319-00969-8_57).
- Riccio, Angela, Luca Simione, Francesca Schettini, Alessia Pizzimenti, Maurizio Inghilleri, Marta Olivetti Belardinelli, Donatella Mattia, and Febo Cincotti. 2013. "Attention and P300-Based BCI Performance in People with Amyotrophic Lateral Sclerosis." *Frontiers in Human Neuroscience* 7 (NOV): 56432. <https://doi.org/10.3389/FNHUM.2013.00732/BIBTEX>.
- Robinson, John. 2023. "Likert Scale." In *Encyclopedia of Quality of Life and Well-Being Research*, 3917–18. Cham: Springer International Publishing. [https://doi.org/10.1007/978-3-031-17299-1\\_1654](https://doi.org/10.1007/978-3-031-17299-1_1654).
- Saha, Simanto, Khondaker A. Mamun, Khawza Ahmed, Raqibul Mostafa, Ganesh R. Naik, Sam Darvishi, Ahsan H. Khandoker, and Mathias Baumert. 2021. "Progress in Brain Computer Interface: Challenges and Opportunities." *Frontiers in Systems Neuroscience*. Frontiers Media S.A. <https://doi.org/10.3389/fnsys.2021.578875>.

- Samara, Maria, Cristina Farmaki, Nikolaos Zacharioudakis, Matthew Pediaditis, Myrto Krana, and Vangelis Sakkalis. 2022. "Comparison between Dry and Wet EEG Electrodes in an SSVEP-Based BCI for Robot Navigation." In *Proceedings - IEEE 22nd International Conference on Bioinformatics and Bioengineering, BIBE 2022*, 333–38. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/BIBE55377.2022.00075>.
- Santamaria-Vazquez, Eduardo, Victor Martinez-Cagigal, Javier Gomez-Pilar, and Roberto Hornero. 2019. "Asynchronous Control of ERP-Based BCI Spellers Using Steady-State Visual Evoked Potentials Elicited by Peripheral Stimuli." *IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society* 27 (9): 1883–92. <https://doi.org/10.1109/TNSRE.2019.2934645>.
- Santamaría-Vázquez, Eduardo, Víctor Martínez-Cagigal, Diego Marcos-Martínez, Víctor Rodríguez-González, Sergio Pérez-Velasco, Selene Moreno-Calderón, and Roberto Hornero. 2023. "MEDUSA©: A Novel Python-Based Software Ecosystem to Accelerate Brain-Computer Interface and Cognitive Neuroscience Research." *Computer Methods and Programs in Biomedicine* 230 (March):107357. <https://doi.org/10.1016/j.cmpb.2023.107357>.
- Santamaría-Vázquez, Eduardo, Víctor Martínez-Cagigal, Sergio Pérez-Velasco, Diego Marcos-Martínez, and Roberto Hornero. 2022. "Robust Asynchronous Control of ERP-Based Brain-Computer Interfaces Using Deep Learning." *Computer Methods and Programs in Biomedicine* 215 (March):106623. <https://doi.org/10.1016/J.CMPB.2022.106623>.
- Santamaria-Vazquez, Eduardo, Victor Martinez-Cagigal, Fernando Vaquerizo-Villar, and Roberto Hornero. 2020. "EEG-Inception: A Novel Deep Convolutional Neural Network for Assistive ERP-Based Brain-Computer Interfaces." *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 28 (12): 2773–82. <https://doi.org/10.1109/TNSRE.2020.3048106>.
- Sellers, Eric W., Dennis J. McFarland, Theresa M. Vaughan, and Jonathan R. Wolpaw. 2009a. "BCIs in the Laboratory and at Home: The Wadsworth Research Program." In *Frontiers Collection*, Part F952:97–111. Springer VS. [https://doi.org/10.1007/978-3-642-02091-9\\_6](https://doi.org/10.1007/978-3-642-02091-9_6).
- . 2009b. "BCIs in the Laboratory and at Home: The Wadsworth Research Program." In *Frontiers Collection*, Part F952:97–111. Springer VS. [https://doi.org/10.1007/978-3-642-02091-9\\_6](https://doi.org/10.1007/978-3-642-02091-9_6).
- Shen, Gencai, Kunpeng Gao, Nan Zhao, al -, Fei Wang, Guangli Li, Jingjing Chen, et al. 2000. "A Direct Comparison of Wet, Dry and Insulating Bioelectric Recording Electrodes." *Physiol. Meas* 21:271–83.
- Singh, Dalwinder, and Birmohan Singh. 2020. "Investigating the Impact of Data Normalization on Classification Performance." *Applied Soft Computing* 97 (December):105524. <https://doi.org/10.1016/j.asoc.2019.105524>.
- Srikantharajah, Kagithiri, Renata Medinaceli Quintela, Kerstin Doerenkamp, Björn M. Kampa, Simon Musall, Markus Rothermel, and Andreas Offenhäusser. 2021. "Minimally-Invasive Insertion Strategy and in Vivo Evaluation of Multi-Shank

- Flexible Intracortical Probes.” *Scientific Reports* 11 (1): 18920.  
<https://doi.org/10.1038/s41598-021-97940-x>.
- Stelmack, Robert M., Michael Houlihan, and Patricia A. McGarry-Roberts. 1993. “Personality, Reaction Time, and Event-Related Potentials.” *Journal of Personality and Social Psychology* 65 (2): 399–409.  
<https://doi.org/10.1037/0022-3514.65.2.399>.
- Tanner, Darren, James J.S. Norton, Kara Morgan-Short, and Steven J. Luck. 2016. “On High-Pass Filter Artifacts (They’re Real) and Baseline Correction (It’s a Good Idea) in ERP/ERMF Analysis.” *Journal of Neuroscience Methods* 266 (June):166–70. <https://doi.org/10.1016/j.jneumeth.2016.01.002>.
- Tonner, P. H., and B. Bein. 2006. “Classic Electroencephalographic Parameters: Median Frequency, Spectral Edge Frequency Etc.” *Best Practice & Research Clinical Anaesthesiology* 20 (1): 147–59.  
<https://doi.org/10.1016/J.BPA.2005.08.008>.
- Tsuchimoto, Shohei, Shuka Shibusawa, Seitaro Iwama, Masaaki Hayashi, Kohei Okuyama, Nobuaki Mizuguchi, Kenji Kato, and Junichi Ushiba. 2021. “Use of Common Average Reference and Large-Laplacian Spatial-Filters Enhances EEG Signal-to-Noise Ratios in Intrinsic Sensorimotor Activity.” *Journal of Neuroscience Methods* 353 (April):109089.  
<https://doi.org/10.1016/J.JNEUMETH.2021.109089>.
- Värbu, Kaido, Naveed Muhammad, and Yar Muhammad. 2022. “Past, Present, and Future of EEG-Based BCI Applications.” *Sensors (Basel, Switzerland)* 22 (9).  
<https://doi.org/10.3390/S22093331>.
- Wei, Qingguo, Yuhui Ma, and Zongwu Lu. 2010. “Independent Component Analysis for Spatial Filtering and Feature Extraction in a Four-Task Brain-Computer Interface.” In *2010 Second International Conference on Intelligent Human-Machine Systems and Cybernetics*, 151–54. IEEE.  
<https://doi.org/10.1109/IHMSC.2010.137>.
- Wolpaw, Jonathan R., Niels Birbaumer, Dennis J. McFarland, Gert Pfurtscheller, and Theresa M. Vaughan. 2002. “Brain-Computer Interfaces for Communication and Control.” *Clinical Neurophysiology* 113 (6): 767–91.  
[https://doi.org/10.1016/S1388-2457\(02\)00057-3](https://doi.org/10.1016/S1388-2457(02)00057-3).
- Wolpaw, Jonathan, and Elizabeth Winter Wolpaw, eds. 2012a. *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press.  
<https://doi.org/10.1093/acprof:oso/9780195388855.001.0001>.
- , eds. 2012b. *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press. <https://doi.org/10.1093/acprof:oso/9780195388855.001.0001>.
- Yuan, Haowen, Yao Li, Junjun Yang, Hongjie Li, Qinya Yang, Cuiping Guo, Shenmin Zhu, and Xiaokang Shu. 2021. “State of the Art of Non-Invasive Electrode Materials for Brain-Computer Interface.” *Micromachines*. MDPI.  
<https://doi.org/10.3390/mi12121521>.
- Zander, Thorsten Oliver, Moritz Lehne, Klas Ihme, Sabine Jatzev, Joao Correia, Christian Kothe, Bernd Picht, and Femke Nijboer. 2011. “A Dry EEG-System for

Scientific Research and Brain-Computer Interfaces.” *Frontiers in Neuroscience*, no. MAY. <https://doi.org/10.3389/fnins.2011.00053>.

Zhao, Hai-bin, Hong Wang, Chun-Sheng Li, and Yun-Gong Li. 2009. “Brain-Computer Interface Design Based on Slow Cortical Potentials Using Matlab/Simulink.” In *2009 International Conference on Mechatronics and Automation*, 1044–48. IEEE. <https://doi.org/10.1109/ICMA.2009.5246255>.